

EMTİA PİYASALARININ BİRLİKTE HAREKETLERİNİN VERİ MADENCİLİĞİ İLE İNCELENMESİ

An Investigation of Co-movements of Commodity Markets by Data Mining

Binali Selman EREN*

Öz

Emtialar, yatırımları çeşitlendirmek ve enflasyona karşı korunmak için alternatif bir yol olarak görülmüştür. Bu nedenle yatırımcıların bir piyasanın düşüşü veya yükselişi sonrasında diğer piyasaların veya finansal varlıkların hangi yöne doğru hareket edeceğini öngörmesi, hızlı ve etkili kararlar almasında kritik öneme sahiptir. Bu çalışmada, emtia piyasalarının birlikte hareketi veri madenciliğinde yer alan birliktelik kuralı ile analiz edilmiştir. Bu doğrultuda çalışmada 20 adet emtianın 01.01.2010-01.08.2023 tarihleri arasındaki 3216 işlem günündeki birlikte hareketleri analiz edilmiştir. Çalışmada birliktelik kuralı analizleri, Apriori ve FP-Growth algoritmaları kullanılarak gerçekleştirilmiştir. Hem Apriori hem de FP-Growth algoritmaları ile üretilen birliktelik kurallarının tümünde Brent petrolün diğer emtialara eşlik ettiği gözlemlenmiştir. Bu sonuç, Brent petrol fiyatlarının yukarı veya aşağı yönde hareketinin, Brent petrol fiyatlarını yakından takip eden yatırımcılara, karar vericilere ve politika yapıcılara, diğer emtiaların hareketi ile ilgili yol gösterici olabileceğini göstermektedir. Petrolün ekonomik sistemi etkileyen stratejik bir enerji kaynağı olduğu gerçeği göz önüne alındığında, bu sonucun şaşırtıcı olmadığı ifade edilebilir.

Anahtar Kelimeler:

Emtia,
Emtia Piyasaları,
Veri Madenciliği,
Birliktelik Kuralı

JEL Kodları:

Q02, G15, C80

Abstract

Commodities have been seen as an alternative way to diversify investments and protect against inflation. As a result, it is critically important for investors to predict the direction in which other stock exchanges or financial assets will move after a stock market's rise or fall in order to make quick and effective decisions. In this study, the co-movement of commodity markets are analyzed with the association rule in data mining. In this direction, the movements of 20 commodities in 3216 trading days between 01.01.2010 and 01.08.2023 are analyzed in the study. Association rule analyses in the study are conducted using the Apriori and FP-Growth algorithms. It is observed that Brent crude oil accompanied other commodities in all association rules generated by both the Apriori and FP-Growth algorithms. This result suggests that the upward or downward movement of Brent oil prices may provide guidance to investors, decision makers and policymakers who closely follow Brent oil prices regarding the movement of other commodities. Considering the fact that oil is a strategic energy source that affects the economic system, this result is not surprising.

Keywords:

Commodity,
Commodity Markets,
Data mining,
Association Rule

JEL Codes:

Q02, G15, C80

*Dr. Öğr. Üyesi, Bitlis Eren Üniversitesi, Tatvan MYO, Türkiye, binaliselmaneren@gmail.com

Makale Geliş Tarihi (Received Date): 02.01.2024 Makale Kabul Tarihi (Accepted Date): 25.03.2024

Bu eser Creative Commons Atıf 4.0 Uluslararası Lisansı ile lisanslanmıştır.



1. Giriş

Emtia piyasaları, paranın icadından önceki zamanlara kadar uzanan ve insanların mal alışverişlerinde kullandığı temel piyasalardan biridir. Günümüzde ise emtia piyasaları, modern ekonomide çok önemli rol oynayan olgun ve son derece gelişmiş piyasalardır. Emtialar küresel ekonomide kilit bir rol oynamakta ve dünyanın dört bir yanındaki ulusları birbirine bağlamaktadır (Kirikkaleli ve Güngör, 2021). Küresel ekonomide ve finans dünyasında merkezi bir role sahip olan emtialar hem gelişmiş hem de gelişmekte olan ekonomilerin endüstriyel süreçleri için de vazgeçilmez varlıklardır. Dolayısıyla emtialar ekonomik büyüme ve kalkınmaya büyük katkı sağlamaktadırlar. Özellikle ham petrol, çeşitli emtia piyasalarını etkilediği için en stratejik emtia olarak kabul edilmektedir. Ayrıca ham petrol vadeli işlemleri ve diğer fosil enerji piyasaları 1970’lerde popülerlik kazanarak emtiaları yalnızca endüstriyel girdiler ve ticari varlıklardan finansal araçlara dönüştürmüştür. Bunun yanı sıra altın gibi değerli metallerin siyasi ve ekonomik istikrarsızlık dönemlerinde güvenli liman olarak görülmesi ve platin, gümüş ve paladyumun da endüstriyel üretimde önemli bir girdi olması, finansal piyasalarda yatırımcılar tarafından giderek daha fazla ilgi görmesine neden olmuştur. Benzer şekilde tarımsal emtialar (buğday gibi) da devam eden Rusya-Ukrayna savaşı ve iklim değişikliği gibi olumsuz koşullarından etkilendiğinden yatırımcılar tarafından yakından takip edilmektedir. Örneğin, buğdayın birim fiyatı Ocak 2000’de 107 dolardan işlem görmeye başlamış ve Aralık 2011’de maksimum 306 dolara ulaşmıştır. Brent petrol fiyatları da benzer bir davranış sergileyerek Ocak 2000’de varil başına 23.95 dolardan işlem görmüş ve Aralık 2011’de varil başına 108.09 dolara ulaşmıştır. Bu gelişmelerle birlikte emtia piyasalarına yapılan yatırımların miktarında yaşanan muazzam artış, emtia piyasalarının finansallaşmasını hızlandırmıştır (Cheng ve Xiong, 2014; Ohashi ve Okimoto, 2016; Mensi vd., 2017; Chalid ve Handika, 2022; Umar vd., 2022). Öyle ki, vadeli Emtia İşlemleri Komisyonu’nun raporuna göre (CFTC, 2008) 2000 yılı başından 2008 yılına kadar olan dönemde vadeli emtia endeksine yapılan yatırımın miktarı 200 milyar ABD dolarını aşmıştır (Cheng ve Xiong, 2014). Benzer şekilde Barclays Capital’in 250’den fazla kurumsal yatırımcıyla yaptığı ankete göre, emtia piyasalarındaki kurumsal yatırımlar 2003 yılında 18 milyar dolarken; 2010 yılında bu rakam 250 milyar dolar seviyesine yükselmiştir (Basu ve Miffre, 2013). Emtia piyasalarının son otuz yılda büyük bir artış göstermesiyle ABD emtia vadeli işlem piyasaları 1990’dan 2019 yılına kadar toplam işlem hacmi 14.1 trilyon dolar seviyesine yükselmiştir. 2021 yılında ise ABD emtia vadeli işlem piyasasının hacmi 40.6 trilyon dolar seviyesine ulaşmıştır. Bu rakam ABD borsasının 2021 yılındaki toplam işlem hacminin yaklaşık yarısına eşittir. Emtia piyasalarının öneminin artmasıyla, özellikle hedge fonları, Emtia Ticaret Danışmanları (CTA) ve emeklilik fonları gibi kurumsal yatırımcılardan emtia vadeli işlem piyasalarına büyük sermaye girişleri olmuştur (Kang vd., 2023). Buradan hareketle günümüzde, emtia piyasalarının alternatif bir yatırım alanına dönüştüğü sonucuna varılabilir (Vivian ve Wohar, 2012; Algieri ve Leccadito, 2017).

Vadeli emtia piyasalarının finansallaşmasıyla birlikte emtialar, hisse senetleri ve tahviller gibi geleneksel varlıkların yanında ayrı bir varlık sınıfı olarak ortaya çıkmış ve emtia endekslerine yapılan yatırımların artmasıyla ve sundukları çeşitlendirme fırsatları nedeniyle küresel yatırımcıların ilgisini daha çok çekmeye başlamışlardır (Matesanz vd., 2014; Ohashi ve Okimoto, 2016; Rehman vd., 2019; Abid vd., 2020). Dolayısıyla emtialar, yatırımları çeşitlendirmek ve enflasyona karşı korunmak için alternatif bir yol olarak görülmektedir (Matesanz vd., 2014; Mbarki vd., 2023). Özellikle enflasyonun yükseldiği dönemlerde, hisse senetleri ve tahviller gibi geleneksel varlık kategorileri zayıflayabilmekte ve düşük performans gösterebilmektedirler. Buna

karřın emtialar bu dnemelerde genellikle iyi performans gstermektedirler (Liu vd., 2023). Mal ve hizmetlere ynelik artan talep genellikle mal ve hizmetlerin retiminde kullanılan emtialara ynelik talebi artırmaktadır. Diđer bir ifadeyle, bir yatırım portfynde emtia bulundurmak, kısmen emtia vadeli iřlem pozisyonunun bir enflasyon koruması olmasından kaynaklanan risk azaltıcı bir etkiye sahiptir (Stoll ve Whaley, 2010).

Emtia fiyatlarındaki deęiřiklikler potansiyel olarak hem politika yapıcıları hem de ticari yatırımcıları etkileyebilmektedir. Finansallařma ile birlikte, emtiaların fiyatları birbirini etkilemeye bařlamıřtır. zellikle petrol fiyatlarının artıřı, tarımsal emtia fiyatlarındaki artıřa neden olmaktadır (Nazlıođlu and Soytaş, 2011; Ji ve Fan, 2012; Wang vd., 2014). rneđin artan petrol fiyatları, insanları nemli tarımsal rnler olarak kabul edilen mısır ve soyadan elde edilen biyo-yakıtlar gibi alternatif enerji kaynakları geliřtirmeye zorlamıřtır (Frankel ve Rose, 2010; Gilbert, 2010; Vacha vd., 2013). Dolayısıyla, ham petrol, deđerli metaller ve tarımsal emtiaların zaman iinde birlikte hareket edip etmediklerini ve aralarındaki iliřkileri anlamak yatırımcılara optimal yatırım kararları vermesinde ve politika yapıcılara da stratejik hamleler yapmak iin fayda sađlayabilir. rneđin birok alıřmada, hisse senedi piyasaları arasındaki daha yksek birlikte hareketin, zellikle yksek volatilitte dnemlerinde, hisse senedi yatırımdan elde edilen eřitlendirme faydalarının azalmasına yol atıđını gstermektedir (Diamandis, 2009; Singhal, vd., 2019; Patel, 2019; Inaba, 2020; Heil vd., 2022; Lee ve Lee, 2023). Bu da yatırımcıların yatırım portfylerini eřitlendirmek iin yeni yollar bulmalarına neden olmaktadır. Emtiaları ynlendiren faktrler (dođal evre ve hava kořulları gibi) geleneksel varlıkları belirleyen baskın faktrlerden farklı olduđundan, emtia rnleri hisse senetleri, tahviller ve para birimleri gibi finansal varlıklar iin iyi bir eřitlendirme aracı olarak grlmektedir (Daskalaki ve Skiadopoulos, 2011; Arouri vd., 2013). Dolayısıyla emtialara yatırım yapmak, riski daha da eřitlendirmenin ve enflasyona karřı korunmanın bir yolu olarak kabul edilmektedir. Bu nedenle, emtia piyasaları arasındaki birlikte hareketleri analiz etmek, modern finansın nemli grdđ bir konudur nk trev fiyatlandırma, portfy optimizasyonu, risk ynetimi ve sr davranıřı iin emtiaların birlikte hareketlerinin etkili bir şekilde arařtırılması yatırımcılar ve politika yapıcılar iin olduka faydalı bilgiler ortaya ıkarmaktadır. zellikle uluslararası finans piyasalarının derinleřmesi ve entegrasyonu, kresel borsa endekslerinin birlikte hareket etmesini artırmaktadır. Dolayısıyla yatırımcıların bir borsanın dřuřu veya ykseliři sonrasında diđer borsaların veya finansal varlıkların hangi yne dođru hareket edeceđini ngrmesi, hızlı ve etkili kararlar almasında kritik neme sahiptir. Buradan hareketle bu alıřmanın amacı, emtia piyasalarının birlikte hareketini arařtırmaktır. Bu kapsamda alıřmada emtia piyasalarının birlikte hareketi, veri madenciliđinde tanımlayıcı modeller sınıfında yer alan birliktelik kuralı analizi tekniklerinden Apriori ve FP (Frequent Pattern)-Growth algoritmaları kullanılarak incelenmiřtir. alıřmanın veri seti yedi deđerli metal, beř bitki, drt hububat,  enerji ve bir et emtiası olmak zere toplam 20 emtia fiyatından oluřmaktadır. alıřmanın veri seti 01.01.2010-01.08.2023 tarihleri arasındaki 20 farklı vadeli emtia fiyatının gnlk kapanıř fiyatını kapsamaktadır. Bunun sonucunda analiz iin toplam 3216 iřlem gn dikkate alınmıřtır. alıřmanın yapıldıđı dnem itibariyle, bu alıřma, bilindiđi kadarıyla, emtia piyasalarının birlikte hareketini veri madenciliđi yntemlerinden birliktelik kuralı analizine gre inceleyen ilk alıřma zelliđini tařımaktadır. Bu bakımdan alıřmanın zellikle literatrdeki eksikliđe katkı sađlayacađı dřnlmektedir. Emtia piyasalarının birlikte hareketleri literatrde birok farklı yntemle arařtırıldıđı geređi gz nne alındıđında, bu alıřmada kullanılan birliktelik kuralı analizinin literatr zenginleřtireceđi dřnlmektedir. alıřmanın literatre bir diđer katkısı ise, birliktelik kuralı algoritmalarından

Apriori ve FP-Growth algoritmalarının ürettiği kuralların karşılaştırmasına olanak vermesidir. Bu doğrultuda analiz sonuçları hem Apriori hem de FP-Growth algoritmalarının birbirlerini destekler nitelikte kurallar ürettiğini göstermektedir.

2. Literatür

Veri madenciliği uygulamalarından birliktelik kuralı analizi ile ilgili literatür birçok farklı disiplinden çalışmanın yapılmasından dolayı her geçen gün zenginleşmektedir. Bu bölümde, veri madenciliği ile birliktelik kuralı analizi yöntemini sermaye piyasaları üzerine ele alan araştırmalara yer verilmiştir.

Yang vd. (2006) tarafından yapılan çalışmada Tayvan borsası elektrik endeksinde işlem gören hisse senetlerinin birlikte hareketleri veri madenciliği uygulamalarından birliktelik kuralına göre analiz edilmiştir. Çalışmanın verileri 1971-2005 yılları arasındaki döneme kadar olan günlük verilerden oluşmaktadır. Çalışmanın sonuçları, analiz edilen hisse senetleri arasından yukarı ve aşağı yönlü nedensel ilişkinin var olduğunu göstermektedir.

Liao vd. (2008) iki aşamalı bir veri madenciliği kullanarak Tayvan borsasındaki yatırım sorunlarını araştırmışlardır. Çalışmanın ilk aşamasında birliktelik kurallarından Apriori algoritmasını kullanarak hisse senetleri arasında birlikte hareketi incelenmiştir. İkinci aşamada ise K-Means algoritması ile bir kümeleme analizi yapmışlardır. Çalışma sonuçları, Tayvan borsası için yatırımcılara farklı koşullar altında alternatif portföyler önermektedir.

