
BAYES AĞ MODELLERİ İLE HİSSE SENEDİ GETİRİLERİNİN KARŞILIKLI DİNAMİK İLİŞKİLERİ

Busem HATİPOĞLU¹

Umut UYAR²

Öz

Modern portföy teorisinde, portföyde yer alan menkul kıymetler arasındaki ilişkinin yönünün ve derecesinin riskin azaltılması yönünde etkili olduğu belirtilmektedir (Markowitz, 1952). Teoride, birbirleriyle yüksek korelasyon içinde bulunan menkul kıymetlerin aynı portföyde yer almasından kaçınılmaktadır. Ancak korelasyon katsayısı, iki rassal değişken arasındaki doğrusal ilişkinin yönünü ve gücünü belirtmektedir. Bayes ağlar kullanılarak oluşturulan modeller menkul kıymetler arasındaki olasılıksal ilişkiyi görsel olarak sunabilmekte ve yeni bilgi geldiğinde ağda yer alan menkul kıymet getiri değerleri eşzamanlı olarak güncellenebilmektedir. Çalışmanın amacı, 2011-2016 dönemleri arasında Borsa İstanbul Ulusal-100 (BIST-100) endeksinde kesintisiz faaliyet gösteren hisse senetlerine ait getirilerin birbirleri ile olan ilişkilerini bir makine öğrenmesi olan Bayes ağ modelleri kullanarak araştırmaktır. Çalışmada Bayes ağ modelleri kullanılarak elde edilecek detaylı ilişkiler ile yatırımcıların portföy seçimlerinde kullanabilecekleri nitel ve nicel bilgiler yer almaktadır.

Anahtar Kelimeler: Makine Öğrenmesi, Bayes Ağlar, Portföy Seçim Teorisi

JEL Sınıflandırması: C11, G1, G11

THE EXAMINE OF DYNAMIC INTERRELATION OF STOCK RETURNS: BAYESIAN NETWORK MODELS

Abstract

In modern portfolio theory, it is stated that the relationship between the securities in the portfolio is influenced by the direction and degree of risk reduction (Markowitz, 1952). In theory, securities that are highly correlated with each other are avoided from being placed in the same portfolio. However, the correlation coefficient indicates the direction and power of the linear relationship between the two random variables. Models created using Bayesian networks can visually present the probabilistic relationship between securities, and when new information is available, the securities return values in the network can be updated simultaneously. The aim of the study is to investigate the relationships between stocks that have been operating continuously in the Stock Exchange Istanbul National-100 (BIST-100) index between 2011-2016 by using Bayes network models which are machine learning. In the study, detailed relationships to be obtained by using Bayesian network models and qualitative and quantitative information that investors can use in portfolio selection are included.

Keywords: Machine Learning, Bayesian Networks, Portfolio Selection Theory

JEL Classification: C11, G1, G11

¹ Dr., Muğla Üniversitesi, Sosyal Bilimler Enstitüsü, busemh@gmail.com

² Yrd. Doç. Dr., Pamukkale Üniversitesi, İ.İ.B.F., İşletme Bölümü, uuyar@pau.edu.tr

DOI: 10.18092/ulikidince.346501

Makalenin Geliş Tarihi (Received Date): 25-10-2017

Yayına Kabul Tarihi (Acceptance Date): 16-01-2018

1. Giriş

Yatırımcılar finansal piyasalarda kazanç elde etmeyi amaçlamakta ve ellerinde bulundurdukları fonları değerlendirmek için finansal varlıklardan portföyler oluşturmaktadır. Modern portföy teorisinin öncüsü olarak kabul edilen Markowitz (1952) portföyün riskini azaltmak için portföy çeşitlendirmesinin tek başına yeterli olmayacağını bunun yanı sıra portföyde yer alan varlıkların birbirleriyle olan ilişkisinin derecesinin ve yönünün de önemli olacağını vurgulamıştır. Portföy yöneticileri ve yatırımcılar finans piyasalarında risk ve getiri arasındaki dengeyi sağlamayı arzulamaktadır. Modern portföy teorisine göre yatırımcılar belirli bir risk düzeyinde en yüksek getiriyi sağlayacak portföyü veya belirli bir getiri düzeyinde en düşük riski sağlayacak portföyü tercih etmelidir. Geleneksel finans modelleri portföy getirisi ve piyasa getirisi arasında yalnızca tarihsel ilişkiyi vurgulamaktadır. Ancak finansal analistler genellikle tarihsel verileri niteliksel bilgilerle birleştirmekte ve bu bilgilerin hisse senedi getirisi, piyasa getirisi veya portföy modelini nasıl etkilediğini değerlendirmektedir. Geleneksel portföy getiri modelleri durağan olmakta ve sonuçları yeni bilgiler ışığında güncelleyecek sistematik bir yol bulunmamaktadır. Analistlerin yeni bilgileri toplamasının ardından Bayes ağ modelleri, bu bilgilerin ağın tüm getiri dağılımı üzerindeki etkisinin görülmesine ve sadece özet istatistiklerin değil, getiri dağılımlarının görselleşmesine olanak tanımaktadır (Shenoy ve Shenoy, 1998: 2).

