İSTANBUL TEKNİK ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ

BORSA İSTANBUL (BIST) HİSSE FİYAT DEĞİŞİM YÖNÜNÜN İLİŞKİSEL BORSA AĞI KULLANILARAK TAHMİN EDİLMESİ

YÜKSEK LİSANS TEZİ

Bircan ERGÜR

Bilgisayar Mühendisliği Anabilim Dalı

Bilgisayar Mühendisliği Programı

MAYIS 2014

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ

BORSA İSTANBUL (BIST) HİSSE FİYAT DEĞİŞİM YÖNÜNÜN İLİŞKİSEL BORSA AĞI KULLANILARAK TAHMİN EDİLMESİ

YÜKSEK LİSANS TEZİ

Bircan ERGÜR
(504111505)

Bilgisayar Mühendisliği Anabilim Dalı

Bilgisayar Mühendisliği Programı

Tez Danışmanı: Doç. Dr. Zehra ÇATALTEPE

MAYIS 2014

İTÜ, Fen Bilimleri Enstitüsü'nün 504111505 numaralı Yüksek Lisans Öğrencisi **Bircan ERGÜR**, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı **"BORSA İSTANBUL (BIST) HİSSE FİYAT DEĞİŞİM YÖNÜNÜN İLİŞKİSEL BORSA AĞI KULLANILARAK TAHMİN EDİLMESİ"** başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı :	**Doç. Dr. Zehra ÇATALTEPE** İstanbul Teknik Üniversitesi	.....
Jüri Üyeleri :	**Yrd. Doç. Dr. Berk CANBERK** İstanbul Teknik Üniversitesi	.....
	Yrd. Doç. Dr. M. Fatih AMASYALI Yıldız Teknik Üniversitesi	.....

Teslim Tarihi : **05 Mayıs 2014**
Savunma Tarihi : **30 Mayıs 2014**

Hayatımın diğer yarısı Önder'e,

ÖNSÖZ

Lisans ve yüksek lisans eğitimim süresince bana her anlamda destek olan, her konuya taze bir hevesle başlamayı öğreten değerli hocam Doç. Dr. Zehra ÇATALTEPE'ye teşekkürlerimi sunarım.
Gerek işimle ilgili, gerekse iş çerçevemin dışında her konuda beni yüreklendiren, bana yol gösteren yöneticim Rahmi Cem ÇEVİKBAŞ'a ve Onur BÜK'e, benim için çok değerli destekleri için teşekkür ederim.
Doğduğum zamandan bu yana elimden tutan, hayatıma en iyi şekilde yön veren başta anne, baba ve ağabeyime sonsuz teşekkür eder, yeni sevinç kaynağımız Hiera'ya mutluluk dolu bir yaşam dilerim.
Birlikte çalışmalarımızı yürüttüğümüz, desteklerini esirgemeyen değerli arkadaşlarım Hakan GÜNDÜZ, Mert SALIK ve Gökhan ÇOBAN'a; veri sağlama konusunda verdiği destekler için Borsa İstanbul'a içtenlikle teşekkür ederim.

Mayıs 2014 Bircan Ergür

İÇİNDEKİLER

Sayfa

ÖNSÖZ ..... **vii**
İÇİNDEKİLER ..... **ix**
KISALTMALAR ..... **xi**
ÇİZELGE LİSTESİ ..... **xiii**
ŞEKİL LİSTESİ ..... **xv**
ÖZET ..... **xvii**
SUMMARY ..... **xix**
1. GİRİŞ **1**
1.1 Tezin Amacı 1
1.2 Tezin Yapısı 2
2. İLGİLİ ÇALIŞMALAR **3**
2.1 Hisseler Arasındaki İlişkilerin Bulunması 3
2.2 Hisselerin Geçmiş Fiyat Bilgisinden Yararlanılarak Yapılan Tahmin Çalışmaları 5
2.2.1 Yapay sinir ağları kullanılarak yapılan borsa tahmini çalışmaları 6
2.2.2 Destek vektör makineleri kullanılarak yapılan borsa tahmini çalışmaları 7
3. BORSA VERİLERİNİN KULLANIM SÜREÇLERİ **9**
3.1 Gün İçi Borsa Verilerinin Tanıtılması 9
3.2 Gün İçi İşlem Verisinin Aralıklandırılması 10
3.2.1 Fiyat vektörlerinin oluşturulması 10
3.2.2 İşlem hacmi ve önemli fiyat değişimlerinin hesaplanması 11
3.3 Öznitelik Seçimi ve Öznitelik Seçiminde Kullanılan Yöntemler 12
3.3.1 Borsa üzerine öznitelikler 12
3.3.1.1 Hareketli ortalama (İng. Moving average – MA) 13
3.3.1.2 Momentum 13
3.3.1.3 Olasılıksal salıngaç (İng. Stochastic oscillator – STOCH) 13
3.3.1.4 Göreceli güçlülük göstergesi (İng. Relative strength index – RSI) 14
3.3.1.5 Hareketli ortalama yakınsama ıraksama (İng. Moving average convergence divergence – MACD) 14
3.3.1.6 Birikim/dağıtım salıngacı (İng. Accumulation/distribution oscillator – ADO) 15
3.3.1.7 Menkul kanal göstergesi (İng. Commodity channel index – CCI) 15
3.3.1.8 İşlem hacmi 16
3.3.2 Öznitelik seçiminde kullanılan yöntemler 16
3.3.2.1 En az tekrar en fazla ilgililik (İng. Maximum redundancy minimum relevance - mRMR) 16
3.3.2.2 Özyinelemeli öznitelik elemesi DVM (İng. Recursive feature elimination SVM) 17
3.4 Hisseler Arasındaki İlişkilerin Bulunması 18
3.4.1 Hisse benzerliklerinin hesaplanması 18
3.4.2 Hisse etkililik çizgelerinin ve borsa ağının oluşturulması 19
3.5 Sınıflandırıcı Öğrenmesi 19
3.5.1 Çok katmanlı perseptron sınıflandırıcısı 20
3.5.2 Destek vektör makineleri (DVM) sınıflandırıcısı 22
3.6 Sınıflandırıcı Performanslarını Değerlendirme Ölçütleri 23
3.7 Bölüm Özeti 25

4. HİSSE SENEDİ GEÇMİŞ FİYAT VERİSİ VE HİSSE ETKİLİLİK ÇİZGESİ KULLANARAK HİSSE FİYAT DEĞİŞİM YÖNÜ TAHMİNİ 27
4.1 Veri Kümesinin Toplanması ve Ön İşlemesi 29
4.2 Finansal Göstergelerin Hesaplanması 31
4.3 Özniteliklerin Ölçeklenmesi 32
4.4 Hisse Etkililik Çizgeleri ve Borsa Ağı 32
4.5 Öznitelik Seçimi 35
4.5.1 Yalnızca geçmiş fiyat bilgisi üzerinde yapılan öznitelik seçimi 36
4.5.2 Geçmiş fiyat bilgisi ve hisse ilişkileri üzerinde yapılan öznitelik seçimi 37
4.6 En İyi Model Belirleme 39
4.7 Sınıflandırma Sonuçları 43
5. SONUÇ VE ÖNERİLER 47
KAYNAKLAR 51
EKLER 57
ÖZGEÇMİŞ 87

KISALTMALAR

ADO : Birikim/Dağıtım Salıngacı (İng. Accumulation/Distribution Oscillator)
CCI : Menkul Kanal Göstergesi (İng. Commodity Channel Index)
DVM : Destek Vektör Makineleri
İVAY : İçerik ve Ağ Yaklaşımı
İY : İçerik Yaklaşımı
MA : Hareketli Ortalama (İng. Moving Average)
MOM : Momentum
MLP : Çok Katmanlı Perseptron (İng. Multilayer Perceptron)
mRMR : En Az Tekrar En Fazla İlgililik (İng. Minimum Relevance Maximum Redundancy)
NIFTY : Hindistan Borsası
NIKKEI : Tokyo Borsası
NYSE : New York Borsası
ÖK : Öğrenme katsayısı
ÖSA : Öznitelik seçim algoritması
RBF : Radyal Bazlı Fonksiyon (İng. Radial Basis Function)
RFESVM : Özyinelemeli Öznitelik Elemesi Destek Vektör Makineleri (İng. Recursive Feature Elimination SVM)
RSI : Göreceli Güçlülük Göstergesi (İng. Relative Strength Index)
SK : Saklı katman
SMA : Basit Hareketli Ortalama (İng. Simple Moving Average)
STOCH : Olasılıksal Salıngaç (İng. Stochastic Oscillator)
WMA : Ağırlıklı Hareketli Ortalama (İng. Weigthed Moving Average)

ÇİZELGE LİSTESİ

Sayfa

Çizelge 3.1 : Finansal gösterge kullanımları. 12
Çizelge 3.2 : İki sınıflı modeller için hata matrisi çizelgesi. 23
Çizelge 3.3 : Sınıflandırıcı performans değerlendirme metrikleri. 24
Çizelge 4.1 : İşlenmiş 15 dakikalık gün içi işlem verisi örneği 30
Çizelge 4.2 : Finansal gösterge örnekleri 31
Çizelge 4.3 : Hisselerin etkililik tablosu 33
Çizelge 4.4 : LINK hissesi için İY ile seçilen en iyi 20 model 41
Çizelge 4.5 : LINK hissesi için İVAY ile seçilen en iyi 20 model 41
Çizelge 4.6 : ISCTR hissesi için İY ile seçilen en iyi 20 model 42
Çizelge 4.7 : ISCTR hissesi için İVAY ile seçilen en iyi 20 model 42
Çizelge 4.8 : Hisselerin en iyi fiyat değişim yönü tahmin sonuçları 44
Çizelge A.1 : Gün içi işlem ham verisi örneği 58
Çizelge A.2 : 15 dakikalık gün içi işlem verisi örneği 59
Çizelge C.1 : AKBNK hissesi için en başarılı 40 tahmin modeli 62
Çizelge C.2 : ALCTL hissesi için en başarılı 40 tahmin modeli 63
Çizelge C.3 : ALNTF hissesi için en başarılı 40 tahmin modeli 64
Çizelge C.4 : ANELT hissesi için en başarılı 40 tahmin modeli 65
Çizelge C.5 : ARENA hissesi için en başarılı 40 tahmin modeli 66
Çizelge C.6 : ARMDA hissesi için en başarılı 40 tahmin modeli 67
Çizelge C.7 : ASYAB hissesi için en başarılı 40 tahmin modeli 68
Çizelge C.8 : DENIZ hissesi için en başarılı 40 tahmin modeli 69
Çizelge C.9 : DESPC hissesi için en başarılı 40 tahmin modeli 70
Çizelge C.10 : ESCOM hissesi için en başarılı 40 tahmin modeli 71
Çizelge C.11 : FINBN hissesi için en başarılı 40 tahmin modeli 72
Çizelge C.12 : GARAN hissesi için en başarılı 40 tahmin modeli 73
Çizelge C.13 : HALKB hissesi için en başarılı 40 tahmin modeli 74
Çizelge C.14 : ISCTR hissesi için en başarılı 40 tahmin modeli 75
Çizelge C.15 : KLNMA hissesi için en başarılı 40 tahmin modeli 76
Çizelge C.16 : KRONT hissesi için en başarılı 40 tahmin modeli 77
Çizelge C.17 : LINK hissesi için en başarılı 40 tahmin modeli 78
Çizelge C.18 : LOGO hissesi için en başarılı 40 tahmin modeli 79
Çizelge C.19 : NETAS hissesi için en başarılı 40 tahmin modeli 80
Çizelge C.20 : SKBNK hissesi için en başarılı 40 tahmin modeli 81
Çizelge C.21 : TCELL hissesi için en başarılı 40 tahmin modeli 82
Çizelge C.22 : TEBNK hissesi için en başarılı 40 tahmin modeli 83
Çizelge C.23 : TTKOM hissesi için en başarılı 40 tahmin modeli 84
Çizelge C.24 : VAKBN hissesi için en başarılı 40 tahmin modeli 85

ŞEKİL LİSTESİ

Sayfa

Şekil 2.1 : NYSE hisse senetlerinin oluşturduğu etkililik grafı (Kullmann ve diğ., 2008). 4
Şekil 3.1 : Çok katmanlı perseptron yapısı. 21
Şekil 4.1 : Tez çalışmasının genel süreci. 28
Şekil 4.2 : 0,06 benzerlik eşiği ile hisse etkililik çizgesi (Salık, 2014). 34
Şekil 4.3 : Sektörel borsa ağı (Salık, 2014). 35
Şekil 4.4 : İY yaklaşımıyla elde edilen özniteliklerin ortalama puanları. 37
Şekil 4.5 : İVAY yaklaşımıyla elde edilen özniteliklerin ortalama puanları 38
Şekil 4.6 : Öznitelik seçim yöntemlerinin başarı dağılımı. 39
Şekil 4.7 : En iyi model belirleme sahte kodu. 40
Şekil B.1 : LINK hissesine ait İY öznitelik puanları. 60
Şekil B.2 : TEBNK hissesine ait İY öznitelik puanları. 60
Şekil B.3 : LINK hissesine ait İVAY öznitelik puanları. 61
Şekil B.4 : TEBNK hissesine ait İVAY öznitelik puanları. 61

BORSA İSTANBUL (BIST) HİSSE FİYAT DEĞİŞİM YÖNÜNÜN İLİŞKİSEL BORSA AĞI KULLANILARAK TAHMİN EDİLMESİ

ÖZET

Borsada bir hisse senedinin fiyatı, ulusal veya küresel etkenler ile ilişki içinde olduğu öteki firmaların durumlarından etkilenebilmektedir. Küresel veya ulusal etkenler, senet fiyatlarında aynı zamanlarda etki gösterirken; ilişkili firmaların etkisi belli zaman kaymalarıyla görülebilmektedir. Yapılan bu tez çalışmasında, Borsa İstanbul (BIST) dahilindeki hisse senetleri arasından, Bankacılık, Telekomünikasyon ve Bilgi Teknolojileri sektörlerine ait hisseler için 15 dakikalık aralık sonundaki fiyat değişim yönü tahmin edilmiştir. Fiyat değişim yönü tahmin modelinde; hem hisselerin kendi geçmiş fiyat bilgisinden, hem de ilişki içinde olduğu saptanan diğer bazı hisseler ile olan bağlantılardan yararlanılmıştır.

Fiyat değişim yönünün 15 dakika aralığıyla tahmin edilebilmesi için, hisselerin gün içi borsa işlem verisinden yararlanılmıştır. Bu veri üzerinden, her 15 dakikalık aktif borsa aralığına ait öznitelik vektörleri oluşturulmuştur. Sınıf etiketleri ise bir sonraki aralık sonunda hisse senetlerinin fiyatlarındaki anlamlı değişikliklerin yönünü gösterecek şekilde belirlenmiş ve bu etiketler öznitelik vektörüne atanmıştır. Öznitelik vektörleri tahmin modelinde kullanılmadan önce, öznitelik seçim yöntemleri ile puanlandırılmış ve sonrasında da [0-1] aralığına normalleştirilmiştir.

Yapılan tez çalışmasında iki farklı yaklaşımla hisse fiyat değişim yönü tahmini yapılmıştır. Birinci yaklaşıma göre (İçerik Yaklaşımı, İY), hisselerin yalnızca kendi geçmiş fiyat bilgisinden yararlanılmış; ikinci yaklaşımda (İçerik ve Ağ Yaklaşımı, İVAY) ise hisselerin kendi geçmiş fiyat bilgisinin yanı sıra, bu hisseyi etkileyen diğer hisse senetleri ile olan ilişkiler kullanılmıştır.

Birinci yaklaşıma göre hisselerin geçmiş fiyat bilgilerinden literatürde kullanılmış finansal göstergeler hesaplanmış ve bu göstergeler öznitelik vektörlerini oluşturmuştur. İkinci yaklaşımda ise, finansal gösterge öznitelik vektörlerine, hisseyi etkileyen diğer hisse senetlerinin geçmiş fiyat değişim yönü etiketleri eklenmiştir. Bir hisseyi etkileyen diğer hisse senetlerinin saptanmasında, iki hisse senedinin geçmiş fiyat vektörleri arasındaki zaman kaymalı Pearson benzerliğinden yararlanılmıştır. Zaman kaymalı benzerlik hesapları sayesinde, hangi hissenin hangi hisseyi ne kadar, ne yönde ve ne tepki süresiyle etkilediği bulunmuştur. Etkileşim bilgisi sayesinde hisse senetlerinin etkileşim çizgesi oluşturulmuştur. Bu heterojen çizgede, hisselerin birbirlerini pozitif ya da negatif etkilediği ve etkileşimin en kuvvetli olarak hangi zaman aralığında olduğu bilgisi gösterilmektedir.

Her iki yaklaşım için kurulan tahmin modellerinde, en iyi model parametrelerinin belirlenmesi amacıyla eğitim verisinin bir kısmı doğrulama veri kümesi olarak kullanılmış ve test modelinde kullanılacak parametrelere bu aşamada karar verilmiştir. Her hisse senedi için ayrı eğitim modeli kurulmuş olup, her birinde başarı gösteren parametreler farklı olmuştur. İY yaklaşımı kullanılarak, hisse senetlerinin

anlamlı fiyat değişim yönü, en başarılı modellerde LINK hissesi için %100, TEBNK hissesi için %95 makro-ortalama F-ölçütü ile tahmin edilmiştir. İVAY yaklaşımı kullanan en başarılı modellerde TEBNK hissesi için %83, SKBNK hissesi için %77 makro-ortalama F-ölçütü ile tahmin edilmiştir. 24 hisse senedi için en iyi tahmin yapan modellerin makro-ortalama F-ölçütü ortalaması ise İY yaklaşımı için %67, İVAY yaklaşımı için %62 bulunmuştur.