Liao vd. (2011) çalışmalarında Tayvan borsası ile 13 farklı döviz kuru arasındaki ilişki veri madenciliği uygulamalarından birliktelik kuralı ile analiz etmişlerdir. Çalışmada birliktelik analizi için Apriori algoritması tercih edilmiştir. Çalışma verileri Haziran 2006 ile Aralık 2008 arasındaki 138 günlük işlem gününü kapsamaktadır. Çalışmanın sonuçları, Tayvan sermaye piyasasında farklı koşullar altında döviz kurları ve hisse senedi yatırımı dahil olmak üzere çeşitli olası portföy alternatifleri önermektedir.

Srisawat (2011) Tayland Borsasında hisse senetleri arasındaki birlikte hareketi veri madenciliği ile analiz etmişlerdir. Çalışmanın verisi 4 Ocak 2010 ile 30 Aralık 2010 tarihleri arasındaki 242 işlem gününden oluşmaktadır. Birliktelik kurallarından elde edilen sonuçlar, ilgili bireysel hisse senetlerinin trendlerini ortaya çıkarmıştır. Ayrıca, bu kurallar yeni başlayan hisse senedi yatırımcılarının daha fazla analiz için ilginç hisse senetlerini önceden seçmelerine yardımcı olabilir.

Na ve Sohn (2011) tarafından yapılan çalışmada Kore, ABD, Japonya, Çin, Tayvan, Hong Kong, İngiltere, Fransa ve Almanya'nın borsa endekslerinin birlikte hareketlerini analiz edilmiştir. Çalışmada veri madenciliği birliktelik analiz için apriori algoritması kullanılmıştır. Çalışmada veriler Ocak 2006 ile Aralık 2008 arasındaki dönemi kapsamaktadır. Çalışmanın sonuçlarına göre, KOSPI endeksi, ABD ve Avrupa'daki borsa endeksleriyle aynı yönde hareket etme eğilimindeyken, Kore ile rekabet ilişkisi içinde olan Hong Kong ve Japonya gibi diğer Doğu Asya ülkelerindeki endekslerle ters yönde hareket etmektedir.

Argiddi ve Apte (2012) Hindistan Bilgi Teknolojileri endeksinde hisse senedi değişimi için birliktelik kuralını kullanmışlardır. Çalışmada analizler için iki farklı birliktelik kuralı algoritması kullanılmıştır. Analiz sonuçları Apriori algoritmasının FITI (First Intra then Inter) algoritmasına kıyasla daha doğru sonuçlar ürettiğini göstermektedir.

Ho vd. (2012) 2006-2010 yılları arasında Asya'nın en büyük ikinci borsası olan Hong Kong Borsasının dięer makroekonomik göstergeleriyle iliřkisini veri madencilięi birliktelik kuralına gre incelemiřlerdir. alıřmanın sonuları, dviz kuru ve ihracat deęer artıřının Hong Kong endeksinin deęiřimini byk lde artırdıęını gstermektedir. Benzer Őekilde dviz kuru, ihracat deęeri ve GSYH'deki artıř da Ha Hong Kong Endeksi'nin deęiřimini yksek oranda artırmaktadır.

Liao ve Chou (2013) birliktelik kuralları ve kmeleme analizini ieren bir veri madencilięi yaklařımı kullanarak Tayvan ve in (Hong Kong) hisse senedi piyasalarındaki ortak hareketleri arařtırmıřlardır. Ekonomik İřbirlięi ereve Anlařması'nın (ECFA) uygulandıęı dnem boyunca hisse senedi endekslerinin birlikte hareketleri iin 30 hisse senedi zerinde incelenmiřtir. alıřmanın sonuları bazı hisse senetlerinin aynı anda birlikte ykseldięini veya dřtęn ya da i veya dıř ekonomik, sosyal ve politik durumlardan karřılıklı olarak etkilendięini gstermektedir.

Paranjape-Voditel ve Deshpande (2013) hisse senedi verilerini analiz eden ve sıralı bir hisse senedi sepeti neren birliktelik kuralı madencilięine (ARM) dayalı bir borsa portfy tavsiye sistemi nermiřlerdir. Bu amala yazarlar ARM tekniklerini, geleneksel ARM'nin dezavantajlarının stesinden gelmek iin tematik sektrlerin oluřturulması, sektrler arası ve sektr ii kuralların kullanılması gibi alana zg tekniklerle zenginleřtirmiřlerdir. alıřmada BSE-30, S&P CNX-100, CNX-50 veya NSE-50 ve DOW-30 endeksler incelenmiřtir. alıřmanın sonuları BSE-30 (Hindistan) endeksinde sonuların Hindistan'daki ilk 5 yatırım fonu sonularına gre getirilerinin olduka iyi olduęunu gstermektedir. Oluřturulan sistemin sonuları, tm veri kmeleri iin yatırım fonlarından elde edilen sonuları geride bırakmıřtır.

Arafah ve Mukhlash (2015) Endonezya'da Jakarta Bileřik Endeksinde (JCI) yer alan 10 hisse senedinin 2010-2014 yılları arasındaki iliřkiyi bulanık birliktelik kuralı madencilięi algoritmasını kullanarak arařtırmıřlardır. alıřmada Apriori algoritması ile hisse senetleri arasında gl birliktelik kuralları elde edilmiřtir.

Prasanna ve Ezhilmaran (2016) geliřtirilmiř apriori algoritması ve modifiye GA kullanarak borsa tahminine yardımcı olacak optimum hisse senedi kuralları oluřturmak iin yeni bir yaklařım geliřtirmiřlerdir. Hisse senedi tahmin sonuları, geliřtirilmiř apriori ve modifiye GA algoritması tarafından seilen kuralların, genel apriori ve GA ile elde edilenlerden daha etkili ve gvenilir olduęunu gstermektedir.

Jalpa ve Rustom (2017) alıřmalarında Hindistan borsasında iřlem gren 1250 hisse senedinin 1 Ocak 2010 ile 30 Eyll 2016 tarihleri arasındaki dnemde verileri veri madencilięi ile birlikte hareketlerini analiz etmiřlerdir. alıřmada birliktelik analizleri iin Apriori ve FP-Growth algoritmaları birleřtiren hibrit bir yaklařım tercih edilmiřtir. Analiz sonuları, FP-Growth algoritmasıyla elde edilen birliktelik kurallarının Apriori algoritmasına gre daha olumlu sonular verdięini gstermektedir.

Masum (2019) alıřmasında, Tahran borsasında iřlem gren 36 Őirketin hisse senetlerinin birlikte hareketini incelemiřtir. alıřmada 2000-2013 yılları arasında veriler kmeleme ve birliktelik kuralı yoluyla incelenmiřtir. Toplam 249.061 gzlem deęerlendirilmiř ve sonular yatırımcılar iin eřitli kurallar ve neriler ortaya koymuřtur. Sonular  ve drt maddede % 81'in zerinde gven (Confidence) deęerine, %1'in zerinde destek (support) deęerine ve ikinin zerinde ilgi (lift) deęerine sahip birliktelik kuralları tespit edilmiřtir.

Memiş ve Kaya (2019) çalışmalarında BIST100 endeksinde yer alan 87 farklı hisse senedinin 21.10.2013 ile 19.10.2018 tarihleri arasında günlük verileri dikkate alarak veri madenciliği uygulamasından Apriori algoritması ile birliktelik analizi gerçekleştirmişlerdir. Analiz sonuçları, hisse senetleri arasında güçlü ilişkiler olduğunu göstermiştir. Ayrıca sektörel bazlı hisse senetlerinin daha fazla birlikte hareket ettiği sonucuna varılmıştır.

Ünsal (2020) çalışmasında Borsa İstanbul’da işlem gören 408 pay senedinin 2019 yılı 249 işlem günü için veri madenciliği uygulamalarında öncelikle K-Means algoritması ile kümeleme analizi yapılmış ve sonrasında elde edilen kümelere Apriori algoritması ile birliktelik analizi yapılmıştır. Analiz sonuçları, 249 işlem gününde EUYO, DYOBY paylarının 188 kez beraber aynı kümede yer aldığı ve NETAS payının da bu iki pay senedi ile beraber görüldüğü kümelere 172 kez yer aldığı görülmüştür.

Kocabıyık vd. (2021) tarafından yapılan çalışmada 30 farklı Borsa İstanbul Endeksinin birlikte hareketini veri madenciliği FP-Growth Algoritması ile analiz edilmiştir. Çalışma 4.11.2014-12.03.2021 tarihleri arasındaki 1601 işlem gününden oluşmaktadır. Çalışma iki grup veri setiyle analiz edilmiştir. İlk olarak BIST30 endeksinin tamamı analiz edilmiştir. Bulgulara göre XU030, XUTUM, XU100, XUSRD, XUMAL, XBANK ve XKURY endekslerinin önemli birlikte hareket ettiği gözlemlenmiştir. İkinci aşamada sektör endeksleri üzerine bir analiz gerçekleştirilmiştir. Burada XBANK ve XUMAL endeksleri arasında önemli birlikte hareket gözlemlenmiştir.

Hernández vd. (2021) çalışmalarında kripto paraların birlikte hareketlerini veri madenciliği yöntemi ile analiz etmişlerdir. Çalışmada analiz kapsamına 131 kripto para alınmıştır. Çalışmanın verileri 01/12/2019-05/07/2020 tarihleri arasında kapsamaktadır. Çalışmada birliktelik analiz için Apriori algoritması tercih edilmiştir. Analiz sonuçlarına göre, kripto paralar arasında birçok birliktelik kuralı tespit edilmiştir.

Karaatlı vd. (2021) portföy oluşturmak amacıyla BIST 30 endeksinde payların makro ekonomik değişkenler (M1 para arzı, altın ons fiyatı, ihracatın ithalatı karşılama oranı, sanayi üretim endeksi, döviz sepeti, imalat sanayi kapasite kullanım oranı, faiz, üretici fiyat endeksi, finansal hizmetler güven endeksi, uluslararası doğrudan yatırımlar, ham petrol, S&P 500 endeksi) ile birlikte hareketini analiz etmek için FP-Growth algoritmasından yararlanılmıştır. Çalışmanın veri seti 2014-2019 yılları arasında kapsamaktadır. Çalışmanın sonuçları yatırımcıların hangi yatırım araçlarına yatırım yapabileceği ve BIST 30 endeksinde yer alan paylardan bankacılık endeks paylarının yüksek oranda birlikte hareket ettiği sonucunu ortaya koymaktadır.

Kartal vd. (2022) çalışmalarında dünyadaki 11 borsa endeksinin 2001-2009 yılları arasındaki birlikte hareketlerini veri madenciliği yöntemlerinde birliktelik kuralı algoritmasıyla analiz etmişlerdir. Bulgular, birliktelik kuralları arasında en yüksek güven seviyesinde ABD borsa endekslerinin yer aldığı görülmüştür. Bunun yanı sıra BIST 100 endeksinin hem Avrupa borsa endeksleri hem de ABD borsa endeksleri ile ortak hareket ettiği gözlemlenmiştir. Ayrıca Hang Seng Endeksinin (HSI) (Hong Kong) tüm borsa endekslerinin birliktelik kurallarında yer aldığı görülmüştür.

Kaur ve Dharni (2022) analiz için MSCI (Morgan Stanley Capital International) piyasa sınıflandırmasına göre gelişmiş piyasalar (Japonya, Birleşik Krallık ve Amerika Birleşik Devletleri) ve gelişmekte olan piyasalardan (Güney Afrika, Hindistan, Brezilya ve Çin) oluşan yedi ülke seçmişlerdir. Veriler 1 Nisan 2005 ile 31 Mart 2017 tarihleri arasındaki on iki yıllık

dönemi kapsamaktadır. Çalışmada birliktelik analizi apriori algoritması ile uygulanmıştır. Çalışmanın bulguları, dünya genelindeki yedi hisse senedi endeksinin tamamı için al ve tut getirilerine kıyasla birliktelik kurallarına dayalı getirilerin önemli ölçüde daha yüksek olduğunu göstermektedir. Birliktelik kuralları, seçilen yedi endeksin tümü için karlılığı göz önüne alındığında, hisse senedi getirisini tahmin etmede daha verimli olduğunu göstermektedir.

Teker ve Konuşkan (2022) çalışmalarında futbol kulüpleri tarafından çıkarılan kripto paralarının birlikte hareketlerini veri madenciliği uygulamalarından birliktelik analizi ile incelemiştir. Çalışmanın verisi 01.01.2022-01.08.2022 tarihlerini kapsamaktadır. Birliktelik analizi için FP-Growth algoritması tercih edilmiştir. Çalışmanın sonuçları Trabzonspor, Lazio ve Porto takımlarının kripto paralarının en sık birlikte hareket ettiğini göstermektedir. Ayrıca Fenerbahçe, İstanbul Başakşehir ve Göztepe spor kulüplerinin kripto paraları en az birlikte hareket ettiği gözlemlenmiştir.

3. Veri Madenciliği

Son yıllarda hem veri üretme hem de veri toplama kapasitesi çok hızlı bir şekilde artmaktadır. Özellikle çoğu iş ve devlet işleminin dijital ortama aktarılması ve veri toplama araçlarındaki gelişmeler, çok büyük miktarda verinin ortaya çıkmasına neden olmuştur. Günümüzde veri ve veri tabanlarındaki hızlı büyüme, işlenen verilerin faydalı bilgi ve enformasyona dönüştürebilecek yeni teknik ve araçlara ihtiyaç doğurmaktadır. Bu durum, veri madenciliğini giderek daha da önemli bir araştırma alanı haline getirmektedir (Chen vd., 1996: 866).

Birçok farklı disiplinde uygulama alanı bulan veri madenciliği, farklı şekillerde tanımlanmaktadır. En genel anlamda ise veri madenciliği, veri tabanlarındaki verilerden (data) örtük, önceden bilinmeyen ve potansiyel olarak yararlı bilgilerin (knowledge) ortaya çıkarılmasını ifade etmektedir (Chen vd., 1996: 866). Veri madenciliği yaygın olarak birçok arařtırmacı tarafından veri aracılığıyla faydalı bilginin keşfedilmesi olarak tanımlanmakta iken, bazıları tarafından ise faydalı bilginin ortaya çıkarılmasında önemli bir adım olarak görülmektedir. Özellikle iş dünyasında kurumsal ve müşteri verileri stratejik bir varlık olarak kabul edilmektedir. Bu verilerde saklı olan yararlı bilgilerin ortaya çıkarılması ve bu bilgilere göre hareket etme yeteneği, günümüzün rekabetçi dünyasında giderek daha önemli hale gelmektedir (Kantardzic, 2020: 2). Han vd. (2011) bilgi keşif sürecini yedi adımda açıklamaktadırlar;

1. Veri temizleme (tutarsız ve doğru olmayan verileri ortadan kaldırma aşaması),
2. Veri birleştirme (birden fazla veri kaynağının birleştirilmesi aşaması),
3. Veri seçimi (analiz göreviyle ilgili verilerin veri tabanından alındığı yer),
4. Veri dönüştürme (özet veya toplama işlemleri gerçekleştirilerek verilerin madenciliğe uygun formlara dönüştürüldüğü ve birleştirildiği aşama),
5. Veri madenciliği (veri kalıplarını çıkarmak için akıllı yöntemlerin uygulandığı önemli bir süreç)
6. Örüntü değerlendirme (Faydalı bilgiyi temsil eden önemli bilgi kalıplarının belirlendiği aşama),
7. Faydalı bilginin sunumu (ortaya çıkarılan bilgiyi kullanıcılara sunmak için görselleştirme ve bilgi temsil tekniklerinin kullanıldığı aşama).