Bayes ağlarının hisse senedi işlemlerinde kullanılmasının nedeni, hem niceliksel verileri hem de temel analizi gerçekleştirmek için genel olarak kullanılan kalitatif verileri birleştirmesidir. Bu durum finansal piyasaların çok hızlı değiştiği ve herhangi bir ani değişime veya olaya karşı hızlı ve hassas bir şekilde tepki verdiği durumlarda önemlidir (Greppi, 2014: 85). Bayes ağında öncelikli olarak modelin nitel yapısı belirlenmektedir. Nitel kısımda bir dizi *değişken (düğüm)* ve değişkenler arasındaki yönlendirilmiş *bağlantılar (yaylar)* kümesi bulunmaktadır. Matematiksel olarak yapıya Yönlendirilmiş Döngüsel Grafik (DAG) adı verilmektedir. Yeni bilgi geldiğinde (kanıt), bu bilgi ağa eklenince portföy getiri dağılımı güncellenmektedir.

Bu çalışmada, beş yıllık süre boyunca kaydedilen aylık hisse senedi getirilerinden otomatik olarak Bayes ağı oluşturmak amacıyla Gözetimsiz Öğrenme algoritmalarından yararlanılmış, BIST-100 endeksine ait 94 hisse senedi arasındaki ilişki incelenmiştir. Çalışmada amaç Borsa İstanbul Ulusal-100 (BIST-100) endeksinde 2011-2016 dönemleri arasında aralıksız faaliyet gösteren şirketlerin hisse senetlerine ait getirilerinin birbirleriyle olan ilişkilerini Bayes ağ modelleri ile araştırmaktır. Araştırma metninin sonraki bölümünde konu ile ilgili literatür araştırmasına yer verilecektir. Üçüncü bölümde veri seti ve yöntem hakkında detaylı bilgiler sunulduktan sonra elde edilen bulgular tartışılacaktır. Metnin sonuç bölümünde elde edilen bulguların Bayes Ağ modellerinin kullanımı ve yatırımcılara sağladığı nitel ve nicel bilgilerine yer verilecektir.

2. Literatür Özeti

Finans teorisinde yüksek korelasyon içeren menkul kıymetlerin aynı portföyde yer almasından kaçınılmaktadır. Bayes ağlarla oluşturulan modellerde korelasyon katsayısının yanında belirli bir eşik değerini ve ağın yapısal karmaşıklığını da hesaba katan çeşitli öğrenme algoritmaları uygulanmaktadır. Ayrıca, portföy teorisi ile ilgili geçmişte yapılan çalışmalar incelendiğinde geleneksel portföy getiri modellerinde değişkenlere yeni bir kanıt eklendiğinde sonuçları güncelleyecek herhangi bir yol bulunmamaktadır. Bayes ağ modelleri değişkenler arasındaki olasılık ilişkilerini herhangi bir varsayıma bağlı kalmadan görsel ve sayısal olarak ortaya koyabilmektedir. Bunlara bağlı olarak Bayes ağlarının finansal modellerde kullanımı giderek artmaktadır. Bu kapsamda, C. Shenoy ve P. Shenoy (1998) geleneksel portföy modellerini temsil etmek amacıyla portföy getirisi ve portföy riskininin Bayes ağlarla nasıl modelleneyeceğini göstermişlerdir. Tseng (2003) portföy seçimi için geri beslemeli yapay sinir ağları, C5.0 Kural Tabanı Sistemi ve Bayes ağı analiz yöntemlerini kullanmış, Bayes ağlarının hisse senedi seçiminde diğer yöntemlere göre daha etkili sonuçlar verdiği bulgusuna ulaşmıştır. Demirer, Mau ve Shenoy (2006) çalışmalarında bireysel hisse senedi analistlerinin ve portföy yöneticilerinin alacakları kararlarda Bayes ağ modellerinin yardımcı olabileceğini göstermektedir. Çalışmada portföyde yer alan dört biyomedikal cihaz