Yaklaşımlar değerlendirildiğinde, bazı hisse senetleri yalnızca kendi geçmiş fiyat bilgisini kullanan İY yaklaşımı ile daha başarılı sonuç üretirken; bazı hisse senetleri ise geçmiş fiyat bilgisi ve hisse ağı bilgisi kullanan İVAY yaklaşımı ile daha başarılı sonuç üretmiştir. İY yaklaşımında başarı elde eden hisselerin sayısı, İVAY yaklaşımında başarı elde eden hisselere oranla daha yüksek bulunmuştur.

Bu tez çalışması sonucunda; ilişkisel borsa ağının çıkarılması, çıkarılan ağ ile içerik bilgisinin birlikte kullanılarak sınıflandırma yapılması, öznitelik seçme ve en iyi model parametresi belirleme süreçlerinin birlikte yapılması bu alanda yapılan çalışmalara katkı sağlamıştır.

FORECASTING STOCK PRICE CHANGE DIRECTION USING RELATIONAL STOCK MARKET NETWORK ON BORSA İSTANBUL (BIST)

SUMMARY

A stock market is a financial place that buyers and sellers agree on a price for stocks of a company, where the stocks are the most common instances of the both real and digital money, representing the specified percentage of that company. Stock market brings investors together to agiotage on company shares. Those shares have flexible prices depending on supply and demand. A stock price will possibly increase in case of high demand, whereas the price will decrease when supply is higher than demand.

By supporting mobile investigation for traders, helping to raise capital for companies, supplying an environment for profit sharing; stock exchanges actually have a crucial role in the economy. Traders as buyers, who chase for daily or long term opportunities, try to get profit from the market, while the businesses as sellers also struggle to get benefit from the investment of those traders. This exchange is mostly balanced between the supply and demand expectations.

Especially for recent years, prediction and analysis models for stock markets, which are financial profit opportunity sources, draw much attention of the researchers. However, forecasting the direction of stock prices is a challenging issue since the financial market traces static and dynamic, linear and nonlinear, multifaceted parameters. Two main opposite ideas related with stock market prediction are argued for years: Efficient Market Hypothesis (EMH), and Prediction Methods.

Efficient Market Hypothesis claims that stock prices follow a random walk; therefore the price trends are completely unpredictable. Especially for long time periods, theory ignores the prediction methods to outperform a buy and hold strategy. Globally, there have been many supporters of this theory.

In fact the situation is not desperate at all with the help of four main prediction methods: Traditional time series predictions, machine learning, technical and fundamental analysis. Time series prediction basically represents a linear combination of past values with a noise factor. This approach is combined with the Moving Average model and constructs a linear and stable relation. Machine learning techniques like linear regression, ANN models, SVMs are commonly used to forecast the stock market.

Technical analysis investigates the financial indicators related with the stock market, and tries to predict future values of time series data belonging specific stocks. This approach assumes that stock market – news relation effects on real time prices, therefore technical analysis does not evaluate news. Fundamental analysis tries to understand the relation between stock prices and supply – demand factors.

Artificial neural networks have been performed successfully in common on financial problems in the recent literature as a technical analysis methodology. One of the

main reasons is that the ANNs are able to find out the complicated relations, since they are general function approximations. As there are chaotic relationships among the parameters affecting the stock market, artificial neural networks seem suitable for such a large complex feature and data set. Secondly, artificial neural networks are so adaptive that they are able to recognize patterns also other than in the training set. So for such extended data sets ANNs would be helpful.

Forecasting the direction of stock prices is a challenging issue since the financial market traces static and dynamic, linear and nonlinear parameters. In a stock market, the direction of a stock price depends on many parameters like financial indicators, company relations, and local or global factors.

However, the exact nature of these dependencies is not fully known, and varies from market to market. While global or local factors affect the stock prices at the same time, the effect of related companies could be seen within a time delay. In this thesis, we construct a prediction model for the next 15 minutes price change direction of each stock among the Banking, Telecommunication and Information Technologies areas of Borsa Istanbul (BIST). For that purpose, we use both the past price vectors of a stock itself, and links representing the effectiveness on a stock network.

In order to predict the future price direction of a stock within 15 minutes, we use day-in stock market activity records between July and November 2013, which BIST shared for academic purposes. Using these records, we construct stock price vectors for each 15 minute active period of stock market. We label these vectors to determine the direction of stock price, considering significant price changes on those prices. In order to eliminate the unimportant price changes for a stock, we use volume information and standard deviation of price vectors. If the price change is over that standard deviation, we label the corresponding period of vector as {+1}. If the price change is under the standard deviation, we label as {-1}, and otherwise, in case of no significant changes, we use label {0}. After labeling the price vectors, we generate feature vectors for each training or test dataset. Generated feature vectors are first ordered by the feature selection/elimination techniques, and then normalized into [0-1] scale.

For the purpose of stock price change prediction, we use two different approaches called Content Only (CO), and Content and Link (CL) while constructing prediction models. In the CO approach, model uses only past prices of a stock itself; while the CL approach uses both past prices and links from the other stocks in the same network.

The first approach (CO) uses the financial indicators, which are statistical metrics representing the trend of the specific stock. There are many kinds of financial indicators, in this study, we use the financial indicators which have been used in previous studies on stock price prediction. The features used by the CO approach for classification are the only the indicators. We use 11 different types of financial indicators in this study. Since every indicator has parameters on its own, we determine three different parameters for each financial indicator. Eventually, after the addition of volume as an indicator, 34 features are used in the CO model.

The second approach (CL) uses both the financial indicators of a period of the specific stock, and the cross-correlations between the other stocks in the network. While constructing the network among other stocks, we analyze the similarities between two stock price change vectors using Pearson correlation coefficient with different time delays. Thus, with the help of sliding comparison of stock price change

vectors, we observed that which stock affects the other, with how much weight, and with how much delay.

With the relational information among stocks, we build an interaction graph of the stock market. In such a heterogeneous graph, we are able to observe the stock relationships. CL uses those relations as features. While extracting link based features, we first determine the most correlated stocks affecting the specific stock. Then, we also determine the most correlated time delay for the specific relationship. According to that information, we choose three labels for each linked stock. Since five most correlated stocks are chosen for each stock, CL uses 15 features from stock market network. Therefore, a total of 34 + 15 = 49 features are used in CL model.

As mentioned above, stock market is a complicated environment where many linear, nonlinear, dynamic parameters influence the prices. Therefore it is important to determine significant features for the specific stock market, or each specific stock. Besides, the cost and running time of the prediction model can be optimized by selecting features, and high performance results might be obtained with a sufficient feature subset.

After generating features for each approach, we score those features using two different feature elimination techniques called mRMR (minimum Relevance Maximum Redundancy) by Peng et. al. (2005), and RFESVM (Recursive Feature Elimination SVM) by Guyon et. al. (2002). Feature selection techniques helps to use much more significant features, and to increase performance of classification model eliminating useless features. For the first approach CO, features are scored 1-to-34; while for the second approach CL, features are scored 1-to-49.

In this thesis, we use a validation dataset to determine the best model parameters. Those parameters are consisting of feature elimination technique, top feature count, classification algorithm, and classification parameters. Thus, we decide the features to be used after testing them on a validation set, like the model parameters. At least 14544 models with different parameters are examined, and then the best 20 of them are chosen for the real tests for each approach of CO, and CL.

At the end of the study, since each kind of stock has its own best model parameter, 40 different models are examined for each stock. Using first approach CO, the future price change direction is predicted with %100 macro-average F-measure for the stock LINK, and %95 macro-average F-measure for the stock TEBNK. Then, using second approach CL, the best results are seen on stock TEBNK with %83 macro-average F-measure, and on stock SKBNK with %77 macro-average F-measure. Considering average results among all stocks, CO approach reaches %67 macro-average F-measure, while CL approach reaches only %62.

Analyzing the results, CO approach that uses only past stock price change data of its own predicts better than CL approach that uses both stock past price changes, and stock market network relations as features, for most of the stocks. Considering the feature elimination methods, and classification techniques, mostly RFESVM and Multilayer Perceptron combination gives much useful information among all the prediction models.

In conclusion, within this thesis, we construct a relational stock market network, we use the relations based on this network while predicting the future stock price change direction with also the content information carrying past stock prices. We also determine the features and model parameters at the same time by testing thousands of combinations on validation dataset.

1. GİRİŞ

Borsa kavramını oluşturan fiyat değişim yönü, endeks, risk gibi metriklerin tahmin edilmesi üzerine çok sayıda çalışma yapılmıştır. Bu çalışmaların, borsayı etkileyebileceği düşünülen parametrelerin çeşitliliği sebebiyle, çok farklı yaklaşımları benimsediği görülmektedir. Çalışmaların bir kısmı, hisse senedi fiyat değişimine etki edebilecek dış etkenleri araştırarak, hisseye olan arz ve talep dengelerinin nasıl değiştiğini gözlemler. Bu dengeleri şirket durum bildirileri, şirket raporlamaları, bilançolar, ulusal veya küresel haberler, enflasyon oranı, gayri safi milli hasıla gibi etkenler değiştirebilmektedir. Bu tip etkenlerin borsaya etkisi, Temel Analiz yaklaşımı ile ele alınmaktadır. Yapılan çalışmaların diğer bir kısmının ise Teknik Analiz yaklaşımını benimsediği görülmüştür. Teknik Analiz yaklaşımında, hisse senetlerinin geçmiş fiyat verileri, birer zaman serisi olarak kabul edilir. Hisselere ait metriklerin tahmini yapılırken; sinyal işleme yöntemleri, yapay sinir ağları, destek vektör makineleri gibi makine öğrenmesi teknikleri kullanılır. Bu teknikler, fiyat bilgisinden oluşan zaman serilerinden örüntü çıkararak, saptanmak istenen tahminler konusunda sayısal veriler oluşturur. Bu tez çalışmasında Teknik Analiz yaklaşımı esas alınarak istatistiksel hesaplamalara dayalı tahmin modelleri oluşturulmuştur.

1.1 Tezin Amacı

Hisse senetleri fiyatlarının oluşması sırasında şirketler, küresel veya ulusal etkenler ve piyasayı etkileyen farklı parametreler; hareketlilikte genel bir desen meydana getirebilmektedir. Bu tez çalışmasında:

- Hisse senetlerinin geçmiş gün içi fiyat verileri kullanılarak finansal göstergeler hesaplanmış,
- Telekomünikasyon, Bankacılık ve Bilgi Teknolojileri sektörlerine ait hisse senetleri arasındaki ilişkiler bulunmuş,
- Yalnızca finansal göstergeler kullanılarak tahmin modeli geliştirilmiş,

- Hem finansal göstergeler, hem de hisse senetlerinin birbirleriyle olan ilişkileri kullanılarak tahmin modeli geliştirilmiş,
- 15 dakika aralığıyla hisselerin fiyat değişim yönü tahmin edilmiş,
- Kullanılan yaklaşımlar ve tahmin modelleri kıyaslanmıştır.

Hisselerin kendi fiyat geçmişleri, genel örüntüleri çıkarmak üzere çalışmaya yardımcı olurken; ilişkili olan hisselerin birbirine etkisi de belli zaman kaymaları ile fiyat değişim yönünü tahmin etmede etkili olabilmektedir.

Birbiri ile ilişkili olan hisselerin tespit edilmesi için, yine gün içi fiyat verileri kullanılmış ve hisselerin fiyat vektörleri arasındaki Pearson benzerliklerinden yararlanılarak; şirketlerin birbirini ne yönde, ne kuvvetle ve ne kadarlık bir tepki süresi ile etkilediği bulunmuştur.

Çalışma sırasında Borsa İstanbul'da Bankacılık, Telekomünikasyon ve Bilgi Teknolojileri sektörlerinde yer alan 24 farklı hisse senedinin 15 dakika aralıklı gün içi fiyat bilgisinden yararlanılmıştır (BIST, Borsa İstanbul). Bu çalışma sonunda, her hisse senedi için kendine özel bir tahmin modeli geliştirilmiş, modelin parametreleri doğrulama verisi üzerinde yapılan testler ile belirlenmiş ve en başarılı modeller test veri kümesi üzerinde sınanarak sonuçlar elde edilmiştir. Sonuçlar arasında, bazı hisselerin yalnızca kendi geçmiş fiyat bilgisini kullanan modellerde başarı gösterdiği, bazı hisselerin ise hem kendi geçmiş fiyat bilgisini hem de diğer hisseler ile olan ilişki bilgisini kullanan modellerde başarı gösterdiği gözlemlenmiştir.

1.2 Tezin Yapısı

Tez çalışması 5 ana bölümden oluşmaktadır. İlk bölümde tez ile ilgili genel bilgiler ve çalışmanın amacı ile ilgili bilgiler verilmiştir. İkinci bölüm ile çalışma, yapılan literatür araştırmalarından sunulan örnekler ile devam etmektedir. Bu örneklerde geçmişte ülkemizde ve dünyada borsa metrikleri üzerine ne türde tahmin çalışmaları yapıldığı, hangi yaklaşımların kullanıldığı özetlenmiştir. Üçüncü bölümde borsa verisi tanıtılmış; verinin nasıl işlendiği, özniteliklerin nasıl oluşturulduğu, hangi öznitelik seçim yöntemlerinin kullanıldığı, hangi tekniklerle sınıflanma yapıldığı ve sınıflandırıcıların nasıl değerlendirildiği anlatılmıştır. Tez çalışmasının dördüncü bölümünde tahmin modeli ile alınan sonuçlar, görsel çıktılar ve bu çıktıların analizi sunulmuştur. Son bölümde ise bu çalışma ile ilgili yorumlar paylaşılmıştır.

2. İLGİLİ ÇALIŞMALAR

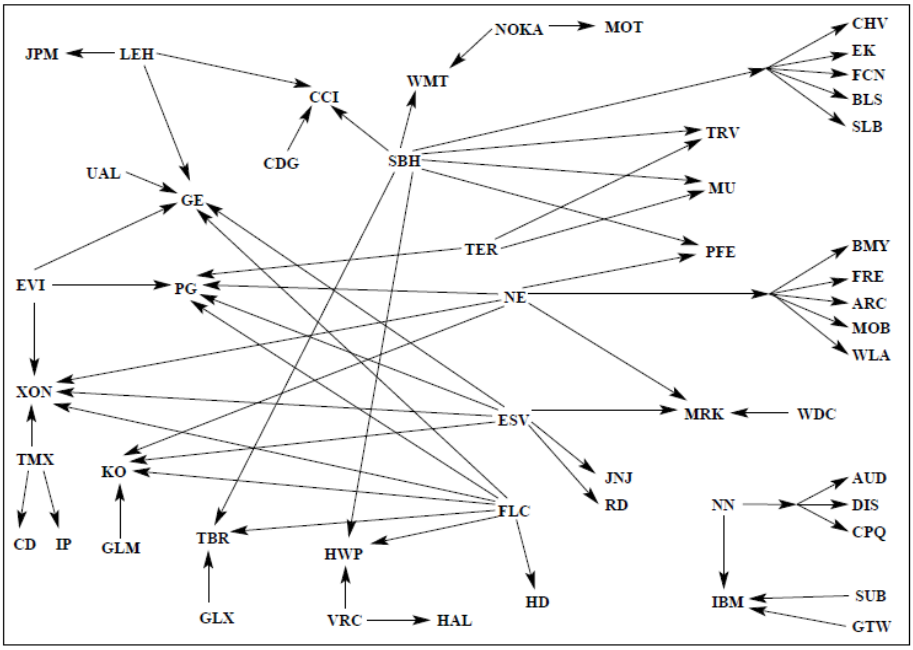
Önceki bölümlerde belirtildiği üzere tez çalışması kapsamında, hisse senetlerinin gün içi fiyatlarından ve hisseler arasındaki ilişkilerden yararlanılarak, 15 dakika aralık ile hisselerin fiyat değişim yönü tahmin edilmiştir. Bu kapsamda yapılan literatür araştırması, hisseler arasındaki ilişkilerin bulunması ve hisselerin geçmiş fiyat bilgisinden yararlanılarak yapılan tahmin çalışmaları olarak sınıflandırılabilir.

2.1 Hisseler Arasındaki İlişkilerin Bulunması

Aynı borsada yer alan hisse senetleri, çoğunlukla benzer zaman ve ekonomi koşullarından etkileneceğinden, aralarında bir ilişki ağı olduğu öngörülebilir. Özellikle aynı veya yakın sektördeki hisselerin hareketliliği benzerlik gösterebilmektedir. Borsadaki hisse senetleri arasında bir ağ oluşturmak üzere yapılan en yakın çalışmalardan bir tanesi Tse ve diğ. (2010) tarafından ele alınmıştır. Bu çalışmada Amerikan borsasındaki tüm hisse senetleri arasındaki benzerlik, bu hisselerin yaklaşık 2 senelik geçmiş fiyat bilgisinden yararlanılarak hesaplanmıştır. Benzerlik metriği olarak Pearson benzerliği kullanılmış ve fiyat bilgisi olarak yalnızca kapanış fiyatları modele dahil edilmiştir. Bu benzerliklerden yararlanılarak oluşturulan ilişkisel borsa ağında, yalnızca aynı zamandaki benzerliklere bakıldığından ilişkilerin yönü hesaplanmamış, sadece ilişkinin var olup olmadığı saptanmıştır. Çalışmanın sonunda, yoğun olarak ilişki kuran hisseler değerlendirildiğinde, finans sektöründeki hisselerin baskınlığı gözlemlenmiştir.

Kullmann ve diğ. (2008) yaptığı bir başka çalışmada ise hisse senetlerinin fiyatları arasındaki karşılıklı ilişkiler, hisse fiyat vektörleri üzerindeki zaman kaymaları dikkate alınarak hesaplanmıştır. Çalışmalarının çıktıları, iki türden etkenin hisse senetlerinin fiyatlarında değişime sebep olduğunu göstermiştir. Bunlardan birincisi dış etkenlere dayanmaktadır. Ekonomi, politik haberler gibi genel geçer dış etkenler, hisse fiyatlarının aynı anda artış veya azalış göstermesine sebep olmaktadır. İkinci tip etken ise, iç etkilerden, yani hisseyle ilgili özel durumlardan oluşmaktadır. Bir şirket ile ilgili bir haber, öteki şirketi ekiliyorsa, bu durum ikincil şirketin hisse fiyatlarında

bir zaman kayması sonrasında artış veya azalış olarak gözlemlenmektedir. Bu durum çalışma içerisinde "çekme etkisi" olarak adlandırılmıştır. Çalışma sonunda hisseler arasındaki ilişkiler Şekil 2.1'deki gibi gösterilmiştir.