Günümüzde veri madenciliği finans, pazarlama, sigortacılık, bankacılık, mühendislik, eğitim, sağlık vb. gibi birçok alanda kullanılmaktadır (Bramer, 2016). Uygulamada veri madenciliğinin tahminleyici ve tanımlayıcı olmak üzere iki temel modeli vardır (Dunham, 2006: 5; Kantardzic, 2020: 2). Tahminleyici modeller sınıflandırma, regresyon, zaman serisi analizleri kestirimden oluşmaktadır. Tanımlayıcı modeller ise kümeleme, özetleme, birliktelik kuralları ve dizi analizinden oluşmaktadır. Tahmine dayalı modeller, farklı verilerden bilinen sonuçları kullanarak veri değerleri hakkında tahmin yapmaya olanak tanır. Tahmine dayalı modelleme diğer tarihsel verilerin kullanımına dayalı olarak yapılabilmektedir. Tanımlayıcı modeller ise verilerdeki kalıpları veya ilişkileri tanımlamaktadır. Tahmine dayalı modellerden farklı olarak, yeni özellikleri tahmin etmenin değil incelenen verilerin özelliklerini keşfetmeye olanak verir (Dunham, 2006: 5).

3.1. Birliktelik Kuralları Analizi

Agrawal vd. (1993) tarafından ortaya atılan birliktelik kuralları bir veri kümesindeki kalıpları ve sık tekrarlayan öğeleri belirlemek için kullanılmaktadır. Günümüzde birliktelik kuralları analizi yöntemi pazarlama, finans, sağlık, fen bilimleri, mühendislik vb. birçok alanda sıklıkla kullanılmaktadır (Son vd., 2018). Örneğin X ürünü satın alan bir kişi aynı zamanda Y ürünü de satın *alıyorsa*, X ürünü ile Y ürünü arasında bir ilişki olduğu söylenebilir ve bu bilgi karar vericiler açısından faydalı bir bilgi olmaktadır. Dolayısıyla birliktelik kuralları analizi için geliştirilen algoritmaların uygulanmasındaki temel amaç, rastgele verileri analiz ederek eşzamanlı ilişkiler bulmak ve bu ilişkileri karar verme sırasında referans olarak kullanmaktır (Liao vd., 2011: 4611). Birliktelik kuralı analizinde şu adımlar uygulanır (Kotu ve Deshpande, 2018: 201):

Adım-1: Veriler işlem formatında düzenlenir. Bir birliktelik algoritması için, giriş verilerinin $t_x = (i_1, i_2, i_3)$ işlem biçiminde biçimlendirilmesi gerekir.

Adım-2: Sık tekrarlanan öğe kümeleri listelenir. Öğe kümeleri ilgili öğelerin kombinasyonlarıdır. Bir birliktelik algoritması, analizi en sık meydana gelen öğelerle sınırlandırır, böylece bir sonraki adımda çıkarılan son kural seti daha anlamlı hale gelir.

Adım-3: Öğe kümelerinden ilgili birliktelik kuralları oluşturulur. Son olarak algoritma, ilgi ölçüsüne dayalı olarak kuralları oluşturur ve filtreler.

Tablo 1. Örnek Öğeler Akışı

Hareket	Öğeler
1	(A, B)
2	(A, B)
3	(C, A, B)
4	(D)
5	(C, A, B)
6	(A, D, E)

Birliktelik kuralı analizinde birlikteliğin anlamlı olup olmadığı belirlemek için çeşitli parametreler kullanılmaktadır. Destek (support), güven (confidence) ve kaldıraç (lift) araştırmacılar tarafından en fazla yararlanılan parametreler olduğu görülmektedir. Bu parametrelere ek olarak farklı çalışmalarda kanaat (conviction), manivela (leverage), X^2 , tam güven (all-confidence) ve maksimum güven (max-Confidence) gibi çeşitli parametrelerden de

yararlanılabileceđi belirtilmiřtir (Han vd., 2012). Bu alıřmada analizler iin nemli olan, destek (support), gven (confidence) ve kaldıra (lift) parametreleri detaylandırılacaktır.

Tablo 2. rnek ğeler Akıřı Veri Kmesi

ID	A	B	E	C	D
1	1	1	0	0	0
2	1	1	0	0	0
3	1	1	0	1	0
4	0	0	0	0	1
5	1	1	0	1	0
6	1	0	1	0	1

Destek (support): Bu parametre temelinde bir oran ve olasılık bilgisi sunmaktadır. Destek parametresi oluřturulan kuralın faydalı olup olmadıđı hakkında bilgi vermektedir. Bir genin desteđi, basite bir ge kmesinin iřlem kmesindeki greceli grlme sıklıđını ifade etmektedir.

$$Destek(X \Rightarrow Y) = P(X \cap Y) = \frac{X \text{ ve } Y' \text{ yi birlikte ieren kayıt sayısı}}{\text{Toplam kayıt sayısı}} \quad (1)$$

Denklem 1’de destek deđeri Tablo-1 ve Tablo-2 zelinde yorumlarsak, X ve Y rnlerinin toplam satıřlarda hangi oranda birlikte yer aldıđını ve X ve Y’nin birlikte satın alınma olasılıđını gstermektedir. Bu dođrultuda birliktelik kuralı analizi yapılmadan nce minimum destek deđeri belirlenmelidir. Uygulamalarda bu deđer genellikle en az % 10 olarak alınır. Ancak uygulamanın tr, kullanılan verilerin yapısı ve boyutuna gre bu durum farklılık gsterebilir. Analizlerde destek deđerinin kk olması daha fazla, byk olması ise daha az kuralın ortaya ıkmasına neden olmaktadır (Zhang vd., 2021: 1464). rneđin Tablo-2’deki veri setinde A rnn destek deđerini altı iřlemden beřidir. Forml yardımıyla destek deđerini řu řekilde gsterilir:

$$Destek \{A\} = 5/6 = 0.83$$

$$Destek \{A, B\} = 4/6 = 0.67$$

$$Destek \{C\} = 2/6 = 0.33$$

rneđin destek deđerini % 50’nin zerinde alındıđında sadece % 50’nin zerindeki destek deđerli olan ğeler dikkate alınarak analiz yapılacaktır. Bu durumda “C” gesinin deđerini % 33 olduđunda analizlerde dikkate alınmayacaktır.

Gven (confidence): Bu parametre, destek parametresi gibi oran ve řartlı bir olasılık bilgisi sunmaktadır. Gven parametresi keřfedilen kuralın kesinliđini ortaya koymaktadır.

$$Gven(X \Rightarrow Y) = P(Y|X) = \frac{Destek(X \cap Y)}{Destek(X)} = \frac{X \text{ ve } Y' \text{ yi birlikte ieren kayıt sayısı}}{X' \text{ i ieren kayıt sayısı}} \quad (2)$$

Denklem 2’deki forml X rnn satın alan mřterilerin hangi oranda Y rnn de satın alma davranıřını sergilediđini gstermektedir. Bařka bir ifadeyle bu forml, X ve Y rnlerini birlikte alan bireylerin, X rnn satın alan bireylerin iindeki oranını ifade etmektedir. Bu oran bydke keřfedilen kural sayısı azalmaktadır (Han vd., 2012: 246).

Tablo 1 ve Tablo 2’deki rnek veri seti iin gven deđerini hesaplayacak olursak; $\{A, B\} \rightarrow \{C\}$ kuralı durumunda, gven lsnn yanıtladıđı soru řudur: Bir alıřveriřte hem A hem de B alan kiřiler, iinde C rnn de alanların oranını nedir?

$$Güven(\{A, B\} \rightarrow \{C\}) = \frac{Destek(\{A,B,C\})}{Destek(\{A,B\})} = \frac{2/6}{4/6} = 0.5 \quad (3)$$

A ve B satın alan bireylerin % 50’si yani yarısı C’de satın almaktadır.

Kaldıraç (lift): Birliktelik kuralları analizi sonucunda keşfedilen bütün kurallar için sadece destek ve güven parametreleri yeterli değildir. Genellikle destek ve güven parametrelerinde belirlenen minimum eşik değerlerinden fazla olması ilginç bir kuralın keşfedildiği kabul edilir. Bununla birlikte yüksek güven ve destek değerlerine rağmen aslında ilginç kabul edilmeyecek kurallar belirlenebilir. Bu durumun üstesinden gelmek için farklı bazı parametrelerin hesaplanması gerekir. Bunun için en yaygın kullanılan kaldıraç (Lift) parametresinden faydalanılır. Kaldıraç parametresi korelasyon prensibine dayanmaktadır (Han vd., 2012: 266).

$$Kaldıraç(X, Y) = \frac{P(X \cap Y)}{P(X)P(Y)} = \frac{P(Y|X)}{P(Y)} = \frac{Güven(Y \Rightarrow X)}{Destek(Y)} = \frac{Destek(X \cup Y)}{Destek(X) * Destek(Y)} \quad (4)$$

Tablo 1 ve Tablo 2’deki örnek veri seti için kaldıraç değerini hesaplayacak olursak;

$$Kaldıraç(\{A, B\} \rightarrow \{C\}) = \frac{0.33}{0.667 * 0.33} = 1.5 \quad (5)$$

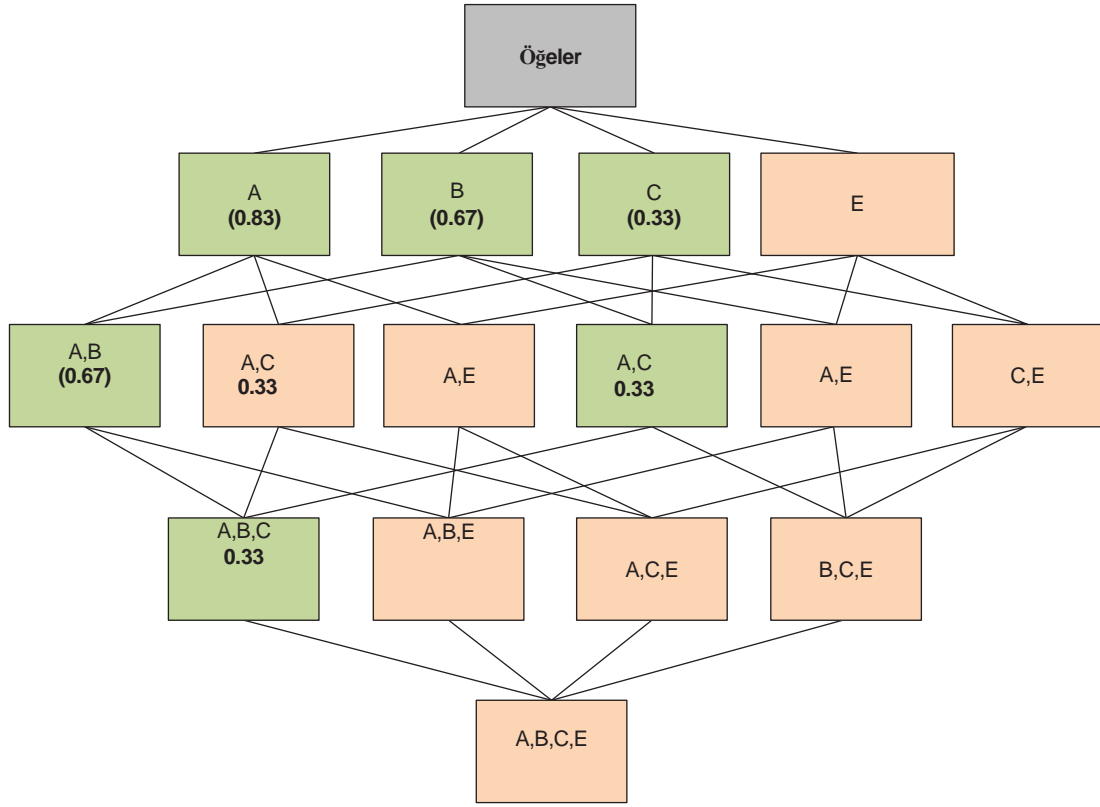
Kaldıraç değerinin 1’den küçük olması durumunda öncül ve ardıllar arasında negatif yönlü bir korelasyon olduğunu göstermektedir. Değerin 1’den büyük olması durumunda pozitif yönlü bir korelasyon olduğunu göstermektedir. Birliktelik kuralları analizinde bir kuralın anlamlı kabul edilebilmesi için kaldıraç değerinin 1’den büyük olması istenir. Bu değer ne kadar büyük olursa ilişki o kadar güçlüdür (Han vd., 2012, s. 266).

3.2. Birliktelik Kuralı Algoritmaları

Birliktelik kuralı analizlerinde birçok farklı algoritma kullanılmaktadır. Bu algoritmalar “ardışık algoritmalar” ve “paralel algoritmalar” olarak iki başlık altında toplanmaktadır. Ardışık algoritmalar, ele alınan öğelerden, öğe kümeleri oluşturularak bunların sayıldığı mantıksal ifadeleri içermektedir. Paralel algoritmalar ise büyük öğe kümelerinin paralellik sağlayarak oluşturulmasını sağlar (Erpolat, 2012: 138). Bu çalışmada ardışık algoritmalarından Apriori ve FP-Growth algoritmaları dikkate alınarak analizler yapılacağından, izleyen bölümde söz konusu algoritmalar detaylandırılacaktır.

3.2.1. Apriori Algoritması

Apriori algoritması birliktelik kurallarının keşfedilmesinde en yaygın olarak kullanılan algoritmalarından biridir. Apriori algoritması, ortak bir öğe kümesini bulmak için kullanılan birliktelik kuralları (Liu vd., 2017: 2) madenciliği için en iyi bilinen algoritma olarak kabul edilir (Azeez vd., 2019: 3). Agrawal ve Srikant (1994) tarafından geliştirilen apriori algoritması ismini, keşfettiği bilgiyi her zaman önceki adımdan aldığından dolayı prior (önceki) kelimesinden almıştır. Apriori algoritması, destek (support) parametresini kullanarak test edilecek öğe kümelerinin sayısını azaltarak, sık öğeler kümesi oluşturan mantıksal kurallar geliştirmektedir. Apriori algoritmasının ilkeleri şunu belirtir: Eğer bir öğe kümesi sık ise, o zaman tüm alt küme öğeleri de sık bir öğe kümesi oluşturacaktır. Dolayısıyla öğe kümesinin destek değeri, belirlenen destek eşliğinden yüksekse, belirlenen kurallar çerçevesinde öğe kümesi daha geniş olacağı varsayılır (Agrawal ve Srikant, 1994).



