



Pearson correlation and Granger causality analysis of Twitter sentiments and the daily changes in Bist30 index returns

Emine Ateş^{ID}, Aysun Güran*^{ID}

Department of Computer Engineering, Doğus University, Istanbul, 34722, Turkey

Highlights:

- Sentiment Analysis of tweets
- Pearson Correlation and Granger causality analysis between tweets and stock markets
- Twitter is an influential platform for financial markets in Turkey.

Keywords:

- Sentiment Analysis
- Correlation Analysis
- Granger Causality Analysis
- Tweets
- Stock Markets

Article Info:

Research Article
Received: 16.12.2019
Accepted: 24.02.2021

DOI:

10.17341/gazimmfd.660018

Correspondence:

Author: Aysun Güran
e-mail:
adogrusoz@dogus.edu.tr
phone: +90 444 7 997

Graphical/Tabular Abstract

In this research an extensive study to identify the relations between Turkish financial-related tweets and the daily changes in Bist30 index returns is presented. After the sentiment analysis of Turkish financial-related tweets, the polarity values of the tweets are determined and the results of Pearson correlation and Granger causality analyses between the polarity values and the changes in Bist30 index returns are examined for two different time periods. The first research period covers the dates between 07.05.2018 and 30.04.2019. The second research period includes the dates between 07.05.2018 and 31.07.2018; where some important events took place in Turkey. To the best of our knowledge, this study is the most comprehensive study that analyses the relations between Turkish financial-related tweets and the daily changes in stock market returns. The framework of the study is shown in Figure A.

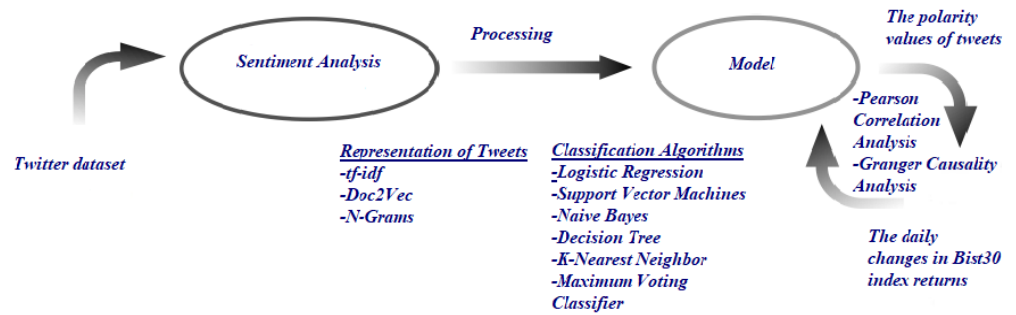


Figure A. Operational framework of the study

Purpose: The aim of this study is to investigate whether there are causal relationships between the sentiments conveyed in Turkish financial-related tweets and the daily changes in Bist30 index returns.

Theory and Methods:

In this study, besides Bag of Words method which is traditionally used for the representation of tweets, Doc2Vec that generates vectors for tweets has also been used with different N-gram representations. To enhance the performance of Doc2Vec, we propose to combine tweet vectors that are generated by two different architectures (*Distributed Bag of Words version of Paragraph Vector* and *Distributed Memory Model of Paragraph Vectors*) that Doc2vec uses when learning tweet vectors. Six different machine learning algorithms have been used to classify the Turkish financial-related tweets into positive, negative and neutral classes. By using the total number of tweets in each sentiment category, three different polarity values of tweets are determined. After that, Pearson correlation and Granger causality analyses are conducted on the polarity values of tweets and the changes in Bist30 index returns. During this process, normality of each of time series is checked with Kolmogorov-Smirnov normality test. Prior to the Granger causality tests, we tested for stationarity in the variables using the Augmented Dickey-Fuller procedure.

Results:

The results show a significant correlation between the tweet sentiments and the daily changes in Bist30 index for both short and long terms. For the long term, there is causality from the stock returns to tweet sentiments and for the short term there is causality from tweet sentiments to the stock return.

Conclusion:

Twitter has been identified as an influential factor for financial markets in Turkey.



Twitter iletileri duygu değerleri ve Bist 30 endeksi günlük değer değişimlerinin Pearson korelasyonu ve Granger nedensellik analizi

Emine Ateş^{ID}, Aysun Güran*^{ID}

Dogus Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 34722, Acıbadem, İstanbul, Türkiye

Ö N E Ç İ K A N L A R

- Twitter kısa iletilerinin duygu analizi
- Kısa iletiler ve Bist 30 endeksi getirileri arasındaki Pearson ve Granger nedensellik analizi
- Twitter Türkiye'deki finansal piyasalar için etkili bir platformdur

Makale Bilgileri

Araştırma Makalesi

Geliş: 16.12.2019

Kabul: 24.02.2021

DOI:

10.17341/gazimmfd.660018

Anahtar Kelimeler:

Duygu analizi,
korelasyon analizi,
Granger nedensellik analizi,
tweet,
hisse senedi piyasası

ÖZ

Müşteri odaklı bir anlayışın egemen olduğu çağımızda, yatırımcılar ile etkin bir iletişim ağının oluşturulabilmesi adına finansal işletmeler sosyal medya platformlarına önem vermeye başlamıştır. Bu çalışmada, iki farklı zaman dilimini kapsayacak şekilde, yatırımcıların etkin bir sosyal medya platformu olan Twitter'da paylaşmış oldukları kısa iletilerden elde edilen farklı duygu polarite değerleriyle, Bist30 endeksi günlük değer değişimleri arasındaki ilişkiyi incelemek için Pearson korelasyon analizi ve Granger nedensellik analizi metodları uygulanmıştır. Analizler sonucunda, duygu polarite değerleri ve Bist30 endeksi günlük değer değişimleri arasında anlamlı korelasyon ilişkileri tespit edilmiştir. Ayrıca, özellikle olağan dışı olayların gerçekleştiği bir dönemde duygu polarite değerlerinden Bist30 değer değişimlerine doğru bir Granger nedensellik ilişkisinin ortaya çıktığı görülmüştür. Türkçe finansal iletiler ile çalışan ve duygu analizi aşamasında Doc2Vec metodu kullanılırken yeni bir öneriyi içeren bu çalışma, korelasyon analizi ve Granger nedensellik analizi aşamalarını barındıran, analizleri gerçekleştirmek için gerekli olan istatistiksel ve ekonometrik tüm testleri uygulayan en kapsamlı çalışmalardanır.

Pearson correlation and Granger causality analysis of Twitter sentiments and the daily changes in Bist30 index returns

H I G H L I G H T S

- Sentiment Analysis of tweets
- Pearson Correlation and Granger causality analysis between tweets and Bist30 index returns
- Twitter is an influential platform for financial markets in Turkey

Article Info

Research Article

Received: 16.12.2019

Accepted: 24.02.2021

DOI:

10.17341/gazimmfd.660018

Keywords:

Sentiment analysis,
correlation analysis,
Granger causality analysis,
tweets,
stock markets

ABSTRACT

In our age, where a customer-oriented approach is dominant, financial enterprises have started to focus on social media platforms in order to create an active communication network with their investors. In this study, encompassing two different time periods, Pearson correlation analysis and Granger causality analysis are conducted in order to identify the relation between the investors' varying sentimental polarity values in their posts they share on Twitter, which is an effective social media platform, and daily changes in Bist30 index returns. As a result, significant correlations are found between the polarity values of tweets and the daily changes in Bist30 index returns. In addition to this result, especially in the period of unusual events, it is seen that there is a Granger causality from the polarity values of tweets towards the daily changes in Bist30 index returns. This study that works with the financial Turkish tweets and proposes a new method while conducting Doc2Vec algorithm at the level of sentiment analysis, is one of the most comprehensive studies since it not only contains correlation analysis and Granger causality analysis steps, but also applies all the statistical and econometric tests, which are necessary to carry out analysis.

1. GİRİŞ (INTRODUCTION)

Müşteri odaklı bir anlayışın egemen olduğu çağımızda finansal işletmeler sosyal medya kullanımına önem vermeye başlamıştır. Bir bilgi güvenliği firması olan Symantech'in yapmış olduğu bir araştırma sonucunda sosyal medyayı etkin kullanmayan firmalara ait olan hisselerin değer kaybettiği vurgulanmıştır [1]. Günümüzde bireysel yatırımcılar, sosyal medyada paylaşılan kısa iletileri takip ederek firmalar hakkındaki olumlu ya da olumsuz genel kanılara erişmeye çalışmaktadırlar. Yatırımcılar bu bilgilere dayanarak varlık portföylerini güncellemekte ve/veya yeni yatırım kanallarına yönelebilmektedirler. Liu vd. [2], kişilerin kendilerine tanıdık gelen hisse senetlerine yatırım yaptıklarını belirtmişlerdir. Hisse senetlerinin tanıdık olma durumunu besleyen nedenlerden biri de finansal piyasalar hakkında paylaşılan haber kaynaklarıdır [3]. Çağımızda, sosyal medya pek çok kaynağa göre gelişmelerin çok daha hızlı bir şekilde yayılmasını sağlamakta ve aynı anda daha fazla fikrin toplanmasına olanak tanımaktadır [4]. Sprenger vd., etkili bir sosyal medya platformu olan Twitter'ı takip eden bireysel yatırımcıların daha kazançlı olduğunu belirtmişlerdir [5]. Sosyal medya kullanımının bu denli yaygınlaştığı günümüzde, finansal işletmeler ile ilgili paylaşılan olumlu ya da olumsuz yorumların finansal piyasalarda bir hareketlilik yaratıp yaratmadığını inceleyen çalışmaların sayısı gittikçe artmaktadır. Bu çalışmalar genellikle görüş bildirilen yorumlardaki duygu durumlarının piyasaların hareketliliğinin tahmin edilmesinde bir teknik gösterge olarak kullanılıp kullanılmayacağını analiz etmektedir. Türkiye için bu kapsamda yapılmış çalışmalar kısıtlı sayıda [6, 7]. Bu nedenle, Türk finansal piyasaları için piyasaların hareket yönünün belirlenmesinde sosyal medyanın bir kaynak olarak kullanılıp kullanılmayacağı üzerine bir çalışma yapılması gerekliliği görülmüştür. Bu doğrultuda çalışmamızdaki amacımız, etkin bir sosyal medya platformu olan Twitter'da paylaşılan Borsa İstanbul 30 (Bist30) şirketlerine ilişkin Türkçe kısa ileti kaynaklarıyla, Bist30 endeksinin günlük değer değişimleri arasında bir ilişki olup olmadığını araştırmaktır.