Şekil 2.1 : NYSE hisse senetlerinin oluşturduğu etkililik grafı (Kullmann ve diğ., 2008).

H.J. Kim ve I.M. Kim (2001)'in bir çalışmasında ise, rastsal çizge teorisi kullanılarak, hisse fiyatları arasındaki karşılıklı ilişkiye ait bazı metrikler öngörülmeye çalışılmıştır. Yine çizge teorisi kullanılarak oluşturulan hisse senedi fiyatlarını gösteren hiyerarşik ağaçlar ve en küçük kapsar ağaç kullanan başka çalışmalar da mevcuttur. En küçük kapsar ağaç kullanılarak hisse ilişkilerini inceleyen çalışmaların amacı, şirketler arasında etkileme gücü en yüksek olanları tespit edebilmektir (Mantegna R.N., 1999; Bonanno G., 2000). Ayrıca L. Laloux ve diğ. (1999) çalışmasında en yüksek özdeğerlere sahip özvektörlerin, borsadaki en etkileyici hisse sahiplerine ait olduğu gösterilmiştir.

En küçük kapsar ağaç kullanılarak hisse ilişkilerinin gösterildiği bir başka çalışma örneği de, Bonanno ve diğ. (2008) çalışmasıdır. Oluşturulan bu topolojide, en yüksek etkiye sahip hisseler merkeze en yakın olanlardır. Küçük etkiye sahip olan hisseler ise uç noktalarda konumlandırılmıştır.

Hisse fiyatlarının ilişkilendirilmesinde hiyerarşik çözüm sunan bir başka çalışma yine Mantegna (2000) tarafından yapılmıştır. Bu çalışmada, hisse fiyatlarının

logaritmik değerlerinin günlük zaman serileri halinde çıkarılması sonucu hiyerarşik bir finansal market ağı kurulmuştur.

Brezilya borsası üzerinde yapılan bir başka çalışmada ise, dalgacık teorisi kullanılarak hisse fiyatlarının öngörülmesi modellenmiştir (Caetano M.A.L. ve Yoneyama T.). Bu modelin oluşturulmasında yine ilişkisel hisse senedi ağı kullanılmıştır.

Bernstein ve diğ. (2002) çalışmasında ise, fiyatlar yerine, hisse senetleri hakkında çıkan haberler incelenerek, aynı haberde çıkmalarına göre şirketler arasında benzerlikler hesaplanmış ve bu şekilde oluşturulan çizge incelenmiştir.

2.2 Hisselerin Geçmiş Fiyat Bilgisinden Yararlanılarak Yapılan Tahmin Çalışmaları

Borsa, küçük veya büyük tüm yatırımcılara dinamik yatırımlarla anaparalarını arttırma şansı tanıdığından ve karlılık paylaşımı adına temel bir ortam oluşturduğundan ekonomide önemli bir rol oynamaktadır (Soni, 2011). Alıcı rolündeki yatırımcılar, günlük veya uzun süreli fırsatları kovalayarak pazardan kar sağlama amacı güderler. Farklı ölçeklerdeki şirketler de satıcı rolünde yer alarak, alıcıların yaptığı yatırımlardan faydalanmaya çalışırlar. Bu alış veriş, arz-talep beklentileri üzerinde dengesini kurar. Bireysel, kurumsal ve hatta ulusal veya küresel ekonominin bu denli içinde yer alan bir oluşum olarak borsalar, araştırmacılar tarafından modellenmeye çalışılmış; analizinin yapılması için çeşitli yöntemler önerilmiştir. Bu yöntemlerden en çok kabul gören yaklaşımlar, Temel Analiz ve Teknik Analiz başlıkları altında toplanmıştır (Elkan, 1999).

Temel analiz yaklaşımı, hisselerin kendisini veya ülkenin genel ekonomisini etkileyebilecek faktörler üzerinde yoğunlaşır. Bir hissenin arz-talep dengesini değiştirebilecek etkenleri analiz ederek, hisse fiyatına yapacağı etkiyi tahmin etmede kullanır. Örneğin şirket bildirileri, raporlamaları, bilanço paylaşımları gibi veriler temel analiz yaklaşımında kullanılır (Gidófalvi, 2001). Şirkete dair bilgilerin dışında, ülke ekonomisinin ölçütleri arasında sayılan enflasyon rakamları, işsizlik oranı, gayri safi milli hasıla gibi finansal verilerin de hisse fiyatlarındaki etkisi (Schumaker ve Chen, 2009) temel analiz ile araştırılır.

Teknik analiz yaklaşımı ise, hisse fiyatlarının tahmin modellerinde hisselerin geçmiş fiyat bilgisinden yararlanır (Abdullah ve Ganapathy, 2000). Geçmiş fiyat bilgilerini anlık sinyaller olarak kabul ederek, bu sinyaller üzerinden örüntü çıkarma işini teknik analiz çalışmaları üstlenir.

Borsa üzerine yapılan tahmin çalışmaları, çoğunlukla teknik analiz yöntemleri üzerinde yoğunlaşmıştır. Önceki yıllara ait çalışmalarda kullanılan tahmin modellerinin çoğunluğu Hareketli Ortalama, Otoregresyon gibi sinyal işleme tekniklerini kullanarak sonuç elde etmeye çalışmıştır. Daha sonraki yıllarda ise yapay sinir ağları ve destek vektör makineleri tahmin modellerinde sınanmış ve çoğunlukla daha başarılı olduğu gözlemlenmiştir.

Hisselerin geçmiş fiyat bilgilerini kullanarak; fiyat yönü tahmin etme, borsa 100 endeksi tahmin etme, risk durumu tahmin etme gibi alanlarda çeşitli modellemeler geliştirilmiştir. Bu bölümde tanıtılan çalışmalar, son zamanlarda başarı oranlarının daha yüksek olduğu saptanan yapay sinir ağları ve destek vektör makineleri tahmin modelleri üzerine yoğunlaştırılmıştır.

2.2.1 Yapay sinir ağları kullanılarak yapılan borsa tahmini çalışmaları

Yakın zamanda yapılan çalışmalarda yapay sinir ağlarının, özellikle finansal problemler üzerinde etkili bir şekilde çalıştığı gözlemlenmiştir. Abhyankar, Copeland, & Wang (1997), Wilson & Sharda (1997), Donaldson & Kamstra (1997), Kim & Chun (1998), Saad, Prokhorov, & Wunsch (1998), Leung, Chen, & Daouk (2000), Castiglione (2001), Liu & Yao (2001), Kanas (2001), Kanas & Yannopoulos (2001), Dunis & Huang (2002), Shively (2003), Phua, Zhu, & Koh (2003), Black & McMillan (2004), Jasic & Wood (2004), Hamid & Iqbal (2004), Altay & Satman (2005), Zhu, Wang, Xu, & Li (2008), Senol & Ozturan (2008), Bildirici & Ersin (2009), Soni (2011), Kara, Boyacioglu, & Baykan (2011) ve daha pek çok çalışmada, yapay sinir ağlarının endeks tahmini, işlem hacimliliği, hisse trendleri gibi konularda başarılı sonuçlar verdiği görülmüştür. Türkiye'de yapılan finansal tahmin çalışmaları ise çoğunlukla işlem hacimliliği, hisse fiyatlarının değişim yönü ve iflas risklerinin tahmin edilmesi üzerine yoğunlaşmıştır (Avcı, 2007).

Egeli ve diğ. (2003), bir sinyal işleme tekniği olan Hareketli Ortalama modeli ile iki farklı sinir ağı yöntemini (çok katmanlı perseptron, genelleştirilmiş ileri besleme modeli) karşılaştırmıştır. Modeli oluştururken parametre olarak önceki günün endeks

bilgisini, TL/dolar eşitliğini, hafta içi her bir günü temsilen 5 farklı değişkeni kullanmıştır. Çalışmasının sonunda, tek saklı katman kullanan genelleştirilmiş ileri besleme modelini en başarılı model olarak göstermiştir.

Yumlu ve diğ. (2005) de farklı sinir ağları yöntemleri ile zaman serisi yöntemlerini karşılaştırmış ve bir sinir ağı yöntemi olan Uzmanların Karışımı (İng. Mixture of Experts) yöntemini en başarılı olarak etiketlemiştir. Geçmiş günlük kapanış fiyat bilgisi serisi dışında 4 farklı seriden daha yararlanmış ve borsa 100 endeksi ile dolar bilgilerinin serilerinde kayan pencereler tekniğini kullanmıştır.

Avcı (2007), çok katmanlı perseptron modelleri kullanarak, günlük ve oturum seanslık endeks tahminlerini modelleme üzerine çalışma yapmıştır. Diler (2003) ise geri yayılım algoritması ile bir hissenin ertesi gün için fiyat değişim yönünü tahmin etme üzerine çalışmıştır. Aktaş ve diğ. (2003) de yaptığı çalışmalarda, sinir ağları kullanan modellemelerin çoklu-regresyon, çoklu-farklılık analizi gibi yöntemlerden daha iyi çalıştığını ispatlamıştır. Kara ve diğ. (2011) de yaptığı çalışmada sinir ağları modellerinin finansal tahmin konularında başarılı olduğu öne sürülmüştür.

Yapay sinir ağları modellerinin finansal tahmin konularında bu denli başarılı bulunmasının esas sebeplerinden biri, genel fonksiyon yaklaşımları olmalarından ötürüdür (Soni, 2011). Borsayı etkileyen parametreler arasındaki çok karmaşık ilişkileri çözebilmesi için yapay sinir ağları oldukça uygun görülmektedir. Diğer bir sebep ise, yapay sinir ağlarının uyarlanabilirliğidir. Yapay sinir ağları, eğitim setinde olmayan veriler için bile örüntü tanıyabilmektedir. Bu şekilde yer alan genişletilmiş veri kümeleri için yapay sinir ağları başarılı sonuçlar üretmektedir.

2.2.2 Destek vektör makineleri kullanılarak yapılan borsa tahmini çalışmaları

Destek vektör makineleri (DVM) de son dönemlerde yapılan makine öğrenmesi çalışmalarında oldukça popüler bir yöntem olarak kullanılmaktadır. Huang ve çalışma diğ. (2005), farklı DVM modellerini lineer farklılık analizi, sinir ağları gibi yaklaşımlarla kıyaslamış ve üzerinde çalıştığı Japon borsasındaki hisselerin haftalık NIKKEI 255 endeksini tahmin etmek üzere, DVM'lerin öteki modellerden daha iyi performans gösterdiğini öne sürmüştür.

Manish ve Thenmozhi (2006)'nin yaptığı çalışmada ise NIFTY endeks dönüşünün tahmin edilmesinde, DVM modellerinin yapay sinir ağlarından, rastgele ağaç regresyonundan ve doğrusal ARIMA modellerinden daha iyi çalıştığını göstermiştir.

Pai ve Lin (2005), ARIMA modelinin kendi başına, borsa örneğinde olduğu gibi doğrusal olmayan örüntüleri yakalayamadığını göstermiş ve DVM kullanılarak ARIMA modelinin daha iyi sonuç vereceğini göstermiştir. Tay ve Cao (2002) da farklı DVM modellerini yapısal riski en aza indirme üzerinde kullanmışlardır.

3. BORSA VERİLERİNİN KULLANIM SÜREÇLERİ

Borsa İstanbul, işlem ve emir kayıtlarına dair pek çok veriyi elinde tutmaktadır. Tez çalışması dahilinde bu verilerden, Temmuz – Kasım 2013 arasını kapsayan 5 aylık süre içindeki, hisse senedi fiyat bilgisi ile ilgili olan, gün içi işlem verileri kullanılmıştır. Bu durumda borsa verilerinin, hisse fiyat değişim yönünün tahmininde kullanılması amacıyla, öncelikle hisselerin geçmiş fiyat bilgileri vektörel forma sokulmuş ve fiyat vektörünün her elemanı için ilgili öznitelikler hesaplanmıştır. Oluşturulan fiyat vektörlerinde, hisse fiyatının son değişim yönü, yukarı (+1), aşağı (-1) ve sabit (0) olarak üç sınıfa etiketlenmiştir. Bu sınıflardan yukarı (+1) etiketi, hisse senedinin bir sonraki aralıkta fiyatının artacağını göstermektedir. Aşağı (-1) etiketi, ölçümlenip değerlendirilen öznitelikler sonucu hisse senedi fiyatının bir sonraki aralıkta azalacağını öngörmektedir. Sabit (0) etiketi ise, hisse fiyatının önemli bir değişime uğramadığını göstermektedir. Bu sınıflar etiketlenirken, artış ve azalışların belirlenmesinde yalnızca önemli değişimler göz önünde bulundurulmuştur. Önemli değişimler hesaplanırken, fiyat vektörlerinin standart sapması ve işlem hacimleri baz alınmıştır.

Hisse senetlerinin alım satımları, belirlenmiş aralıklarda olmayıp anlık gerçekleştiğinden, verilerin vektörel hale getirilmesi için gün içi hisse senedi fiyatlarının sabit aralıklarla ölçümlenmesi gerekmektedir. Tez çalışmasının bu bölümünde, vektör oluşturmak üzere borsa verisinin işlenmesi, hisse senetleri arasındaki ilişkilerin bulunması, fiyat vektörleri ve hisse ilişkilerinden özniteliklerin elde edilmesi, özniteliklerin seçim yöntemlerine göre puanlanması ve oluşturulan verinin sınıflandırılması ile bu süreçlerde kullanılan yöntemler anlatılacaktır.

3.1 Gün İçi Borsa Verilerinin Tanıtılması

Borsa İstanbul, geçmişe dönük gün içi ve gün sonu verilerini kayıt altında tutmaktadır. Gün sonu verilerini fiyat ve işlem hacmi bilgileri ile endeks ve işlem hacmi bilgileri oluştururken; gün içi verilerini işlem defteri bilgileri, emir defteri bilgileri ve endeks bilgileri oluşturmaktadır (www.borsaistanbul.com). Gün içi işlem

defteri bilgilerinde; alım satımı gerçekleşen hisse ismi, market tipi bilgileri, işlemin gerçekleştiği tarih, zaman, seans bilgisi, hangi alım emri ile hangi satım emrinin birbirini karşıladığı bilgisi ve hissenin hangi fiyattan kaç adet işlem gördüğü bilgisi tutulmaktadır. Gün içi emir defteri bilgilerinde ise, alım veya satım emrinin verildiği hisse senedi bilgisi, verilen emrin fiyat ve adet bilgisi, emrin verildiği tarih ve geçerlilik süresi gibi bilgiler tutulmaktadır.

Bu tez çalışmasında gün içi borsa verilerinden işlem defter bilgileri hesaplamalarda kullanılmıştır. İşlem defter bilgilerindeki tarih ve zaman bilgisi, hisse senedi bilgisi, işlem görülen fiyat ve adet bilgisi tez çalışmasının ham verisini oluşturmaktadır.

3.2 Gün İçi İşlem Verisinin Aralıklandırılması

Borsa İstanbul'un kayıt altında tuttuğu geçmiş gün içi işlem verisi, gerçekleşen işlemlerin fiyat ve adet bilgilerini anlık zaman damgalarıyla tutmaktadır. Bir hisse senedi için aynı dakika içerisinde farklı adet ve fiyatlarda işlem görülebilmektedir. Bu işlemler alım satım emirleri ile ilişkili olarak tutulduğundan aynı hisseye ait aynı fiyattan görülen işlemler için dahi birden fazla kayıt tutulmaktadır.

Yapılan tez çalışmasında, hisse senetlerinin fiyat değişim yönlerinin tahmin edilebilmesi için, geçmiş fiyat bilgilerinin vektörel olarak tutulması ve vektörü oluşturan işlem bilgilerinin önceden belirlenmiş zaman aralıkları ile toplanması gerekmektedir. Bu amaçla, gün içi işlemler için vektör oluşturma aralığı 15 dakika olarak seçilmiş ve anlık işlem bilgisi içeren ham borsa verisi bu aralığa göre işlenmiştir.

3.2.1 Fiyat vektörlerinin oluşturulması

Hisse senetlerinin fiyat bilgilerini birbiri ile karşılaştırabilmek için eş zamanlardaki fiyat bilgilerinin esas alınması gerekmektedir. Bu sebeple, hedef olarak seçilen her hisse için, belirlenen aralıklar ile bir fiyat vektörü oluşturulmuştur. Aralığı 15 dakika olarak belirlenmiş fiyat vektörlerini oluştururken, vektörün o aralığa ait fiyat bilgisini, istenen aralıkta gerçekleşen son işleme ait fiyat bilgisi oluşturur. Örneğin; AKBNK hissesi için, fiyat vektörü üzerinde 01.10.2013 10:00:00 zamanına denk düşen fiyat bilgisini elde etmek için, bu zamanda gerçekleşen bir işlem varsa o işlemin fiyat bilgisi vektöre alınır. Tam olarak bu zamanda bir işlem

gerçekleşmemişse, bu zamandan önce gerçekleşen son işlemin fiyat bilgisi temel alınarak, vektörün bu zamandaki fiyat bilgisi oluşturulur.

3.2.2 İşlem hacmi ve önemli fiyat değişimlerinin hesaplanması

Hedef seçilen her bir hisse senedi için 15 dakikalık aralık ile oluşturulan fiyat vektörlerinin yanı sıra, yine 15 dakikalık aralıktaki işlem adeti bilgisi de vektörel olarak hesaplanmıştır. İşlem adeti bilgisi, bir hisseye ait gerçekleşen alım satımın hacimliliğini göstererek, bu işlemde belirlenen fiyatın hisse senedinin değeri üzerinde ne kadar önemli etki bıraktığı konusunda fikir vermektedir. Hisse senedine ait fiyat değişimleri belirlenirken, yüksek hacimle gerçekleşen işlemlerin fiyatları, düşük hacimle gerçekleşen işlemlerin fiyatlara göre önceliklendirilmesi gerekmektedir. Böylelikle yalnızca önemli fiyat değişimleri tahmin modelinde değerlendirilmiştir.