endüstri hisse senedine ait getiri tahmini ve bunların ekonomik faktörlerle ilişkileri Bayes ağ modelleri ile ilişkilendirilmiştir. Olbryś (2009) çalışmasında makroekonomik değişkenler, borsa alt endeksleri ve üç inşaat firmasının hisse senedine özgü değişkenleri ve portföy getirisi değişkenlerini Bayes ağ modelleri ile ilişkilendirmiştir. Olbryś senaryo analizleri yaptığı çalışmasında Bayes ağ modelleri ile elde edilen portföy getirisi ve portföy riski sonuçlarının Elton ve Gruber'in 1981 yılında yayınlanan çalışması ile paralellik gösterdiği bulgusuna ulaşmıştır. Villa ve Stella (2012) portföy analizi ve optimizasyonu için Modern Portföy Teorisi ve Bayes ağ modelleri arasındaki etkileşimi araştırmaktadır. Greppi, Giuli ve Tarantola (2013) çalışmalarında tarihi verileri Bayes ağ modelleri ile incelemiş, temel analiz yaklaşımı faktörlerinin yanı sıra piyasa değişkenlerini de modele dahil etmiştir. 1990 yılından bu yana üç aylık muhasebe ve piyasa verilerini kullandıkları çalışmalarında Bayes ağ modellerinin finansal varlıkları seçme konusunda etkili bir araç olduğu sonucuna ulaşmışlardır. Greppi (2014) çalışmasında makroekonomik faktörler, hisse senedi değişkenleri, hisse senedi ağırlığı ve portföy getirisi katmalarını hiyerarşik bir düzende Bayes ağ modelleri kullanarak sıralamış ardından değişkenlerin durumlarına yeni gelen bilgiyi ekleyerek senaryo analizleri yapmıştır. Hoe 2014 yılında yapmış olduğu çalışmada, makine öğrenmesinin portföy risk analizi için hisse senedi seçiminde portföy yöneticilerine ve yatırımcılara yardımcı olabileceği sonucuna ulaşmıştır.


3. Veri Seti ve Yöntem

Çalışmada 2011-2016 dönemleri Borsa İstanbul Ulusal-100 (BIST-100) endeksinde aralıksız faaliyet gösteren 94 şirkete ait hisse senedi getirileri Bayes ağ modelleri kullanarak araştırılmaktadır.

Bayes ağlar bir rassal değişken kümesinin $X = \{X_1, X_2, \dots, X_p\}$ yönlendirilmiş döngüsüz grafiği $G = (V, A)$ olarak olasılık bağımlılıklarının gösterilmesini sağlayan grafiksel ağ modelleridir. Her *düğüm* $v_i \in V$ bir rasgele değişken X_i 'ye karşılık gelirken, A , *bağlantıları* temsil etmektedir (Nagarajan vd., 2013: 13; Mittal vd., 2007: 15). Bayes ağlar, rasgele değişkenleri temsil eden bir takım *düğüm*ler ve genellikle nedensel ilişkileri gösteren, olasılıksal bağımlılıkları temsil eden bir dizi yönlendirilmiş *bağlantılardan* (*yaylar*) oluşur (Bensi vd., 2011: 16).

Şekil 1'de gösterilen grafiğe göre *düğüm A*'nın komşusu *ebeveyn* (*parent*) ve *çocuk* (*child*) *düğüm*lerin birleşimidir. *A*'nın ebeveyn *düğüm*leri aynı zamanda *ata* (*ancestors*) *düğüm*lerdir; çünkü topolojik olarak *A* *düğüm*ünden önce gelirler. Aynı şekilde *çocuk* *düğüm*ler de *soydan gelen* veya *torun* (*descendants*) olarak adlandırılır. Eğer bir *düğüm*e gelen herhangi bir bağlantı yer almıyorsa (ebeveyn *düğüm*ü yoksa) bu *düğüm* *kök* (*root*) *düğüm*; bir *düğüm*den başka bir *düğüm*e giden bir bağlantı söz konusu değilse (*çocuk* *düğüm*ü yoksa) bu *düğüm* *yaprak* (*leaf*) *düğüm* olarak adlandırılır (Nagarajan vd., 2013: 3).

Şekil 1: *A* *Düğüm*ünün Ebeveyn, Çocuklar, Ata ve Komşu *Düğüm*lerinin Yönlendirilmiş Döngüsüz Grafiği



Kaynak: Nagarajan vd., 2013: 3.

Bayes ağlar nitel ve nicel kısım olmak üzere iki kısımdan oluşur. Yönlendirilmiş döngüsüz grafik (DAG) yapısına sahip olan Bayes ağlarda *düğüm*ler arasındaki nedensel bağımlılıkların grafiksel

olarak gösterimi ağın *niteliksel* (yapısal) kısmını oluşturmaktadır (Trucco vd., 2008: 825). Modelin *niceliksel* kısmı parametre öğrenmesidir ve ebeveynleri verilen düğümlerin koşullu olasılıklarının (koşullu olasılık tabloları-CPT) öğrenilmesi gerekir (Sammur ve Webb, 2011: 585). Bu parametre öğrenmesi, grafiğin ebeveyn düğümleri verildiğinde her düğümün koşullu olasılıklarıdır (Sucar, 2015: 106).