Finansal piyasalar ve olumlu ya da olumsuz kanılar taşıyan kısa iletiler arasındaki ilişkinin varlığını tespit edebilmek için kısa iletiler duygu analizi aşamalarından geçirilerek olumlu, olumsuz veya nötr olarak etiketlenmektedir. Kısa iletiler etiketlenirken sözlük tabanlı veya makine öğrenmesine dayalı yaklaşımlar kullanılmaktadır. Sözlük tabanlı yaklaşımlarda kısa iletiler Afinn [8], OpinionMiner [9] ve SentiWordNet [10] gibi alandan bağımsız olan duygu sözlüklerinin kullanımıyla etiketlenmektedir. Bu sözlükler etiketleme işlemi hızlandırmakla beraber, özel alanlardaki veya farklı kültürlerdeki duygu varyasyonlarını taşıyamadıkları için yetersiz kalabilmektedir [11]. Loughran ve McDonalds [12] genel amaçlı duygu sözlüklerinin finansal kaynakların sınıflandırılması amacıyla kullanılması halinde analiz sonuçlarının olumsuz etkilendiğini belirtmişlerdir. Maalesef finans alanı için özel olarak oluşturulmuş açık kaynaklı olarak yayınlanan bir Türkçe

duygu sözlüğü bulunmamaktadır. Ayrıca diğer finansal kaynaklara kıyasla (örneğin finansal haber siteleri), kısa iletilerde yazım hataları daha fazla gözlemlenebilmekte ve iletilerdeki farklı yazım stilleri, uygulanacak olan sözlük tabanlı metinsel analizi güç hale getirmektedir. Tüm bu nedenlerden ötürü bu çalışmada, kısa iletilerin etiketlenme aşamasında finans yatırımcılarının görüşleri esas alınmıştır. Çalışmamızın başlatıldığı 07.05.2018 – 30.04.2019 zaman aralığını kapsayan bir dönemde Twitter'da Bist30 endeksinde listelenen hisse senetleriyle ilgili olarak paylaşılan 57933 adet kısa ileti içerdiği duygu durumuna göre finans yatırımcıları tarafından olumlu, olumsuz ve nötr olarak etiketlenmiştir. Etiketlenen bu kısa iletilerin eğitim amaçlı kullanılmasıyla, yine aynı zaman dilimine ait 200 bin kısa iletiden oluşan bir test veri kümesi farklı makine öğrenmesi algoritmaları ile olumlu, olumsuz ve nötr olarak üç sınıfa atanmıştır. Ayrıca kısa iletilerin vektörleştirilmesi aşamasında tf-idf ağırlığı ve n-gramların yanısıra, kelimeler arasındaki anlamsal ilişkileri belirleyebilen ve yönetilebilir boyutlu metin vektörlerinin çıkarılmasını sağlayan yapay sinir ağlarına (YSA) dayalı Doc2Vec [13] metodu, başarımlı değerinin artmasını sağlayan bir öneri ile kullanılmıştır. Test veri kümesinin sınıflandırılmasındaki amaç etiketlenmiş kısa iletilerin duygu polarite değerlerini bulmaktır. Bu amaçla üç farklı duygu polarite değeri kullanılmıştır. Daha sonra bu değerlerle, Bist30 endeksi verilerinin günlük değer değişimleri arasındaki korelasyon analizi irdelenmiştir. Korelasyon analizinde amaç bir değişkenin değeri değiştiğinde, diğer değişkenin ne yönde değişeceğini görebilmektir. Korelasyon analizi sonucunda ortaya çıkan ilişki bir neden-sonuç ilişkisi olarak yorumlanmamalıdır. Eğer iki ölçüm değeri arasında bir nedensellik ilişkisi aranacaksa, bu durum Granger Nedensellik analizi ile aranabilir. Granger nedenselliğine göre, rastsal bir X değişkeninin geçmişi diğer bir rastsal Y değişkeninin geleceğinin daha iyi tahmin edilmesini sağlıyorsa X değişkeni Y'nin Granger nedenidir [14]. Bu çalışmada duygu polarite değerleri ile Bist30 endeksi verilerinin günlük değer değişimleri arasındaki Granger nedensellik analizi sonuçları da yorumlanmıştır. Bu aşamadaki amaç, duygu polarite değerleri ve endeks hareketliliğinin ön görülebilme aşamalarında birbirlerini destekleyip desteklemediklerini analiz etmektir. Korelasyon ve Granger analizleri gerçekleştirilirken iki farklı zaman dilimi esas alınmıştır. Ele alınan ilk dönem 07.05.2018 – 30.04.2019 tarihleri arasındaki yaklaşık bir yıllık bir zaman dilimidir. İncelenen ikinci dönem ise ülkemiz için Cumhurbaşkanlığı seçimi ve kabine değişikliği gibi önemli olayların gerçekleştiği 07.05.2018 – 31.07.2018 zaman dilimidir.

Bu çalışmanın literatüre katkısı; öncelikle Türkçe metinler üzerinde yapılan diğer çalışmalara göre çok daha geniş bir veri kümesi üzerinde çalışılması, hisse senetleri değer değişimleri ile kısa iletiler arasındaki ilişkiyi belirlemek için 3 farklı duygu polarite değerinin kullanılması ve analizlerin hem kısa, hem de uzun dönem için yapılmış olmasıdır. Çalışmamız, sosyal medya ile finansal piyasalar arasındaki Granger analiz sonuçlarını gözler önüne seren ilk çalışmadır.

Özellikle Türkiye için önemli bir çalışma olduğu söylenebilir, çünkü kısa dönem olarak ülkemiz için Cumhurbaşkanlığı seçimi ve kabine değişikliği gibi önemli olayların gerçekleştiği 07.05.2018 – 31.07.2018 zaman dilimi seçilmiştir ve elde edilen sonuçlar literatüre katkı niteliğindedir. Çalışmanın literatüre diğer bir katkısı ise Doc2Vec mimarisinin başarımlarını arttırmak adına bir öneri sunulmuş olmasıdır. Son olarak, uygulanan testler ve analizler açısından, çalışmanın literatürdeki en kapsamlı çalışmalarından biri olduğu söylenebilir.

Çalışmanın ilerleyişi şu şekildedir: İkinci bölümünde Twitter kısa iletileri ile finansal piyasaların hareket yönünü araştıran çalışmalar sunulmuştur. Üçüncü bölümde, veri kümelerinin detaylı açıklamaları yer almaktadır. Dördüncü bölümde duygu analizi, korelasyon analizi ve Granger nedensellik analizi konularına ait anlatımlar bulunmaktadır. Beşinci bölüm uygulanmış olan duygu analizi, korelasyon analizi ve Granger nedensellik analizi sonuçlarını içermektedir. Son olarak çalışma, genel değerlendirmenin yapıldığı altıncı bölüm ile sonlandırılmaktadır.

2. LİTERATÜR TARAMASI (LITERATURE REVIEW)

Twitter kısa iletilerinin içerdiği duygu değerleriyle hisse senedi getirilerini ve/veya hisse senedi piyasalarının yönünü tahmin eden pek çok çalışma ortaya konmuştur. Bu çalışmalardan Bollen vd. [15], sözlük tabanlı yazılımları kullanarak 10 aylık bir zaman diliminde paylaşılan ve finansal piyasalarla ilgili olmayan yaklaşık 9,8 milyon Twitter kısa iletilerini altı duygu kategorisine (sakin, alarm durumu, emin, mutlu, nazik, hayati önem) ayırmıştır. Çalışmada, sınıflandırılan kısa iletiler ile New York menkul kıymetler borsasında işlem gören Dow Jones Endeksi (DJIA) değer değişimleri arasında Granger nedensellik ilişkisi olduğu belirtilmiştir. Mittal ve Goel [16], sözlük tabanlı bir yaklaşımla 4 farklı duygu kategorisine ayrılmış 476 milyon Twitter paylaşımı ile DJIA değerleri arasındaki nedensellik ilişkisini incelemişlerdir. Sonuç olarak sadece sakinlik ve mutluluk belirteçlerinin bulunduğu kısa iletiler ile DJIA değer değişimleri arasında bir Granger nedenselliği olduğunu belirtmişlerdir. Smailovic vd. [17], uyguladıkları Granger nedensellik analizi sonucunda kısa iletilerdeki duyguların hisse senedi fiyat hareketlerinin bir göstergesi olarak kullanılabileceğini ifade etmişlerdir. Risius vd. [18], çalışmalarının ele alındığı dönemde negatif ve depresif düşüncelerin bulunduğu kısa iletilerin hisse senedi getirilerinin tahmin edilmesinde bir etkiye sahip olduğunu belirtmişlerdir. Sul vd. [19] finansal piyasalar ile ilgili olan olumlu ve olumsuz etiketlere sahip 2,5 milyon Twitter kısa iletilerini kullanarak finansal şirketleri takipçi sayılarına göre incelemişlerdir. Sonuçta kısa iletilerin hisse senedi getirilerini tahmin etmede kullanılabilmesine dair anlamlı bulgular ortaya koymuşlardır.

Tabari vd. [20], bir yıllık bir zaman diliminde paylaşılan 20 bin adet kısa iletiyi elle etiketlemiş ve kısa iletiler ile hisse senetleri arasında çift yönlü Granger nedenselliği olduğunu belirtmişlerdir. Ranco vd. [21], finans yatırımcıları

tarafından insan gücüyle etiketlenen yüz bin kısa iletiyi baz alarak makine öğrenmesi teknikleri ile bir buçuk milyon kısa iletiyi olumlu, olumsuz ve nötr olarak sınıflandırmıştır. Sonuçta, endeksi oluşturan hisseler ile paylaşılan kısa iletiler arasında zayıf bir korelasyon ilişkisi olduğunu belirtmişlerdir. Pagolu vd. [22], Twitter’da paylaşılmış olan 3216 adet iletiyi elle olumlu, olumsuz ve nötr olarak etiketleyerek 250 bin kısa iletilerden oluşan bir test veri kümesini n-gram ve Word2Vec metotları ile vektörleştirip sınıflandırmışlardır. Sonuçta, kısa iletilerdeki duygu değişimlerinin endeks değer değişimleri üzerinde etkili olduğunu tespit etmişlerdir. Zhang vd. [23], kısa iletilerdeki olumlu ve olumsuz duygular ile DJIA, S&P 500, NASDAQ ve VIX endeksleri arasındaki korelasyonu incelemiş ve kısa iletilerin endekslerin hareket yönlerine dair bir öngörü sağladığını belirtmişlerdir. Deng vd. [24], 4 yıllık zaman diliminde StockTwit platformundan toplanan yaklaşık 18 milyon kısa iletiyi sözlük tabanlı bir yazılım ile olumlu ve olumsuz olarak etiketlemişlerdir. Sonuç olarak, DJIA endeksinin saatlik değer değişimleri ile kısa iletilerden elde edilen duygu polarite değerleri baz alındığında, olumsuz kısa iletilerin nedensellik ilişkisinde etkili olduğunu belirtmişlerdir. Zhao [25], Singapur Borsasında işlem gören piyasa değeri en yüksek ilk 30 hisse senedinden oluşan Singapore Straits Times Endeksi (STI) değerleri ile Twitter kısa iletilerinden elde edilen mutluluk endeksi arasındaki korelasyon ve Granger nedenselliği analizini gerçekleştirmişlerdir. Sonuçta, Twitter mutluluk endeksi ve 4 yıllık zaman dilimini kapsayan STI Endeksi getirileri arasında Granger nedenselliği analizi ile desteklenen pozitif yönlü bir korelasyon olduğunu belirtmişlerdir. You vd. [26], Twitter tabanlı mutluluk endeksi ile on uluslararası hisse senedi getirisi arasında nedensel bir ilişki bulunduğunu belirtmişlerdir. Aynı şekilde Li vd. [27], Twitter tabanlı mutluluk endeksi ile borsa değişkenleri arasında çift yönlü bir nedensellik ilişkisi olduğunu öne sürmüşlerdir.