Fiyat vektörlerini oluştururken olduğu gibi, işlem hacim vektörleri de oluşturulurken, belirtilen vektör aralığında hisseye ait işlem hacmi adetleri hesaplanmış ve vektöre atanmıştır.

Fiyat ve işlem hacmi vektörlerinden yararlanılarak, bu vektörlere ait aynı zaman aralıklarında bir de fiyat değişim vektörü oluşturulmuştur. Fiyat değişim vektörleri oluşturulurken, fiyat ve işlem hacmi bilgilerinin standart sapma aralığından farklı olması, bu değişimin önemli olduğu bilgisini oluşturmuştur.

Örneğin, i. hisse senedinin herhangi bir s anına ait fiyatı $p_i(s)$ ve son aralıktaki işlem adeti $v_i(s)$ olarak kabul edildiğinde, s. zaman için hisse senedinin fiyatındaki değişim ve işlemlilik çarpımı aşağıdaki şekilde hesaplanmıştır:

$$q_i(s) = \frac{\left(p_i(s) * v_i(s) - p_i(s-1) * v_i(s-1)\right)}{p_i(s) * v_i(s)} \qquad \textbf{(3.1)}$$

σ_i 'yi q_i'in standart sapması olarak kabul edildiğinde ise, hisse senedi fiyatındaki önemli değişiklikler aşağıdaki şekilde hesaplanmıştır:

$$r_i(s) = \begin{cases} -1\text{, Eğer } q_i(s) < -\sigma_i \\ 0\text{, Eğer } -\sigma_i \leq q_i(s) \leq \sigma_i \\ 1\text{, Eğer } q_i(s) > \sigma_i \end{cases} \qquad \textbf{(3.2)}$$

Eğer s'inci 15 dakikalık hisse fiyatı $p_i(s)$, 15 dakika önceki görülen $p_i(s-1)$, fiyatına göre önemli bir miktarda artmışsa (azalmışsa) etiket olarak +1 (-1), önemli bir değişim olmamışsa etiket olarak 0 atanmıştır. Değişimin önemli olup olmadığına i senedi için veri kümesi içinde fiyat değişiminin standart sapmasına (σ_i) göre karar verilmiştir. Günlük açılış ve kapanış saatleri dışındaki fiyat değerleri için bu zamanlardaki $r_i(s)$ değerleri hesaplamalarda kullanılmamıştır. Bu şekilde her hisse senedi i için fiyat değişim vektörü r_i oluşturulmuştur.

3.3 Öznitelik Seçimi ve Öznitelik Seçiminde Kullanılan Yöntemler

3.3.1 Borsa üzerine öznitelikler

Giriş bölümünde bahsedildiği üzere, borsa üzerine yapılan istatistiksel çalışmaların büyük çoğunluğu teknik analiz kavramını temel almaktadır. Teknik analiz yaklaşımı, ölçülebilir metrikleri ele alarak zaman serileri formunda düşünülen hisse hareketlerini modellemeyi esas alır. Ölçülebilir metriklerden en önemlilerini yine istatistiksel temellere dayanan finansal göstergeler oluşturmaktadır. Chang (2006), Huang (2008), Kara (2011), Çataltepe (2011) çalışmalarında hesaplanabilir birtakım finansal göstergeleri kullanmıştır. Geçmiş çalışmalarda çoğunlukla ortak kullanılan ve tahmin modellemesinde başarılı olduğu gözlemlenen finansal göstergeler, bu tez çalışmasının da özniteliklerini oluşturmak üzere kullanılmıştır. Finansal göstergelerin geçmiş çalışmalardaki kullanım örnekleri Çizelge 3.1'de gösterilmiştir.

Çizelge 3.1 : Finansal gösterge kullanımları.

Gösterge	Geçmiş Kullanımları
SMA	(Avcı, 2011; Senol, 2010; Huang 2008; Kara, 2011)
WMA	(Avcı, 2011; Senol, 2010; Huang 2008; Kara, 2011)
MOM	(Huang 2008; Kara, 2011)
RSI	(Senol, 2010; Kara, 2011; Chang, 2006; Çataltepe, 2011)
MACD	(Huang 2008; Kara, 2011; Chang, 2006)
MACD SIGNAL	(Huang 2008; Kara, 2011; Chang, 2006)
MACD HISTORY	(Huang 2008; Kara, 2011; Chang, 2006; Çataltepe, 2011)
STOCH K	(Senol, 2010; Huang 2008; Kara, 2011) Chang, 2006)
STOCH D	(Senol, 2010; Huang 2008; Kara, 2011) Chang, 2006)
ADOSC	(Huang 2008; Kara, 2011; Çataltepe, 2011)
CCI	(Kara, 2011)

Bu bölümde, kullanılan finansal göstergeler tanıtılacaktır. İndikatörlerin tanımlarında MetaStock'un verilerinden yararlanılmıştır (http://www.metastock.com).

3.3.1.1 Hareketli ortalama (İng. Moving average – MA)

Hareketli ortalama, seçilen bir aralığa göre dizide bulunan değerlerin çeşitli ortalamalarını alır. Türleri arasında basit, üstsel, üçgensel, değişken ve ağırlıklı çeşitleri bulunmakla birlikte; tez çalışması kapsamında basit (İng. SMA) ve ağırlıklı (İng. WMA) hareketli ortalama değerlerinden yararlanılmıştır. SMA, aralıktaki değerlerin aritmetik ortalamasını alırken; WMA, doğrudan yerine ağırlıklandırma yaparak ortalama alır. Aşağıda SMA'nın formülü gösterilmiştir.

$$\mathrm{SMA}(p_i) = \frac{\sum_s^S p_i(s_L)}{S} \qquad \textbf{(3.3)}$$

Denklem 3.3'te belirtilen p_i, i. hissenin fiyat vektörünü; S değeri, hareketli ortalamanın aralık sayısını; s değeri, kaçıncı aralıkta olunduğunu, $p_i(s_L)$ ise aralıktaki son fiyat değerini ifade eder.

3.3.1.2 Momentum

Momentum, incelediği aralıkta fiyat değerlerinin kadar değiştiğini ölçümler. Oransal olarak hesapladığı değişim değeri yorumlanırken, momentum çok fazla yükselmiş ve sonrasında düşüş yaşamışsa, değerlerin yine yüksek seviyede seyredeceği öngörülür. Ayrıca beklentilerin yüksek değerlerde olduğu bir marketteki hızlı fiyat yükselişleri veya yatırımcıların hisselerini çekmek istediği bir marketteki hızlı fiyat düşüşlerini öngörmek için momentumdan yararlanılır.

$$\mathrm{MOM}(p_i(s)) = \left(\frac{p_i(s_L)}{p_i((s-k)_L)}\right) * 100 \qquad \textbf{(3.4)}$$

Denklem 3.4'te gösterilen $p_i(s)$, i. hissenin s anındaki fiyat değerini; $p_i(s_L)$, aralığın son fiyat değerini; $p_i((s-k)_L)$ k aralık önceki son fiyat değerini ifade etmektedir.

3.3.1.3 Olasılıksal salıngaç (İng. Stochastic oscillator – STOCH)

Olasılıksal salıngaç, bir hisse senedinin fiyatının, verilen aralıktaki fiyat aralığına yakınlığını karşılaştırır. Olasılıksal salıngaç iki çizgi ile gösterilir. Ana çizgi, %K

olarak isimlendirilirken, ikinci çizgi %D olarak adlandırılır. %D değeri, %K çizgisinin hareketli ortalaması anlamına gelir. Olasılıksal salıngaç ölçümü yorumlanırken, %K veya %D değerlerinin o hisse için belli bir seviyenin altına düşmesi ve sonrasında bu seviyenin üstüne çıkması durumu; yatırımcılara alım yapmasının önerilmesi anlamına gelir. Tersi şekilde, olasılıksal salıngaç belli bir değerin üstüne çıkıyor ve sonrasında bu değerin altına düşüyorsa; yatırımcılara satış yapması önerilir.

$$\mathrm{STOCH}(p_i(s)) = \left(\frac{p_i(s_L) - \%K * p_i(s_{min})}{\%K * p_i(s_{max}) - \%K * p_i(s_{min})}\right) * 100 \quad \textbf{(3.5)}$$

Denklem 3.5'te gösterilen $p_i(s)$, i. hissenin s anındaki fiyat değerini; $p_i(s_L)$, aralığın son fiyat değerini; $p_i(s_{min})$ ve $p_i(s_{max})$ aralıktaki en düşük ve yüksek değerleri ifade etmektedir.

3.3.1.4 Göreceli güçlülük göstergesi (İng. Relative strength index – RSI)

Göreceli güçlülük göstergesi, değerleri 0 ile 100 arasında değişen ve tekil bir hisse senedinin güçlülüğünü ifade eden göstergedir. Bu değeri oluşturmak için belirlenen aralıktaki en yüksek ve en düşük fiyat değişimlerini kullanır. Bu gösterge yorumlanırken kendi değerinin altına veya üstüne inip çıkmadığına bakılır. Örneğin RSI düşmüş ve son zamanlardaki derecesinin altına inmişse, hissenin düşüşe geçişi tamamladığı söylenir.

$$\mathrm{RSI}(p_i(s)) = 100 - \frac{100}{1 + \left(\frac{U}{D}\right)} \quad \textbf{(3.6)}$$

Denklem 3.6'da gösterilen $p_i(s)$, i. hissenin s anındaki fiyat değerini; U, yükselen fiyat değişim ortalamasını; D düşen fiyat değişim ortalamasını ifade etmektedir.

3.3.1.5 Hareketli ortalama yakınsama ıraksama (İng. Moving average convergence divergence – MACD)

MACD değeri, iki fiyat için alınan hareketli ortalamaların arasındaki ilişkiyi gösteren bir momentum göstergesidir. Özellikle geniş salınımlar yapan piyasalarda bu değerin etkililiği görülmektedir. Hesaplamaya bakıldığında, sabit olarak 26 ve 12 aralıklı zaman dilimlerine dair hesaplanan üstel hareketli ortalama değerlerinin farkını alır. Aşağıdaki formül üstel hareketli ortalama (EMA) hesabını göstermektedir.

$$\mathrm{EMA}(p_i(s)) = (p_i(s_L) * 0.09) + (p_i((s-1)_L) * 0.91) \quad \textbf{(3.7)}$$

Denklem 3.7'de gösterilen $p_i(s)$, i. hissenin s anındaki fiyat değerini; $p_i(s_L)$, aralığın son değerini; $p_i((s-1)_L)$ bir önceki aralığın son değerini ifade eder.

3.3.1.6 Birikim/dağıtım salıngacı (İng. Accumulation/distribution oscillator – ADO)

Birikim/dağıtım salıngacı olarak adlandırılan bu göstergede, fiyat bilgisi ve işlem hacmi bilgisi üzerindeki değişiklikler arasında bağlantı kurulur. Temel olarak değişimleri incelediği için bir momentum göstergesi olarak temsil edilir. İşlem hacminin yüksek olduğu zamanda fiyat değişiminin de bir o kadar önemli olduğunu savunur.

$$\mathrm{ADO}(p_i(s_L)) = \sum \left[\frac{(p_i(s_L) - p_i(s_{min})) - (p_i(s_{max}) - p_i(s_L))}{(p_i(s_{max}) - p_i(s_{min}))} \right] * v_i(s) \quad \textbf{(3.8)}$$

Denklem 3.8'de gösterilen $p_i(s)$, i. hissenin s anındaki fiyat değerini; $p_i(s_L)$, aralığın son değerini; $p_i(s_{min})$ ve $p_i(s_{max})$ aralıktaki en düşük ve yüksek değerleri; $v_i(s)$ ise işlem hacmini ifade etmektedir.

3.3.1.7 Menkul kanal göstergesi (İng. Commodity channel index – CCI)

Menkul kanal göstergesi, bir hisse senedinin fiyatının istatistiksel olarak ortalamasından ne kadar saptığını gösterir. Yüksek değerler görüldüğünde, hissenin kendi seviyesinin yukarısında seyrettiği; alçak değerler görüldüğünde, hissenin genel seviyesinin altında işlemini sürdürdüğü görülür. Hesaplanırken önce, her aralıktaki en yüksek, en düşük ve son fiyat değerleri toplanır; 3'e bölünerek ortalaması alınır. Daha sonra hesaplanan ortalama değer üzerinde, n-aralıklı bir basit hareketli ortalama hesaplanır. Kaç aralık üzerinden CCI hesaplanmak isteniyorsa, o kadar hareketli ortalama hesabı, ilk hesaplanan ortalama değerden çıkarılır. Elde edilen sonuç üzerinden yine n-aralıklı basit hareketli ortalama hesaplanır. Bu değer sabit bir sayı olan 0.015 ile çarpılarak ilk hesaplanan hareketli ortalama değerinden çıkarılır. Çok adımda hesaplanan bu göstergenin en önemli özelliği, fiyatının düşük veya yüksek olduğuna bakılmaksızın herhangi bir tipteki hisse senedi üzerinde çalışabilmesidir.

3.3.1.8 İşlem hacmi

İşlem hacmi bilgisi, borsadan alınan gün içi işlem bilgileri arasından, ilgilenilen 15 dakikalık aralıkta toplam kaç adet hissenin mevcut fiyattan işlem gördüğü bilgisidir. Yoğun işlem hacmi taşıyan hisse senetleri için, fiyat değişimlerinin daha önemli olacağı öngörülür.

3.3.2 Öznitelik seçiminde kullanılan yöntemler

Öznitelikler, oluşturulan tahmin modellemesinde sonucu doğrudan veya dolaylı olarak sonucu etkilediği düşünülen değerlerdir. Bir modelde kullanılan özniteliklerin tamamı, tahmini olumlu yönde etkilemeyebilmektedir. Hangi özniteliklerin ve kombinasyonlarının model üzerinde daha sağlıklı sonuç verdiğini araştırmak için öznitelik seçimi yöntemleri kullanılmaktadır. Bu yöntemler her özniteliği model üzerinde değerlendirip, öznitelikleri puanlamakta veya sıralamaktadır. Değerlendirme sonunda en iyi olarak belirlenen öznitelikler modellemenin temel girdisini oluşturur.

Bu tez çalışmasında, yukarıda tanıtılan finansal göstergeler ile hisseler arasındaki ilişkiler öznitelik olarak kullanılacaktır. Öznitelikler seçim yapılmadan önce bu değerler farklı aralık değerleri parametre verilerek çoğullandırılmış, daha sonra öznitelik seçim teknikleri kullanılarak indirgenmiştir. Başarılı bir öznitelik seçim süreci, anlam taşımayan özniteliklerin modelden çıkarılmasını ve sınıflandırıcıların daha az karmaşıklıkla daha performanslı çalışmasını sağlar (Gündüz, 2013).

Bu bölümde, tez çalışmasında kıyaslanan öznitelik seçim yöntemleri tanıtılmıştır.

3.3.2.1 En az tekrar en fazla ilgililik (İng. Maximum redundancy minimum relevance - mRMR)

Peng ve diğ. (2005) ortaya koyduğu mRMR yaklaşımı, genler üzerinde yapılan bir modellemede, hedef sınıf ile en çok ilgili olan ve aynı zamanda birbiri ile en az bağımlı ve benzer olan genlerin belirlenmesinde kullanılmıştır. Hesaplama yapılırken karşılıklı bilgi hesaplamasından da yararlanılmıştır. Aşağıdaki formüle göre g_i, i genini; c_i sınıf etiketini temsil eder. Buna göre karşılıklı bilgi, bu gen ve sınıflarının görülme sıklığı olan $p(g_i)$, $p(c)$ ve $p(g_i, c)$ baz alınarak şu şekilde hesaplanmıştır:

$$I(g_i, c) = \int p(g_i, c) \ln \frac{p(g_i, c)}{p(g_i)p(c)} dg_i dc \quad \textbf{(3.9)}$$

Karşılıklı bilgi ilişkisi kullanılarak, hedef sınıf ile en çok ilgili olan genler aşağıdaki yöntemle hesaplanmıştır:

$$\max_S \frac{1}{|S|} \sum_{g_i \in S} I(g_i, c) \quad \textbf{(3.10)}$$

mRMR yaklaşımının en belirleyici özelliği yalnızca en ilişkili öznitelikleri çıkarması değil, aynı zamanda birbiriyle en az ilişkili öznitelikleri çıkarabilmesidir. En az ilişkili genleri belirleyebilmek için aşağıdaki hesaplama kullanılmıştır:

$$\min_S \frac{1}{|S|^2} \sum_{g_i, g_j \in S} I(g_i, g_j) \quad \textbf{(3.11)}$$

Bu iki hesaplama mRMR yönteminde birleştirilerek kullanılmaktadır. Aşağıdaki formüle göre G'nin tüm genlerin kümesi olduğu ve modelin S_{m-1} gene sahipken, m. en iyi gene sahip olmak için kullanılan formül aşağıdaki şekilde tanıtılmıştır:

$$\max_{g_j \in G - S_{m-1}} \left[I(g_i, c) - \frac{1}{m-1} \sum_{g_i \in S_{m-1}} I(g_j, g_i) \right] \quad \textbf{(3.12)}$$

mRMR yaklaşımı, basit, hızlı ve anlaşılır yapısı ile pek çok çalışmada öznitelik eleme yöntemi olarak kullanılmıştır (Mundra, 2010; Pavithra, 2014). Yalnızca genlerle ilgili değil, öznitelik seçimi gerektiren farklı alanlara ait çalışmalarda başarılı sonuçlar veren bu yöntem, bu tez çalışmasında da kullanılmış ve bir sonraki bölümde tanıtılan Özyinelemeli Öznitelik Elemesi DVM olarak isimlendirilmiş diğer bir öznitelik seçim yöntemi ile kıyaslanmıştır.