Bayes ağlar modeldeki değişkenler arasındaki ilişkilerin görselleşmesine olanak tanımaktadır. Bir Bayes ağı bir dizi *değişken (düğüm)* ve değişkenler arasındaki yönlendirilmiş *bağlantılar (yay)* kümesinden oluşmaktadır. Bir değişken, olası herhangi bir sayıda *duruma (state)* sahip olabilmektedir. *Yeni bilginin (kanıt)* ağa eklenmesi durumu, kullanılan serinin dağılımını güncellemektedir. Bir Bayes ağı, bir dizi rasgele değişkenin olasılık dağılımını, koşullu bağımsızlık varsayımları kümesiyle birlikte, bu değişkenler ve bunlarla ilişkili ortak olasılıklar arasındaki ilişkilerin bir kümesiyle kodlar (Lauria ve Duchessi, 2007: 238).

Zincir kuralı, Bayes ağının, yönlendirilmiş döngüsüz grafiği ve marjinal olarak temsil edilen tüm değişkenler üzerindeki ortak olasılık dağılımını temsil eder ve ağın her bir düğümü için koşullu olasılıkların hesaplanmasını sağlar. X değişkenlerin bir evreni ise, $X = \{X_1, X_2, \dots, X_n\}$, X 'in ortak olasılık dağılımı Eşitlik (1)'de gösterilmektedir.

$$P(X) = \prod_{i=1}^{n-1} P(X_i | X_{i+1}, \dots, X_n) \quad (1)$$

Ortak olasılık dağılımı $P(X)$ ile $P(X_i)$, $P(X_i | X_j)$, $P(X_i | e)$ gibi çeşitli marjinal ve koşullu olasılıklar hesaplanabilir. Burada genel olarak *e kesin kanıtı* ifade etmektedir: $e = \{e_1, e_2, \dots, e_m\}$. Kanıt, bu ağın değişkenlerinin bir alt kümesinin olası durumları/değerleri hakkında dış kaynaklardan alınan bir bilgidir (Trucco vd., 2008: 825).

Yeni bilginin (kanıt) ağa eklenmesi durumu, kullanılan serinin dağılımını güncellemektedir. Bir dizi kesikli değişken X_i için, kanıtlar X_i 'nin durumları üzerinde olasılık dağılımı şeklinde görünür. Ağın bazı değişkenleri üzerinde bir gözlem verilirse, bazı olayların ortaya çıkma ihtimali kanıtlar göz önüne alındığında hesaplanabilir:

$$P(X|e) = \frac{P(X, e)}{P(e)} \quad (2)$$

Değişkenlerin durumları için kesin olmayan bir bilgi verildiğinde *hafif*, kesin bir gözlem olduğunda *kesin* kanıt değişkenin durumlarından birinde tanımlanmış olur. Başka bir deyişle, gözlemi verilen olaylar hakkındaki inancı güncelleyebilen bir olasılık çıkarımı verilmişse, farklı alt kümeleri verilen değişken olasılıklarının duyarlılık analizini yapmak mümkündür (Trucco vd., 2008: 826).

Korelasyon çok zayıf ilişki durumunda bile tüm düğümler arasında ilişkiyi gösterebilirken, Bayes ağ modellerini oluşturmak için kullanılan öğrenme algoritmaları ağın yapısal karmaşıklığını da hesaba katarak belirli bir eşik değerine dayanarak ilişkiler oluşturmaktadır. Çalışmada kullanılan verilerden Bayes ağı elde etmek için gözetimsiz öğrenme algoritmalarından yararlanılmıştır. Çalışmada yer alan 94 sürekli değişken mevcut gözlem sayısı göz önüne alınarak *K-means veri kümeleme algoritması* ile kesikli değişken haline getirmek amacıyla beş duruma ayrıştırılmıştır.

Değişken sayısı da göz önüne alınarak, diğer algoritmalara kıyasla ağaç yapısını çok daha hızlı öğrenen *Maksimum Kapsayan Ağaç (Maksimum Spanning Tree)* algoritması ile öğrenme gerçekleştirilmiştir. Maksimum Kapsayan Ağaç algoritmasında skorlama ölçüsü olarak, korelasyonun yanı sıra ağın yapısal karmaşıklığını hesaba katarak otomatik anlamlılık eşikleri oluşturan *Minimum Tanımlama Uzunluğu (Minimum Description Length-MDL)* ölçütü kullanılmıştır. Minimum Tanımlama Uzunluğu (MDL) puanı en iyi çözümü elde etmek için skoru en aza indirgeyen iki bileşenli bir skordur. MDL bir "model" ve "bu modelde girilen veriyi" temsil eden bit sayısını tahmin etmek için kullanılır.