Dünyada Twitter kısa iletileri ile finansal piyasalar arasındaki ilişkiyi inceleyen pek çok çalışma mevcut olmasına rağmen Türkiye için bu kapsamda yapılmış çalışma sayısı çok azdır. Bu durumun temel sebeplerinden bazıları, Türkçe olarak düzenlenmiş finansal piyasalar ile ilgili açık kaynaklı bir borsa duygu sözlüğünün olmaması ve duygu durumlarına göre etiketlenmiş yeterli sayıda finansal kısa iletiyi içeren bir veri kümesinin eksikliği olabilir. Eliaçık ve Erdoğan [6], insan gücü ile etiketlenmiş 907’si olumlu ve 1501’i olumsuz olmak üzere 6 aylık bir zaman dilimini kapsayan toplam 2408 adet Twitter paylaşımını kullanmışlardır. Kısa iletilerin içerdiği duygu polarite değerlerinin hesaplanması için paylaşımında bulunan kişinin topluluk içerisindeki inandırıcılığını gösteren bir yaklaşım önermişlerdir. Sonuç olarak, önerilen duygu polarite değeri ile Bist100 endeksi haftalık değer değişimleri arasında anlamlı bir korelasyon ilişkisi olduğunu tespit etmişlerdir. Ayrıca, çalışmada veri kümesinin toplandığı periyotta olağan dışı olayların olduğu haftalar incelendiğinde, ilişki kuvvetini belirleyen Pearson katsayısının arttığını raporlamışlardır. Yıldırım ve Yüksel [7], telekomünikasyon sektöründe yer alan ve Borsa İstanbul’da işlem gören bir firma hakkında

toplanan 500 adet Twitter paylaşımının insan gücüyle olumlu ve olumsuz olarak etiketlenmişlerdir. Çalışmalarında sınıflandırılan kısa iletilerden elde edilen duygu polarite değerleri ile firmanın hisse değerleri arasındaki günlük korelasyon ilişkisini araştırmışlardır. Sonuç olarak iki örneklem arasında negatif yönlü ve orta düzeyde bir ilişki olduğunu bildirmişlerdir. Atan ve Çınar [3], Bist30 şirketleri hakkında çeşitli kaynaklardan ulaşılan 14108 haber metni ile şirket değerleri arasındaki korelasyonu inceleyen derin bir çalışma ortaya koymuşlardır. Çalışmalarında Hu ve Liu'ya [28] ait olan sözlük Türkçe'ye çevrilmiştir. Gerekli görülen ifadeler temizlendikten sonra, temizlenen bu sözlüğün esas alınmasıyla haberlerin duygu skorları belirlenmiştir. Çalışmalarında hem haberlere ait duygu skor değerleri, hem de yayınlanan haber sayılarının dikkate alınmasıyla çeşitli analiz sonuçları paylaşılmıştır. Sonuç olarak, haber sayıları ve şirket değerleri arasında orta düzeyde bir pozitif ilişkinin var olduğu belirtilmiştir. Haberlerin duygu skorları ile şirket değerleri arasındaki analizde ise bu iki değer arasındaki korelasyonun yükseldiği ifade edilmiştir.

Bu çalışmanın ülkemiz adına gerçekleştirilen benzer çalışmalardan [3, 6, 7] farkları, daha geniş bir veri kümesi üzerinde çalışılmış ve üç farklı duygu polarite değerinin kullanılmış olmasıdır. Ayrıca çalışmamızda korelasyon analizi dışında Granger nedensellik analizi de uygulanmış ve tüm analizler farklı iki zaman dilimi için gerçekleştirilmiştir. Son olarak çalışmamızda son zamanlarda yüksek başarımlı değerleri üreten YSA'lara dayalı Doc2vec modelinin başarımlı değerini arttıracak bir durum önerilmiş ve klasik makine öğrenmesi metotlarının başarımlı değerleri kıyaslanmıştır. Çalışmamız uygulanan testler ve analizler açısından literatürdeki en kapsamlı çalışmalardan biridir.

3. VERİ KÜMELERİ (DATASETS)

3.1. Piyasa verileri (Market data)

Çalışmamızda 07.05.2018 – 30.04.2019 tarihlerini kapsayan bir dönemde Bist30 endeksi verileri kullanılmıştır. Bu zaman dilimi çalışmamızın gerçekleştirildiği tarihte erişilebilecek en güncel veri kümesini içermektedir. Bist30 endeksi verilerinin bu tarihler arasındaki günlük kapanış fiyatları www.bloomberght.com/borsa/endeks/bist-30 adresinden alınmıştır. P_d değeri Bist30 değerinin d . gündeki kapanış fiyatı olmak üzere Bist30 endeksi verilerinin günlük değer değişimleri (daily return- R_d) Eş. 1'e göre hesaplanmıştır.

$$R_d = \frac{P_d - P_{d-1}}{P_{d-1}} \quad (1)$$

3.2. Twitter veri kümesi (Twitter data)

Bu çalışmada Twitter API'den faydalanılmış ve Python Tweepy kütüphanesi kullanılarak bir modül oluşturulmuştur. Bu modül son yedi gün içinde paylaşılan kısa iletilere erişim sağlayabilmektedir. Bu nedenle Bist30 ve Bist30 şirketleri ile ilgili olan kısa iletiler her gün toplanarak bir veri tabanına kaydedilmiştir. Eğitim veri kümesi olarak 07.05.2018 – 30.04.2019 tarihlerinde paylaşılan 57933 adet kısa ileti kullanılmıştır. Kısa iletiler içerdiği duygu durumuna göre akademisyen, bankacı ve finans alanında çalışan kişilerden oluşan 20 farklı borsa yatırımcısı tarafından olumlu, olumsuz ve nötr olarak etiketlenmiştir. Snow vd. [29], etiketleme işleminin güvenilir olması için 4 kişinin fikrinin alınmasının yeterli olduğunu belirtmişlerdir. Bu nedenle 20 kişinin görev aldığı etiketleme aşamasında her kısa iletinin 4'er kişi tarafından etiketlenmesi sağlanmıştır. Etiketleme yapan kişiler kısa iletilere -2 (çok olumsuz), +2 (çok olumlu) aralığında bir tam sayı vererek puanlandırmışlardır. Sonrasında bu ağırlık değerlerinin ortalaması alınarak her bir kısa iletinin sahip olduğu puan belirlenmiştir. Kısa iletiler, eğer iletinin ortalama puanı [-2, -0,5] arasında ise olumsuz, [-0,5, 0,5] arasındaysa nötr ve (0,5, 2] arasındaysa olumlu olarak etiketlenmiştir. Bu sınır değerleri Tabari vd. [20] çalışması baz alınarak belirlenmiştir. Etiketleme işlemi sonunda eğitim veri kümesinde 14691 olumlu, 10802 olumsuz ve 32440 adet nötr etikete sahip olan kısa ileti elde edilmiştir. Eğitim veri kümesindeki etiketlenmiş kısa iletilere ait bazı örnekler Tablo 1'den görülebilir.

Finans ile ilgili kısa iletilerin yatırımcılar tarafından etiketlendiği pek çok çalışma mevcuttur. Tabari vd. [20], 20 bin Twitter kısa iletisini insan gücüyle etiketlenmişlerdir. Ranco vd. [21], finansal 100 bin kısa iletinin yatırımcıların tecrübelerine dayanarak insan gücüyle sınıflandırılmasını sağlamışlardır. Pagolu vd. [22], 3216 adet kısa iletinin insan eliyle teker teker etiketlenmesini sağlamışlardır. Türkçe finansal Twitter kısa iletilerini insan gücüyle etiketleyerek kısa iletiler ile hisse senetleri arasındaki ilişkiyi inceleyen çalışmalar sırasıyla [6, 7] çalışmalarıdır.

Çalışmamızdaki analizler iki farklı dönem için gerçekleştirilmiştir. Ele alınan ilk dönem 07.05.2018 – 30.04.2019 tarihleri arasındaki yaklaşık bir yıllık bir zaman dilimidir. İncelenen ikinci dönem ise ülkemiz için

Tablo 1. İnsan gücü ile olumlu, olumsuz ve nötr olarak etiketlenmiş kısa ileti örnekleri
(Examples of tweets that are labeled manually as positive, negative and neutral)

Kısa İleti Örneği	İleti Sınıfı
%- 8,15 bir günlük düşüş. biraz daha gayret etseydi taban kapanacaktı.	Olumsuz
ihracat şampiyonuna bak yerlerde sürünüyor... Yazıklar olsun	Olumsuz
gün içerisinde hedefine ulaşmış olup %14 getiri sağlamıştır.	Olumlu
Borsa düşmüş çıkmış umrunda olmayan tek hisse helal olsun.	Olumlu
Kademeleri paylaşan olursa haber versin.	Nötr
Hgv programı ile teknik analiz	Nötr

Cumhurbaşkanlığı seçimi ve kabine değişikliği gibi önemli olayların gerçekleştiği 07.05.2018 – 30.07.2018 zaman dilimidir. Çalışmamızda uzun dönem analizi için kullanılan test veri kümesi 07.05.2018 – 30.04.2019 tarihlerinde paylaşılan 200 bin kısa iletiyi içermektedir. Kaydedilen iletilere ait olan kimlikler (tweet id), [30] ile paylaşılan bağlantıdan indirilebilir. Bu kısa iletilerin ait oldukları hisse kodlarına göre dağılımı Tablo 2’de belirtildiği gibidir.

Uzun zaman analizinde kullanılan 200 bin test veri kümesinin paylaşım günlerine göre dağılımı Şekil 1 ile belirtilmiştir. Çalışmamızda kısa dönem analizi için kullanılan test veri kümesi Cumhurbaşkanlığı seçimi ve kabine değişikliği gibi önemli olayların gerçekleştiği 07.05.2018 – 30.07.2018 tarihlerinde paylaşılan 31591 kısa iletiyi içermektedir. Kısa zaman analizi için kullanılan 31591 kısa iletinin paylaşım günlerine göre dağılımı Şekil 2 ile belirtilmiştir. Test veri kümesini oluşturan kısa iletiler, makine öğrenmesi teknikleri ile olumlu, olumsuz ve nötr olarak sınıflandırılmıştır. Daha sonra olumlu ve olumsuz sınıflardaki kısa ileti sayılarının kullanılmasıyla duygu polarite değerleri hesaplanmıştır. Duygu polarite değerleri olarak Eş. 2 - Eş. 4 ile belirtilen S_1 , S_2 , S_3 değerleri kullanılmıştır. t gününde atılan olumlu (pozitif) kısa ileti sayısı p_t , olumsuz (negatif) kısa ileti sayısı n_t olmak üzere korelasyon ve nedensellik ilişkisinde ölçüm değeri olarak kullanılacak duygu polarite değerleri aşağıda belirtilmiştir.

$$S_1 = \frac{p_t - n_t}{p_t + n_t} \quad (2)$$

$$S_2 = \frac{p_t + 1}{n_t + 1} \quad (3)$$

$$S_3 = \frac{p_t}{p_t + n_t} - \frac{p_{t-1}}{p_{t-1} + n_{t-1}} \quad (4)$$

S_3 duygu değerinde belirtilen $t - 1$ ele alınan t .günden bir önceki gün atılan kısa ileti sayısı hakkında bilgi vermektedir.