3.3.2.2 Özyinelemeli öznitelik elemesi DVM (İng. Recursive feature elimination SVM)

Özyinelemeli öznitelik elemesi DVM yöntemi de yine mRMR gibi gen çalışmalarında ortaya konmuş bir öznitelik eleme yöntemidir (Guyon, ve diğ., 2002). Bu yöntemin öznitelik elemede kullandığı DVM yöntemleri, yine DVM

sınıflandırıcıları ile birlikte kullanılmış ve başarılı sonuçlar verdiği görülmüştür (Gysels, 2005; Bedo, 2006; Zhang, 2006).

Yöntem, eğitim verisi örnekleri (x) ve sınıf etiketleri (y) üzerinde DVM sınıflandırıcısı ile hesaplamalar yapar.

$$\alpha = \text{DVMeğit}(X, y) \tag{3.13}$$

Sonrasında boyut uzunluklarından bir ağırlık vektörü hesaplar.

$$w = \sum_{k} \alpha_k y_k x_k \tag{3.14}$$

Bu ağırlıklar kullanılarak öznitelikler puanlanır ve en küçük puanlandırılan öznitelik, en iyi sonuç vermesi beklenen öznitelik olarak işaretlenir. Buna göre sonuçlanan puanlar, öznitelik sıralaması olarak da düşünülebilir. Örneğin, çalışma kapsamında yalnızca geçmiş fiyat bilgisinden elde edilen 34 öznitelik 1'den 34'e kadar; hisse ilişkilerinin de eklenmesiyle elde edilen modelde kullanılan 49 öznitelik 1'den 49'a kadar puanlandırılarak değerlendirilmiştir.

3.4 Hisseler Arasındaki İlişkilerin Bulunması

Hisseler arasındaki ilişkilerin saptanabilmesi için, hisselerin fiyat bilgilerinin çizdiği grafiklerin benzerliklerinin bulunması gereklidir. Bu benzerlik aynı zamanda görülebileceği gibi, belli zaman kaymalarıyla da benzer örüntüler yakalanabilir. Bir hissenin fiyat değişim grafiği, diğer bir hissenin fiyat değişim grafiğini dt zaman farklıyla takip ediyorsa, bu hisse diğer hisseden etkileniyor anlamına gelir. Bu bölümde hisseler arasındaki benzerliklerin nasıl hesaplandığı ve etkililik çizgelerinin nasıl oluşturulduğu anlatılmıştır.

3.4.1 Hisse benzerliklerinin hesaplanması

Hisse benzerlikleri hesaplanırken, hisselerin geçmiş fiyat değişim vektörlerinin benzerliğinden yararlanılmıştır. Zaman kayması hesaplanmadan bulunan benzerlikler, hisselerin aynı zaman diliminde ulusal veya küresel etmenler gibi daha üst katmanlardan etkilendiğini gösterir (Kullmann ve diğ., 2008). Zaman kayması gözetilerek yapılan hesaplamalar ile bulunan benzerlikler ise, hisselerin birbirini etkileme yönünü saptamayı sağlamıştır. Bu çalışmada, hisselerin birbirine etkisinin

daha iyi görülebilmesi için, yakın olduğu öngörülen sektörlere ait hisse senetlerinin fiyat değişim yönü tahmin edilmiştir. Her hisse için 15 dakika aralıklarla oluşturulan fiyat değişim vektörlerinin benzerliği, Pearson benzerliği yöntemiyle hesaplanmıştır.

$$\mathrm{Pearson}(x,y) = \frac{\sum xy - \frac{\sum x \sum y}{N}}{\sqrt{\left(\sum x^2 - \frac{(\sum x)^2}{N}\right)\left(\sum y^2 - \frac{(\sum y)^2}{N}\right)}} \tag{3.15}$$

3.4.2 Hisse etkililik çizgelerinin ve borsa ağının oluşturulması

Zaman kaymalı benzerlikler hesaplanırken yine Pearson benzerliğinden yararlanılmış ve $\mathrm{dt} = \pm 15$ dk, $\mathrm{dt} = \pm 30$ dk, $\mathrm{dt} = \pm 1$ sa, $\mathrm{dt} = \pm 2$ sa, $\mathrm{dt} = \pm 1$ gün zaman kaymaları için hesaplama yapılmıştır. Zaman kayması metriği, fiyat değişimi vektöründe kaç sıra öncesi ile eşleştiği göz önünde bulundurularak oluşturulmuştur. Örneğin $\mathrm{dt} = \pm 1$ gün kaymasının hesaplanması için, 1 gün içinde borsanın aktif olduğu zaman aralığına ait 15 dakika aralıkla 36 fiyat bilgisi bulunduğundan, zaman kayması metriği 36 olarak verilmiştir. Buna göre Pearson benzerliğine zaman kayması metriği eklendiğinde, denklemler 3.16'daki halini almıştır.

$$\begin{aligned}
\mathrm{Pearson}(x,y,-1) &= \mathrm{Pearson}\big(x(t-1), y(t)\big) \\
\mathrm{Pearson}(x,y,-2) &= \mathrm{Pearson}\big(x(t-2), y(t)\big) \\
\mathrm{Pearson}(x,y,-4) &= \mathrm{Pearson}\big(x(t-4), y(t)\big) \\
\mathrm{Pearson}(x,y,-8) &= \mathrm{Pearson}\big(x(t-8), y(t)\big) \\
\mathrm{Pearson}(x,y,-36) &= \mathrm{Pearson}\big(x(t-36), y(t)\big)
\end{aligned} \tag{3.16}$$

3.5 Sınıflandırıcı Öğrenmesi

Borsa verisi üzerinden elde edilen öznitelikler, öznitelik seçimi aşamasından sonra sınıflandırıcıda girdi olarak kullanılır. Sınıflandırıcılar eğitilirken, önemli olmayan özniteliklerin elenmesi ile indirgenen öznitelik vektörlerini kullanarak, her bir örnek veri için fikir edinir.

Finans alanında yapılan çalışmalarda, özellikle fiyat yönü, endeks bilgisi, risk durumu gibi borsa metriklerinin tahmini konularında, borsa işlem verileri zaman serileri olarak düşünülmüş ve buna yönelik sinyal işleme teknikleri ile modellemeler yapılmıştır (Bollerslev, 1993; Schwert, 1989). 1990'ların başından itibaren ise

popülerleşen modellerden yapay sinir ağları ve destek vektör makineleri finansal çalışmalarda daha sık kullanılmaya başlanmış ve eski modellere göre çok daha başarılı sonuçlar verdiği gözlenmiştir. Bu türde yapılan çalışmalara "İlgili Çalışmalar" bölümünde yer verilmiştir.

İncelenen geçmiş çalışmalar sonucunda, yapılan tez çalışmasında kullanmak üzere çok katmanlı perseptron (ÇKP) ve destek vektör makineleri (DVM) sınıflandırıcı olarak seçilmiştir. Bu başlık altında bu iki sınıflandırıcı modeli tanıtılacaktır.

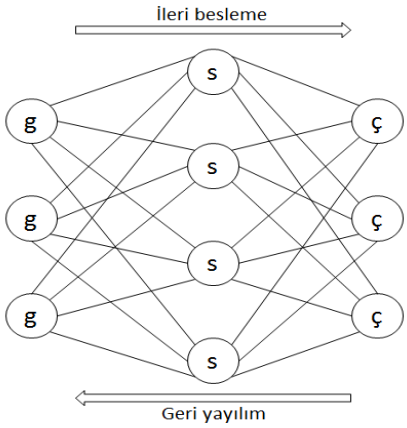
3.5.1 Çok katmanlı perseptron sınıflandırıcısı

Yapay sinir ağları, insan beyninin çalışma biçiminin modellenmeye çalışılması sırasında ortaya konan başarılı modellerdir. Bu modellerin en önemli avantajı, daha önce hiç görmediği örnekler hakkında dahi genelleme yaparak başarılı fikir verebildiğinin gözlemlenmesidir. Yapay sinir ağları, yapay sinir hücresi olarak konumlandırılmış yapıların birbiriyle farklı şekillerde bağlanması ile oluşur ve yaygın kullanımı katmanlar vasıtasıyla sağlanır. Katmanlar kurulduktan sonra sinir ağları, öğrenme süreci içinde bilgi toplar ve hücreleri birbirine bağlayan bağlantıların ağırlıklarını kullanarak bilgiyi saklar. Öğrenme süreci bütün olarak düşünülürse, yapay sinir ağındaki bağlantıların ağırlıkları güncellenerek eğitimi tamamlanır (Gardner, ve diğ., 1998). Yapay sinir ağlarının uyarlanabilir yapısı, paralel çalışabilirliği finansal tahmin çalışmalarında kolaylık sağlamaktadır. Finansal örüntüler arasında önceden hiç öğrenilmeyen örneklere sıkça rastlandığından, yapay sinir ağları bu alanda başarılı bulunan sınıflandırıcılar arasında gösterilmektedir.

Vural (2007) yaptığı çalışmasında Japonya finans piyasasından örnek vermektedir. Araştırmaya göre, yapay sinir ağları ile kurulan borsa tahmin sisteminin Daiichi Kangyo Bankasının hazine bonosu vuruş hızını %60 oranından %75'e, Daiwa Güvenlik'in ise %70'ten %80'e çıkardığı iddia edilmiştir. Çalışmada ayrıca, yapay sinir ağlarının makro-ekonomik bazı ölçütlerin tahmininde, endeks tahmin modellemelerinde, finansal hilelerin tespit edilmesinde, iflas tahminlerinde ve risk analizlerinde gibi pek çok finansal araştırma alanında kullanıldığı vurgulanmıştır.

Çok katmanlı perseptronlar, doğrusal olmayan problemlerin çözümünde kullanılan ve temel olarak giriş katmanı, gizli katman, çıkış katmanı olmak üzere üç katmandan oluşan ileri beslemeli ve geri yayılımlı bir yapay sinir ağı modelidir (Chaudhuri, 2000). İleri besleme ile modelden sonuç çıkarılırken, geri yayılım ile hücreler arası

bağlantıların ağırlıkları güncellenmektedir. Aradaki gizli katmanların sayısı birden fazla da olabilmektedir. Bu katmanların sayısına ve modelin diğer parametrelerine eğitim sırasında deneme yanılma yoluyla en uygun olan sonuç gözlemlenerek karar verilir. Aşağıdaki şekilde çok katmanlı perseptronların yapısı gösterilmiştir. Bu gösterimde g hücreleri, giriş; s hücreleri saklı; ç hücreleri çıkış katmanlarını ifade etmektedir.



Şekil 3.1 : Çok katmanlı perseptron yapısı.

Çok katmanlı perseptron yapısında, gizli katmana ait her bir sinir hücresi j indisi ile temsil edilirse, i indisli giriş değerini bağlantı ağırlığı ile çarpıp toplamına ekler. Bu toplamın aktivasyon fonksiyonundan geçirilmesi ile çıkış hücre değeri aşağıdaki gibi hesaplanır.

$$ç_j = f\left(\sum w_{ji} x_i\right) \tag{3.17}$$

Aktivasyon fonksiyonu olarak adlandırılan f fonksiyonu, genellikle sigmoid fonksiyonu olarak kullanılır ve sinir hücrelerindeki değerlerin ağırlıklı toplamlarını anlamlılaştırmak için gereklidir. Sigmoid fonksiyonunun doğrusal olmaması, sürekli ve türevinin alınabilir olması, ağırlıkların ayarlanmasında hataların değişim ölçülerini elde edebilmeyi de sağlamaktadır.

Geri yayılımda ise, ağırlık değişimi hesaplanırken eğim inişi (İng. gradient descent) hesabı kullanılabilir. Buna göre sinir hücreleri arasındaki bağlantı değişimi aşağıdaki gibi hesaplanır:

$$\Delta w_{ji}(k) = -\alpha \frac{\partial E}{\partial w_{ji}(k)} + \mu \Delta w_{ji}(k-1) \quad \textbf{(3.18)}$$

Bu hesaba göre, α öğrenme katsayısını, k iterasyon sayısını, i ve j sinir hücresi indisini, w bağlantı ağırlığını temsil etmektedir. Tercih edilen öğrenme katsayısı parametresine göre, çok katmanlı perseptron modellerinin eğitimi uzun sürebilmektedir. Yapılan tez çalışmasında, bu parametreye doğrulama verisi üzerinde yapılan denemeler sonucu karar verilmiştir.

3.5.2 Destek vektör makineleri (DVM) sınıflandırıcısı

Destek vektör makineleri, farklı çalışma alanlarında sınanmış modeller olup, veriler doğru kullanılabildiğinde başarılı sonuçlar veren sistemler olduğu görülmüştür. Özellikle son 20 yıl içerisinde sıklıkla çalışmalarda yapay sinir ağları ile kıyaslanmıştır. Borsa metriklerinin tahmini üzerinde yapılan çalışmalar araştırılırken de destek vektör makineleri ile yapay sinir ağları karşılaştırılmış, bazı çalışmalarda yapay sinir ağlarının, bazı çalışmalarda destek vektör makinelerinin daha başarılı sonuç verdiği gözlemlenmiştir.

Destek vektör makinelerinde, eğitim seti vektörleri ∅ olarak gösterilen çekirdek (İng. kernel) fonksiyonu kullanılarak daha üst boyutta bir uzaya adreslenir (Hsu, C.W., ve diğ., 2010). Bu çekirdeklerin lineer, polinomal, RBF, sigmoid gibi tipleri kullanılmaktadır. Fonksiyonun DVM modellemesinde kullanımı Boser (1992) ve Cortes, Vapnik (1995) tarafından şu şekilde belirlenmiştir:

$$y_i(w^T \emptyset(x_i) + b) \geq 1 - \xi_i, \xi_i \geq 0 \quad \textbf{(3.19)}$$

olmak koşuluyla,

$$\min_{w,b,\xi} \frac{1}{2} w^T w + C \sum_{i=1}^{l} \xi_i \quad \textbf{(3.20)}$$

Destek vektör makineleri kullanılırken, verinin doğru modellenmesi ve doğru çekirdek ile doğru parametrelerin saptanması, modelin başarısı için oldukça etkili olmaktadır. Bu nedenle DVM kullanılmadan önce, veri kümesi mümkünse [0,1] veya [-1,1] aralığına ölçülenmeli ve en iyi parametreler bulunana kadar doğrulama kümeleri ile denemeler yapılmalıdır. Verinin doğru ölçülenmemesi DVM

sınıflandırıcısının sonuç alamamasına, doğru parametrelerin seçilmemesi de modelin başarımının düşük olmasına sebep olabilmektedir.

3.6 Sınıflandırıcı Performanslarını Değerlendirme Ölçütleri

Sınıflandırıcıların eğitimi sırasında en iyi model parametreleri doğrulama veri kümesi üzerinde belirlenir ve bu parametreler ile kurulan model, gerçek test verileriyle test edilir. Test verilerinin gerçek sınıfı ile sınıflandırıcının yaptığı tahmin sınıfı kıyaslanarak, sınıflandırıcının performansı değerlendirilir. Sınıflandırıcı performansı ölçülürken genel geçer kullanılan birtakım ölçütler mevcuttur. Bu ölçütlerin temeli, hata matrisi (İng. Confusion matrix) olarak adlandırılan çizelge üzerinde yapılan hesaplara dayanır (Yang, 1997). Çizelge 3.2'de iki sınıflı bir sınıflandırma problemi için modelin hata matrisi gösterilmiştir.

Çizelge 3.2 : İki sınıflı modeller için hata matrisi çizelgesi.

Gerçek Sınıf/Model Tahmini	Pozitif	Negatif
Pozitif	dp	yn
Negatif	yp	dn

Hata matrisinde görülen 4 bölme, test verilerinin ne oranda doğru veya yanlış işaretlendiğini gösterir. Doğru pozitif (dp) alanı, gerçekte pozitif sınıfa ait örneklerin, bu modelde de pozitif olarak doğru işaretlendiğini belirtir. Yanlış pozitif (yp) alanı, gerçek sınıf etiketi negatif olan örneklerin, bu modelde pozitif olarak yanlış işaretlendiğini gösterir. Yanlış negatif (yn) alanı, aslında pozitif sınıf etiketi olan örneklerin, bu modelde negatif olarak yanlış işaretlendiğini temsil eder. Dördüncü alan olan doğru negatif (dn) alanı ise, gerçek etiketi negatif olan örneklerin, modelde de negatif olarak doğru etiketlendiğini gösterir. Buna göre doğru pozitif ve doğru negatif oranlarının yüksek olması, yanlış pozitif ve yanlış negatif alanlarındaki oranların düşük olması; modelin başarılı sonuç verdiğini gösterir. Bu alanlar kullanılarak modelin kesinlik (İng. Precision), duyarlık (İng. Recall), doğruluk oranı (İng. Accuracy), F-ölçütü (İng. F-measure) gibi toplamdaki performansı hesaplanabilmektedir (Davis ve Goadrich, 2006).

Makine öğrenmesi modellerinin performansları ölçülürken en çok kullanılan değerlendirme metriklerinden biri doğruluk oranıdır (DO). Sınıflandırıcının pozitif iken pozitif, negatif iken negatif olarak doğru işaretlediği örneklerin sayısının, tüm örnek sayısına bölünmesiyle doğruluk oranı elde edilir. Sınıflandırıcının başarımı bu oranın büyüklüğü ile doğru orantılıdır.

Doğruluk oranı ölçütü en sık kullanılan değerlendirme metriklerin biri olmasına rağmen; sınıf dağılımlarının bazı sınıflar üzerinde yoğunlaştığı verilerde, model farklı sınıfa ait örnekler için tek bir etiket kullandığında, bu etiketin sınıf yoğunluğu yüksek olduğu zaman doğruluk oranı da yüksek çıkmakta ve yanıltıcı ölçüm yapmaktadır. Tez çalışmasında kullanılan verinin sınıf dağılımı, yine belli bir sınıf etrafında toplandığı için doğruluk oranı hesabı sağlıklı bir ölçüm olmayacaktır.