Şekil 1. Apriori Algoritmasını Kullanan Sık Öğe Kümeleri

Şekil 1, Tablo 1 ve Tablo 2’deki değerleri dikkate alarak Apriori ilkesinin bir çapraz desen öğeleri (lattice) uygulanmasını göstermektedir. {A, B, C} için alt küme öğelerinin destek seviyesi şöyledir:

Destek {A, B, C}= 0.33 (eşik destek seviyesinin üzerinde)

Destek {A, B}=0.66

Destek {A, C}=0.33

Destek {C}=0.33

Destek {A}=0.66

Tablo 3. Örnek Sık Öğe Kümesi Destek Değerleri

Öğe	Destek Sayısı	Destek Değeri
{A}	5	0.83
{B}	4	0.67
{E}	1	0.17
{C}	2	0.33
İkili Öğe Setleri	Destek Sayısı	Destek Değeri
{A, B}	4	0.67
{A, C}	2	0.33
{B, C}	2	0.33
Üçlü Öğe Setleri	Destek Sayısı	Destek Değeri
{A, B, C}	2	0.33

Şekil 1’de minimum eşik destek değerlerini sağlayan alt öge kümeleri yeşil renkli kutucukların içerisinde gösterilmiştir. Tersine, eğer öge kümesi seyrekse, o zaman tüm üst kümeleri de seyrek olacaktır. Şekil 1’de E’nin desteği 0.17’dir ve E’yi bir öge olarak içeren tüm üst kümelerin desteği 0.17’den küçük veya ona eşit olacaktır; bu durum örneğin minimum 0.25’lik destek eşiği dikkate alındığında sık görülmeyen bir durumu temsil etmektedir. Bu destek değerini sağlamayan öge kümeleri Şekil 1’de kırmızı renkli kutucuklar içinde gösterilmiştir. Kısacası minimum destek eşiğini sağlamayan ögeler çıkarılır (kırmızı renkli kutucuklar), sağlayanlar ise sık ögeler kümesine (yeşil renkli kutucuklar) eklenirler.

Tüm öge kümeleri için destek sayıları ve destek değerleri hesaplanmıştır. Destek sayısı, işlemlerin mutlak sayısıdır ve destek, destek sayısının toplam işlem sayısına oranıdır. Eşik destek sayısının (örneğinizde 2) altındaki herhangi bir öge kümesi daha sonraki işlemlerden çıkarılmaktadır. Şekil 1’de her bir ögenin destek sayısı ve destek değeri görülmektedir. Örneğin {E} destek sayısı belirlenen eşikten az olduğundan, öge kümesi oluşturmanın bir sonraki yinelemesi için ortadan kaldırılmaktadır. Bir sonraki adımda {A}, {B} ve {C} için üç adet iki öge kümesini sağlayan olası iki öge kümesi oluşmaktadır. Bu süreç, önceki kümelerden tüm n ögeli kümeler dikkate alınana kadar devam etmektedir. Sonuçta destek eşiğini aşan yedi adet sık öge kümesi ortaya çıkar.

Sık öge kümeleri oluşturulduktan sonra birliktelik analizindeki bir sonraki adım, kural formatında açık bir öncül ve sonuç ardıl içeren yararlı kurallar oluşturmadır:

{öge A} → {öge B} Kuralının güvenilirliği 2 no’lu denklemdeki formül dikkate alınarak hesaplanır. Örneğin n ögeden oluşan her sık öge kümesi $2^n - 2$ kural oluşturabilir. {A, B, C} aşağıdaki gibi güven puanlarına sahip kurallar oluşturabilir:

$$1-\{A, C\} \rightarrow \{B\} = 0.33/0.33 = 1.0$$

$$2-\{A, B\} \rightarrow \{C\} = 0.33/0.67 = 0.5$$

$$3-\{C, B\} \rightarrow \{A\} = 0.33/0.33 = 1.0$$

$$4-\{A\} \rightarrow \{C, B\} = 0.33/0.83 = 0.4$$

$$5-\{C\} \rightarrow \{A, B\} = 0.33/0.33 = 1.0$$

$$6-\{B\} \rightarrow \{A, C\} = 0.33/0.67 = 0.5$$

Örneğin birinci kuralda A ve C alan kişilerin %100 güven düzeyinde B ürününü aldığı söylenebilir. Hesaplanan güven değerleri için minimum güven eşiğini aşamayan alt kümeler çıkarılır, aşanlar ise güçlü kurallar listesine eklenir. Örneğimizde 0,5’in altında kalan kuralları elemek istersek dördüncü kural elimine edilecektir (Agrawal ve Srikant, 1994: 5).

3.2.2. FP-Growth Algoritması

FP algoritması, FP-ağacı adı verilen özel bir grafik veri yapısı kullanarak işlem kayıtlarını sıkılaştırarak sık öge kümesini hesaplamının alternatif bir yolunu sağlar. FP-ağacı veri setinin grafik formatına dönüştürülmesi olarak düşünülebilir. Apriori algoritmasında kullanılan aday kümesi oluşturma ve test etme yaklaşımından ziyade, FP-Growth ilk olarak bir FP-ağacı oluşturur ve sık öge kümelerini oluşturmak için bu sıkılaştırılmış ağacı kullanır. FP-Growth algoritmasının verimliliği, FP-ağacının oluşturulmasında ne kadar sıkılaştırmanın elde edileceğine bağlıdır (Han

vd., 2000: 1). FP-Growth algoritmasının etkinliđi üç teknikle sađlanmaktadır: (1) büyük bir veri tabanı, yüksek oranda yoğunlaştırılmıř, çok daha küçük bir veri yapısına sıkıřtırılarak daha maliyetli tekrarlanan veri tabanı taramaları önlenir. (2) FP-ađacı tabanlı algoritma, çok sayıda aday kümesinin maliyetli bir řekilde oluřturulmasını önlemek için bir örüntü parçası büyüme yöntemini benimser. (3) Kořullu veri tabanlarında bađlantılı kalıpların madenciliđi için madencilik görevini daha küçük görevlerden oluřan bir diziye ayırmak için bölümlenmeye dayalı, böl ve yönet yöntemi kullanılır, bu da arama alanını önemli ölçüde azaltmaktadır. Örneđin, FP-Growth algoritmasını kullanarak ařađıdaki veri tabanındaki tüm sık görülen öđe kümelerini veya sık görülen kalıpları minimum desteđi %30 olarak řekilde bulmamız gerekirse, algoritma takip eden řekilde çalıřmaktadır (Sidhu vd., 2014).

Tablo 4. FP-Growth Öđe Kümesi

Hareket	Öđeler
1	(E, A, D, B)
2	(D, A, C, E, B)
3	(C, A, B, E)
4	(B, A, D)
5	(D)
6	(D, B)
7	(A, D, E)
8	(B, C)

Birinci adımda minimum destek sayısı hesaplanır. Minimum destek sayısı $(30/100 * 8) = 2,4$ tür hesaplamayı kolaylařtırmak için minimum destek sayısı 3 olarak alınabilir.

İkinci adımda öđelerin oluřma sıklıđı hesaplanır. Örneđin, A öđesi satır 1, satır 2, satır 3, satır 4 ve satır 7'de yer almaktadır. Veri tabanı tablosunda toplam 5 kez geçer. Her bir öđenin sayılan görölme sıklıđını Tablo 5'te gösterilmiřtir.

Tablo 5. Öđe Görölme Sıklıđı

Öđe	Görölme Sıklıđı	Sıralama Önceliđi
A	5	3
B	6	1
C	3	5
D	6	2
E	4	4


Üçüncü adımda her bir öđenin görölme sıklıđına göre öncelik verilir. Örneđin B ve D öđesi en yüksek görölme sayısı nedeniyle en yüksek önceliđe sahip olur. Aynı zamanda minimum destek deđerini karřılamayan öđelerde çıkarılır. Veri tabanı frekansı bir (1) olan F çıkarılır. Bazen B:6, D:6, A:5, E:4, C:3 řeklinde sık görölme listesi de kullanılabilir.

Dördüncü adımda öđeler önceliđe göre sıralanırlar. Sıralı Öđeler sütununda tüm öđeler, Tablo 5'teki belirtilen önceliđine göre sıralanır. Örneđin, satır 1'in sıralanması durumunda, en yüksek öncelikli öđe B'dir ve bundan sonra sırasıyla D, A, E ve C gelir. Bu adımdan sonra FP-Growth ađacı çizilebilir.

Tablo 6. Sıralı Öğeler

Hareket	Öğeler	Sıralı Öğeler
1	E, A, D, B	B, D, A, E
2	D, A, C, E, B	B, D, A, E, C
3	C, A, B, E	B, A, E, C
4	B, A, D	B, D, A
5	D	D
6	D, B	B, D
7	A, D, E	D, A, E
8	B, C	B, C

Ağaca birinci satırdaki öğeler sırasıyla eklenir bu işlem son satırdaki öğelerin eklenmesiyle son bulur. Sıralı öğelerin eklenmesiyle ağaç sürekli güncellenir. Örneğin tablo 6'daki birinci satırdaki sıralı öğeler eklendiğinde B:1, D:1, A:1 ve E:1 ağacı oluşur. Sonrasında ikinci satırdaki sıralı öğelerin eklenmesiyle B:2, D:2, A:2, E:2 ve C:1 ağacı oluşur. Üçüncü satırda ise ağaçta yeni bir dal oluşturulmalıdır. Çünkü B ile başlayan üçüncü satırda ikinci öge A olduğu için mevcut dalda D'yi geçerek A'ya bağlantı kurulamaz. Bunun için B'den başlayarak yeni bir A, E ve C dal oluşturulmalıdır. Bu durumda B:3, A:1, E:1 ve C:1 bir dal oluşur. Dördüncü sıralı öğeler için ise yine B:4, D:3 ve A:3 düğümü oluşmaktadır. Beşinci sıralı öğede ise D:1 düğümü, altıncı sıralı öğede B:5 ve D:4 yedinci sıralı öğede D:2, A:1 ve E:1 düğümü oluşur. Son sıralı öge için yine B'den yeni bir C:1 düğümü oluşur. Sonuçta B:6 ve C:1 dalı oluşur. Bu aşamalardan sonra FP-Growth ağacı Şekil 2'deki gibi olacaktır.

**Şekil 2. FP-Growth Ağacı**

Bu aşamadan sonra FP ağacından sık kullanılan kalıplar bulunmalıdır. Burada sıklık kalıplarının (FP) tablo 5'teki verilen önceliklere göre tanımlandığına dikkat edilmelidir. Yani FP'leri gözlemlemek için aşağıdan yukarıya, C'den B'ye gitmemiz gerekir. Öncelikle C:3 için koşullu kalıpların bulunması gerekir. C:3 C'nin görülme sıklığını temsil etmektedir. Bütün

C'lerden hareket edersek üç adet dal elde edilir. Bunlar, BDAE:1, B:1 ve BAE:1 şeklindedir. Bu dallar C için Koşullu Desen Tabanı olarak kabul edilir. Burada üç önemli husus vardır: (1) Aşağıdan yukarıya doğru hareket etsek bile dalları yukarıdan aşağıya doğru yazılmalı, (2) C alınmamalı ve (3) Her dalda C'nin görülme sıklığını temsil etmek için her dalın ardından 1 sayısı yazılır. Bu da C'nin görülme sıklığını yani 3'ü temsil etmektedir.

Daha sonra C'nin koşullu desen tabanından FP listesinin bulunması gerekir. BDAE:1, B:1 ve BAE:1 dikkate alarak görülme sıklığı şu şekilde oluşur. B:3, D:1, A:2 ve E:2 şeklindedir. Ancak örneğimizde minimum destek sayısını B karşıladığından, B:3 yalnızca FP listesinde yer almaya uygundur. C için koşullu FP ağacı C:3, BC:3 şeklinde oluşur. Benzer şekilde E için koşullu FP ağacı ise şöyle oluşur: BDA:2, BA:1 ve DA:1'dir. Buradan FP listesi A:4, B:3 ve D:3'tür.

Sonuç olarak diğer öge kümeleri için bu prosedür işletilerek koşullu FP ağacı minimum %30 destek seviyesi ile sık öge kümeleri şöyle oluşmaktadır: C:3, BC:3, DE:3, ADE:3, BE:3, ABE:3, AE:4, E:4, AD:4, ABD:3, AB:4, A:5, D:6, BD:4, B:6. Bu koşullu sık öge kümelerinin sayısı destek seviyesinin yükseltilmesiyle daha az olacaktır.

3.2.3. Apriori ve FP-Growth Algoritmalarının Karşılaştırılması

Apriori algoritması, tekli öge kümesi, ikili öge kümesi, üçlü öge kümesi gibi eşleştirmeleri kullanarak öge kümelerinin sık örüntülerini oluşturmaktadır. FP-Growth algoritması ise sık kalıplar oluşturmak için bir FP ağacı oluşturmaktadır. Apriori algoritması, sık görülen alt kümelerin her defasında bir öge olarak genişletildiği aday oluşturmayı kullanmaktadır. FP-Growth algoritması ise, verilerdeki her öge için koşullu FP ağacı oluşturmaktadır. Apriori algoritması, veri tabanını her adımında taradığından, öge sayısının daha fazla olduğu veriler için zaman alıcı hale gelir. FP ağacı ise, başlangıç adımlarında veri tabanının yalnızca bir kez taranmasını gerektirir, böylece daha az zaman harcamaktadır. Apriori algoritması veri tabanının dönüştürülmüş bir versiyonunu belleğe kaydeder. FP Growth algoritması ise her öge için koşullu FP ağacı seti belleğe kaydedilir. Apriori algoritması genişlik öncelikli aramayı kullanırken, FP-Growth algoritması ise derinlik öncelikli aramayı kullanmaktadır (Kocabıyık vd., 2021).

Her iki algoritmanın tekniğe, bellek kullanımına, tarama sayısına ve tüketilen süreye dayalı karşılaştırmaları ise şöyledir (Kavitha ve Selvi, 2016: 163):

Teknik: Apriori algoritması, sık görülen kalıpları tespit etmek için Apriori özelliğini yani birleştirme özelliğini kullanırken, FP-Growth algoritması ise minimum desteği karşılayan veri tabanından koşullu bir desen kısıtlaması olmadan koşullu desen tabanı oluşturmaktadır.

Arama Türü: Apriori algoritması genişlik öncelikli arama yöntemini kullanırken, FP-Growth algoritması böl ve yönet yöntemini kullanmaktadır.

Bellek Kullanımı: Apriori algoritması, çok sayıda aday öge kümesi üretimiyle uğraştığı için geniş bellek alanına ihtiyaç duymaktadır. Buna karşın FP-Growth algoritması, kompakt yapısı nedeniyle daha az bellek gerektirir ve aday öge kümesi oluşturmadan sık öge kümelerini keşfeder.

Tarama Sayısı: Apriori algoritması aday kümesi oluşturmak için birden fazla tarama gerçekleştirir. FP-Growth algoritması veri tabanını yalnızca iki kez tarar.

Zaman: Apriori algoritmasında yürütme süresi her seferinde adayların üretilmesinde daha fazla israf edilir. FP-Growth algoritmasının yürütme süresi Apriori algoritmasına kıyasla daha kısadır.

4. Veri Seti ve Veri Ön İşleme

Çalışmanın ham veri seti 01.01.2010-01.08.2023 tarihleri arasındaki 20 farklı vadeli emtia fiyatının günlük kapanış fiyatından oluşmaktadır. Çalışmanın tüm verileri NASDAQ’dan (2024) elde edilmiştir. Bu emtialar Tablo 7’de gösterilmiştir.