4. UYGULANAN METOTLAR (APPLIED METHODS)

4.1. Duygu analizi (Sentiment analysis)

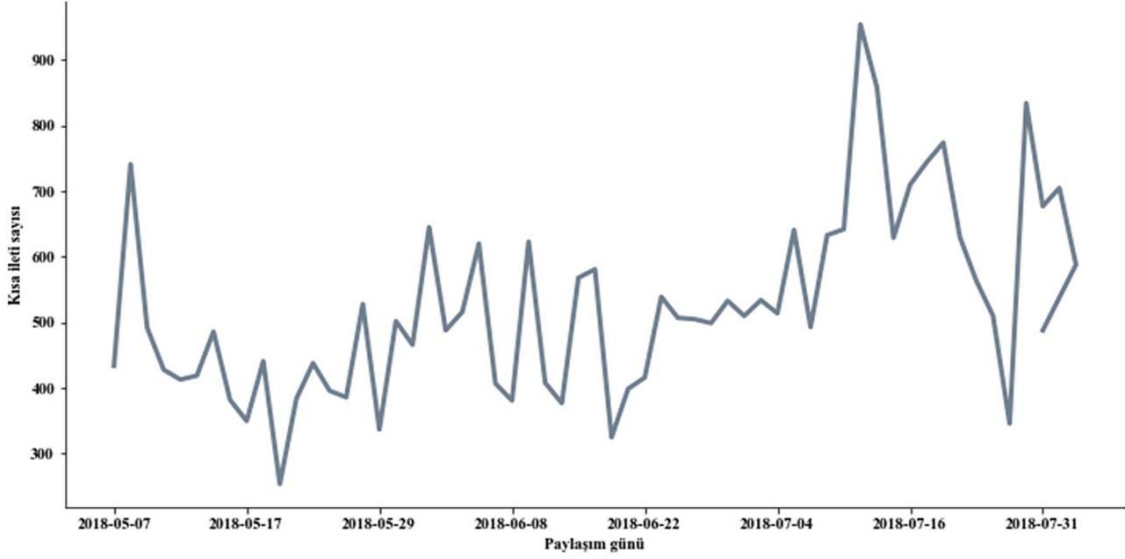
Duygu analizi en çok kullanılan sosyal medya izleme yöntemidir [31]. Sosyal medyada paylaşılan metinsel tabanlı yorumların duygu durumlarına göre sınıflandırılmasını sağlamaktadır. Bir sınıflandırıcının eğitilebilmesi için öncelikle metinsel verilerin vektörleştirilmesi gerekmektedir. Bu çalışmada veri kümemizi oluşturan kısa iletiler n-gram dizilimlerinin ve tf-idf ağırlıklandırmasının kullanılmasıyla vektörleştirilmiştir. Değerlendirilecek kelime sayısının azaltılabilmesi için Ki-Kare özellik seçim metodunun etkisi incelenmiştir. Ayrıca tf-idf ağırlıklandırmasının yanı sıra kelimeler arasındaki anlamsal ilişkilerin tespiti için Doc2vec metodu, algoritmanın

Tablo 2. Test veri kümesini oluşturan kısa iletileri bilgileri (The information of tweets in the test dataset)

Hisse Kodu	İleti sayısı	Hisse Kodu	İleti sayısı	Hisse Kodu	İleti sayısı	Hisse Kodu	İleti sayısı	Hisse Kodu	İleti sayısı
#AKBNK	7995	#ENJSA	1727	#KCHOL	3422	#SAHOL	2960	#TKFEN	1848
#ARCLK	4129	#EREGL	8374	#KOZAA	10172	#SISE	2072	#TOASO	3360
#ASELS	17945	#PROTO	1668	#KOZAL	9906	#SODA	4930	#TTKOM	8510
#BIMAS	837	#GARAN	16038	#KRDMD	11442	#TAVHL	2579	#TUPRS	7510
#DOHOL	3634	#HALKB	11974	#PETKM	12749	#TCELL	4362	#VAKBN	4581
#EKGYO	5687	#ISCTR	3960	#PGSUS	3933	#THYAO	16168	#YKBNK	5528



Şekil 1. Uzun zaman analizi için kullanılan test veri kümesinin paylaşım günlerine göre dağılımı (Long-term dataset by sharing days)



Şekil 2. Kısa zaman analizi için kullanılan test veri kümesinin paylaşım günlerine göre dağılımı
(Short-term dataset by sharing days)

başarımını arttıracak bir yöntem ile kullanılmıştır. Mikalov vd. [32] tarafından önerilen YSA'lara dayalı olan Word2Vec modelinde, kelimeler belirli bir pencere boyutunda komşularıyla birlikte değerlendirilmektedir. Bu sayede yakın anlamlı kelimeler benzer vektörler ile ifade edilebilir. Word2Vec kelimeleri vektörler ile ifade ederken iki farklı öğrenme mimarisi olan Sürekli Kelime Çantası (Continuous Bag of Words- CBOW) ve Gram Atla (Skip-gram) modellerini kullanmaktadır. CBOW modelinde, bir kelimenin komşularına bakılmakta ve hedef kelime bu komşu kelimelerden tahmin edilmektedir. Skip-gram mimarisinde ise, tam tersi şekilde hedef kelimeye bakılarak komşu kelimeler tahminlenir. Mikalov vd. [13], sunmuş olduğu Doc2Vec isimli yeni bir yöntem ile kelimelerin yanı sıra, metinlerin de vektörleştirilebileceğini göstermişlerdir. Bu model, Word2Vec modeli kullanılarak, kelime vektörlerinin yanına her doküman için bir doküman vektörünün eklenmesiyle tasarlanmıştır. Böylelikle herhangi bir doküman da yönetilebilir boyutlu bir vektör ile ifade edilebilmiştir. Doc2Vec öğrenimindeki mimariler, Doküman Vektörlerinin Dağıtılmış Bellek Modeli (Distributed Memory Model of Paragraph Vectors- PV-DM) ve Doküman Vektörünün Dağıtılmış Kelime Çantası Modeli (Distributed Bag of Words-Paragraph Vector- PV-DBOW) mimarileridir. Bu mimariler sırasıyla Word2Vec'in CBOW ve SkipGram mimarilerine benzemektedir. Çalışmamızda tf-idf ve Doc2Vec özellik çıkarımı ile yapısal hale getirilen kısa iletilerin sınıflandırılması için Lojistik Regresyon (LR), Destek Karar Makineleri (DVM), Naive Bayes (NB), Karar Ağaçları (KA) ve En yakın K- komşu (EKK) sınıflandırıcıları kullanılmıştır. Bu bireysel sınıflandırıcılar dışında Maksimum Oylama (MO) topluluk öğrenmesi yöntemine de başvurulmuştur. Tüm deneyler sonucunda en iyi başarımlarına sahip olan sınıflandırma metodu seçilmiş ve bu metot ile test veri kümesini oluşturan iki yüz bin kısa ileti otomatik bir şekilde sınıflandırılmıştır.

4.2. Korelasyon analizi (Correlation analysis)

Korelasyon analizi, iki ya da daha fazla değişken arasındaki doğrusal ilişkiyi test etmek ve ilişki derecesini belirlemek için kullanılan istatistiksel bir yöntemdir. Korelasyon analizinde ilişki derecesi korelasyon katsayısı (r) ile gösterilmektedir. Bu katsayı -1 ile +1 arasında değer alabilmektedir. Korelasyon katsayısının mutlak değerinin büyüklüğü, var olan ilişkinin gücünü belirtmektedir. Literatürde en çok kullanılan korelasyon analizleri Pearson ve Spearman korelasyon analizleridir [33]. Değişkenlerin dağılımının normal ya da normale yakın olduğu durumlarda Pearson korelasyon analizi kullanılırken, değişkenlerin normallikten uzak olduğu durumlarda Spearman korelasyonu kullanılmaktadır. Bu nedenle hangi analiz kullanılacağına karar vermek için doğrusal ilişkinin varlığı ve normallik, grafik çizimi ve örneklem sayısına göre seçilen Kolmogorov-Smirnov ya da Shapiro-Wilk normalite testleri ile kontrol edilmelidir [34]. Çalışmamızda S_1 , S_2 ve S_3 duygu ölçüm değerleri ile hisse değer değişimlerini içeren R_d ölçüm değerlerinin normal dağılıma olan uygunlukları gerekli testler ile sınanmıştır. Bu adımları gerçekleştirmek için IBM SPSS [35] yazılımı kullanılmıştır.

4.3. Granger nedensellik analizi (Granger causality analysis)

Literatürde zamana bağlı olarak değişen iki değişken arasındaki nedensellik ilişkisinin varlığını ve yönünü test etmek için sıklıkla Granger nedensellik analizinin kullanıldığı görülmüştür. Çalışmamızda gerçekleştirdiğimiz korelasyon analizinin ardından, Twitter'da Bist30 endeksini oluşturan hisseler hakkında günlük olarak atılan olumlu ve olumsuz kısa ileti sayılarıyla elde edilen S_1 , S_2 ve S_3 duygu polarite değerleri ile hisse değer değişimlerini içeren R_d değeri arasında Granger nedensellik analizi gerçekleştirilmiştir. Ortalaması, varyansı ve kovaryansı

zaman boyunca sabit kalan serilere durağan seriler denir. Granger nedensellik analizine başlamadan önce zamana bağlı olan değişkenlerin zaman içinde belirli bir değere yaklaşması durumunu denetleyen durağanlık testinden geçmesi gerekmektedir. Çünkü, durağan olmayan zaman serileri ile çalışılan modellerde değişkenler arasında sahte bir ilişki ortaya çıkabilir. Bir serinin durağan olup olmadığının sınılanması için en çok kullanılan yöntem Genişletilmiş Dickey-Fuller (ADF-1979) testidir [36]. X_t ve Y_t durağan iki zaman serisi olmak üzere, Granger Y_t 'nin öngörüsü gerçekleştirilirken bu dizinin geçmiş (gecikmeli) değerlerinin yanında X_t 'nin şimdiki ve geçmiş değerlerini kullanmanın, yalnızca Y_t 'nin geçmiş değerlerini kullanmaktan daha iyi sonuç verdiğini göstermiştir. Zamana bağlı olan X_t ve Y_t arasındaki nedensellik ilişkileri, a_i , b_i , β_i ve θ_i gecikme katsayıları, m tüm değişkenler için ortak gecikme uzunluğu, ε_{1t} , ε_{2t} birbirinden bağımsız hata terimleri olmak üzere, Eş. 5 ve Eş. 6 yardımıyla bulunabilir.

$$Y_t + b_0 X_t = \sum_{i=1}^m a_i Y_{t-i} + \sum_{i=1}^m b_i X_{t-i} + \varepsilon_{1t} \quad (5)$$

$$X_t + b\theta_0 Y_t = \sum_{i=1}^m \beta_i X_{t-i} + \sum_{i=1}^m \theta_i Y_{t-i} + \varepsilon_{2t} \quad (6)$$

Burada sistem en küçük kareler metodu ile çözüldükten sonra elde edilen:

- b_i değerleri belirli bir anlamlılık düzeyi ile sıfırdan farklı olursa X_t 'nin Y_t 'ye neden olduğu söylenir. Bu durum X_t 'den Y_t 'ye tek yönlü bir Granger nedenselliği olduğunu belirtir. Bu ifade $X_t \rightarrow Y_t$ şeklinde gösterilebilir.
- θ_i değerleri belirli bir anlamlılık düzeyi ile sıfırdan farklı olursa, bu sefer Y_t 'nin X_t 'ye neden olduğu söylenir. Bu durum Y_t 'den X_t 'ye tek yönlü bir Granger nedenselliği olduğunu belirtir ve ifade $Y_t \rightarrow X_t$ şeklinde gösterilebilir.
- Hem b_i , hem de θ_i değerleri belirli bir anlamlılık düzeyinde sıfırdan farklı olursa X_t ve Y_t arasında çift yönlü bir nedensellik ilişkisi olduğu söylenir. Bu durum $X_t \leftrightarrow Y_t$ ile gösterilir.
- Hem b_i , hem de θ_i değerlerinin belirli bir anlamlılık düzeyinde sıfırdan farklı olmadığı durumlarda X_t ve Y_t 'nin birbirinden bağımsız olduğu belirtilir.

Granger nedensellik testi gecikme uzunluğuna karşı duyarlıdır. Bu nedenle, gecikme uzunluğunun belirlenmesi önemlidir. Vektör Otoregresif (Vector Autoregression - VAR) modeline dayalı olan Granger analizinde gecikme sayılarının tespiti dahil tüm analizler, E-Views 10.0 yazılımı ile gerçekleştirilmiştir. Çalışmada, bu yazılım ile ulaşılan sonuçlarda karşılaşılan p-olasılığının %5 anlamlılık düzeyi için 0,05'den küçük olması durumunda " $H_0 : R_d$ ilgili duygu polarite değerinin Granger nedeni değildir." şeklinde tanımlanan sıfır hipotezi reddedilmiş, aksi durumda hipotez kabul edilmiştir.