Makine öğrenme uygulamasında Bayes ağ modelinin ilk terimi bir grafik ve olasılık tablolarından oluşur. İkinci terim ise, Bayes ağı (model) göz önüne alındığında, gözlemlerin (veri) olasılığı ile ters orantılı olan, girilen verinin logaritmik olabilirliğidir (Conrady ve Jouffe, 2015: 212).

$$MDL(B, D) = \alpha DL(B) + DL(D|B) \quad (3)$$

Eşitlik (3)'te yer alan α , MDL puanının yapısal kısmının ağırlığını değiştiren bir parametredir. α 'nın değeri ne kadar düşükse, sonuçtaki ağların karmaşıklığı da o kadar büyük olur. $DL(B)$ Bayes ağını temsil eden bit sayısı B (grafik ve olasılıklar) ve $DL(D|B)$ Bayes ağı B verildiğinde veri kümesi D 'yi temsil eden bit sayısıdır (Bayes ağına girilen verilerin olasılığı).

MDL ölçütü uygulamasının ardından makina öğrenimi sürecinde lokal minimum probleminden kaçınmayı sağlayan *veri pertürbasyonu (data perturbation)* algoritmasından bir skor elde edilmiştir. Veri pertürbasyonu skoru ile MDL ölçütü karşılaştırılmış, her ikisi de aynı sonucu verdiği için MDL ölçütünün kullanılmasına karar verilmiştir. Ağın analizi aşamasında, oluşturulan ağın tamamına göre en baskın yay ve düğümü bulmak amacıyla *ark kuvveti (arc force)* ve *düğüm kuvveti (node force)* analizleri yapılmıştır. İki olasılıksal dağılımın arasındaki doğrudan ilişkinin gücünü ölçmeye yarayan *Kullback Leibler Ayrışması (Kullback Leibler Divergence)* fonksiyonu kullanarak hesaplanan ark kuvveti sonucunda ağın en güçlü yayı ve doğrudan ark kuvvetinden yararlanarak elde edilen baskın düğüm tespit edilmiştir. KL ayrıştırması, iki olasılık dağılımı olan P ve Q 'yu karşılaştırmaya olanak tanır. P , bağlantı ile birlikte Bayes ağındadır ve Q bağlantısızdır (Conrady ve Jouffe, 2015: 181).

$$D_{KL}(P(X)|Q(X)) = \sum_x P(X) \log_2 \frac{P(X)}{Q(X)} \quad (4)$$

Baskın düğüm ile 1. dereceden ilişkili düğümleri tespit etmek için baskın düğüm öncelikli olarak *hedef düğüm (target node)* olarak belirlenmiş ve *yarı denetimli öğrenme algoritması (semi-supervised learning algorithm)* ile ağ tekrar öğrenilmiştir. *Markov Blanket* kullanılarak baskın düğüm ile ilişkili ebeveyn düğümler, çocuk düğümler ve eş düğümler belirlenmiş ve bu örüntüde yer alan değişkenler haricindeki değişkenlerden bağımsız hale getirilmiştir.

Analizin son aşamasında hedef değişkene (baskın değişken) yönelik güncel bir *kesin kanıt (hard evidence)* eklenmiştir. Kesin kanıtın hedef düğüm ile 1. dereceden ilişkili olan düğümler üzerindeki *çıkarsamalarına (inferences)* ulaşılmıştır.

4. Ampirik Bulgular

Çalışmada kullanılan veri seti, BIST-100'de 3 Şubat 2011-5 Ağustos 2016 dönemleri arasında kesintisiz faaliyet gösteren 94 şirkete ait 1437 günlük hisse senedi getirisi serilerinden oluşmaktadır. Analizler yöntem bölümünde yer alan sıra ile gerçekleştirilmiştir.

Öğrenme algoritmalarından sonra yapılan ark kuvveti ve düğüm kuvveti (Şekil 2) analizleri sonucunda ISCTR hissesinin belirlenen tarih aralığındaki getiri serileri içerisindeki baskın değişken olduğu bulgusuna ulaşılmıştır.

-0,039; $\leq -0,016$; ≤ 0 ; $\leq 0,018$; $> 0,018$ şeklindedir. Kesin kanıt, değişkenin her durumunda oluşan aralığın gerçekleşme olasılığının %100 olmasıdır. Baskın düğümüne kesin kanıt girilmesi halinde, 1. dereceden ilişkili hisse senetlerinin günlük ortalama getirilerinde meydana gelen değişiklikler incelenmiştir. İlişkili hisse senetleri içerisinde en fazla değişime uğrayan beş hisse senedi bulgulara dahil edilmiş ve yorumlanmıştır.