Tablo 7. Analiz Kapsamına Dâhil Edilen Emtialar

Değerli Metaller	Bitkiler	Hububat	Enerji	Etler
Altın	Kahve	Buğday	Brent Petrol	Sığır
Gümüş	Kakao	Mısır	Ham Petrol WTI	
Bakır	Pamuk	Soya Fasulyesi	Doğalgaz	
Platin	Şeker	Çeltik		
Paladyum	Kereste			
Çinko				
Nikel				

Çalışmada 20 emtianın günlük kapanış fiyatları 3405 günlük ham veriden oluşmaktadır. Birliktelik analizi için ham verilerin bazıları farklı günlerde de işlem gördüğünden tüm değişkenlerin aynı günlerde işlem gördüğü günler alınmıştır. Bunun sonucunda analiz için toplam 3216 işlem günü dikkate alınmıştır. Çalışmada kullanılan verilerin birliktelik kuralı yöntemi ile analiz edilebilmesi için ham verilerin kategorik (nominal) veriye dönüştürülmesi gerekmektedir. Bu doğrultuda 20 emtianın kapanış fiyatları dikkate alınarak her emtianın MS Excel’de günlük getirileri hesaplanmıştır. Sonraki adımda ise yine MS Excel’de “EĞER” fonksiyonu kullanılarak eğer getiri pozitif (↑) ise 1 negatif (↓) ise 0 kategorik değer ile gösterilmiştir. Bu kategorik veri örneği Tablo 8’de sadece değerli metaller ile ilgili olarak gösterilmiştir. Diğer tüm emtialar da bu şekilde kategorik veriye dönüştürülmüştür. Daha sonra elde edilen veri seti, arff formatına çevrilip WEKA paket programına yüklenmiştir. Bu aşamadan sonraki adımda kategorik veriler WEKA 3.9.6 paket programına tanıtılarak analizler gerçekleştirilmiştir. Çalışmada analizler Apriori ve FP-Growth algoritması olmak üzere iki farklı algoritma kullanılarak gerçekleştirilmiştir.

Tablo 8. Birliktelik Kuralı Analizine Ait Veri Setinin Düzenlenmesi

	Altın	Gümüş	Bakır	Platin	Paladyum	Çinko	Nikel
1	0↓	1↑	0↓	1↑	0↓	1↑	1↑
2	1↑	0↓	0↓	1↑	1↑	0↓	0↓
3	0↓	1↑	1↑	1↑	1↑	1↑	1↑
·	·	·	·	·	·	·	·
·	·	·	·	·	·	·	·
·	·	·	·	·	·	·	·
·	·	·	·	·	·	·	·
3216	0↓	1↑	0↓	1↑	0↓	1↑	1↑

5. Analiz Sonuları

alıřmada ncelikle hem Apriori hem de FP-Growth algoritmasına gre en dřk 0.95 gven dzeyinde ve  farklı destek (0.25, 0.30 ve 0.40) seviyesinde birliktelik kuralları elde edilmiřtir. Birliktelik kuralı analizi sonucunda farklı destek deęerleri dzeyinde ortaya ıkan kural sayıları Tablo 9’da ve ekte yer alan Grafik 1,2 ve 3’te gsterilmektedir. Tablo 9’da hem Apriori hem de FP-Growth algoritması ile gerekleřtirilen birliktelik kurallarında Brent petroln tm dięer emtialarla birlikte hareket ettięi grlmektedir.

Tablo 9. Farklı Destek ve 0.95 Gven Deęerlerine Gre Ortaya ıkan Kural Sayısı

Emtialar	Destek Seviyesi					
	min 0.25 (100 Kural)		min 0.3 (20 Kural)		min 0.4 (16 Kural)	
	Gven min 0.95		Gven Dzeyi min 0.95		Gven min 0.95	
	Apriori	FP-Growth	Apriori	FP-Growth	Apriori	FP-Growth
Altın	8	8	1	1	0	1
Gmř	9	6	1	2	1	1
Bakır	10	13	2	3	1	1
Platin	12	0	4	0	1	0
Paladyum	6	0	2	0	1	0
inko	4	1	1	0	1	0
Nikel	8	9	0	1	0	1
Kahve	14	15	1	1	1	1
Kakao	16	16	1	1	1	2
Pamuk	8	11	1	1	1	1
řeker	7	10	0	1	0	1
Kereste	2	4	1	1	1	1
Buęday	13	12	2	2	1	1
Mısır	13	16	3	3	1	1
Soya Fasulyesi	8	12	2	2	1	1
eltik	14	14	1	1	1	1
Brent Petrol	100	100	20	20	16	16
Ham Petrol WTI	17	15	2	2	1	1
Doęalgaz	12	12	1	1	1	1
Sıęır	9	13	0	1	0	1

Tablo 9’da 0.25 destek (support) seviyesinde ve 0.95 gven (confidence) dzeyinde hem Apriori hem de FP-Growth algoritmaları ile elde edilen toplam 100 kuralın tmnde brent petroln dięer emtialarla birlikte hareket ettięi grlmektedir. Apriori algoritması ile gerekleřtirilen birliktelik kurallarında brent petrol ile en fazla birlikte hareket eden  emtia sırasıyla ham petrol WTI (17), kakao (16) ve eltik (14) olmuřtur. FP-Growth algoritması birliktelik kurallarında ise brent petrol ile en fazla birlikte hareket eden emtialar sırasıyla Mısır (16), Kakao (16) ve Ham Petrol WTI (15) olmuřtur. 0.30 destek (support) seviyesinde ve 0.95 gven (confidence) dzeyinde Apriori algoritması ile elde edilen birliktelik kurallarında brent petrolle en fazla birlikte hareket eden ilk iki emtia platin (4) ve mısır (3) olmuřtur. FP-Growth algoritması birliktelik kurallarında ise Brent petrol ile en fazla birlikte hareket eden emtialar sırasıyla Bakır (3) ve Mısır (3) olmuřtur. 0.40 destek (support) seviyesinde ve 0.95 gven (confidence) dzeyinde hem Apriori hem de FP-Growth algoritmaları ile elde edilen birliktelik kurallarının oęunlukla benzer sonular rettięi grlmektedir. 0.25 destek (support) seviyesinde

ve 0.95 güven (confidence) düzeyinde hem Apriori hem de FP-Growth algoritmaları ile elde edilen birliktelik kurallarında brent petrol bitki ve hububat emtiaları ile daha sık görülmüştür.

5.1. Apriori Algoritması Sonuçları

Apriori algoritması ile öncelikle %100 güven (confidence) düzeyinde birliktelik analizi için WEKA 3.9.6 paket programında veri analize sokulmuş ancak bir kural tespit edilememiştir. Daha sonra % 98 güven (confidence) ve %10 destek (support) düzeyi temel alınarak toplam 100 kural üretilmiş ve en yüksek güven seviyesine sahip ilk 25 adet üç değişkenli ve dört değişkenli kurallar Tablo 10'da gösterilmiştir. Tablo 10 incelendiğinde ilk iki birliktelik kuralının %99 güven düzeyinde, diğerlerinin ise % 98 güven düzeyinde olduğu görülmektedir.

Tablo 10. Apriori Algoritması Üç ve Dört Değişkenli İlk 25 Kural

Birliktelik Kuralları		Conf	Lift.	Conv.
1 BAKIR ↑ PLATIN ↓ SIGIR ↑	335 → BRENT ↑ 331	0.99	1.04	3.21
2 PLATIN ↓ CINKO ↑ KAKAO ↑	366 → BRENT ↑ 361	0.99	1.04	2.92
3 PLATIN ↓ KAKAO ↑ SIGIR ↑	388 → BRENT ↑ 382	0.98	1.03	2.65
4 PALADYUM ↓ KAKAO ↑ SIGIR ↑	369 → BRENT ↑ 363	0.98	1.03	2.52
5 PLATIN ↓ NIKEL ↑ KAKAO ↑	362 → BRENT ↑ 356	0.98	1.03	2.48
6 PLATIN ↓ SOYA ↑ PAMUK ↓	359 → BRENT ↑ 353	0.98	1.03	2.46
7 PLATIN ↓ DOGALGAZ ↑ SIGIR ↑	416 → BRENT ↑ 409	0.98	1.03	2.49
8 BAKIR ↑ DOGALGAZ ↑ BUGDAY ↑ MISIR ↑	342 → BRENT ↑ 336	0.98	1.03	2.34
9 PLATIN ↓ SOYA ↑ SIGIR ↑	398 → BRENT ↑ 391	0.98	1.03	2.38
10 PALADYUM ↓ CINKO ↑ KAKAO ↑	341 → BRENT ↑ 335	0.98	1.03	2.33
11 PALADYUM ↓ CINKO ↓ SOYA ↑	339 → BRENT ↑ 333	0.98	1.03	2.32
12 PLATIN ↓ WTI ↑ CELTIK ↑	338 → BRENT ↑ 332	0.98	1.03	2.31
13 WTI ↑ CINKO ↓ BUGDAY ↑	389 → BRENT ↑ 382	0.98	1.03	2.33
14 PLATIN ↓ KAHVE ↑ SIGIR ↑	388 → BRENT ↑ 381	0.98	1.03	2.32
15 PALADYUM ↓ BUGDAY ↑ KAKAO ↑	332 → BRENT ↑ 326	0.98	1.03	2.27
16 CINKO ↓ BUGDAY ↑ PAMUK ↑	387 → BRENT ↑ 380	0.98	1.03	2.32
17 PALADYUM ↓ SOYA ↑ KAKAO ↑	331 → BRENT ↑ 325	0.98	1.03	2.26
18 SOYA ↑ PAMUK ↓ SIGIR ↓	331 → BRENT ↑ 325	0.98	1.03	2.26
19 CINKO ↓ BUGDAY ↑ MISIR ↑ SIGIR ↑	329 → BRENT ↑ 323	0.98	1.03	2.25
20 DOGALGAZ ↑ CINKO ↓ SOYA ↑	433 → BRENT ↑ 425	0.98	1.03	2.3
21 PLATIN ↓ WTI ↑ SOYA ↑	375 → BRENT ↑ 368	0.98	1.03	2.24
22 PLATIN ↓ WTI ↑ SEKER ↑	355 → BRENT ↑ 348	0.98	1.03	2.12
23 BAKIR ↑ BUGDAY ↑ MISIR ↑ KAKAO ↑	354 → BRENT ↑ 347	0.98	1.03	2.12
24 CINKO ↓ BUGDAY ↑ MISIR ↑ SOYA ↑	400 → BRENT ↑ 392	0.98	1.03	2.13
25 MISIR ↑ KAKAO ↑ SEKER ↓	350 → BRENT ↑ 343	0.98	1.03	2.09

Not: ↑ yönlü ok emtianın günlük getirisinin pozitif, ↓ yönlü ok emtia fiyatının getirisinin negatif olduğunu göstermektedir. → ise birlikte harekete eşlik eden emtiayı göstermektedir. (Conf: güven düzeyini, lift: birlikte hareket etme katsayısı ve Conv: ilişki düzeyini göstermektedir.)

Kural 1 incelendiğinde; bakır ve sığır emtialarındaki artış ve platin emtiasındaki azalışın birlikte 335 gün birlikte hareket ettiği görülmektedir ve bu birlikteliğe Brent petrol 331 gün artış yönünde eşlik etmiştir. Bu kuralın güven düzeyi, 331/335 işlem sonucunda %99 olarak hesaplanmıştır. Kural 2 incelendiğinde; çinko ve kakao emtialarındaki artış ve platin emtiasındaki azalışın birlikte 336 gün hareket ettiği görülmektedir ve bu birlikteliğe Brent petrol 361 gün artış yönünde eşlik etmiştir. Bu kuralın güven düzeyi, 361/366 işlem sonucunda %99 olarak hesaplanmıştır. Kural 3 incelendiğinde; kakao ve sığır emtialarındaki artış ve platin emtiasındaki azalışın birlikte 388 gün hareket ettiği görülmektedir ve bu birlikteliğe Brent petrol 382 gün artış

yönünde eşlik etmiştir. Bu kuralın güven düzeyi, 382/388 işlem sonucunda %98 olarak hesaplanmıştır. Diğer tüm birliktelik kurallarında Brent petrolün diğer emtialara eşlik ettiği görülmektedir. Bu durum Brent petrolün emtialar arasında belirleyici olduğunu göstermektedir.

İkinci aşamada apriori algoritması ile güven (confidence) düzeyi %90 ve %25 destek (support) düzeyi temel alınarak elde edilen 100 kuraldan ilk 25 üç değişkenli kurallar Tablo 11’de gösterilmiştir. Tablo 11 incelendiğinde ilk beş birliktelik kuralının %97 güven düzeyinde, diğerlerinin ise %96 güven düzeyinde olduğu görülmektedir.

Kural 1 incelendiğinde; platin ve buğday emtialarındaki 848 gün birlikte azalışına Brent petrol 820 gün artış yönünde eşlik etmiştir. Bu kuralın güven düzeyi, 820/848 işlem sonucunda %97 olarak hesaplanmıştır. Kural 2 incelendiğinde; çeltik ve kakao emtialarındaki 847 gün birlikte artışına Brent petrol 819 gün artış yönünde eşlik etmiştir. Bu kuralın güven düzeyi, 819/847 işlem sonucunda %97 olarak hesaplanmıştır. Kural 3 incelendiğinde; WTI ve çeltik emtialarındaki 869 gün birlikte artışına Brent petrol 840 gün artış yönünde eşlik etmiştir. Bu kuralın güven düzeyi, 840/869 işlem sonucunda %97 olarak hesaplanmıştır. Diğer tüm birliktelik kurallarında Brent petrolün diğer emtialara eşlik ettiği görülmektedir. Bu durum Brent petrolün emtialar arasında belirleyici olduğunu göstermektedir.

Tablo 11. Apriori Algoritması İki Değişkenli İlk 25 Kural

	Birliktelik Kuralları			Conf	Lift.	Conv.
1	PLATIN ↓ BUGDAY ↓	848	→ BRENT ↑820	0.97	1.02	1.4
2	CELTİK ↑ KAKAO ↑	847	→ BRENT ↑819	0.97	1.02	1.4
3	WTI ↑ CELTİK ↑	869	→ BRENT ↑840	0.97	1.02	1.39
4	BUGDAY ↑ KAKAO ↑	838	→ BRENT ↑809	0.97	1.01	1.34
5	DOGALGAZ ↑ CELTİK ↑	836	→ BRENT ↑807	0.97	1.01	1.33
6	WTI ↑ BUGDAY ↑	851	→ BRENT ↑821	0.96	1.01	1.31
7	BAKIR ↑ MISIR ↑	933	→ BRENT ↑900	0.96	1.01	1.31
8	DOGALGAZ ↑ KAKAO ↑	848	→ BRENT ↑818	0.96	1.01	1.31
9	BAKIR ↑ KAKAO ↑	918	→ BRENT ↑885	0.96	1.01	1.29
10	CELTİK ↑ KAHVE ↑	860	→ BRENT ↑829	0.96	1.01	1.29
11	MISIR ↑ KAKAO ↑	880	→ BRENT ↑848	0.96	1.01	1.28
12	BAKIR ↑ DOGALGAZ ↑	878	→ BRENT ↑846	0.96	1.01	1.27
13	ALTIN ↑ CELTİK ↑	856	→ BRENT ↑824	0.96	1.01	1.24
14	GUMUS ↓ PALADYUM ↓	976	→ BRENT ↑939	0.96	1.01	1.23
15	PAMUK ↑ KAKAO ↑	867	→ BRENT ↑834	0.96	1.01	1.22
16	CELTİK ↑ MISIR ↑	945	→ BRENT ↑909	0.96	1.01	1.22
17	DOGALGAZ ↑ NIKEL ↑	840	→ BRENT ↑808	0.96	1.01	1.22
18	PLATIN ↓ PAMUK ↓	866	→ BRENT ↑833	0.96	1.01	1.22
20	DOGALGAZ ↑ SIGIR ↑	885	→ BRENT ↑851	0.96	1.01	1.21
21	SOYA ↑ KAKAO ↑	904	→ BRENT ↑869	0.96	1.01	1.2
22	DOGALGAZ ↑ PAMUK ↑	850	→ BRENT ↑817	0.96	1.01	1.2
23	PLATIN ↓ PALADYUM ↓	1056	→ BRENT ↑1015	0.96	1.01	1.2
24	KAKAO ↑ KERESTE ↑	871	→ BRENT ↑837	0.96	1.01	1.19
25	ALTIN ↓ PALADYUM ↓	921	→ BRENT ↑885	0.96	1.01	1.19

Not: ↑ yönlü ok emtianın günlük getirisinin pozitif, ↓ yönlü ok emtia fiyatının getirisinin negatif olduğunu göstermektedir. → ise birlikte harekete eşlik eden emtiayı göstermektedir. (Conf: güven düzeyini, lift: birlikte hareket etme katsayısı ve conv: ilişki düzeyini göstermektedir.)