5. DENEYSEL SONUÇLAR (EXPERIMENTAL RESULTS)

5.1. Duygu analizi sonuçları (Sentiment analysis results)

Bu bölümün amacı, eğitim veri kümesini oluşturan 57933 kısa iletiyi n-gramlar, tf-idf terim ağırlığı ve Doc2Vec

gösterimleriyle vektörleştirmek ve başarımlık değeri en yüksek olan sınıflandırıcıyı belirlemektir. Sınıflandırma işleminden önce kısa iletilerdeki '@', '\$' karakterleri ile başlayan kelimeler, url adresi içeren ifadeler ve noktalama işaretleri temizlenmiştir. '%+', '+%', '-%', '%-', ':', ': (' gibi belirteçler artış/azalış veya olumlu/olumsuz duygu durumlarını yansıttığı için kaldırılmamıştır. Farklı sınıflandırıcıların başarımlık değerlerinin kıyaslandığı tüm deneylerde eğitim veri kümesinin %80'i eğitim, %20'si ise test amaçlı kullanılmıştır. Ayrıca 10 kat çapraz doğrulama yöntemi uygulanmıştır. Deneyler sırasında Python programlama dili kullanılmıştır. DVM algoritması için lineer çekirdek fonksiyonu seçilmiştir. EKK metodunda en yakın 3 komşu dikkate alınarak, öklit uzaklığı baz alınmıştır. KA sınıflandırıcısı için Gini indeksi esas alınmıştır. MO topluluk öğrenmesinde ise çoğunluk oylaması stratejisi kullanılmıştır.

Kelime frekansı tabanlı tf-idf değerlerinin kullanılması ile gerçekleştirilen ilk deneyde vektör uzayındaki toplam kelime sayısının 100 bin olduğu tespit edilmiştir. Bu durumda kısa iletilerin sınıflandırılması amacıyla kullanılan LR, DVM, NB, KA ve EKK sınıflandırıcıları arasında en yüksek başarımlık değerine sahip olan yöntemin %63,41 (+/- 0,28)'lik bir değerle LR olduğu görülmüştür. 100 bin olan vektör uzayının boyutunu azaltmak adına hem yüksek tf-idf ağırlık değerlerine sahip olan, hem de Ki-kare metodu ile belirlenmiş olan farklı sayıdaki kelime kullanımlarının LR üzerindeki etkisi analiz edilmiştir. Şekil 3 ile belirtilen analiz sonuçlarına göre, Ki-Kare özellik seçim metodunun belirlediği kelime kullanımlarının, yüksek tf-idf değerine sahip olan kelime kullanımlarına göre bir iyileştirme sağlamadığı görülmüştür. Fakat yüksek tf-idf ölçüm değerlerine göre seçilmiş 50 bin kelimenin dikkate alınmasının, 100 bin kelimenin tamamının kullanılması duruma göre hemen hemen aynı başarımlık değerini verdiği görülmüştür. Bu nedenle çalışmamızda sınıflandırma aşamasında en yüksek tf-idf değerine sahip olan 50 bin kelime dikkate alınmıştır.

Yüksek tf-idf değerlerine sahip olan 50 bin özelliğin kullanımı ile vektörleştirilen kısa iletilerin sınıflandırılması sonuçları Tablo 3 ile belirtildiği gibidir. Bu aşamada kelime tabanlı 1-gramların dışında, 2-gram ve 3-gramların etkisi de incelenmiştir. Tablo 3'e göre en iyi başarımlık değeri %63,60 ile yine LR algoritmasına ait çıkmıştır. En iyi değer, 2-gramlar ile elde edilmiştir. Topluluk öğrenmesi metodu olan maksimum oylama yöntemi ile pek çok deney gerçekleştirilmiş ve farklı kombinasyonlar ile bireysel sınıflandırıcılardan faydalanılmıştır. En iyi başarımlık sonuçlarına LR, SVM ve NB algoritmalarının birleştirilmesi ile elde edilmiştir (%63,39). Fakat bu sonuç LR temel sınıflandırıcısının gerisinde kalmıştır.

Bölüm 4'de belirtildiği gibi Doc2Vec modelinin PV-DM ve PV-DBOW isimlerinde farklı iki öğrenme mimarisi mevcuttur. PV-DM Word2Vec'deki CBOW'a, PV-DBOW ise Word2Vec'deki Skip-Gram'a karşılık gelmektedir. Tablo 4, kısa iletileri kelimeler arasındaki anlamsal ilişkileri barındıracak şekilde vektörleştirebilen Doc2Vec modelinin

kullanımının şu ana kadar en iyi başarımlarını vermiş olan LR üzerindeki etkilerini göstermektedir. Doc2Vec mimarisi kullanılarak vektör boyutunun belirlenmesi adına pek çok deney yapılmış ve en iyi sonuca vektör boyutu 100 ve iterasyon sayısı 5 olduğunda ulaşılmıştır. Bu çalışmada ayrıca PV-DM ve PV-DBOW kelime vektörlerinin birleşiminin kullanımı önerilmiştir. Bu durumda doküman vektörünün boyutu 200 olmuştur.

Tablo 3. tf-idf gösterimi ile elde edilen sınıflandırma sonuçları

(Classification results with the tf-idf representation)

	1-Gram	2-Gram	3-Gram
LR	%63,41 (+/- 0,28)	%63,60 (+/- 0,29)	%63,47 (+/- 0,24)
DVM	%62,53 (+/- 0,48)	%62,32 (+/- 0,54)	%62,32 (+/- 0,47)
NB	%59,55 (+/- 0,32)	%61,58 (+/- 0,43)	%61,40 (+/- 0,56)
KA	%58,01 (+/- 0,30)	%57,60 (+/- 0,36)	%57,47 (+/- 0,41)
EKK	%56,16 (+/- 0,45)	%55,43 (+/- 0,45)	%55,34 (+/- 0,49)
MO	%63,03 (+/- 0,24)	%63,39 (+/- 0,22)	%63,29 (+/- 0,20)

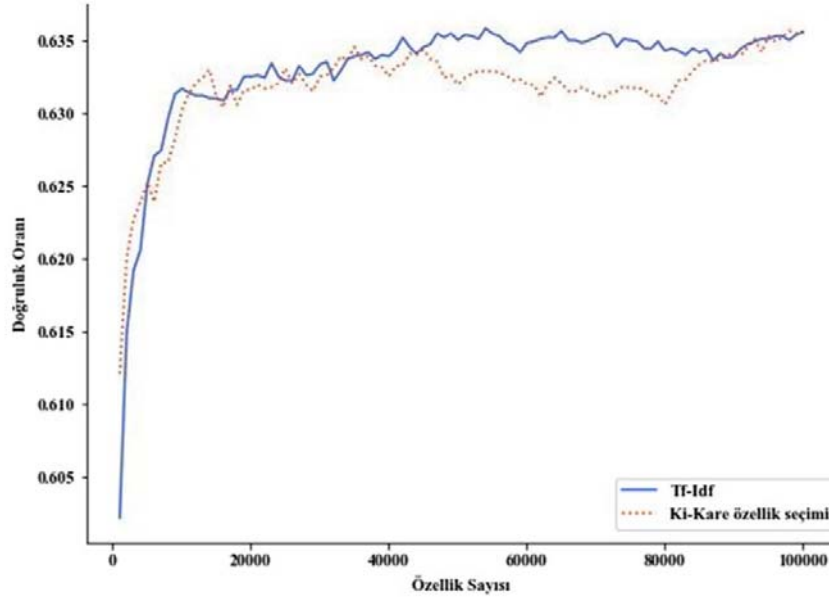
Tablo 4'den görüleceği gibi en iyi sonuç çalışmamız kapsamında önerilen PV-DM ve PV-DBOW vektörlerinin birleşiminden elde edilen durumda ortaya çıkmıştır (%58,96). Fakat Doc2Vec ile elde edilen bu iyileştirilmiş sonuç tf-idf ile elde edilen sonucu geçememiştir. Sonuç olarak eğitim aşamasında incelenen durumlar arasında en iyi başarımların değeri tf-idf ağırlık değeri ile oluşturulan sistemde 50 bin öznelik baz alınarak ve LR algoritmasının

uygulanması ile 2-gram gösterimi kullanıldığında elde edilmiştir (%63,60). Bundan sonraki süreçte, test veri kümesi bu şartlar altında olumlu, olumsuz ve nötr olarak sınıflandırılmıştır. Ardından, olumlu ve olumsuz sınıflardaki kısa ileti sayıları baz alınarak S_1, S_2, S_3 duyu polarite değerleri hesaplanmıştır.

5.2. Korelasyon analizi sonuçları

(The results of the correlation analysis)

Bu bölüm ile hedeflenen durum, test veri kümesinin sınıflandırılmasıyla elde edilen duyu polarite değerleri ile hisse değer değişimlerini içeren R_d değerleri arasındaki korelasyon analizini gerçekleştirmektir. Korelasyon analizine başlamadan önce S_1, S_2, S_3 ile R_d değerlerinin normal dağılıma uyup uymadığı test edilmiştir. Bu amaçla yapılan analizlerde örneklem sayısının 29'dan büyük olması durumunda Kolmogorov-Smirnov testi, örneklem sayısının 29'dan küçük olması durumunda ise Shapiro-Wilks testi kullanılmaktadır. 07.05.2018 – 30.04.2019 tarihleri arasında dikkate alınan işlem günü 242 olduğundan ötürü Kolmogorov-Smirnov testi uygulanmıştır. SPSS yazılımı ile gerçekleştirilen, H_0 ve H_1 hipotezlerinin sırasıyla “Verilerin gösterdiği dağılım ile normal dağılım arasında fark yoktur.” ve “Verilerin gösterdiği dağılım ile normal dağılım arasında fark vardır.” gibi tanımlandığı bir durumda 0,05 anlamlılık düzeyinde Kolmogorov-Smirnov testinin sonuçları Tablo 5 ile belirtilmiştir.



Şekil 3. tf-idf ile Ki-Kare metodunun kıyaslanması (Comparison of tf-idf and Chi-Square method)

Tablo 4. LR'nin Doc2Vec gösterimi ile elde edilen sınıflandırma sonuçları (Classification results of LR with the Doc2vec representation)

	1-Gram	2-Gram	3-Gram
PV-DM	%57,93 (+/- 0,014)	%57,39 (+/- 0,013)	%58,05 (+/- 0,019)
PV-DBOW	%56,53 (+/- 0,017)	%56,63 (+/- 0,020)	%56,41 (+/- 0,015)
PV-DM + PV-DBOW	%58,55 (+/- 0,016)	%58,34 (+/- 0,019)	%58,96 (+/- 0,013)

Tablo 5. Kolmogorov-Smirnov normal dağılım testi sonuçları
(The results of Kolmogorov-Smirnov Normal Distribution Test)

	Test İstatistiği	N	p
S_1	0,052	242	0,200*
S_2	0,062	242	0,024
S_3	0,041	242	0,200*
R_d	0,047	242	0,200*

Kolmogorov-Smirnov testi sonuçları incelendiğinde S_1 , S_3 ve R_d için p değerinin 0,200 olduğu, S_2 içinse 0,024 olduğu görülmüştür. S_1 , S_3 ve R_d anlamlılık değerlerinin 0,05'ten büyük olmasından ötürü H_0 hipotezi kabul edilmiş, S_2 içinse aynı hipotez reddedilmiştir. Sonuç olarak S_1 , S_3 ve R_d 'nin normal dağıldığı, S_2 'nin ise normal dağılmadığı tespit edilmiştir. S_2 değerini normal dağılıma uygun hale getirmek için, değer çarpıklığına bakılmış ve değer ortalamasının medyandan büyük olduğu yani sağa çarpık olduğu tespit edilmiştir. Bu nedenle S_2 üzerinde logaritmik dönüşüm uygulanarak Kolmogorov-Smirnov testi tekrar uygulanmıştır. Logaritmik dönüşüm ile $\log(S_2)$ 'nin anlamlılık değerinin 0,200 olduğu ve bu değer 0,05'den büyük olduğu için normal dağıldığı görülmüştür. Bundan sonraki süreçte, Kolmogorov-Smirnov testi ile normal dağıldığı gösterilen S_1 , $\log(S_2)$, S_3 duygu polarite değerleri ile R_d arasındaki Pearson korelasyon analizi gerçekleştirilmiştir. Sonuçlar Tablo 6 ile belirtilmiştir.