Sınıflandırıcıların, her sınıf için başarımının yüksek olup olmadığının ölçülebilmesi için doğruluk oranı ile birlikte duyarlılık, kesinlik gibi bilgilerden de yararlanılması gerekir. Kesinlik (K) bilgisi, pozitif olarak doğru işaretlenen örnek sayısının, doğru veya yanlış pozitif olarak işaretlenen örnek sayısına oranı ile hesaplanır. Böylelikle modelin işaretlediği sınıflardan biri için ne derece doğru tahmin yapıldığı ortaya konur. Duyarlılık (D) hesabı ise, yine pozitif olarak doğru işaretlenen örnek sayısının, pozitif olarak doğru işaretlenen örnek sayısı ile negatif olarak yanlış işaretlenen örnek sayısının toplamına oranı ile bulunur. Bu hesap ise, gerçekte pozitif olan örnekler arasında, modelin kaç tanesini doğru bildiği sonucuna varılır. Anlatılan metrikler Çizelge 3.3'te gösterilmiştir.

Çizelge 3.3 : Sınıflandırıcı performans değerlendirme metrikleri.

Metrik Tipi	Hesaplama
Doğruluk Oranı (DO)	$\frac{dp + dn}{dp + yp + dn + yn}$
Kesinlik (K)	$\frac{dp}{dp + yn}$
Duyarlık (D)	$\frac{dp}{dp + yn}$

Tanıtılan değerlendirme ölçütlerine kıyasla, özellikle sınıfları dengesiz dağılım gösteren veri kümeleri üzerinde çalışan bir sınıflandırıcıyı değerlendirmek için F-

ölçütü metriği daha sağlıklı sonuç verebilmektedir. F-ölçütü hesaplanırken kesinlik ve duyarlılık hesaplarından yararlanılarak sonuç alınır. F-ölçütü de, doğruluk oranı gibi makine öğrenmesi uygulamalarının değerlendirilmesinde sıklıkla kullanılan bir ölçüm yöntemi olarak kullanılmaktadır. F-ölçütü kesinlik ve duyarlılık değerlerinin ağırlıklı harmonik ortalamasını alır. Yine iki sınıflı bir problem için sınıflandırıcının değerlendirildiği F-ölçütü hesabı aşağıda gösterilmiştir.

$$\mathrm{F-ölçütü} = \frac{2 * \mathrm{K} * \mathrm{D}}{\mathrm{K} + \mathrm{D}} \tag{3.21}$$

Çoklu sınıflı veri kümelerinin sınıflandırıcıları ölçümlenirken, her bir sınıf için ayrı F-ölçütü hesaplanır ve hesabı yapılan sınıf pozitif, diğer tüm sınıflar negatif kabul edilir. Her sınıf için F-ölçütü değeri hesaplanıp, sınıflandırıcı performansı hesaplandıktan sonra; sınıflandırıcının toplam performans değerlendirmesi tüm sınıflar için bulunan F-ölçütü değerlerinin aritmetik ortalama ile hesaplanan makro-ortalaması alınarak yapılır. Yapılan tez çalışmasında kullanılan sınıflandırıcı modelleri, her sınıf için eşit ağırlık veren makro-ortalama F-ölçütü kullanılarak kıyaslanacaktır.

3.7 Bölüm Özeti

Tez çalışmasına ait bu bölüm, çalışmada kullanılan yöntemlerin ve süreçlerin tanıtılmasına ayrılmıştır. Öncelikle veri kümesinde öznitelikleri oluşturacak olan finansal göstergelerin, esas fiyat serisi bilgilerinden nasıl elde edildiği anlatılmıştır. Daha sonra finansal göstergelerin hangilerinin gerçek modelde tahmin başarımını arttırdığını araştırmak üzere kullanılan öznitelik seçim yöntemleri tanıtılmıştır. Öznitelik seçimi sayesinde, bilgi içermeyen öznitelikler veri kümelerinden çıkartılır ve gerek performans, gerekse model başarımı açısından gelişme sağlanır. Hissenin en çok ilişkili olduğu diğer hisselerin, fiyat bilgilerinin benzerliklerinden yararlanılarak bulunması aşaması ile hisse ağını, tahmin modelinde parametre olarak kullanan yaklaşım için özniteliklerin nasıl oluşturulduğu anlatılmıştır. Bu ilişkilerden elde edilen öznitelikler de öznitelik seçim yöntemleri ile puanlandırılmıştır. Son olarak, elde edilen tüm özniteliklerin hangi sınıflandırıcılarda modellendiği ve bu sınıflandırıcı modellerinin başarımlarının nasıl ölçüldüğü tanıtılmıştır.

Sonraki bölümde tanıtılan bu yöntemlerin çalışma içinde nasıl kullanıldığı anlatılacaktır.

4. HİSSE SENEDİ GEÇMİŞ FİYAT VERİSİ VE HİSSE ETKİLİLİK ÇİZGESİ KULLANARAK HİSSE FİYAT DEĞİŞİM YÖNÜ TAHMİNİ

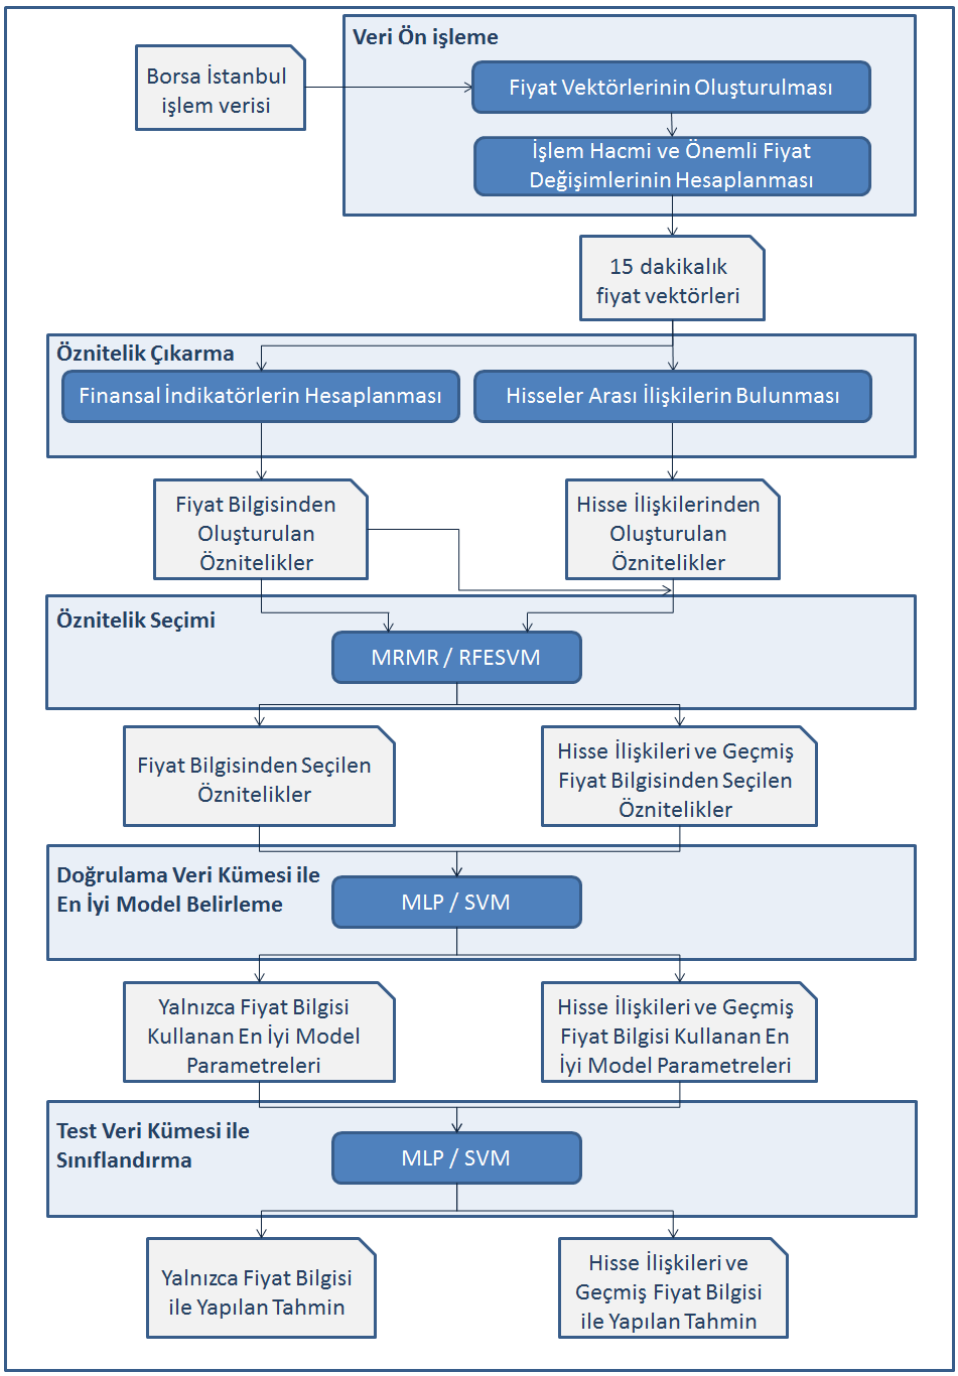
Bu bölümde tez çalışmasının uygulama süreci detaylandırılacaktır. Çalışmanın ilk aşaması, borsadan alınan işlem verilerinin vektörel hale getirilmesi olmuştur. Vektörler oluşturulurken, anlık borsa verisi 15'er dakikalık aralıklara bölünmüştür. Fiyat vektörleri elde edildikten sonra, 15 dakika aralığı içinde gerçekleşen işlem hacmi hesaplanarak vektörlere eklenmiştir. Daha sonra hisse fiyatlarındaki önemli değişimler, standart sapma ve işlem hacmi göz önünde bulundurularak hesaplanmış ve hisselerin 15 dakika sonundaki fiyat değişim yönü etiketi bu hesaba göre belirlenmiştir.

Geçmiş fiyat bilgileri vektörler halinde finansal gösterge hesaplarında kullanılmıştır. Finansal göstergeler, hisselerin fiyat örüntüleri hakkında fikir veren istatistiksel hesaplamalardır. Çalışma kapsamında 11 farklı finansal gösterge hesaplanmış ve her biri 3'er farklı parametre ile çoğullandırılarak kullanılmıştır. İşlem hacminin de öznitelik olarak eklenmesiyle, geçmiş fiyat bilgisini kullanan 34 öznitelik elde edilmiştir. mRMR ve RFESVM öznitelik seçim yöntemleri ile öznitelikler her hisse için ayrı ayrı puanlanmıştır.

Hisseler arasındaki ilişkilerin hesaplanmasıyla, incelenen hisseyi etkileyen diğer hisselerin geçmiş fiyat değişim yönü etiketleri, birer öznitelik gibi kullanılarak veri kümesine eklenmiştir. Her hisse için, hisseyi en çok etkileyen 5 hisse senedinin, 3 farklı fiyat değişim yönü etiketi alınmıştır. Hisseler arasındaki benzerliğin en fazla olduğu zaman ile bu zamanın 1 ve 2 önceki zamanına ait etiketler, yeni birer öznitelik olarak kullanılmıştır. Hisseler arasındaki ilişkiler ile hissenin geçmiş fiyat bilgisini birlikte kullanan modellerde böylelikle 49 öznitelik oluşturulmuştur.

Her hisse için ayrı sınıflandırıcı eğitileceğinden, yine her hisse için ayrı model parametreleri belirlenmiştir. Her hisseye özel seçilen model parametrelerini; hangi öznitelik seçim yönteminin kullanılacağı, en iyi kaç özniteliğin alınacağı, hangi sınıflandırıcının kullanılacağı ve bu sınıflandırıcıya ait parametrelerin hangi değerleri alacağı belirlemiştir. En iyi model parametreleri seçilirken, 5 aylık borsa verisinin ilk

3 ayı eğitim verisi olarak kullanılmış ve sonraki 1 aylık doğrulama verisi üzerinde test sonuçları alınmıştır. En iyi sonuç veren 20 model için, ilk 4 aylık veri ile yeniden model eğitilmiş ve son 1 aylık test verisi üzerinde sonuç alınmıştır. Sınıflandırıcı modeli seçme ve test yapma aşamaları; hem yalnızca geçmiş fiyat bilgilerinin oluşturduğu veri üzerinde, hem de hisseler arasındaki ilişkiler ve geçmiş fiyat bilgilerinin oluşturduğu veri üzerinde gerçekleştirilmiş, sonuçları karşılaştırılmıştır. Şekil 4.1'de tez çalışmasının genel süreci görsel olarak sunulmuştur.



Şekil 4.1 : Tez çalışmasının genel süreci.

4.1 Veri Kümesinin Toplanması ve Ön İşlemesi

Önceki bölümlerde belirtildiği üzere, yapılan tez çalışmasında, gün içi 15 dakikalık aralığa dair finansal verileri kullanarak, bu aralığın sonunda hisse fiyatlarının ne yönde değişeceğini tahmin edilmiştir. Hisselere ait finansal göstergeler ve hisselerin birbiriyle ilişkileri; hisselerin geçmiş fiyat bilgilerinden elde edilen, işlenmiş iki temel girdi olarak tahmin modelinde kullanılmıştır.

Hisselerin geçmiş fiyat bilgileri, Borsa İstanbul'un üniversitelerin akademik çalışmaları için ücretsiz olarak paylaştığı gün içi borsa işlem verisi kümesinden sağlanmıştır (www.borsaistanbul.com). Borsa İstanbul'dan alınan veri, Temmuz 2013 – Kasım 2013 aralığında yer alan 5 aylık veri bütününü kapsamaktadır. Bu veri kümesinde, her hisseye ait gün içinde gerçekleşen işlemlerin detaylı bilgileri yer almaktadır. Birbirini karşılayan alım satımların işlem olarak değer gördüğü borsada; alım satım tarihleri, emir bilgileri, işlem adeti, işlem fiyatı gibi bilgiler saklanmaktadır. Bu ham veri içerisinden, tez çalışması kapsamında yalnızca "hisse ismi, işlem zamanı, işlem adeti, işlem fiyatı" bilgileri kullanılmıştır. Gün içi işlem ham verisi örneği Ekler bölümünde Çizelge A.1 üzerinde örneklendirilmiştir.

Tez çalışmasında, modelin hisseler arasındaki ilişkileri göz önüne alınması amacıyla; borsanın genel endeks bilgisi yerine, belirlenen hedef sektörlere ait hisseler tahmin modelinde değerlendirilmiştir. Hedef sektörler telekomünikasyon, bankacılık ve bilgi teknolojileri alanlarında seçilmiş; bu alanlara ait 24 hisse senedi ayrı ayrı sınıflandırıcılarda eğitilerek modellenmiştir. Bu hisse senetlerinin Borsa İstanbul'daki karşılıkları isim sırasıyla şu şekildedir: AKBNK, ALCTL, ALNTF, ANELT, ARENA, ARMDA, ASYAB, DENIZ, DESPC, ESCOM, FINBN, GARAN, HALKB, ISCTR, KLNMA, KRONT, LINK, LOGO, NETAS, SKBNK, TCELL, TEBNK, TTKOM, VAKBN.

Hedef hisseler için elde edilen filtrelenmiş fiyat bilgileri, 15'er dakikalık aralıklarda toplanarak, sabit uzunluklu gün içi fiyat vektörleri haline getirilmiştir. Burada amaç, borsanın işleme açık olduğu süreyi 15'er dakikalık aralıklara bölerek, aynı zaman dilimi sonunda her hisse için aynı hesaplamayı yapmaktır. Bu şekilde hisseler arasındaki benzerlikler hesaplanırken, aynı zaman aralıkları veya belli zaman kaymalarıyla hesaplanan zaman aralıkları birbiriyle kıyaslanmıştır. Sonuç olarak, 15

dakikalık fiyat vektörü haline getirilen işlem verisi örneği Ekler bölümündeki Çizelge A.2'de gösterilmiştir.

Sabit aralıklı fiyat vektörleri hesaplandıktan sonra, finansal göstergelerin hesaplanabilmesi amacıyla, bu aralıklardaki en düşük ve en yüksek işlem fiyat bilgileri de ham işlem verisi üzerinden hesaplanmıştır. Benzer şekilde, hisseler arası ilişkilerin hesaplanmasında ve hisselerin aralık sonundaki fiyat değişim yönünün hesaplanmasında kullanmak üzere, her aralık için fiyat değişim oranı hesaplanmıştır.

Buna göre göstergeler hesaplanmadan önce, verinin 15 dakika aralık ile vektörel hale getirilmiş, aralıklardaki önemli fiyat değişimleri ile işlem hacminin çarpılmış son hali Çizelge 4.1'de örneklendirilmiştir.

Çizelge 4.1 : İşlenmiş 15 dakikalık gün içi işlem verisi örneği.