5.2. FP-Growth Algoritması Sonuçları

FP-Growth algoritması ile öncelikle %100 güven (confidence) düzeyinde birliktelik analizi için WEKA 3.9.6 paket programında veri analize sokulmuş ancak bir kural tespit edilememiştir. Daha sonra %97 güven (confidence) düzeyi ve %10 destek (support) seviyesi temel alınarak toplam 77 adet dört değişkenli ve beş değişkenli kurallar elde edilmiş ve bu kurallardan en yüksek güven düzeyine sahip ilk 25 tanesi Tablo 12’de gösterilmiştir. Tablo 12 incelendiğinde ilk 18 birliktelik kuralının %98 güven düzeyinde, diğerlerinin ise %97 güven düzeyinde olduğu görülmektedir.

Kural 1 incelendiğinde; mısır, bakır, doğalgaz ve buğday emtialarındaki 342 gün birlikte artışına Brent petrol 336 gün artış yönünde eşlik etmiştir. Bu kuralın güven düzeyi, 336/342 işlem sonucunda %98 olarak hesaplanmıştır. Kural 2 incelendiğinde; mısır, kakao, bakır ve buğday emtialarındaki 354 gün birlikte artışına Brent petrol 347 gün artış yönünde eşlik etmiştir. Bu kuralın güven düzeyi, 347/354 işlem sonucunda %98 olarak hesaplanmıştır. Kural 3 incelendiğinde; WTI, mısır, gümüş ve çeltik emtialarındaki 344 gün birlikte artışına Brent petrol 337 gün artış yönünde eşlik etmiştir. Bu kuralın güven düzeyi, 337/344 işlem sonucunda %98 olarak hesaplanmıştır. Diğer tüm birliktelik kurallarında Brent petrolün diğer emtialara eşlik ettiği görülmektedir. Bu durum Brent petrolün emtialar arasında belirleyici olduğunu göstermektedir.

Tablo 12. FP Growth Algoritması ile Elde Edilen Üç, Dört ve Beş Değişkenli İlk 25 Kural

Birliktelik Kuralları		Conf	Lift.	Conv.
1	MISIR ↑ BAKIR ↑ DOGALGAZ ↑ BUGDAY ↑ 342 → BRENT ↑336	0.98	1.03	2.34
2	MISIR ↑ KAKAO ↑ BAKIR ↑ BUGDAY ↑ 354 → BRENT ↑347	0.98	1.03	2.12
3	WTI ↑ MISIR ↑ GUMUS ↑ CELTIK ↑ 344 → BRENT ↑337	0.98	1.03	2.06
4	WTI ↑ MISIR ↑ KAHVE ↑ CELTIK ↑ 337 → BRENT ↑330	0.98	1.03	2.02
5	WTI ↑ MISIR ↑ PAMUK ↑ BUGDAY ↑ 385 → BRENT ↑377	0.98	1.03	2.05
6	WTI ↑ MISIR ↑ CELTIK ↑ BUGDAY ↑ 379 → BRENT ↑371	0.98	1.03	2.02
7	MISIR ↑ BAKIR ↑ CELTIK ↑ BUGDAY ↑ 371 → BRENT ↑363	0.98	1.03	1.97
8	WTI ↑ MISIR ↑ BAKIR ↑ BUGDAY ↑ 407 → BRENT ↑398	0.98	1.03	1.95
9	WTI ↑ MISIR ↑ DOGALGAZ ↑ BUGDAY ↑ 359 → BRENT ↑351	0.98	1.03	1.91
10	WTI ↑ MISIR ↑ PAMUK ↑ CELTIK ↑ 351 → BRENT ↑343	0.98	1.03	1.87
11	MISIR ↑ KAKAO ↑ PAMUK ↑ BUGDAY ↑ 344 → BRENT ↑336	0.98	1.03	1.83
12	MISIR ↑ KAKAO ↑ BAKIR ↑ KAHVE ↑ 338 → BRENT ↑330	0.98	1.03	1.8
13	KAKAO ↑ KERESTE ↑ CELTIK ↑ 464 → BRENT ↑453	0.98	1.03	1.85
14	WTI ↑ BAKIR ↑ SEKER ↑ BUGDAY ↑ 331 → BRENT ↑323	0.98	1.02	1.76
15	MISIR ↑ KAKAO ↑ DOGALGAZ ↑ BUGDAY ↑ 331 → BRENT ↑323	0.98	1.02	1.76
16	SOYA ↑ MISIR ↑ KAKAO ↑ BAKIR ↑ 412 → BRENT ↑402	0.98	1.02	1.79
17	ALTIN ↑ MISIR ↑ CELTIK ↑ BUGDAY ↑ 366 → BRENT ↑357	0.98	1.02	1.75
18	MISIR ↑ KAKAO ↑ BAKIR ↑ 527 → BRENT ↑514	0.98	1.02	1.8
19	MISIR ↑ GUMUS ↑ KAKAO ↑ BUGDAY ↑ 359 → BRENT ↑350	0.97	1.02	1.72
20	KAKAO ↑ BAKIR ↑ BUGDAY ↑ 478 → BRENT ↑466	0.97	1.02	1.76
21	SIGIR ↑ MISIR ↑ BAKIR ↑ BUGDAY ↑ 353 → BRENT ↑344	0.97	1.02	1.69
22	WTI ↑ MISIR ↑ BAKIR ↑ DOGALGAZ ↑ 352 → BRENT ↑343	0.97	1.02	1.69
23	KAKAO ↑ KAHVE ↑ CELTIK ↑ 507 → BRENT ↑494	0.97	1.02	1.73
24	WTI ↑ PAMUK ↑ BUGDAY ↑ 502 → BRENT ↑489	0.97	1.02	1.72
25	WTI ↑ KAHVE ↑ CELTIK ↑ 496 → BRENT ↑483	0.97	1.02	1.7

Not: ↑ yönlü ok emtiaın günlük getirisinin pozitif, ↓ yönlü ok emtia fiyatının getirisinin negatif olduğunu göstermektedir. → ise birlikte harekete eşlik eden emtiayı göstermektedir. (Conf: güven düzeyini, lift: birlikte hareket etme katsayısı ve Conv: ilişki düzeyini göstermektedir.

İkinci ařamada minimum %90 güven (Confidence) düzeyi ve %10 destek (support) seviyesi temel alınarak toplam 100 kural elde edilmiř ve bu 100 kuralın ilk 25 tanesi Tablo 13'te gsterilmiřtir. Tablo 13 incelendiđinde ilk 4 birliktelik kuralının %97 güven düzeyinde, diđerlerinin ise %96 güven düzeyinde olduđu grrlmektedir.

Tablo 13. FP Growth Algoritması ile Elde Edilen Üç Deđişkenli İlk 25 Kural

	Birliktelik Kuralları			Conf	Lift.	Conv.
1	KAKAO ↑ CELTIK ↑	847	→ BRENT ↑819	0.97	1.02	1.4
2	WTI ↑ CELTIK ↑	869	→ BRENT ↑840	0.97	1.02	1.39
3	KAKAO ↑ BUGDAY ↑	838	→ BRENT ↑809	0.97	1.01	1.34
4	DOGALGAZ ↑ CELTIK ↑	836	→ BRENT ↑807	0.97	1.01	1.33
5	WTI ↑ BUGDAY ↑	851	→ BRENT ↑821	0.96	1.01	1.31
6	MISIR ↑ BAKIR ↑	933	→ BRENT ↑900	0.96	1.01	1.31
7	KAKAO ↑ DOGALGAZ ↑	848	→ BRENT ↑818	0.96	1.01	1.31
8	KAKAO ↑ BAKIR ↑	918	→ BRENT ↑885	0.96	1.01	1.29
9	KAHVE ↑ CELTIK ↑	860	→ BRENT ↑829	0.96	1.01	1.29
10	MISIR ↑ KAKAO ↑	880	→ BRENT ↑848	0.96	1.01	1.28
11	BAKIR ↑ DOGALGAZ ↑	878	→ BRENT ↑846	0.96	1.01	1.27
12	ALTIN ↑ CELTIK ↑	856	→ BRENT ↑824	0.96	1.01	1.24
13	KAKAO ↑ PAMUK ↑	867	→ BRENT ↑834	0.96	1.01	1.22
14	MISIR ↑ CELTIK ↑	945	→ BRENT ↑909	0.96	1.01	1.22
15	NIKEL ↑ DOGALGAZ ↑	840	→ BRENT ↑808	0.96	1.01	1.22
16	SIGIR ↑ DOGALGAZ ↑	885	→ BRENT ↑851	0.96	1.01	1.21
17	SOYA ↑ KAKAO ↑	904	→ BRENT ↑869	0.96	1.01	1.2
18	PAMUK ↑ DOGALGAZ ↑	850	→ BRENT ↑817	0.96	1.01	1.2
19	KAKAO ↑ KERESTE ↑	871	→ BRENT ↑837	0.96	1.01	1.19
20	BAKIR ↑ KAHVE ↑	919	→ BRENT ↑883	0.96	1.01	1.19
21	SIGIR ↑ KAKAO ↑	913	→ BRENT ↑877	0.96	1.01	1.18
22	SIGIR ↑ BUGDAY ↑	887	→ BRENT ↑852	0.96	1.01	1.18
23	KAKAO ↑ KAHVE ↑	937	→ BRENT ↑900	0.96	1.01	1.18
24	MISIR ↑ DOGALGAZ ↑	881	→ BRENT ↑846	0.96	1.01	1.17
25	WTI ↑ SEKER ↑	926	→ BRENT ↑889	0.96	1.01	1.17

Not: ↑ yönlü ok emtianın günlük getirisinin pozitif, ↓ yönlü ok emtia fiyatının getirisinin negatif olduđunu gstermektedir. → ise birlikte harekete eşlik eden emtiayı gstermektedir.

(Conf: güven düzeyini, lift: birlikte hareket etme katsayısı ve Conv: ilişki düzeyini gstermektedir.)

Kural 1 incelendiđinde; kakao ve çeltik emtialarındaki 847 gün birlikte artışına Brent petrol 819 gün artış yönünde eşlik etmiştir. Bu kuralın güven düzeyi, 819/847 işlem sonucunda %97 olarak hesaplanmıştır. Kural 2 incelendiđinde; WTI ve çeltik emtialarındaki 869 gün birlikte artışına Brent petrol 840 gün artış yönünde eşlik etmiştir. Bu kuralın güven düzeyi, 840/869 işlem sonucunda %97 olarak hesaplanmıştır. Kural 3 incelendiđinde; kakao ve buđday emtialarındaki 838 gün birlikte artışına Brent petrol 809 gün artış yönünde eşlik etmiştir. Bu kuralın güven düzeyi, 809/838 işlem sonucunda %97 olarak hesaplanmıştır. Diđer tüm birliktelik kurallarında Brent petrolün diđer emtialara eşlik ettiđi grrlmektedir. Bu durum brent petrolün emtialar arasında belirleyici olduđunu gstermektedir.

6. Sonuç

Emtia piyasalarının 2000'li yılların başında finansallařması ile birlikte, emtia piyasalarına yapılan yatırımlarda büyük artış yařanmış ve sundukları çeřitlendirme fırsatları nedeniyle küresel yatırımcıların ilgisini çekmeye başlamışlardır. Dolayısıyla emtialar, yatırımcılar tarafından

özellikle portföy çeşitlendirme ve enflasyona karşı korunmak için alternatif bir varlık sınıfı olarak görülmüştür. Bu yüzden emtialar birçok yatırımcı için güvenli liman ve riskten korunmak için en iyi alternatif olarak görülmektedir. Günümüzde yatırımcılar, finansal piyasalardaki varlıkların hangi yönde hareket ettiğini yakından takip etmektedir. Özellikle küresel finans piyasalarının entegrasyonu, finansal piyasaları daha fazla birlikte hareket etme kabiliyetini artırmaktadır. Bu doğrultuda yatırımcıların özellikle riskten ve enflasyondan korunmak için portföylerine yeni varlık sınıflarını ekleme iştahı giderek artmaktadır. Dolayısıyla yatırımcıların bir borsanın düşüşü veya yükselişi sonrasında diğer borsaların veya finansal varlıkların hangi yöne doğru hareket edeceğini öngörmesi, hızlı ve etkili kararlar almasında kritik öneme sahiptir. Emtialar arasındaki ortak hareket, iki veya daha fazla emtianın birlikte hareket etmesi ve bir emtia fiyatının artış veya azalışı diğer emtiaları etkilediğinde bu durum emtia vadeli işlem piyasalarındaki tüccarlara ve yatırımcılara değerli bilgiler sunabilir.

Spekülatörler, risk yönetimi, riskten korunma stratejileri ve varlık fiyatlandırması için vadeli işlem piyasalarında spekülasyon yapmak amacıyla fiyat hareketleri ve bunların bağlantıları hakkında bilgi edinmek isterken (Chao vd., 2021; Kou vd., 2021), tüccarlar ise fiyat hareketlerini tahmin edebilmek için belirli emtiaların fiyatları arasındaki bağlantıyı bilmek isterler. Petrol, enerji kaynağı olarak en yaygın kullanılan emtia olduğundan, enerji maliyetleri ve dolayısıyla üretim maliyetleri aracılığıyla hemen hemen diğer tüm emtialarla bağlantısı vardır. Bu nedenle petrol fiyatları diğer birçok emtia üzerinde yayılma etkisine sahiptir. Bu durum üretim maliyetleri, yurt içi enflasyon ve döviz kurları aracılığıyla petrol fiyatlarının küresel ekonomideki önemini arttırmaktadır.