Tablo 6'da belirtilen tüm p değerlerinin 0,05 den küçük olmasından ötürü duygu polarite değerleri ile hisse değer değişimleri arasındaki korelasyon ilişkilerinin anlamlı olduğu söylenebilir.


Ayrıca duygu polarite değerleri ile hisse değer değişimleri arasındaki Pearson korelasyon katsayıları pozitif ve 0,50 ile 0,69 arasında olduğu için S_1 , $\log(S_2)$, S_3 duygu polarite değerleri ile R_d arasında pozitif yönde ve orta seviyede ilişki bulunduğu belirtilebilir. Bu pozitif yönlü orta düzey ilişkiyi görselleştirmek adına Şekil 4'ten görülebileceği gibi 242 işlem gününde S_1 , $\log(S_2)$, S_3 duygu polarite değerleri ile R_d değerlerini aynı düzlem üzerinde gösterilmiştir.

Tablo 6. 242 işlem gününü içeren dönemde S_1, S_2, S_3 ve R_d arasındaki Pearson Korelasyonu sonuçları
(The results of Pearson correlation between S_1, S_2, S_3 and R_d for 242 trading days)

	R_d		
	N	Pearson Korelasyon Katsayısı	p
S_1	242	0,578	0,000*
S_2	242	0,575	0,000*
S_3	242	0,509	0,000*

Şekil 4 incelendiğinde $S_1, \log(S_2), S_3$ duygu polarite değerleri ile R_d değerlerinin hareket yönlerinin aynı dönemlerde sıklıkla birlikte hareket ettiği görülmüştür. 07.05.2018 – 30.04.2019 tarihleri arasındaki yaklaşık 242 işlem gününü içeren bu zaman aralığında ülkemizde cumhurbaşkanlığı seçimi ve akabinde kabine değişimi gibi önemli durumlar yaşanmıştır. Belirtilen bu önemli olaylar 2018 yılının Haziran ayında gerçekleşmiştir. Şekil 2 incelendiğinde özellikle Haziran ayını içinde bulunduran 07.05.2018-31.07.2018 tarihleri arasındaki 57 işlem gününde (Cumhurbaşkanlığı seçimi öncesi ve sonrasında geçen süreç) R_d değerlerinin pek çok kez keskin iniş ve çıkış yaptığı görülebilir. İşte bu nedenle ülkemiz adına önemli olan olayların gerçekleştiği bir dönemi içeren 57 işlem gününü kapsayan 07.05.2018- 31.07.2018 tarihleri arasında S_1, S_2, S_3 ile R_d değerleri arasında yeniden ikinci bir korelasyon analizi gerçekleştirilmiştir. Bu bağlamda öncelikli olarak 07.05.2018 - 31.07.2018 tarihleri arasındaki 57 işlem günündeki S_1, S_2, S_3 duygu polarite ve R_d değerlerinin normal dağılıma uygun olup olmadığını Kolmogorov-Smirnov testi ile tekrar sınamış ve verilerin p değerlerinin 0,05'den büyük olmasından ötürü normal dağıldığı görülmüştür. Sonuçlar Tablo 7 ile paylaşılmıştır.

Sonraki aşamada Cumhurbaşkanlığı seçimi ve kabine değişiminin gerçekleştiği olayları içeren 57 işlem gününde elde edilen duygu polarite değerleri ve hisse değerleri arasındaki Pearson korelasyon analizi gerçekleştirilmiştir. Sonuçlar Tablo 8 ile belirtilmiştir.



Şekil 4. Duygu polarite değerleri ve R_d arasındaki ilişki (The relationship between sentiment polarity values and R_d)

Tablo 7. 57 işlem gününü içeren dönemde S_1, S_2, S_3 ve R_d arasındaki Kolmogorov-Smirnov testi sonuçları
(The results of Kolmogorov-Smirnov Normal Distribution test between S_1, S_2, S_3 and R_d for 57 trading days)

	Test İstatistiği	N	p
S_1	0,108	57	0,098
S_2	0,062	57	0,158
S_3	0,041	57	0,200
R_d	0,047	57	0,200

Tablo 8. 57 işlem gününü içeren dönemde S_1, S_2, S_3 ve R_d arasındaki Pearson korelasyon analizi sonuçları (The results of Pearson correlation between S_1, S_2, S_3 and R_d for 57 trading days)

	R_d		
	N	Pearson Korelasyon Katsayısı	p
S_1	57	0,549	0,000*
S_2	57	0,490	0,000*
S_3	57	0,573	0,000*

Tablo 8’de görüldüğü gibi tüm p değerlerinin 0,05 den küçük olmasından ötürü korelasyonlar anlamlıdır. Hisse değer değişimleri ile duygu polarite değerleri arasındaki ilişki önemli olayların olduğu dönemlerde yine pozitif yönlü ve orta düzeye yakın bir ilişki çıkmıştır.

5.3. Granger nedensellik analizi sonuçları (Granger causality analysis results)

Bu bölümde, tıpkı korelasyon analizinde olduğu gibi hem 242 işlem günü, hem de Cumhurbaşkanlığı seçimi ve kabine

değişimi gibi önemli olayların gerçekleştiği 57 işlem günü için Granger nedensellik analizi sonuçları yorumlanacaktır. Böylece anlamlı korelasyon ilişkilerine sahip S_1, S_2, S_3 ve R_d değerleri arasında bir Granger nedenselliğinin olup olmadığı görülebilecektir. Uzun dönem için yapılan analize başlamadan önce E-views 10.0 yazılımı yardımıyla zamana bağlı olarak değişen S_1, S_2, S_3 ve R_d değerleri ADF durağanlık testinden geçirilmiştir. Sonuçlar Tablo 9 ile paylaşılmıştır. ADF durağanlık testi için varsayılan hipotezler bu tablonun en alt satırında belirtilmiştir.

ADF testi sonucunda yüzde beş hata payı ile S_1, S_2, S_3 ve R_d için Tablo 9’un en alt satırında belirtilmiş olan sıfır hipotezi reddedilmiştir. Sıfır hipotezinin reddedilme sebebi p ile belirtilen olasılık değerlerinin 0,05’den küçük olması ve her bir “*t istatistiği*” verisinin mutlak değerinin, ilgili “*Test Kritik Değerinin*” mutlak değerinden büyük olmasıdır ($|-11,32780| > |-2,873339|$, $|-11,61509| > |-2,873339|$, $|-14,55398| > |-2,873339|$). Tüm bunlar S_1, S_2, S_3 ve R_d değerlerinin durağan olduğunu göstermiştir. S_1, S_2, S_3 ve R_d ’in durağan olduklarının gösterilmesinin ardından en uygun gecikme değerleri E-views 10.0 yazılımı VAR modeli ile belirlenmiş ve uzun dönem baz alındığında erişilen Granger nedensellik ilişkisi sonuçları Tablo 10 ile paylaşılmıştır.

Tablo 10’dan görüldüğü gibi %5 anlamlılık düzeyinde olasılık değeri olan p değerinin 0,05’den küçük olduğu durumlarda sıfır hipotezi reddedilmiştir. İlgili sıfır

Tablo 9. 242 işlem gününü içeren uzun dönem için gerçekleştirilen ADF durağanlık testi sonuçları
(The results of ADF test for the long term that consists of 242 trading days)

	S_1		S_2		S_3		R_d	
	t istatistiği	Olasılık (p)	t istatistiği	Olasılık (p)	t istatistiği	Olasılık (p)	t istatistiği	Olasılık (p)
ADF Test İstatistiği	-11,32780	0,00	-11,61509	0,00	-14,55398	0,00	-14,76942	0,00
Test Kritik Değeri (%5)	-2,873339		-2,873339		-2,873440		-2,873339	

H_0 : S_1, S_2, S_3 ve R_d durağan değildir.

H_1 : S_1, S_2, S_3 ve R_d durağandır.

Tablo 10. 242 işlem gününü içeren uzun dönem için gerçekleştirilen Granger Analizi sonuçları
(The results of Granger causality test for the long term that consists of 242 trading days)

İnceleme Dönemi : 07.05.2018 – 30.04.2019

Sıfır Hipotezi (H_0)	Gecikme Sayısı	Gözlem Sayısı	F İstatistiği	Olasılık(p)	%5 Anlamlılık Düzeyinde Karar	Sonuç
R_d S_1 ’in Granger nedeni değildir.	2	240	6,45596	0,0019*	H_0 reddedilir.	R_d S_1 ’in Granger nedeni değildir.
S_1, R_d ’nin Granger nedeni değildir.		240	2,56218	0,0793	H_0 kabul edilir.	S_1, R_d ’nin Granger nedeni değildir.
R_d S_2 ’nin Granger nedeni değildir.	2	240	6,92085	0,0012*	H_0 reddedilir.	R_d S_2 ’nin Granger nedeni değildir.
S_2, R_d ’nin Granger nedeni değildir.		240	2,17074	0,1164	H_0 kabul edilir.	S_2, R_d ’nin Granger nedeni değildir.
R_d S_3 ’ün Granger nedeni değildir.	7	235	3,39474	0,0018*	H_0 reddedilir.	R_d S_3 ’ün Granger nedeni değildir.
S_3, R_d ’nin Granger nedeni değildir.		235	1,23319	0,2856	H_0 kabul edilir.	S_3, R_d ’nin Granger nedeni değildir.

H_0 : R_d, S_x ($x = 1,2,3$) duygu polarite değerinin Granger nedeni değildir.

H_1 : R_d, S_x ($x = 1,2,3$) duygu polarite değerinin Granger nedeni değildir.

hipotezlerinin reddedilmesiyle birlikte “ R_d, S_1 ’in Granger nedenidir”, “ R_d, S_2 ’in Granger nedenidir” ve “ R_d, S_3 ’in Granger nedenidir” sonuçları ortaya çıkmıştır. Bu durum $R_d \rightarrow S_1, R_d \rightarrow S_2, R_d \rightarrow S_3$ ifadeleri ile özetlenebilir. Yine Tablo 10’dan görüleceği gibi p değerinin 0,05’den büyük olduğu durumlarda H_0 hipotezi kabul edilmiştir. Bu nedenle ortaya çıkan sonuçlar “ S_1, R_d ’nin Granger nedeni değildir.”, “ S_2, R_d ’nin Granger nedeni değildir.” ve “ S_3, R_d ’nin Granger nedeni değildir.” sonuçlarıdır. Yani uzun dönem için yapılan bu analizde paylaşılan kısa ileti sayılarından elde edilen duygu polarite değerlerinin, Bist30 endeksi değer değişimlerinin Granger nedeni olmadığı görülmüştür.

Tablo 11-Tablo 12 Cumhurbaşkanlığı seçimi ve kabine değişimi gibi önemli olayların gerçekleştiği 57 işlem günü için uygulanan Granger nedensellik analizi sonuçlarını göstermektedir. Bu kısa dönem analizdeki amaç, yukarıda paylaşılan 242 günlük işlem gününe ait olan uzun dönem sonuçlarından farklı bir sonuca ulaşıp ulaşılamayacağını araştırmaktır. Bu dönem için Granger nedensellik analizine

başlamadan önce kısa dönemde elde edilen S_1, S_2, S_3 ve R_d değerleri yine durağanlık testinden geçirilmiş ve serilerin durağan olduğu görülmüştür. Bu durum Tablo 11 ile belirtilmiştir.

Tüm verilerin durağan olduğunun gösterilmesinin ardından gerçekleştirilen Granger nedensellik analizi sonuçları ise Tablo 12’de paylaşıldığı gibidir. En uygun gecikme sayıları yine E-Views yazılımı kullanılarak VAR modeli ile belirlenmiştir ve p olasılık değerinin 0,05’den küçük olması durumunda Tablo 12’de belirtilen sıfır hipotezleri reddedilmiş aksi durumda kabul edilmiştir.