Hisse ismi	**İşlem zamanı**	**İşlem fiyatı**	**İşlem adeti**	**En yüksek fiyat**	**En düşük fiyat**	**Fiyat değişimi ile işlem hacmi çarpımı**
ASYAB	09.09.2013 15:30:00	1,83	104710	1,84	1,83	-572,186
FINBN	09.09.2013 15:30:00	2,65	104	2,65	2,65	0
HALKB	09.09.2013 15:30:00	13,55	1636132	13,75	13,55	-12074,775
SKBNK	09.09.2013 15:30:00	1,89	1000	1,89	1,89	0
KLNMA	09.09.2013 15:30:00	5,7	0	0	0	0
TEBNK	09.09.2013 15:30:00	2,18	0	0	0	0
VAKBN	09.09.2013 15:30:00	4,23	1928134	4,27	4,23	-9116,473
ARENA	09.09.2013 15:30:00	2,16	5000	2,16	2,15	23,148
ARMDA	09.09.2013 15:30:00	1,58	412	1,58	1,57	2,608
DESPC	09.09.2013 15:30:00	1,37	19	1,38	1,37	0
TCELL	09.09.2013 15:30:00	10,65	106226	10,75	10,65	-498,714
ESCOM	09.09.2013 15:45:00	1	362	1	0,99	3,62
LOGO	09.09.2013 15:45:00	4,21	1502	4,22	4,21	3,568
TCELL	09.09.2013 15:45:00	10,65	74894	10,7	10,65	0
TTKOM	09.09.2013 15:45:00	6,24	55156	6,26	6,22	0

Bu değerler hesaplandıktan sonra, eğitim verisinin etiketlenmesi için, aralık sonundaki fiyat değişim yönü işaretlenmiştir. Sınıf etiketi; azalan fiyatlar için {-1}, değişmeyen fiyatlar için {0}, artan fiyatlar için {1} değerini almıştır. Bu etiketlerin değeri hesaplanırken, önemli değişikliklerin hesapta tutulması için fiyat değişimi ile işlem hacmi bilgisinin çarpımından ve bu bilginin oluşturduğu vektörün standart sapmasından yararlanılır. Standart sapmadan düşük veya yüksek değerler önemli olarak tanımlanmıştır. Hesaplamalar sırasında 3.1 ve 3.2'de tanıtılan eşitliklerden yararlanılmıştır.

4.2 Finansal Göstergelerin Hesaplanması

Borsa tahmini konusunda yapılan geçmiş çalışmalarda da görüldüğü üzere, hisselerin fiyat bilgilerinden elde edilen bazı istatistiksel hesaplamalar, tahmin modeli üzerinde yararlı yol gösterebilmektedir. Bu istatistik hesaplamalar, finansal göstergeler olarak isimlendirilmekte ve her aralık için ayrıca hesaplanarak kullanılmaktadır. Finansal göstergelerin hesaplanması için Java dilinde yazılmış ta-lib kütüphanesi kaynak olarak kullanılmıştır (http://ta-lib.org/).

Çok sayıda finansal gösterge metrik olarak kullanılabilirken, aralarında en yaygın olanları ve geçmiş çalışmalardaki modellerde başarı gösterenleri Çizelge 4.2'de örneklendirilmiştir. Bu örnek, AKBNK hissesine ait rastgele seçilmiş bir 15 dakika aralığına ait gösterge bilgilerini içermektedir. Bu gösterge değerleri daha sonra, sınıflandırıcıya verilmek üzere [0-1] aralığına normalleştirilmiştir.

Çizelge 4.2 : Finansal gösterge örnekleri.

Gösterge ismi	**Değeri**
SMA	7,856
WMA	7,862
MOM	0,039
RSI	49,369
MACD	0,035
MACD SIGNAL	0,042
MACD HISTORY	-0,007
STOCH K	75

Çizelge 4.2 (devam): Finansal gösterge örnekleri.

Gösterge ismi	Değeri
STOCH D	65
ADOSC	-11591,616
CCI	26,315

Finansal göstergeler hesaplanırken, kaç aralıklı veri üzerinden hesaplama yapılacağı ile ilgili bazı parametreler hesaplama içinde kullanılmaktadır. Bu parametrelerden en uygun olanlarının seçilmesi maksadıyla, her finansal gösterge için 3 tane parametre değeri belirlenmiş ve bu değerler finansal göstergelerin oluşturduğu öznitelik kümesini belirlemiştir. Toplamda 11 farklı tip gösterge üzerinden çoğullandırılan 33 adet gösterge öznitelik olarak kullanılmıştır. Özniteliklere işlem hacmi bilgisinin de eklenmesiyle, toplam öznitelik sayısı 34 olarak belirlenmiştir. Sonraki adımlarda bu öznitelikler seçime tabi tutularak, yüksek öncelikli öznitelikler ön plana çıkarılmıştır.

4.3 Özniteliklerin Ölçeklenmesi

Hesaplanan özniteliklerin farklı aralıklarda değer alması ve büyük sayıların sınıflandırıcı performansını düşürmesi sebebiyle, veri kümesi üzerinde ölçeklendirme yapılmıştır. Buna göre 34 gösterge değeri [0,1] aralığına Denklem 4.1'deki gibi ölçeklendirilmiştir.

$$\text{Ölçeklendir}(f_i) = \frac{f_i - F_{min}}{F_{max} - F_{min}} \tag{4.1}$$

Buna göre f_i, ölçeklendirilen öznitelik değerini; F_{max} ve F_{min}, bu öznitelik vektöründe görülen en yüksek ve en düşük değerleri ifade eder.

4.4 Hisse Etkililik Çizgeleri ve Borsa Ağı

Hisselerin fiyat değişimleri arasındaki etkililik hesaplanırken, fiyat vektörlerinin Denklem 3.16'da tanıtılan Pearson benzerliklerinden yararlanılmıştır. Bu denklemlere göre, hisselerin 15 dakika ile aralıklandırılmış fiyat vektörleri arasında, $dt = \pm 15$ dk, $dt = \pm 30$ dk, $dt = \pm 1$ sa, $dt = \pm 2$ sa, $dt = \pm 1$ gün zaman kaymaları ile benzerlik hesabı yapılmıştır.

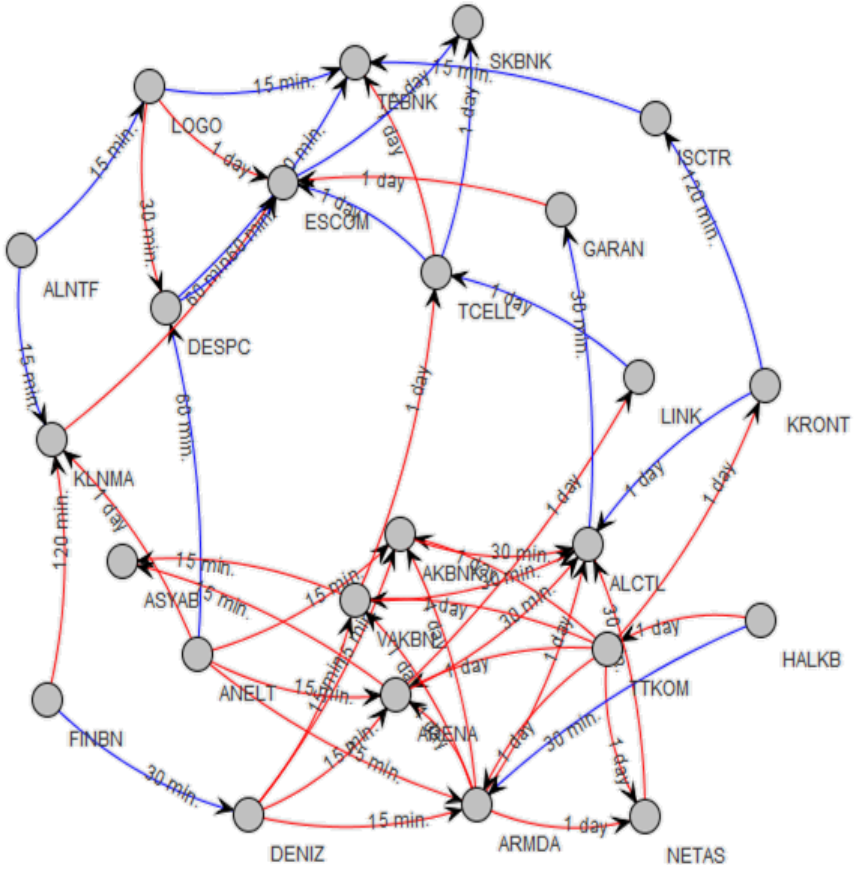
Hisselerin zaman kaymalı benzerlikleri ile aynı zamandaki ($dt = 0$) benzerlikleri birlikte değerlendirildiğinde, iki hisse arasındaki benzerlik, 6 farklı dt üzerinden hesaplanmıştır. Buna göre en yüksek benzerliği veren dt zaman kayması baz alınarak, her hisse için etkililik analizi yapılmıştır. Sonuç olarak; bazı hisselerin diğer hisseleri etkilediği, bazı hisselerin diğer hisselerden etkilendiği, bazılarının ise diğer hisseler ile pek fazla etkileşim kurmadığı saptanmıştır.

İncelenen sektörlerde yer alan 24 hisse senedi için etkililik tablosu Çizelge 4.3'te gösterilmiştir. Buna göre en etkili ilk 3 hissenin LINK, ISCTR ve DENIZ olduğu, en çok etkilendiği görülen ilk 3 hissenin LOGO, FINBN ve TTKOM olduğu, diğer hisseler ile pek fazla etkileşim kurmadığı görülen ilk 3 hissenin de VAKBN, AKBNK ve ARMDA olduğu bulunmuştur. Bulgular Çizelge 4.3'te gösterilmiştir.

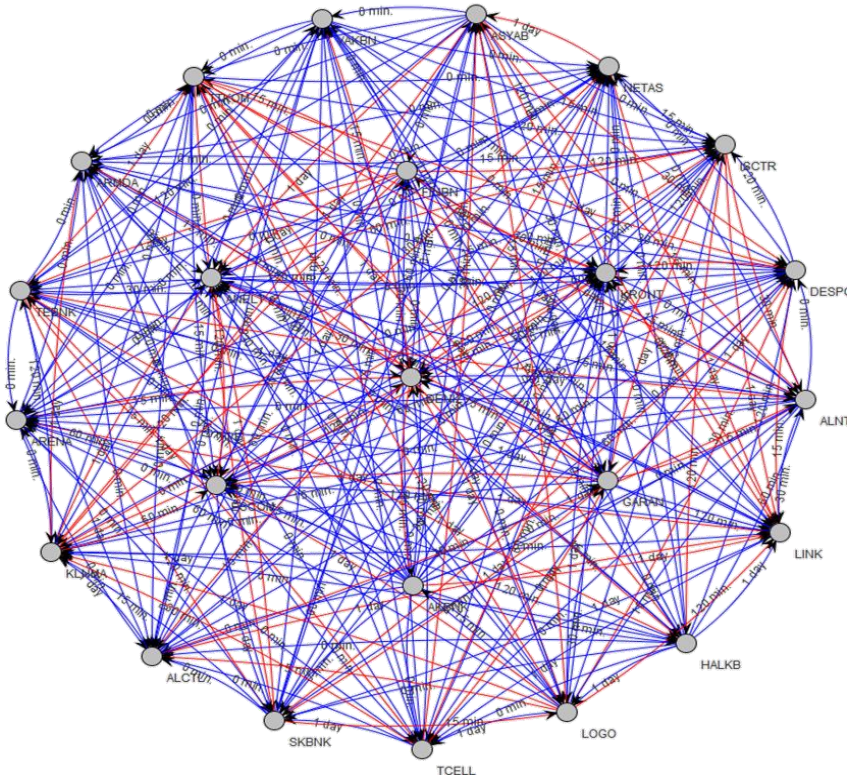
Çizelge 4.3 : Hisselerin etkililik tablosu.

Hisse Adı	Etkilediği Hisse Sayısı	Etkilendiği Hisse Sayısı	Toplam İlişki Sayısı
LINK	16	6	22
ISCTR	12	7	19
DENIZ	11	8	19
ALNTF	9	4	13
DESPC	9	6	15
ESCOM	9	7	16
KLNMA	9	7	16
ANELT	7	3	10
ASYAB	7	7	11
GARAN	7	8	14
KRONT	7	4	15
LOGO	7	14	21
SKBNK	6	8	14
TEBNK	6	9	15
ALCTL	5	6	11
HALKB	4	6	10
ARENA	3	2	5
FINBN	3	11	6
NETAS	3	3	9
TCELL	3	6	13
TTKOM	3	10	14
AKBNK	2	3	5
ARMDA	2	3	5
VAKBN	1	3	4

Çizelge 4.3'te tanıtılan etkililik tablosu üzerinde, [0-1] arasında değer bulan benzerlik katsayısına 0,06 eşik değeri koyularak, Şekil 4.2'de gösterilen etkililik çizgesi elde edilmiştir. Çizgeye göre okların yönü hisselerin etkililik yönünü belirtirken; mavi bağlar aynı yönde oluşan etkiyi, kırmızı bağlar ters yönde oluşan etkiyi temsil etmektedir. Benzerlik katsayısı üzerine eşik değeri koymadan elde edilen sektörel borsa ağı ise Şekil 4.3'te görülmektedir. Ağ çizgelerinin görsellerini oluşturmak için Salık (2014)'ın lisans bitirme çalışmasından yararlanılmıştır.



Şekil 4.2 : 0,06 benzerlik eşiği ile hisse etkililik çizgesi (Salık, 2014).



Şekil 4.3 : Sektörel borsa ağı (Salık, 2014).

Yukarıda anlatılan hesaplamalar kullanılarak, böylelikle her hisse için; hisseyi en çok etkileyen veya hisse ile aynı anda yüksek benzerlik gösteren ilk 5 hisseye ait öznitelikler oluşturulmuştur. Öznitelikler oluşturulurken, etkili olduğu saptanan hissenin, en etkili olduğu dt zaman kaymasına ait sınıf etiketi ile dt zamanından 1 ve 2 önceki sınıf etiketleri doğrudan kullanılmıştır. Buna göre en etkili 5 hisse için toplam 15 öznitelik, incelenen hissenin fiyat özniteliklerine eklenmiştir. Bu durumda hissenin geçmiş fiyat bilgisi ve hisseler arasındaki ilişkileri kullanarak oluşturulan öznitelik sayısı 49 olmuştur.

Sonraki bölümde bu özniteliklerin, farklı öznitelik seçim yöntemleriyle nasıl sıralandıkları ve en iyi özniteliklerin belirlenme süreci anlatılmıştır.

4.5 Öznitelik Seçimi

Önceki bölümlerde anlatıldığı üzere, bir hisseye ait tahmin modeli eğitilirken iki tür yaklaşım kullanılmıştır. Birinci yaklaşımda (İY yaklaşımı) hissenin bir sonraki fiyat yönü tahmin edilirken yalnızca geçmiş fiyat bilgisi kullanılmış, ikinci yaklaşımda (İVAY) ise hisseye ait geçmiş fiyat bilgisinin yanı sıra hisse üzerinde etkili olduğu tespit edilen diğer hisseler ile olan ilişkiler de tahmin modelinde kullanılmıştır.

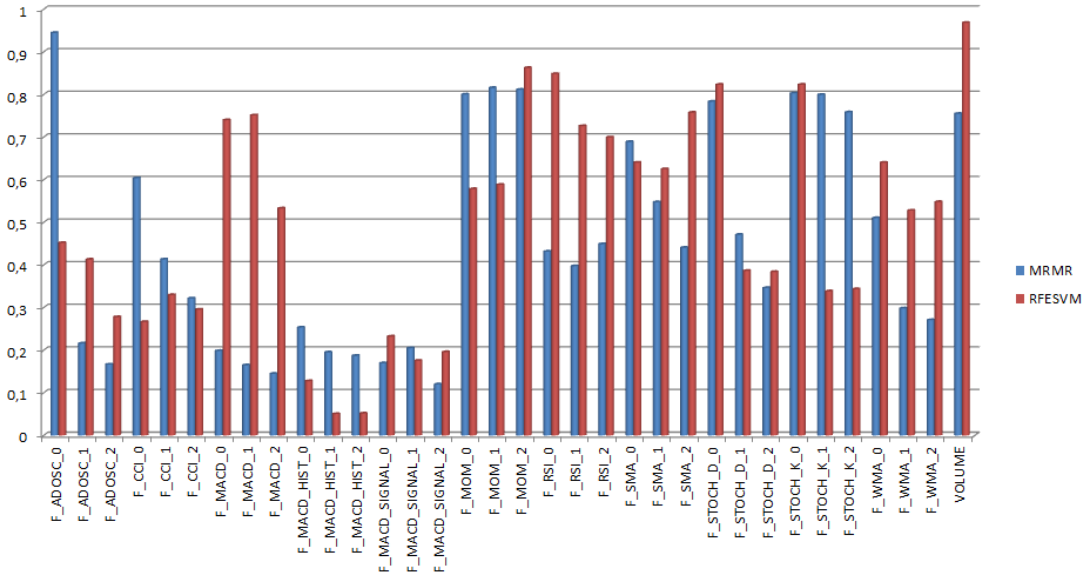
Bu bölümde, her iki yaklaşım için de özniteliklerin önem derecelerinin analizi yapılmıştır.

4.5.1 Yalnızca geçmiş fiyat bilgisi üzerinde yapılan öznitelik seçimi

Hissenin geçmiş fiyat bilgisi, finansal gösterge olarak tanıtılan istatistiksel metriklerin oluşturulmasında kullanılmıştır. Bu metrikler, hisseye özel çıkarılan fiyat vektörlerini kullanarak, vektörün her aralığına karşılık düşen son fiyat değeri, en yüksek fiyat değeri, en düşük fiyat değeri gibi bilgilerden yararlanır. Yapılan tez çalışmasında 11 adet finansal gösterge, her biri için 3'er parametre denenerek hesaplanmış ve sonunda 33 adet finansal gösterge bilgisi elde edilmiştir. Finansal göstergelerin yanı sıra işlem hacmi bilgisi de öznitelik olarak değerlendirilmiş, finansal göstergeler ile birlikte toplamda 34 özniteliği oluşturmuştur.

34 adet öznitelik arasından, her bir hisse için en iyi öznitelikleri belirleyebilmek için öznitelik seçim yöntemleri kullanılmıştır. Bu amaçla iki farklı öznitelik seçim yöntemi olarak mRMR ve RFESVM kullanılmış; her hisseye özel tahmin modeli eğitilirken en iyi yöntemin hangisi olduğu sınanmıştır.

34 öznitelik için, mRMR ve RFESVM yöntemlerinin verdiği puanların ortalaması alınarak, çoğunlukla hangi finansal metriklerin başarılı yorum verdiği bilgisi araştırılmıştır. Bu analize göre, hisse fiyat değişim yönü tahmininde çoğunlukla başarılı bulunan öznitelikler Momentum (MOM), Göreceli Güçlülük Göstergesi (RSI), Olasılıksal salıngaç K ve D (STOCH K, STOCH D), Ağırlıklı Hareketli Ortalama (WMA), Hareketli Ortalama Yakınsama Iraksama (MACD) ve işlem hacmi (İng. Volume) olarak tespit edilmiştir. Özniteliklerin farklı öznitelik yöntemlerine göre aldıkları ortalama puanlar [0-1] aralığına normalleştirilmiş ve grafiği, Şekil 4.4'te sunulmuştur.