Bu çalışmada 20 emtia piyasasının birlikte hareketleri veri madenciliği yöntemlerinden birliktelik kuralı ile analiz edilmiştir. Analizler için 20 emtianın 01.01.2010-01.08.2023 tarihleri arasındaki 3.216 günlük kapanış fiyatları dikkate alınmıştır. Çalışmada analizler için literatürde sıklıkla kullanılan birliktelik kuralı algoritmalarından Apriori ve FP-Growth algoritmaları kullanılmıştır.

Apriori algoritması ile öncelikle % 98 güven (confidence) ve %10 destek (support) düzeyi temel alınarak toplam 100 kural üretilmiş ve en yüksek güven seviyesine sahip ilk 25 adet üç değişkenli ve dört değişkenli kuralların tümünde Brent petrolün diğer emtialara eşlik ettiği görülmüştür. Brent petrolden sonra ilk 25 kuralda en yüksek görülme sıklığı platin 11, kakao 9, sığır 8, çinko 8, soya 8, buğday 7, paladyum 5, mısır 5, WTI 4, pamuk 3, doğalgaz 3, bakır 3, şeker 2, kahve 1, nikel 1 ve çeltik 1 kuralda görülmüştür. Apriori algoritması ile ikinci aşamada güven (confidence) düzeyi %90 ve %25 destek (support) düzeyi temel alınarak elde edilen 100 kuraldan ilk 25 iki değişkenli kuralların tümünde de yine Brent petrolün diğer emtialar eşlik ettiği görülmüştür. Brent petrolden sonra en yüksek görülme sıklığı kakao 8, doğalgaz 6, çeltik 6, platin 4, buğday 3, paladyum 3, mısır 3, pamuk 3, bakır 3, WTI 2, kahve 1, nikel 1, altın 1, sığır 1, soya 1, gümüş 1 ve kereste 1 kuralda görülmüştür.

FP-Growth algoritması ile öncelikle %97 güven (confidence) düzeyi ve %10 destek (support) seviyesi temel alınarak toplam 77 adet dört değişkenli ve beş değişkenli kurallar elde edilmiş ve bu kurallardan en yüksek güven düzeyine sahip ilk 25 kuralın tümünde Brent petrolün diğer emtialara eşlik ettiği tespit edilmiştir. Brent petrolden sonra en yüksek görülme sıklığı mısır 19, buğday 15, bakır 11, WTI 11, kakao 10, çeltik 9, doğalgaz 4, kahve 4, pamuk 4, gümüş 2, kereste 1, soya 1, altın 1, sığır 1 ve şeker 1 kuralda gözlemlenmiştir. İkinci aşamada minimum %90 güven (confidence) düzeyi ve %10 destek (support) seviyesi temel alınarak iki ve üç

deęişkenli toplam 100 kural elde edilmiş ve ilk 25 kuralın tümünde Brent petrolün dięer emtialara eşlik ettięi görülmüştür. Brent petrolden sonra en yüksek görölme sıklığı kakao 11, doğalgaz 7, çeltik 6, mısır 4, bakır 4, buęday 3, sığır 3, kahve 3, WTI 2, pamuk 2, soya 1, kereste 1, altın 1 ve nikel 1 kuralda gözlemlenmiştir.

FP-Growth algoritması ile üretilen dört deęişkenli ve beş deęişkenli kuralların (Tablo 12), Apriori algoritması ile üretilen dört deęişkenli (Tablo 10) kurallara göre daha sık öęe oluşturduęu görülmüştür. Dięer bir ifadeyle FP-Growth algoritması ile üretilen ilk 25 kural (Tablo 12), apriori algoritması ile oluşturulan ilk 25 kuraldan (Tablo 10) daha sık öęe kümeleri oluşturmuştur. Hem apriori hem de FP-Growth algoritmaları ile üretilen üç deęişkenli (Tablo 11 ve 12) kurallar ise benzer sonuçlar vermiştir.

Hem apriori hem de FP-Growth algoritmaları ile üretilen kuralların tümünde Brent petrolün dięer emtialara eşlik ettięi gözlemlenmiştir. Bu durumda, yatırımcıların emtia yatırımları ile ilgili kararlarında, Brent petrolün hareketlerini yakından takip etmeleri kritik öneme sahiptir. Dolayısıyla Brent petrol fiyatlarının yukarı veya aşağı yönde hareketinin Brent petrol fiyatlarını yakından takip eden yatırımcılara, karar vericilere ve politika yapıcılara, dięer emtiaların hareketi ile ilgili yol gösterici olabileceęi de söylenebilir. Ayrıca sonuçlar, yatırımcıların tek bir emtiayı analiz ederek deęil emtiaların ortak hareketlerini de dikkate alarak yatırım kararı vermesinde etkili olabilir. Ham petrol, dięer emtia piyasalarını çeşitli şekillerde etkiledięi için stratejik bir emtia olduęu söylenebilir. Petrolün emtia piyasalarında kilit rol oynadıęı gerçeęi göz önüne alındığında, sonuçların şaşırtıcı olmadığı söylenebilir. Bu sonuçlar ayrıca teoriyi de desteler niteliktedir. Çünkü ham petrol fiyatlarındaki artışlar harcanabilir geliri azaltarak sanayi üretimini yavaşlatabilir. Prensip olarak harcanabilir gelirin düşük olması, özellikle tarım emtiaları üzerinde olumsuz bir etkiye sahip olabilir. Öte yandan, sanayi üretimindeki düşüş, hammadde ve deęerli metal talebini olumsuz etkileyerek fiyatlar üzerinde aşağı yönlü bir baskı oluşturabilir. Bu nedenle ham petrol fiyatlarındaki artışların artan üretim/ulaştırma maliyetleri yoluyla tarım emtiaları fiyatları üzerinde olumsuz bir etkiye sahip olması beklenir.

Gelecek çalışmalarda farklı borsalarda benzer yöntem kullanılarak, farklı çalışmalar yapılabilir. Özellikle borsaların birlikte hareketleri bulanık (fuzzy) birliktelik kuralı ile analiz edilebilir. Bu sayede borsalar arasındaki etkileşimler keşfedilebilir.

Araştırma ve Yayın Etięi Beyanı

Etik kurul izni ve/veya yasal/özel izin alınmasına gerek olmayan bu çalışmada araştırma ve yayın etięine uyulmuştur.

Arařtırmacıların Katkı Oranı Beyanı

Yazar, makalenin tamamına yalnız kendisinin katkı sağlamış olduęunu beyan eder.

Arařtırmacıların Çıkar Çatışması Beyanı

Bu çalışmada herhangi bir potansiyel çıkar çatışması bulunmamaktadır.

Kaynakça

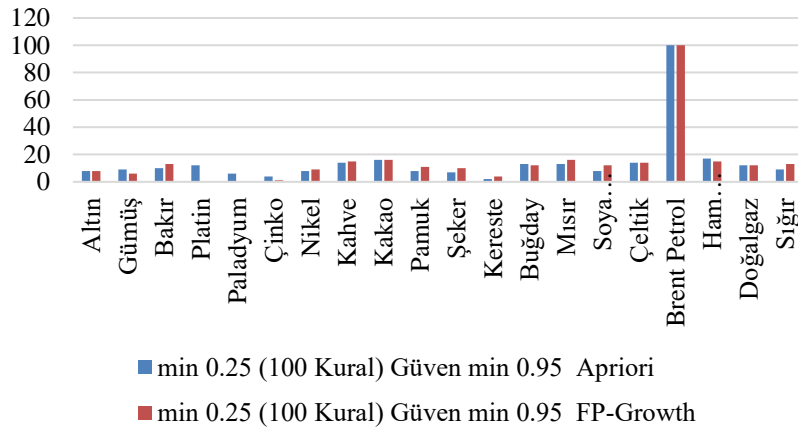
- Abid, I., Dhaoui, A., Goutte, S. and Guesmi, K. (2020). Hedging and diversification across commodity assets. *Applied Economics*, 52(23), 2472-2492. <https://doi.org/10.1080/00036846.2019.1693016>
- Agrawal, R., Imieliński, T., and Swami, A. (1993). Mining association rules between sets of items in large databases. In P. Buneman, S. Jajodia and W. Kim (Eds.), *SIGMOD '93: Proceedings of the 1993 ACM SIGMOD international conference on management of data* (pp. 207-216). Papers presented at the SIGMOD International Conference on Management of Data, New York: Association for Computing Machinery.
- Agrawal, R. and Srikant, R. (1994). Fast algorithms for mining association rules. In J.B. Bocca, M. Jarke and C. Zaniolo (Eds.), *Proceedings of 20th international conference on very large data bases* (pp. 487-499). Papers presented at the International Joint Conference on Very Large Data Bases, Santiago Chile, San Fransisco: Morgan Kaufmann Publishers.
- Algieri, B. and Leccadito, A. (2017). Assessing contagion risk from energy and non-energy commodity markets. *Energy Economics*, 62, 312-322. <https://doi.org/10.1016/j.eneco.2017.01.006>
- Arafah, A.A. and Mukhlash, I. (2015). The application of fuzzy association rule on co-movement analyze of Indonesian stock price. *Procedia Computer Science*, 59, 235-243. <https://doi.org/10.1016/j.eneco.2017.01.006>
- Argiddi, R.V. and Apte, S.S. (2012). Future trend prediction of Indian IT stock market using association rule mining of transaction data. *International Journal of Computer Applications*, 39(10), 30-34. <https://doi.org/10.5120/4858-7132>
- Arouri, M.E.H., Hammoudeh, S., Lahiani, A. and Nguyen, D.K. (2013). On the short-and long-run efficiency of energy and precious metal markets. *Energy Economics*, 40, 832-844. <https://doi.org/10.1016/j.eneco.2013.10.004>
- Azeez, N.A., Ayemobola, T.J., Misra, S., Maskeliūnas, R. and Damaševičius, R. (2019). Network intrusion detection with a hashing based Apriori algorithm using Hadoop MapReduce. *Computers*, 8(4), 86. <https://doi.org/10.3390/computers8040086>
- Basak, S. and Pavlova, A. (2016). A model of financialization of commodities. *The Journal of Finance*, 71(4), 1511-1556. <https://doi.org/10.1111/jofi.12408>
- Basu, D. and Miffre, J. (2013). Capturing the risk premium of commodity futures: The role of hedging pressure. *Journal of Banking and Finance*, 37(7), 2652-2664. <https://doi.org/10.1016/j.jbankfin.2013.02.031>
- Bramer, M. (2016). *Principles of data mining*. London: Springer.
- CFTC. (2023). *Commodity futures trading commission*. Retrieved from <https://www.cftc.gov/>
- Chalid, D.A. and Handika, R. (2022). Comovement and contagion in commodity markets. *Cogent Economics & Finance*, 10(1), 2064079. <https://doi.org/10.1080/23322039.2022.2064079>
- Chao, X., Kou, G., Peng, Y. and Viedma, E.H. (2021). Large-scale group decision-making with non-cooperative behaviors and heterogeneous preferences: An application in financial inclusion. *European Journal of Operational Research*, 288(1), 271-293. <https://doi.org/10.1016/j.ejor.2020.05.047>
- Chen, M.S., Han, J. and Yu, P.S. (1996). Data mining: An overview from a database perspective. *IEEE Transactions on Knowledge and Data Engineering*, 8(6), 866-883. doi:10.1109/69.553155
- Cheng, I.H. and Xiong, W. (2014). Financialization of commodity markets. *Annual Review of Financial Economics*, 6(1), 419-441. <https://doi.org/10.1146/annurev-financial-110613-034432>
- Daskalaki, C. and Skiadopoulos, G. (2011). Should investors include commodities in their portfolios after all? New evidence. *Journal of Banking & Finance*, 35(10), 2606-2626. <https://doi.org/10.1016/j.jbankfin.2011.02.022>
- Diamandis, P.F. (2009). International stock market linkages: Evidence from Latin America. *Global Finance Journal*, 20(1), 13-30. <https://doi.org/10.1016/j.gfj.2009.03.005>

- Dunham, M.H. (2006). *Data mining: Introductory and advanced topics*. London: Pearson.
- Erpolat, S. (2012). Otomobil yetkili servislerinde birliktelik kurallarının belirlenmesinde Apriori ve FP-Growth algoritmalarının karřılařtırılması. *Anadolu Üniversitesi Sosyal Bilimler Dergisi*, 12(1), 151-166. Eriřim adresi: <https://earsiv.anadolu.edu.tr/>
- Frankel, J.A. and Rose, A.K. (2010) *Determinants of agricultural and mineral commodity prices* (HKS Faculty Research Working Paper No. RWP10-038). Retrieved from <https://dash.harvard.edu/handle/1/4450126>
- Gilbert, C.L. (2010). Commodity speculation and commodity investment. *Market Review*, 28, 26-46. doi:10.5555/20103231905
- Han, J., Kamber, M. and Pei, J. (2012). *Data mining concepts and techniques*. New York: Elsevier.
- Han, J., Pei, J. and Kamber, M. (2011). *Data mining: Concepts and techniques*. New York: Elsevier.
- Han, J., Pei, J. and Yin, Y. (2000). Mining frequent patterns without candidate generation. *ACM Sigmod Record*, 29(2), 1-12. <https://doi.org/10.1145/335191.335372>
- Heil, T.L., Peter, F.J. and Prange, P. (2022). Measuring 25 years of global equity market co-movement using a time-varying spatial model. *Journal of International Money and Finance*, 128, 102708. <https://doi.org/10.1016/j.jimonfin.2022.102708>
- Hernández, C.J.B., García-Medina, A. and Porro, V.M.A. (2021). Study of the behavior of cryptocurrencies in turbulent times using association rules. *Mathematics*, 9(14), 1620. <https://doi.org/10.3390/math9141620>
- Ho, G.T., Ip, W.H., Wu, C.H. and Tse, Y.K. (2012). Using a fuzzy association rule mining approach to identify the financial data association. *Expert Systems with Applications*, 39(10), 9054-9063. <https://doi.org/10.1016/j.eswa.2012.02.047>
- Inaba, K.I. (2020). A global look into stock market comovements. *Review of World Economics*, 156(3), 517-555. <https://doi.org/10.1007/s10290-019-00370-1>
- Jalpa, P.P. and Rustom, M.D. (2017). A novel hybrid method for generating association rules for stock market data. *International Journal of Latest Technology in Engineering, Management & Applied Science 3rd Special Issue on Engineering and Technology* 6(7), 6-15. Retrieved from <https://www.ijltemas.in/>
- Ji, Q. and Fan, Y. (2012). How does oil price volatility affect non-energy commodity markets? *Applied Energy*, 89(1), 273-280. <https://doi.org/10.1016/j.apenergy.2011.07.038>
- Kang, W., Tang, K. and Wang, N. (2023). Financialization of commodity markets ten years later. *Journal of Commodity Markets*, 30, 100313. <https://doi.org/10.1016/j.jcomm.2023.100313>
- Kantardzic, M. (2020). *Data mining: Concepts, models, methods, and algorithms*. John Wiley & Sons.
- Karaatlı, M., Kocabıyık, T., Yalçiner Çal, D. ve Çolak, M. (2021). BIST-30 Endeksinde yer alan payların ortak hareketlerinin veri madencilięi kapsamında birliktelik kuralı ile incelenmesi. *Finansal Arařtırmalar ve Çalıřmalar Dergisi*, 13(25), 548-571. <https://doi.org/10.14784/marufacd.976609>
- Kartal, B., Sert, M.F. and Kutlu, M. (2022). Determination of the world stock indices' co-movements by association rule mining. *Journal of Economics, Finance and Administrative Science*, 27(54), 231-246. <https://doi.org/10.1108/JEFAS-04-2020-0150>
- Kaur, J. and Dharni, K. (2022). Assessing efficacy of association rules for predicting global stock indices. *Decision*, 49(3), 329-339. <https://doi.org/10.1007/s40622-022-00327-8>
- Kavitha, M. and Selvi, S.T. (2016). Comparative study on Apriori algorithm and FP growth algorithm with pros and cons. *International Journal of Computer Science Trends and Technology*, 4(4), 161-164. Retrieved from <https://api.semanticscholar.org>
- Kirikaleli, D. and Güngör, H. (2021). Co-movement of commodity price indexes and energy price index: A wavelet coherence approach. *Financial Innovation*, 7(1), 15. <https://doi.org/10.1186/s40854-021-00230-8>