Tablo12’nin ilk iki satırındaki durumlar yorumlandığında, uzun dönemi içeren analiz sonuçlarından farklı olarak, önemli olayların gerçekleştiği 57 günlük kısa zaman dilimini içeren bu analizde R_d ve S_1 arasında çift yönlü ($R_d \leftrightarrow S_1$) bir nedenselliğin elde edildiği görülmüştür. Bunun sebebi “ R_d, S_1 ’in Granger nedenidir.” ve “ S_1, R_d ’nin Granger nedenidir.” sonuçlarının aynı anda kabul edilmesidir. Tablo 12’nin

Tablo 11. 57 işlem gününü içeren kısa dönem için gerçekleştirilen ADF testi sonuçları
(The results of ADF test for the short term that consists of 57 trading days)

	S_1		S_2		S_3		R_d	
	t istatistiği	Olasılık (p)	t istatistiği	Olasılık (p)	t istatistiği	Olasılık (p)	t istatistiği	Olasılık (p)
ADF Test İstatistiği	-5,176954	0,0001	-4,739455	0,0003	-8,254359	0,0000	-7,307557	0,0000
Test Kritik Değeri (%5)	-2,914517		-2,914517		-2,915522		-2,914517	

H_0 : S_1, S_2, S_3 ve R_d durağan değildir.

H_1 : S_1, S_2, S_3 ve R_d durağandır.

Tablo 12. 57 işlem gününü içeren kısa dönem için gerçekleştirilen Granger Analizi sonuçları
(The results of Granger causality test for the short term that consists of 57 trading days)

İnceleme Dönemi : 07.05.2018 – 31.07.2018

Sıfır Hipotezi (H_0)	Gecikme Sayısı	Gözlem Sayısı	F İstatistiği	Olasılık (p)	%5 Anlamlılık Düzeyinde Karar	Sonuç
R_d, S_1 ’in Granger nedeni değildir.	2	55	3,31268	0,0446	H_0 reddedilir.	R_d, S_1 ’in Granger nedenidir.
S_1, R_d ’nin Granger nedeni değildir.		55	3,98953	0,0247	H_0 reddedilir.	S_1, R_d ’nin Granger nedenidir.
R_d, S_2 ’nin Granger nedeni değildir.	2	55	3,00064	0,0588	H_0 kabul edilir.	R_d, S_2 ’nin Granger nedeni değildir.
S_2, R_d ’nin Granger nedeni değildir.		55	4,24328	0,0199	H_0 reddedilir.	S_2, R_d ’nin Granger nedenidir.
R_d, S_3 ’ün Granger nedeni değildir.	4	53	2,42516	0,0621	H_0 reddedilir.	R_d, S_3 ’ün Granger nedenidir.
S_3, R_d ’nin Granger nedeni değildir.		53	0,66780	0,6178	H_0 kabul edilir.	S_3, R_d ’nin Granger nedeni değildir.

H_0 : R_d, S_x ($x = 1,2,3$) duygu polarite değerinin Granger nedeni değildir.

H_1 : R_d, S_x ($x = 1,2,3$) duygu polarite değerinin Granger nedenidir.

üçüncü ve dördüncü satırındaki durumlar incelendiğinde “ R_d, S_2 ’nin Granger nedeni değildir.” ve “ S_2, R_d ’nin Granger nedenidir.” sonuçlarının ortaya çıktığı görülmüştür. Başka bir ifadeyle, $S_2 \rightarrow R_d$ yönünde tek taraflı bir nedenselliğin varlığı söz konusu olmuştur. Son olarak Tablo12’nin beşinci ve altıncı satırında ele alınan R_d ve S_3 duygu polarite değeri arasındaki Granger nedenselliği yorumlandığında, zamana bağlı olan bu iki değişken arasında sadece $R_d \rightarrow S_3$ yönünde tek taraflı bir nedensellik ilişkisi oluştuğu görülmüştür. Bu sonuca “ R_d, S_3 ’ün Granger nedenidir.” ve “ S_3, R_d ’nin Granger nedeni değildir.” sonuçlarından ötürü ulaşılabilmektedir.

6. SONUÇLAR VE TARTIŞMALAR (RESULTS AND DISCUSSIONS)

6.1. Sonuçlar (Results)

Bu çalışmanın temel amacı, Bist30 endeksiyle ilgili olan Twitter kısa iletilerinden elde edilen üç farklı duygu polarite değeri ile endeksin günlük değer değişimleri arasındaki korelasyon ve Granger nedensellik ilişkilerinin araştırılmasıdır. Böylece sosyal medyanın Türk finansal piyasalarının hareket yönünün değerlendirilmesinde bir kaynak olarak kullanılıp kullanılmayacağı görülebilecektir. Bu amaçla, çalışmanın gerçekleştirildiği 07.05.2018 - 30.04.2019 tarih aralığında paylaşılan olumlu, olumsuz ve nötr olarak etiketlenmiş 57933 kısa iletiyi içeren bir eğitim veri kümesi; aynı döneme ait 200 bin kısa iletiyi içeren etiketsiz bir test veri kümesi ve Bist30 endeksi günlük değer değişimleri kullanılmıştır. Belirtilen üç farklı duygu polarite değerinin elde edilebilmesi için metinsel veriler üzerinde duygu analizi gerçekleştirilmiştir. Bu doğrultuda, kısa iletilerin vektörler ile ifade edilebilmesi için kelime tabanlı n-gramlar, tf-idf kelime ağırlığı ölçümü ve YSA’ya dayalı Doc2Vec mimarisi kullanılmıştır. Çalışmamızda YSA’lara dayalı bir metodun kullanılma sebebi teknolojik gelişmeler ile YSA’lara dayalı olan metodların daha verimli sonuçlar üretmesi ve Türkçe veriler üzerinde sıklıkla kullanılmasıdır [37, 38]. Ayrıca çalışmamız kapsamında Doc2Vec mimarisinin başarımlarını arttırmak adına bir öneri sunulmuş ve bu öneri ile metodun daha iyi bir başarımlarını sergilediği gösterilmiştir. Kısa iletilerin olumlu, olumsuz ve nötr olarak sınıflandırılması için LR, DVM, NB, KA, EKK bireysel sınıflandırıcıları ve MO topluluk öğrenmesi metodu kullanılmıştır. Eğitim veri kümesinin duygu analizinde, 2-gram’ların ve tf-idf kelime ağırlığının kullanılmasıyla en yüksek başarımlarına sahip olan sınıflandırma algoritmasının LR olduğu görülmüştür. En iyi başarımlarına sahip LR sınıflandırıcısının kullanılmasıyla, test veri kümesi olumlu, olumsuz ve nötr olarak sınıflandırılmıştır. Test veri kümesinin sınıflandırılmasıyla olumlu ve olumsuz sınıflardaki kısa ileti sayılarına bağlı olarak üç farklı duygu polarite değeri elde edilmiştir. Elde edilen duygu polarite değerleri Twitter’da Bist30 şirketleriyle ilgili olan Türkçe kısa ileti kaynaklarıyla, endeksin günlük değer değişimleri arasında bir ilişki olup olmadığını göstermek için kullanılmıştır. Çalışmamızda analizler iki farklı zaman dilimi için gerçekleştirilmiştir. Analizlerden ilki bir yıllık bir zaman dilimini ele alırken,

diğeri ülkemiz için Cumhurbaşkanlığı seçimi ve kabine değişikliği gibi önemli olayların gerçekleştiği 3 aylık bir zaman dilimini ele almaktadır. Elde edilen korelasyon ve Granger nedensellik ilişkisi sonuçları aşağıda belirtilmiştir:

- Korelasyon analizi sonuçlarına göre, hem uzun dönem, hem de kısa dönem için gerçekleştirilen analizlerde, sosyal medyada paylaşılan kısa iletilerden elde edilen duygu polarite değerleri ve Bist30 endeksi hisselerinin günlük değer değişimleri arasında orta düzeyde ve pozitif yönde bir korelasyon ilişkisi ortaya çıkmıştır.
- Granger nedensellik analizi sonuçlarına göre ise, uzun dönem için gerçekleştirilen analizlerde endeksin değer değişimini ifade eden R_d değerinden duygu polarite değerlerine doğru tek yönlü bir Granger nedenselliği ortaya çıkmıştır. Diğer bir ifadeyle, sadece $R_d \rightarrow S_1, R_d \rightarrow S_2, R_d \rightarrow S_3$ Granger nedensellik ilişkilerine rastlanmıştır. Bu sonuçlardan yola çıkarak, hisse senedi piyasalarındaki hareketliliğin insanların duygu değerlerindeki değişimi desteklediğini söylemek mümkün olmuştur. Öte yandan, S_1, S_2, S_3 duygu polarite değerlerinden endeksin hareket yönünü ifade eden R_d değerine doğru herhangi bir Granger nedensellik ilişkisine rastlanmamıştır. Bu sonuca dayanarak, uzun dönem adına S_1, S_2, S_3 duygu değerlerine dayalı bir endeks hareketliliğinin mevcut olmadığı söylenebilir.
- Cumhurbaşkanlığı seçimi ve kabine değişikliği gibi önemli olayların meydana geldiği kısa dönem için gerçekleştirilen Granger nedensellik analizinde uzun dönem analizinden farklı sonuçlara ulaşılmıştır. Paylaşılan olumlu ve olumsuz kısa ileti sayılarının farkına dayalı olan S_1 duygu değeri ile R_d değeri arasında çift yönlü ($R_d \leftrightarrow S_1$) bir Granger nedenselliği görülmüştür. Araştırma sonucuna göre, endekste ki değer değişimi ile S_1 duygu polarite değerinin birbirini etkilediğini söylemek mümkün olmuştur. Olumlu ve olumsuz kısa ileti sayılarının oranına bağlı olan S_2 duygu değeri ile R_d arasında $S_2 \rightarrow R_d$ yönünde tek taraflı bir Granger nedenselliği ortaya çıkmıştır. Dolayısıyla S_2 duygu değerinin R_d değişikliklerini desteklediği söylenebilir. Son olarak, ardışık iki gün arasındaki olumlu kısa ileti sayılarının farkına dayalı olan S_3 duygu değeri ile R_d arasında, $R_d \rightarrow S_3$ yönünde tek taraflı bir nedensellik ilişkisi görülmüş; fakat $S_3 \rightarrow R_d$ yönünde bir nedensellik ilişkisine rastlanmamıştır. Yani endekste ki fiyat değişimleri S_3 duygu değerini etkilemiş; fakat S_3 duygu değeri R_d değer değişikliklerini desteklememiştir. Sonuç olarak, kısa dönem analizinde olumlu ve olumsuz kısa ileti sayılarının birlikte değerlendirildiği S_1 ve S_2 duygu polarite değerlerinin, endeks değerleri üzerindeki değişimleri desteklediğini söylemek mümkün olmuştur.

Elde edilen korelasyon ve Granger analizlerinin sonuçları, sosyal medyanın Türk finansal piyasalarının hareket yönünün değerlendirilmesinde bir kaynak olarak ele alınabileceğini göstermiştir. Uzun dönem için olmasa da, özellikle olağan dışı olayların gerçekleştiği bir kısa dönemde duygu polarite değerlerinin borsa değer değişimlerini desteklediği görülmüştür. İleriki çalışmalarda veri kümesi

genişletilerek bir borsa duygu sözlüğü oluşturulacak ve duygu değerleri endeksin tahminlenmesi aşamasında teknik bir gösterge olarak kullanılmaya çalışılacaktır.