Analiz bulgularına göre, ilk üç durum için baskın düğüm olan ISCTR'ye kesin kanıt girişi, ilişkili tüm hisselerinin günlük ortalama getirilerini negatif yönde etkilemektedir. Son iki durum için ise kesin kanıt girişi, ilişkili tüm hisselerinin günlük ortalama getirilerini pozitif yönde etkilemektedir. Bulgularda birinci durum için baskın düğümüne girilen kesin kanıttan günlük ortalama getirisi en yüksek miktarda etkilenen hisse senetleri sırasıyla "VAKBN, PRKME, NETAS, ALCTL, GARAN" şeklindedir. İkinci durum için baskın düğümüne girilen kesin kanıttan günlük ortalama getirisi en yüksek miktarda etkilenen hisse senetleri sırasıyla "VAKBN, GARAN, NETAS, EKGYO, TRKCM" şeklindedir. Üçüncü durum için baskın düğümüne girilen kesin kanıttan günlük ortalama getirisi en yüksek miktarda etkilenen hisse senetleri sırasıyla "GARAN, VAKBN, EKGYO, THYAO, TTCOM" şeklindedir. Dördüncü durum için baskın düğümüne girilen kesin kanıttan günlük ortalama getirisi en yüksek miktarda etkilenen hisse senetleri sırasıyla "VAKBN, GARAN, EKGYO, TRKCM, CLEBI" şeklindedir. Beşinci durum için baskın düğümüne girilen kesin kanıttan günlük ortalama getirisi en yüksek miktarda etkilenen hisse senetleri sırasıyla "GARAN, VAKBN, NETAS, GUBRF, THYAO" şeklindedir.

5. Sonuç

Bayes ağlar kullanılarak oluşturulan modeller modern portföy teorisindeki korelasyon ilişkisine farklı bir bakış açısı getirebilmektedir. Bayes ağ modelleri menkul kıymetler arasındaki olasılıksal ilişkiyi görsel olarak yatırımcılara ya da analistlere sunabilmekte, ayrıca sisteme yeni bilgi girişi olduğunda ağda yer alan menkul kıymet getiri değerlerini eşzamanlı olarak güncellenebilmektedir.

Çalışmanın amacı, 3 Şubat 2011-5 Ağustos 2016 dönemleri arasında Borsa İstanbul Ulusal-100 endeksinde kesintisiz faaliyet gösteren 94 şirketin hisse senetlerine ait günlük getirilerin, birbirleriyle olan dinamik ilişkilerini Bayes ağ modelleri kullanarak araştırmaktır. Çalışmada Bayes ağ modelleri kullanılarak elde edilecek detaylı ilişkiler ile yatırımcıların portföy seçimlerinde kullanabilecekleri nitel ve nicel bilgilerin oluşturulması hedeflenmektedir.

Uygulanan analiz sonuçlarına göre, öncelikle tüm seriler K-means veri kümeleme algoritmasına göre beş duruma ayrıştırılmıştır. İncelenen dönemde BIST-100 endeksi içerisindeki baskın hisse senedi ark ve düğüm kuvveti analizlerine göre, ISCTR hisse senedi olarak tespit edilmiştir. Sonraki aşamada, 1. dereceden ilişkili hisse senetleri ile olan ağ modeli Markov Blanket kullanılarak çıkarılmış ve hisselerin kendi aralarındaki ilişkiler incelenmiştir. Elde edilen bulgularda, GARAN ve VAKBN hisselerinin ISCTR hissesinin her durumuna girilen kesin kanıttan etkilendikleri tespit edilmiştir. Ayrıca, ilk üç durum için baskın düğüm olan ISCTR'ye kesin kanıt girişi (yani ISCTR getirisinin negatif ya da sıfır olmasının kesin olduğu durumlarda), ilişkili tüm hisselerin günlük ortalama getirilerini negatif yönde etkilemektedir. Hisse getirisinin pozitif olmasının kesin olduğu son iki durum için ise kesin kanıt girişinin, ilişkili tüm hisselerin günlük ortalama getirilerini pozitif yönde etkilediği gözlemlenmiştir.