- Kocabıyık, T., Dağ, O. ve Karaatlı, M. (2021). Borsa İstanbul endekslerinin birlikte hareketi: FP Growth algoritması ile bir uygulama. *Uluslararası İşletme, Ekonomi ve Yönetim Perspektifleri Dergisi (IJBEMP)*, 5(2), 659-672. doi:10.29228/ijbemp.52518
- Kotu, V. and Deshpande, B. (2018). *Data science: Concepts and practice*. Massachusetts: Morgan Kaufmann.
- Kou, G., Xu, Y., Peng, Y., Shen, F., Chen, Y., Chang, K. and Kou, S. (2021). Bankruptcy prediction for SMEs using transactional data and two-stage multiobjective feature selection. *Decision Support Systems*, 140, 113429. <https://doi.org/10.1016/j.dss.2020.113429>
- Lee, C.C. and Lee, C.C. (2023). International spillovers of US monetary uncertainty and equity market volatility to China's stock markets. *Journal of Asian Economics*, 84, 101575. <https://doi.org/10.1016/j.asieco.2022.101575>
- Liao, S.H. and Chou, S.Y. (2013). Data mining investigation of co-movements on the Taiwan and China stock markets for future investment portfolio. *Expert Systems with Applications*, 40(5), 1542-1554. <https://doi.org/10.1016/j.eswa.2012.08.075>
- Liao, S.H., Chu, P.H. and You, Y.L. (2011). Mining the co-movement between foreign exchange rates and category stock indexes in the Taiwan financial capital market. *Expert Systems with Applications*, 38(4), 4608-4617. <https://doi.org/10.1016/j.eswa.2010.09.134>
- Liao, S.H., Ho, H.H. and Lin, H.W. (2008). Mining stock category association and cluster on Taiwan stock market. *Expert Systems with Applications*, 35(1-2), 19-29. <https://doi.org/10.1016/j.eswa.2007.06.001>
- Liu, C., Zhang, X. and Zhou, Z. (2023). Are commodity futures a hedge against inflation? A Markov-switching approach. *International Review of Financial Analysis*, 86, 102492. <https://doi.org/10.1016/j.irfa.2023.102492>
- Liu, X., Zhao, Y. and Sun, M. (2017). An improved Apriori algorithm based on an evolution-communication tissue-like p system with promoters and inhibitors. *Discrete Dynamics in Nature and Society*, 2017, 6978146. <https://doi.org/10.1155/2017/6978146>
- Masum, Z.H. (2019). Mining stock category association on Tehran stock market. *Soft Computing*, 23, 1165-1177. <https://doi.org/10.1007/s00500-017-2835-9>
- Matesanz, D., Torgler, B., Dabat, G. and Ortega, G.J. (2014). Co-movements in commodity prices: A note based on network analysis. *Agricultural Economics*, 45(S1), 13-21. doi:10.1111/agec.12126
- Mbarki, I., Khan, M.A., Karim, S., Paltrinieri, A. and Lucey, B.M. (2023). Unveiling commodities-financial markets intersections from a bibliometric perspective. *Resources Policy*, 83, 103635. <https://doi.org/10.1016/j.resourpol.2023.103635>
- Memis, E. and Kaya, H. (2019). Association rule mining on the BIST100 stock exchange. Paper presented at the *2019 3rd International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT)*. Ankara, Turkey. Retrieved from <https://ieeexplore.ieee.org/document/8932923>
- Mensi, W., Tiwari, A., Bouri, E., Roubaud, D. and Al-Yahyaee, K.H. (2017). The dependence structure across oil, wheat, and corn: A wavelet-based copula approach using implied volatility indexes. *Energy Economics*, 66, 122-139. <https://doi.org/10.1016/j.eneco.2017.06.007>
- Na, S.H. and Sohn, S.Y. (2011). Forecasting changes in Korea composite stock price index (KOSPI) using association rules. *Expert Systems with Applications*, 38(7), 9046-9049. <https://doi.org/10.1016/j.eswa.2011.01.025>
- NASDAQ. (2024). *Nasdaq website* [Dataset]. Retrieved from <https://www.nasdaq.com/>
- Nazlioglu, S. and Soytaş, U. (2012). Oil price, agricultural commodity prices, and the dollar: A panel cointegration and causality analysis. *Energy Economics*, 34(4), 1098-1104. <https://doi.org/10.1016/j.eneco.2011.09.008>
- Ohashi, K. and Okimoto, T. (2016). Increasing trends in the excess comovement of commodity prices. *Journal of Commodity Markets*, 1(1), 48-64. <https://doi.org/10.1016/j.jcomm.2016.02.001>

- Paranjape-Voditel, P. and Deshpande, U. (2013). A stock market portfolio recommender system based on association rule mining. *Applied Soft Computing*, 13(2), 1055-1063. <https://doi.org/10.1016/j.asoc.2012.09.012>
- Patel, R.J. (2019). BRICS emerging markets linkages. *The Journal of Private Equity*, 22(4), 42-59. Retrieved from <https://www.jstor.org/>
- Prasanna, S. and Ezhilmaran, D. (2016). Association rule mining using enhanced Apriori with modified GA for stock prediction. *International Journal of Data Mining, Modelling and Management*, 8(2), 195-207. <https://doi.org/10.1504/IJDMMM.2016.077162>
- Rehman, M.U., Bouri, E., Eraslan, V. and Kumar, S. (2019). Energy and non-energy commodities: An asymmetric approach towards portfolio diversification in the commodity market. *Resources Policy*, 63, 101456. <https://doi.org/10.1016/j.resourpol.2019.101456>
- Sidhu, S., Meena, U. K., Nawani, A., Gupta, H. and Thakur, N. (2014). FP Growth algorithm implementation. *International Journal of Computer Applications*, 93(8), 6-10. doi:10.5120/16233-5613
- Singhal, S., Choudhary, S. and Biswal, P.C. (2019). Return and volatility linkages among international crude oil price, gold price, exchange rate and stock markets: Evidence from Mexico. *Resources Policy*, 60, 255-261. <https://doi.org/10.1016/j.resourpol.2019.01.004>
- Son, L.H., Chiclana, F., Kumar, R., Mittal, M., Khari, M., Chatterjee, J.M. and Baik, S.W. (2018). ARM-AMO: An efficient association rule mining algorithm based on animal migration optimization. *Knowledge-Based Systems*, 154, 68-80. <https://doi.org/10.1016/j.knosys.2018.04.038>
- Srisawat A. (2011). *An application of association rule mining based on stock market*. Paper presented at the 3rd International Conference on Data Mining and Intelligent Information Technology Applications (ICMIA), Macao, China: IEEE. Retrieved from <https://ieeexplore.ieee.org/document/6108440>
- Stoll, H.R. and Whaley, R. (2010). Commodity index investing and commodity futures prices. *Journal of Applied Finance (Formerly Financial Practice and Education)*, 20(1). Retrieved from <https://papers.ssrn.com>
- Teker, T. ve Konuşkan, A (2022). Fan token fiyatlarında birliktelik etkisi. *Uluslararası İşletme, Ekonomi ve Yönetim Perspektifleri Dergisi*, 6(2), 359-376. <http://dx.doi.org/10.29228/ijbemp.65914>
- Umar, Z., Jareño, F. and Escribano, A. (2022). Dynamic return and volatility connectedness for dominant agricultural commodity markets during the COVID-19 pandemic era. *Applied Economics*, 54(9), 1030-1054. <https://doi.org/10.1080/00036846.2021.1973949>
- Ünsal, Ö. (2020). Veri madenciliği teknikleri ile hisse senetleri arasındaki fiyat etkileşimlerinin belirlenmesi. *Mühendislik Bilimleri ve Tasarım Dergisi*, 8(5), 106-112. <https://doi.org/10.21923/jesd.834105>
- Vacha, L., Janda, K., Kristoufek, L. and Zilberman, D. (2013). Time-frequency dynamics of biofuel-fuel-food system. *Energy Economics*, 40, 233-241. <https://doi.org/10.1016/j.eneco.2013.06.015>
- Vivian, A. and Wohar, M.E. (2012). Commodity volatility breaks. *Journal of International Financial Markets, Institutions and Money*, 22(2), 395-422. <https://doi.org/10.1016/j.intfin.2011.12.003>
- Wang, Y., Wu, C. and Yang, L. (2014). Oil price shocks and agricultural commodity prices. *Energy Economics*, 44, 22-35. <https://doi.org/10.1016/j.eneco.2014.03.016>
- Yang, D.L., Hsieh, Y.L. and Wu, J. (2006). Using data mining to study upstream and downstream causal relationship in stock market. In X. Luo, A.A. Almohammed, C-H. Chen, S. Guan and D. Pamucar (Eds.), *Advances in intelligent systems research* (pp. 528-531). Papers presented at the 9th Joint International Conference on Information Sciences (JCIS-06). Atlantis Press. doi:10.2991/jcis.2006.191
- Zhang, X., Liu, Q., Tang, Y., Liu, G., Ning, X. and Chen, J. (2021). A FP-Growth algorithm based fault analysis method for distribution terminal unit. In J. Shi (Ed.), *2021 IEEE/IAS industrial and commercial power system Asia (I&CPS Asia)* (pp. 1463-1467). Papers presented at the IEEE/IAS Industrial and Commercial Power System Asia Conference, Chengdu, China: IEEE.

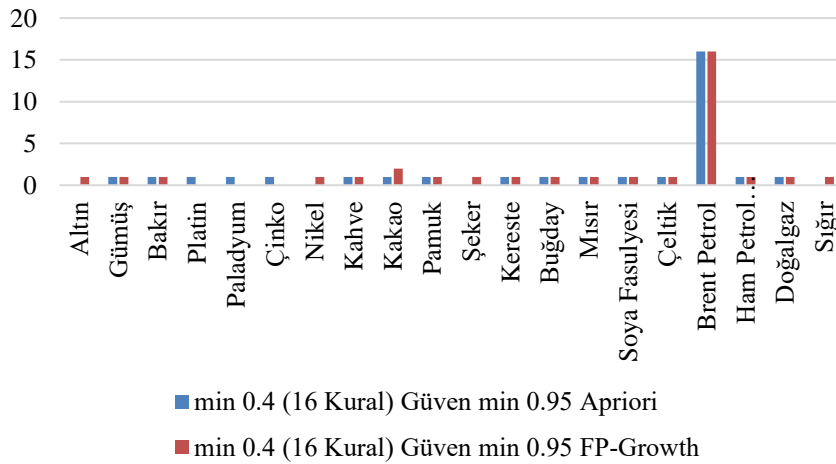
Ek 1. Farklı Destek ve Güven Değerlerine Göre Ortaya Çıkan Kural Sayıları



Grafik 1. 0.25 Destek Seviyesi ve 0.95 Güven Düzeyinde 100 Kural



Grafik 2. 0.3 Destek Seviyesi ve 0.95 Güven Düzeyinde 20 Kural



Grafik 3. 0.4 Destek Seviyesi ve 0.95 Güven Düzeyinde 16 Kural

AN INVESTIGATION OF CO-MOVEMENTS OF COMMODITY MARKETS BY DATA MINING

EXTENDED SUMMARY

The Aim of the Study

The aim of this study is to investigate the co-movement of commodity markets by the data mining method. In this context, in the study, the co-movement of commodity markets are examined by Apriori and FP-Growth algorithms, which are association rule analysis techniques in data mining methods.

Considering the fact that the co-movements of commodity markets have been investigated with many different methods in the literature, it is thought that the association rule analysis used in this study will enrich the literature. Another contribution of the study to the literature is that it allows a comparison of the rules produced by Apriori and FP-Growth algorithms, which are association rule algorithms.

Literature Review

In their study, Hernández et al. (2021) analyzed the joint movements of cryptocurrencies with the data mining method. Karaatlı et al. (2021) stated that in order to create a portfolio, shares in the BIST 30 index are included in macroeconomic variables (M1 money supply, gold ounce price, export-import coverage ratio, industrial production index, foreign exchange basket, manufacturing industry capacity utilization rate, interest, producer price index, financial FP-Growth algorithm was used to analyze its movement with services confidence index, international direct investments, crude oil, S&P 500 index). In their study, Kartal et. al. (2022) analyzed the joint movements of 11 stock market indices in the world between 2001 and 2009 with the association rule algorithm in data mining methods. Kaur and Dharni (2022) selected seven countries for analysis, consisting of developed markets (Japan, the United Kingdom, and the United States) and emerging markets (South Africa, India, Brazil, and China) according to the MSCI (Morgan Stanley Capital International) market classification. In their study, Teker and Konuskan (2022) examined the joint movements of cryptocurrencies issued by football clubs with association analysis from data mining applications.

Methodology

Association rules introduced by Agwaral, et.al. (1993) are used to identify patterns and frequently recurring elements in a data set. Nowadays, the association rules analysis method is used in marketing, finance, health, science, engineering, etc. It is frequently used in many fields (Son et al., 2018). For example, if a person who buys product X also buys product Y, it can be said that there is a relationship between product X and product Y, and this information is useful information for decision makers. Therefore, the main purpose of applying the algorithms developed for association rules analysis is to find simultaneous relationships by analyzing random data and use these relationships as a reference during decision-making (Liao et.al. 2011: 4611).

Findings

With the Apriori algorithm, a total of 100 rules were generated based on a confidence level of 98% and a support level of 10%, and it was observed that Brent oil accompanied other commodities in all of the first 25 trivariate and four-variate rules with the highest confidence level.

With the FP-Growth algorithm, a total of 77 four-variable and five-variable rules were generated based on 97% confidence level and 10% support level, and it was found that Brent oil accompanied other commodities in all of the first 25 rules with the highest confidence level.

Conclusion

In all the rules generated by both Apriori and FP-Growth algorithms, Brent oil is observed to accompany other commodities. In this case, it is critical for investors to closely follow the movements of Brent oil in their commodity investment decisions. Therefore, it can be said that the upward or downward movement of Brent oil prices can guide investors who closely follow Brent oil prices regarding the movement of other commodities. Crude oil is a strategic commodity as it affects other commodity markets in various ways. Given the fact that oil plays a key role in commodity markets, the results are not surprising. These results also support the theory since increases in crude oil prices can slow down industrial production by reducing disposable income. In principle, lower disposable income can have a negative impact, especially on agricultural commodities. On the other hand, a decline in industrial production may adversely affect demand for raw materials and precious metals, putting downward pressure on prices. Higher crude oil prices are therefore expected to have a negative impact on agricultural commodity prices through higher production/transportation costs.