6.2. Tartışmalar (Discussions)

Günümüzde bireysel yatırımcılar, yatırım kararlarını verirken bilimsel bulguların sunduğu analizlerin yanısıra sosyal medyanın yansıttığı durum algısını da yol gösterici bir kaynak olarak benimsemeye başlamıştır. Dünyada yatırımcıların finansal piyasalar hakkında yaratmış olduğu olumlu ya da olumsuz algıların finansal piyasalar üzerindeki etkilerini analiz eden pek çok çalışma mevcuttur. Sosyal medya ve finansal piyasalar arasındaki ilişkiyi analiz eden bu çalışmaların çoğu, duygu analizi, korelasyon analizi ve Granger nedensellik analizi gibi yöntemleri kullanmaktadır. Çalışmalarda genellikle kaynak olarak, son zamanların en popüler sosyal medya platformlarından biri olan Twitter'da paylaşılan kısa iletiler kullanılmıştır. Bu çalışmaların pek çoğunda, kısa iletilerin taşıdığı duygu durumlarıyla finansal piyasalar arasında anlamlı korelasyon ve Granger nedensellik ilişkilerinin varlığından söz edilmiştir. Bahsi geçen bu çalışmalar, çalışmamızın literatür taraması bölümünde ayrıntıyla ele alınmıştır.

Bu çalışma, sosyal medyada yaratılan olumlu/olumsuz duygu durumları ve Türk finansal piyasalarının hareketliliğini konu alan literatürü derinleştirmek ve bu değişkenler arasındaki korelasyon ve Granger nedensellik ilişkilerini araştırmak amacıyla gerçekleştirilmiştir. Dünya çapında sosyal medya ve finansal piyasaların karşılıklı etkileşimlerini inceleyen geniş bir literatür olmasına rağmen, Türkiye'de bu çalışmaların sayısı oldukça kısıtlıdır [6, 7]. Bu durum büyük ölçüde, kısa iletilerdeki olumlu ve olumsuz algıların daha hızlı bir şekilde belirlenebilmesini sağlayan açık kaynaklı bir borsa duygu sözlüğünün olmamasından kaynaklanmaktadır. Böyle bir duygu sözlüğünün bulunmamasından ötürü, bu çalışmada hem daha önce sunulan Türkçe çalışmalarda [6, 7], hem de dünya genelindeki pek çok çalışmada [20-22] esas alındığı gibi, borsa yatırımcılarının görüşlerine başvurularak insan gücüyle etiketlenmiş oldukça geniş bir eğitim veri kümesi yaratılmıştır. İleriki çalışmalar için hedef, yaratılan veri kümesinin daha da genişletilerek, bir borsa duygu sözlüğünün oluşturulması olacaktır.

Bu akademik çalışmanın katkısı dört ana başlık ile sunulabilir:

- Sosyal medya ile finansal piyasaların arasındaki ilişki ele alınırken, Türkçe kısa iletilerle çalışan diğer araştırmalara göre çok daha geniş bir veri kümesi üzerinde çalışılmıştır.
- Veri kümesinin sınıflandırılması aşamasında hem geleneksel kelime çantası modelleri, hem de son zamanların en popüler algoritmalarından olan YSA'lara dayalı Doc2Vec modeli kullanılmıştır. Doc2Vec modeli kullanılırken, Doc2Vec algoritmasının iki farklı öğrenme mimarisinden elde edilen kelime vektörlerinin birleştirilmesi önerilmiştir. Sonuçta, bu önerinin Doc2Vec metodunun başarımlarını arttırdığı gözlemlenmiştir.

- Çalışmamızdaki tüm analizler iki farklı dönem için gerçekleştirilmiştir. Olumlu ve olumsuz kısa iletilerin birlikte farklı şekillerde değerlendirildiği veya sadece olumlu kısa ileti sayılarının baz alınması ile oluşturulan 3 farklı duygu polarite değeri dikkate alınmıştır. Ele alınan her dönem için bu üç farklı duygu polarite değeri ve Bist30 endeksi günlük değer değişimleri üzerinde hem korelasyon, hem de Granger nedensellik analizi uygulanmıştır.
- Hem korelasyon, hem de Granger nedensellik analizi için gerekli olan tüm ekonometrik ve istatistiksel testler uygulanmıştır.

KAYNAKLAR (REFERENCES)

1. Symantech. Social Media Protection Flash Poll Global Results. http://www.symantec.com/about/news/release/article.js?p?prid=20110721_01. Yayın tarihi Temmuz 21, 2011. Erisim tarihi Mart, 20, 2019.
2. Liu, L. X., Ann E. S., Yong Z., The long-run role of the media: Evidence from initial public offerings, *Management Science*, 60 (8), 1945-1964, 2014.
3. Atan, S., Çınar, Y. Borsa İstanbul'da finansal haberler ile piyasa değeri ilişkisinin metin madenciligi ve duygu (sentiment) analizi ile incelenmesi, *Ankara Üniversitesi Sbf Dergisi*, 74 (1), 1-34, 2019.
4. Teti, E., Dallochio, M., Aniasi, A. The relationship between twitter and stock prices. Evidence from the US technology industry, *Technological Forecasting and Social Change*, 149 (119747), 1-9, 2019.
5. Sprenger T. O., Tumasjan A., Sandner P. G., Welpe, I. M., Tweets and trades: The information content of stock microblogs, *European Financial Management*, 20 (5), 926-957, 2014.
6. Eliaçık A. B., Erdogan N., Mikro Bloglardaki Finans Toplulukları için Kullanıcı Ağırlandirilmiş Duygu Analizi Yöntemi, *Ulusal Yazılım Mühendisliği Sempozyumu*, İzmir, 782-793, 2015.
7. Yildirim M., Yüksel C. A., Sosyal Medya ile Hisse Senedi Fiyatının Günlük Hareket Yönü Arasındaki İlişkinin İncelenmesi: Duygu Analizi Uygulaması. *Uluslararası İktisadi ve İdari İncelemeler Dergisi*, 22, 33-44, 2017.
8. Nielsen F., A new anew: evaluation of a word list for sentiment analysis in microblogs, In *The ESQ2011 Workshop on Making Sense of Microposts*, Heraklion, Crete, 93-98, 2011.
9. Wilson T., Wiebe J., Hofmann P., Recognizing contextual polarity in phrase-level sentiment analysis, in: *Proceedings of the Conference on Human Language Technology and Empirical Methods in Natural Language Processing-HLT*, 347-354, 2005.
10. Baccianella, S., Esuli, A., Sebastiani, F., Sentiwordnet 3.0: an enhanced lexical resource for sentiment analysis and opinion mining, In *LREC'10*, Valetta, 2200-2204, 2010.
11. Dehkharghani, R., Saygin, Y., Yanikoglu, B., Oflazer, K., SentiTurkNet: a Turkish polarity lexicon for

- sentiment analysis. *Language Resources and Evaluation*, 50 (3), 667-685, 2016.
12. Loughran, T. I. M., McDonald, B., When is a Liability not a Liability? Textual Analysis, Dictionaries, and 10-Ks. *Journal of Finance*, 66 (1), 35-65, 2011.
 13. Le Q., Mikolov T., Distributed representations of sentences and documents, In Proceedings of the 31st International Conference on Machine Learning, Pekin-Çin, 1188-1196, 21-22 Haziran, 2014.
 14. Granger, C. W. J., Investigating causal relations by econometric models and cross-spectral methods, *Econometrica*, 37 (3), 424-438, 1969.
 15. Bollen J., Mao H., Zeng X., Twitter mood predicts the stock market, *Journal of computational science*, 2 (1), 1-8, 2011.
 16. Mittal A., Goel A., Stock prediction using twitter sentiment analysis, Working Paper Stanford University, CS 229, 1-5, 2012.
 17. Smailovic, J., Grcar, M., Lavrac, N., Znidarsic, M. (2014), Stream-based active learning for sentiment analysis in the financial domain, *Information Sciences*, 285 (32), 181-203, 2014.
 18. Risius, M., Akolk, F., Beck, R., Differential emotions and the stock market—The case of company-specific trading, *European Conference on Trading on Twitter Information Systems*, Germany, Paper 147, 2015.
 19. Sul, H.K., Dennis, A.R., Yuan, L., Trading on twitter: using social media sentiment to predict stock returns, *Decision Sciences*, 48 (3), 454-488, 2017.
 20. Tabari, N., Biswas, P., Praneeth, B., Seyeditabari, A., Hadzikadic, M., Zadrozny, W., Causality analysis of twitter sentiments and stock market returns. In Proceedings of the First Workshop on Economics and Natural Language Processing, 11-19, 2018.
 21. Ranco G., Aleksovski D., Caldarelli G., Grcar M., Mozetic I., The effects of Twitter sentiment on stock price returns, *PloS one*, 10 (9), 1-21, 2015.
 22. Pagolu V. S., Reddy K. N., Panda G., Majhi B, Sentiment analysis of Twitter data for predicting stock market movements, In 2016 international conference on signal processing, communication, power and embedded system (SCOPEs), Paralakhemundi-Hindistan, 1345-1350, 3-5 Ekim, 2016.
 23. Zhang, W., Li, X., Shen, D., Teglio, A., Daily happiness and stock returns: some international evidence. *Phys. A Stat. Mech. Its Appl.* 460, 201-209, 2016.
 24. Deng S., Huang Z. J., Sinha A. P., Zhao H., The Interaction between Microblog Sentiment and Stock Return: An Empirical Examination, *MIS quarterly*, 42 (3), 895-918, 2018.
 25. Zhao R., Quantifying the correlation and prediction of daily happiness sentiment and stock return: The Case of Singapore, *Physica A: Statistical Mechanics and its Applications*, 533, 1-9, 2019.
 26. You, W., Guo, Y., Peng, C., Twitter's daily happiness sentiment and the predictability of stock returns, *Financ. Res. Lett.* 23, 58-64, 2017.
 27. Li, X., Shen, D., Xue, M., Zhang, W., Daily happiness and stock returns: the case of Chinese company listed in the United States, *Econ. Model.* 64, 496-501, 2017.
 28. Hu, M., Liu., B., Mining and summarizing customer reviews, Proceedings of the tenth ACM SIGKDD international conference on Knowledge discovery and data mining, 168-177, 2004.
 29. Snow, R., O Connor, B., Jurafsky, D., Ng, A., Labs, D., Capp St., Cheap and Fast But is it Good? Evaluating NonExpert Annotations for Natural Language Tasks, 254-263, 2008.
 30. Github. <https://github.com/SentimentAnalysisofBist30>, Erişim tarihi: Aralık, 27, 2020.
 31. Güven Z.A., Diri B., Çakaloğlu T., Comparison of n-stage Latent Dirichlet Allocation versus other topic modeling methods for emotion analysis, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 35 (4), 2135-2146, 2020.
 32. Mikolov T., Chen K., Corrado G., Dean J., Efficient estimation of word representations in vector space, Proceedings of Workshop at ICLR, Arizona-Amerika, 1-12, 2-4 Mayıs, 2013.
 33. Bonett D. G., Wright T. A., Sample size requirements for estimating Pearson, Kendall and Spearman correlations, *Psychometrika*, 65 (1), 23-28, 2000.
 34. Genceli M., Kolmogorov-Smirnov, Lilliefors and Shapiro-Wilk tests for normality, *Sigma Journal of Engineering and Natural Sciences*, 25 (4), 306-328, 2007.
 35. IBM SPSS yazılımı. <https://www.ibm.com/tr-tr/analytics/spss-statistics-software>. Erişim tarihi: Haziran, 1, 2019.
 36. Cheung Y. W., Lai K. S., Lag order and critical values of the augmented Dickey-Fuller test, *Journal of Business & Economic Statistics*, 13 (3), 277-280, 1995.
 37. Işık G., Artuner H., Turkish dialect recognition in terms of prosodic by long short-term memory neural networks, *Journal of the Faculty of Engineering and Architecture of Gazi University* 35 (1), 213-224, 2020.
 38. Kilimeci Z.H., Financial sentiment analysis with Deep Ensemble Models (DEMs) for stock market prediction, *Journal of the*