Sonuç olarak, Bayes ağ modelleri kullanılarak elde edilen veriler, baskın düğüm olarak belirlenen İş Bankası hisse senedi ile Garanti Bankası ve Vakıfbank hisse senetleri arasındaki dinamik ilişkiyi ortaya koymaktadır. Yatırımcıların modern portföy teorisinde vurgulanan ilişki yönünü, farklı durumlar için ele almasına olanak sağlamaktadır. Yatırımcılar tek bir korelasyon katsayısından ziyade, Bayes ağ modelinden çalışmada elde edilen beş farklı durum için farklı ilişki olasılıklarına ulaşmakta ve hisseler arasındaki dinamiği daha detaylı görebilmektedir. Ayrıca, Bayes ağ modellerinin istenildiği anda yeni bilgi girişine açık olması, yatırımcılara, ilişkileri geleneksel analiz yöntemlerine göre daha dinamik bir şekilde takip etme imkanı sağlamaktadır.

Çalışmada yapılan analizlerden elde edilen bir diğer sonuç ise, araştırmaya dahil edilen hisselerin nasıl bir ağ yapısına sahip olduğunun belirlenebilmesidir. Belirlenen ilişki ağının detaylı incelenmesi sonucunda 22.07.2016 tarihinde piyasaya ulaşan bir bilgi ile araştırma sonuçlarının paralel olduğu gözlenmiştir. İlgili tarihteki bilgide, uluslararası kredi derecelendirme kuruluşu Standard & Poor's (S&P), Garanti Bankası, Yapı Kredi Bankası, Vakıfbank ve İş Bankası'nın kredi notlarını BB+ 'dan BB 'ye indirdiği yer almaktadır. Bu olay, analizlerden elde edilen ilişki ağını, başka bir deyişle belirlenen hisse senedi ilişkilerini desteklemektedir.

Kaynakça

- Bensi, M. T., Kiureghian, A. D. ve Straub, D. (2011). A Bayesian Network Methodology for Infrastructure Seismic Risk Assessment and Decision Support (Rapor No. PEER Report 2011/02). Pacific Earthquake Engineering Research Center. Erişim adresi http://peer.berkeley.edu/publications/peer_reports/reports_2011/webPEER-2011-02-BENS1etal.pdf
- Conrady, S. ve Jouffe, L. (2015). *Bayesian Networks & BayesiaLab—A Practical Introduction for Researchers*, Bayesia USA.
- Demirer, R., Mau, R. ve Shenoy, C. (2006). Bayesian Networks: A Decision Tool to Improve Portfolio Risk Analysis. *Journal of Applied Finance*, 16(2), 106-133.
- Greppi, A. (2014, June-July). A Bayesian Network Approach to Portfolio Management, First DREAMT Research in Progress Workshop, Pavia. Erişim adresi https://www.researchgate.net/profile/Fabio_Stella/publication/299760529_Bayesian_Networks_for_Portfolio_Analysis_and_Optimization/links/574ff94908ae1880a8229222/Bayesian-Networks-for-Portfolio-Analysis-and-Optimization.pdf
- Greppi, A., De Giuli M. E. ve Tarantola C. (2013). Bayesian Network for Stock Picking. Erişim Adresi <http://convegna.unica.it/cladag2015/files/2015/10/Greppi.pdf>
- Hoe, T. K. (2014). A Machine Learning-based Decision Support Tools for Portfolio Risk Analysis. (Yayımlanmamış Yüksek Lisans Tezi). Tunku Abdul Rahman Üniversitesi, Malaysia.
- Lauria, E. J. M. ve Duchessi, P. (2007). A methodology for developing Bayesian networks: An application to information technology (IT) implementation, *European Journal of Operational Research*, 179, 234-252.
- Markowitz, H. (1952). Portfolio Selection, *The Journal of Finance*, Blackwell Publishing, 7(1), 77-91.
- Mittal, A., Kassim, A. ve Tan, T. (2007). *Bayesian Network Technologies: Applications and Graphical Models*, IGI Global, USA.
- Nagarajan, R., Scutari, M. ve Lebre, S. (2013). *Bayesian Networks in R with Applications in Systems Biology*, Springer Science+Business Media, New York.
- Olbrýś, J. (2009). Forecasting Portfolio Return Based on Bayesian Network Model, [in:] W. Milo, G. Szafranski, P. Wdowiński (eds.) Financial Markets. Principles of Modelling, Forecasting and Decision-Making, *FindEcon Monograph Series: Advances in Financial Market Analysis*, 7, Lodz University Press, 157-171.
- Sammut, C. ve Webb, G. I. (2011). *Encyclopedia of Machine Learning*, Springer.
- Shenoy, C. ve Shenoy, P. P. (1998). *Bayesian Networks: A Decision Tool to Improve Portfolio Risk Analysis* (Working paper). School of Business, University of Kansas. Erişim adresi <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.111.1084&rep=rep1&type=pdf>
- Sucar, L. E. (2015). *Probabilistic Graphical Models Principles and Applications*, Springer-Verlag, London.

- Trucco, P., Cagno, E., Ruggeri, F. ve Grande, O. (2008). Bayesian Belief Network modelling of organisational factors in risk analysis: A case study in maritime transportation, *Reliability Engineering and System Safety*, 93, 823-834.
- Tseng, C. (2003). Comparing Artificial Intelligence Systems for Stock Portfolio Selection. Erişim adresi depts.washington.edu/sce2003/Papers/236.pdf.
- Villa, S. ve Stella, F. (2012). Bayesian Networks for Portfolio Analysis and Optimization, *Financial Decision Making Using Computational Intelligence*, 70, 209-232.
- Zuo, Y. ve Kita, E. (2012). Up/Down Analysis of Stock Index by Using Bayesian Network, *Engineering Management Research*, 1(2), 46-52.

THE EXAMINE OF DYNAMIC INTERRELATION OF STOCK RETURNS: BAYESIAN NETWORK MODELS

Extended Abstract

Aim: The aim of the study is to analyze Bayesian network models, which are the relationships between the stocks belonging to the stock exchanges which are continuously operating in the Stock Exchange Istanbul National-100 (BIST-100) index between the years 2011-2016, using a machine learning model and to create qualitative and quantitative information that investors can use in portfolio selection. In modern portfolio theory, it is stated that the relationship between the securities in the portfolio is influenced by the direction and degree of risk reduction (Markowitz, 1952). In theory, securities that are highly correlated with each other are avoided from having the same portfolio. Models created with Bayesian networks can be updated simultaneously when new information is available.

Method(s): In the study 94, the K-means clustering algorithm has been broken down into five states by considering the number of continuous variable observations. The maximum number of spanning trees, which is the unattended learning algorithm, has been studied by considering the number of variables. In this algorithm, the Minimum Description Length (MDL) is used as the scoring criterion. The MDL was compared with the score obtained from the data perturbation which avoided the local minimum problem, and it was decided to use MDL because both gave the same result. In the analysis phase, arc strength and node strength analyzes were performed to find the most dominant arc and node of the network. The strongest arc of the network as a result of the arc force calculated by the Kullback Leibler Divergence function, which measures the difference of two probability distributions; and the dominant node was found in the result of arc force. The dominant node is determined as the target node and the network is re-learned with semi-supervised learning algorithm to find the nodes related to the dominant node. Using Markov Blanket, parents, children and co-nodes related to the dominant node were identified and these variables were independent of the variables except for. In the last stage, definitive evidence has been added to the target variable.

Findings: The dataset used in the study consists of 1437 days of stock return series of 94 companies operating continuously between 3 February 2011 and 5 August 2016 in BIST-100. Analyzes were performed in the order listed in the method section. As a result of arc force and node force analysis after learning algorithms, ISCTR was found to be dominant in the return series in the determined date range. The ISCTR variable identified as the dominant node is determined as the target node and the network is re-learned with the semi-supervised learning algorithm. In the following stage, 27 shares were selected using the Markov Blanket, the series of shares related to the ISCTR exchange. At the end of the analysis, learning algorithms and definitive evidence were entered in five cases of the ISCTR variable, the predominant node in the Bayesian network model created after the selection analysis. The five states determined by the K-means clustering algorithm of ISCTR are " $\leq -0,039$; $\leq -0,016$; ≤ 0 ; $\leq 0,018$; > 0.018 ". The precise evidence is that the probability of occurrence of the interval occurring in each case of the variable is 100%. For the first case, the stocks that are affected by the highest amount of definite evidence entered the dominant node are "VAKBN, PRKME, NETAS, ALCTL, GARAN"; for the second case, the stocks that are affected the highest amount are "VAKBN, GARAN, NETAS, ECGYO, TRKCM" respectively; the stocks most affected for the third case are "GARAN, VAKBN, ECGYO, THYAO, TTCOM" respectively; the stocks most affected for the fourth case are "VAKBN, GARAN, ECGYO, TRKCM, CLEBI" respectively; the stocks that are most affected for the fifth case are "GARAN, VAKBN, NETAS, GUBRF, THYAO" respectively.

Conclusion: The data obtained by using Bayesian network models reveal the dynamic relationship between İş Bank stocks, which are determined as the dominant node, and Garanti Bank and Vakıfbank stocks. From a single correlation coefficient, investors reach different probabilities for

five different situations in the Bayesian network model and see the dynamics among the stocks in more detail. As a result of the detailed examination of the determined relationship network, it was observed that the results of the research reached parallel with the information reached to the market on 22.07.2016. In the related information, the credit ratings of the international credit rating agencies Standard & Poor's (S&P), Garanti Bank, Yapı Kredi Bank, Vakıfbank and İş Bank have been reduced from BB+ to BB. This event supports the network of relationships obtained from the analyzes.