Şekil 4.4 : İY yaklaşımıyla elde edilen özniteliklerin ortalama puanları.

Her hisse senedine ait özel bir model eğitileceği için, özniteliklerin puanları da farklı hisseler için farklı sonuçlar verebilmektedir. Bu sebeple, ortalama seçim puanlarına bakılmaksızın, her hisse için yeni bir öznitelik puanlaması yapılmıştır.

Örnek olarak LINK ve TEBNK hisselerine ait öznitelik puanlamaları sırası ile Ekler bölümünde yer alan Şekil B.1 ve Şekil B.2'de gösterilmiştir.

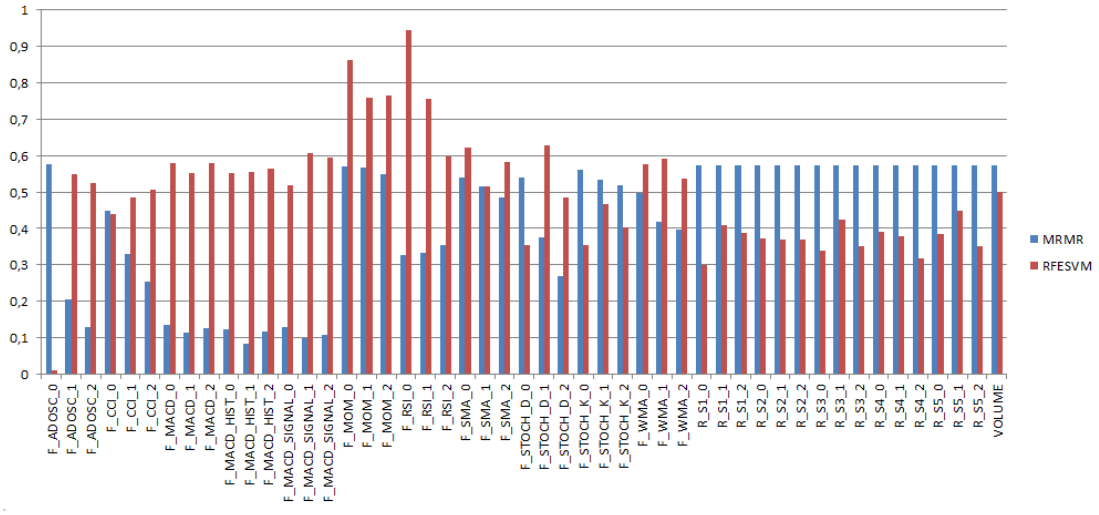
4.5.2 Geçmiş fiyat bilgisi ve hisse ilişkileri üzerinde yapılan öznitelik seçimi

Hisselere ait fiyat değişim yönü modellerinde, hisseler arasındaki ilişkilerin de kullanılmasıyla, hissenin hem kendi geçmiş fiyat bilgisinden, hem de kendisini etkilediği tespit edilen diğer hisselerin geçmiş fiyat bilgisinden yararlanılmıştır. Bu modellemede hisseye dair hesaplanan finansal göstergeler öznitelik olarak aynen kullanılmış, bu ölçümlerin yanı sıra diğer hisselerin fiyat değişim yönlerinden elde edilen etiketler de öznitelik olarak eklenmiştir. Bir hisseyi en çok etkilediği bulunan 5 farklı hisse senedinin, 3 geçmiş fiyat değişim yönü öznitelik olarak eklenmiştir. Bu 3 etiket, hisseyi en çok etkileyen zaman kayması baz alınarak seçilmiştir.

Buna göre her hisse senedi için, geçmiş fiyat bilgisi ve hisse ilişkilerini kullanan modelde 34 + 15 = 49 öznitelik oluşturulmuştur.

Bu öznitelikler önceki modeldeki gibi öznitelik seçim yöntemlerince puanlanmış ve en iyi model belirlenirken bu puanlara göre sıralama yapılmıştır. mRMR ve RFESVM yöntemlerine göre [0-1] aralığına normalleştirilmiş özniteliklerin puan

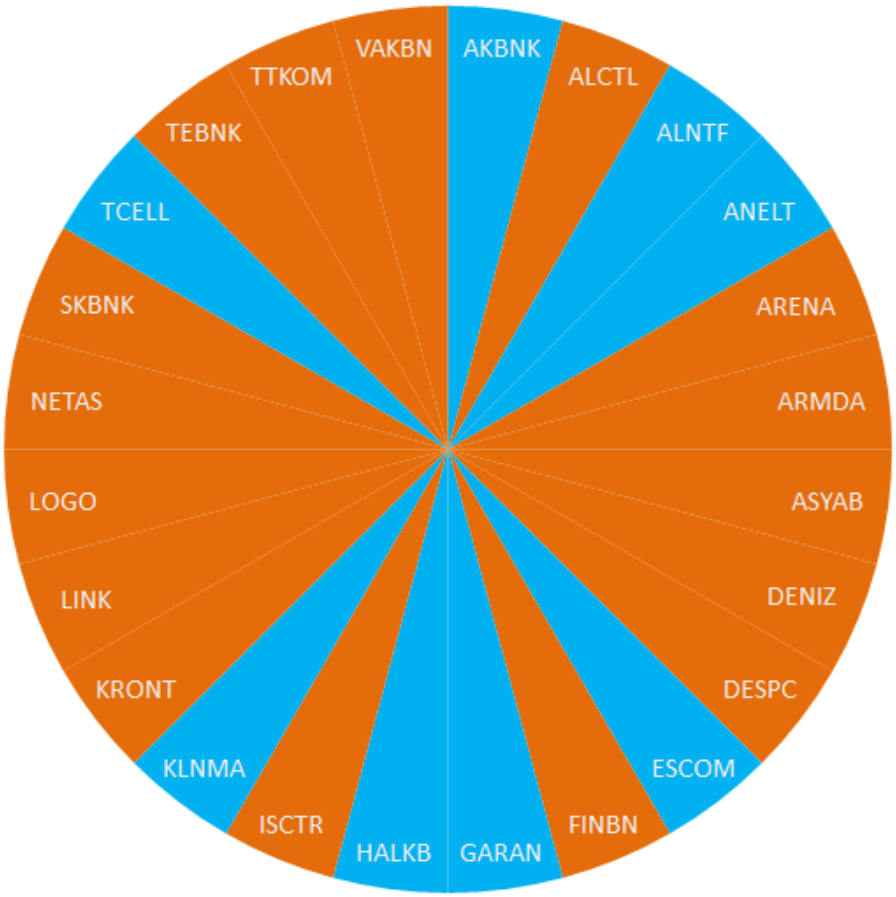
grafiği Şekil 4.5'te gösterilmiştir. Bu analize göre hisseler arası ilişkilerin (R_S1_0, R_S2_0, …) mRMR puanlamasına göre önemli olduğu, RFESVM'in ise ortalama puan verdiği görülmüştür.



Şekil 4.5 : İVAY yaklaşımıyla elde edilen özniteliklerin ortalama puanları.

Yine her hisse senedine ait özel bir model eğitileceği için, ayrı öznitelik puanlamaları yapılmıştır. Buna göre örnek olarak LINK ve TEBNK hisselerine ait öznitelik puanlamaları sırası ile Ekler bölümünde yer alan Şekil B.3 ve Şekil B.4'te gösterilmiştir.

Sonuç olarak, iki öznitelik eleme yönteminin puanlamalarının birbiri ile çok benzer olmadığı gözlemlenmiştir. Her hisseye ait en iyi öznitelik seçimi yönteminin belirlenmesi için doğrulama verisi üzerinde denemeler yapılmış ve her hisseye ait oluşturulan en iyi model belirlenmiştir. En iyi model belirleme süreci bir sonraki bölümde anlatılacak olup, her hisse için en iyi seçilen 40 model arasında mRMR ve RFESVM yöntemlerinin başarılı bulunma oranı Şekil 4.6'daki gibi bulunmuştur. Bu şekle göre turuncu boyalı hisseler için RFESVM yöntemi başarılı olurken, mavi boyalı hisseler için mRMR yöntemi başarılı olmuştur.



Şekil 4.6 : Öznitelik seçim yöntemlerinin başarı dağılımı. (**mRMR**, **RFESVM**)

4.6 En İyi Model Belirleme

Tahmin modelini oluştururken, doğrudan test verisi üzerinde ölçümleme yapmak yerine; eğitim verisini eğitim ve doğrulama veri kümesi olarak iki bölerek en iyi çalışan modelleri belirlemek, daha iyi ve sağlıklı sonuçlar üretmektedir. Çalışmanın bu bölümü, en başarılı model parametrelerini belirlemek üzere; 3 aylık eğitim verisi ile eğitilen modelin, 1 aylık doğrulama verisi üzerinde test edilmesi aşamalarını detaylandırmaktadır. En iyi model aranırken, aşağıdaki parametrelerin kombinasyonları test edilmiştir:

- Öznitelik seçim algoritması
- En iyi n öznitelik
- Sınıflandırma algoritması
- Sınıflandırıcı parametreleri (Saklı katman, Momentum, Öğrenme oranı)

Kombinasyonların oluşturduğu akış, sahte kod gösterimi ile Şekil 4.7'de gösterilmiştir.

```
Girdi:  3 aylık eğitim verisi       EV
        1 aylık doğrulama verisi    DV

her hedef hisse H için
FOR
    her öznitelik seçim algoritması ÖSA için
    FOR
        n -> minN : maxN
        FOR
            ÖznitelikVektörü = ÖSA'ya göre H için en iyi n öznitelik;
            filtrele(EV, ÖznitelikVektörü);
            filtrele(DV, ÖznitelikVektörü);

            her sınıflandırıcı S için
            FOR
                Eğer S = MLP ise
                    her öğrenme katsayısı ÖK için
                    FOR
                        her momentum MOM için
                        FOR
                            her saklı katman SK için
                            FOR
                                eğit( S(ÖK,MOM,SK), EV);
                                testEt( S(ÖK,MOM,SK), DV);
                                Makro-F-ÖlçütüHesapla();
                            END
                        END
                    END
                END
                Eğer S = SVM ise
                    eğit( optimize(S), EV);
                    testEt( optimize(S), DV);
                    Makro-F-ÖlçütüHesapla();
                END
            END

        END
    END
END

Çıktı:  Her hisse için sınanan modellerin Makro-F-Ölçütleri.
```

Şekil 4.7 : En iyi model belirleme sahte kodu.

Makine öğrenmesi yöntemleri için, JavaML (java-ml.sourceforge.net/) ve Weka'dan (http://www.cs.waikato.ac.nz/ml/weka/) yararlanılmıştır. Proje sıkıştırılmış Java formatı olan ".jar" paketi şeklinde Unix tabanlı bir sunucuda çalıştırılmış ve sonuçları dosyalarda toplanmıştır. Aynı kod akışı, tez çalışmasında kıyaslanacak olan iki farklı yaklaşım için tekrarlanmıştır. Yalnızca geçmiş fiyat bilgisi kullanan yaklaşım için 34 öznitelikli veri kümeleri, hem geçmiş fiyat bilgisi hem de hisse ilişkilerini kullanan yaklaşım için ise 49 öznitelikli veri kümeleri kullanılmıştır.

Böylelikle her hisse senedi için; 2 farklı öznitelik seçim yöntemi, yaklaşım sırası ile 3 - 34 ve 3 - 45 en iyi öznitelik, 2 farklı sınıflandırıcı ve ÇKP sınıflandırıcısı için 5 farklı öğrenme katsayısı, 5 farklı momentum değeri, 4 farklı saklı katman yöntemi test edilmiştir. Toplamda her hisse senedi için 14544 model denenmiş ve yine her iki yaklaşıma ait ilk 20 en iyi model test edilmek üzere belirlenmiştir. LINK ve ISCTR hisseleri için farklı yaklaşımlar ile seçilen modeller Çizelge 4.4, 4.5, 4.6 ve 4.7'de gösterilmiştir.

Çizelge 4.4 : LINK hissesi için İY ile seçilen en iyi 20 model.

Hisse	ÖSA	En iyi N Öznitelik	Sınıflandırıcı	ÖK	MOM	SK	Makro-ortalama F-Ölçütü
LINK	RFESVM	13	ÇKP	0,1	0,3	a	0,916
LINK	mRMR	18	ÇKP	0,1	0,1	a	0,916
LINK	mRMR	25	ÇKP	0,5	0,5	o	0,908
LINK	mRMR	25	ÇKP	0,7	0,3	o	0,908
LINK	mRMR	25	ÇKP	0,3	0,7	o	0,908
LINK	RFESVM	22	ÇKP	0,5	0,3	a	0,904
LINK	mRMR	18	ÇKP	0,7	0,1	o	0,888
LINK	mRMR	24	ÇKP	0,1	0,1	t	0,888
LINK	RFESVM	20	ÇKP	0,9	0,7	a	0,888
LINK	mRMR	25	ÇKP	0,5	0,5	t	0,888
LINK	RFESVM	24	ÇKP	0,5	0,3	a	0,888
LINK	RFESVM	23	ÇKP	0,7	0,5	i	0,888
LINK	RFESVM	24	ÇKP	0,7	0,1	a	0,888
LINK	mRMR	18	ÇKP	0,7	0,7	o	0,888
LINK	RFESVM	20	ÇKP	0,3	0,1	a	0,888
LINK	RFESVM	20	ÇKP	0,1	0,7	a	0,888
LINK	mRMR	16	ÇKP	0,7	0,3	o	0,888
LINK	mRMR	16	ÇKP	0,9	0,1	o	0,888
LINK	mRMR	24	ÇKP	0,1	0,1	a	0,888
LINK	mRMR	24	ÇKP	0,1	0,1	i	0,888

Çizelge 4.5 : LINK hissesi için İVAY ile seçilen en iyi 20 model.

Hisse	ÖSA	En iyi N Öznitelik	Sınıflandırıcı	ÖK	MOM	SK	Makro-ortalama F-Ölçütü
LINK	mRMR	30	ÇKP	0,5	0,3	o	0,916
LINK	mRMR	40	ÇKP	0,1	0,1	a	0,888
LINK	mRMR	45	ÇKP	0,1	0,7	a	0,888
LINK	mRMR	45	ÇKP	0,1	0,5	a	0,888
LINK	mRMR	45	ÇKP	0,1	0,3	a	0,888
LINK	mRMR	45	ÇKP	0,3	0,1	a	0,888
LINK	RFESVM	40	ÇKP	0,7	0,3	o	0,888
LINK	RFESVM	40	ÇKP	0,1	0,1	a	0,888

Çizelge 4.5 (devam) : LINK hissesi için İVAY ile seçilen en iyi 20 model.

LINK	RFESVM	40	ÇKP	0,1	0,1	t	0,888
LINK	RFESVM	40	ÇKP	0,1	0,5	t	0,888
LINK	RFESVM	40	ÇKP	0,1	0,3	t	0,888
LINK	RFESVM	40	ÇKP	0,1	0,3	a	0,888
LINK	RFESVM	40	ÇKP	0,1	0,7	t	0,888
LINK	RFESVM	40	ÇKP	0,1	0,5	a	0,888
LINK	RFESVM	45	ÇKP	0,1	0,3	a	0,888
LINK	RFESVM	45	ÇKP	0,7	0,1	a	0,888
LINK	RFESVM	45	ÇKP	0,5	0,3	a	0,888
LINK	RFESVM	45	ÇKP	0,1	0,7	i	0,888
LINK	RFESVM	45	ÇKP	0,1	0,7	a	0,888
LINK	mRMR	40	ÇKP	0,1	0,5	a	0,888

Çizelge 4.6 : ISCTR hissesi için İY ile seçilen en iyi 20 model.

Hisse	ÖSA	En iyi N Öznitelik	Sınıflandırıcı	ÖK	MOM	SK	Makro-ortalama F-Ölçütü
ISCTR	mRMR	21	ÇKP	0,5	0,7	t	0,759
ISCTR	RFESVM	18	ÇKP	0,1	0,3	t	0,745
ISCTR	RFESVM	16	ÇKP	0,3	0,5	i	0,741
ISCTR	RFESVM	23	ÇKP	0,3	0,3	i	0,733
ISCTR	RFESVM	22	ÇKP	0,7	0,1	i	0,730
ISCTR	RFESVM	30	ÇKP	0,3	0,7	a	0,720
ISCTR	RFESVM	15	ÇKP	0,7	0,1	a	0,720
ISCTR	RFESVM	22	ÇKP	0,3	0,7	i	0,720
ISCTR	mRMR	23	ÇKP	0,9	0,3	i	0,720
ISCTR	mRMR	33	ÇKP	0,9	0,5	t	0,720
ISCTR	mRMR	25	ÇKP	0,1	0,5	t	0,720
ISCTR	mRMR	30	ÇKP	0,1	0,5	i	0,720
ISCTR	RFESVM	33	ÇKP	0,9	0,5	t	0,720
ISCTR	RFESVM	22	ÇKP	0,7	0,5	t	0,719
ISCTR	RFESVM	16	ÇKP	0,7	0,1	t	0,719
ISCTR	RFESVM	24	ÇKP	0,9	0,5	t	0,716
ISCTR	RFESVM	33	ÇKP	0,7	0,3	t	0,716
ISCTR	mRMR	33	ÇKP	0,7	0,3	t	0,716
ISCTR	RFESVM	25	ÇKP	0,3	0,5	t	0,711
ISCTR	mRMR	30	ÇKP	0,9	0,7	t	0,709

Çizelge 4.7 : ISCTR hissesi için İVAY ile seçilen en iyi 20 model.

Hisse	ÖSA	En iyi N Öznitelik	Sınıflandırıcı	ÖK	MOM	SK	Makro-ortalama F-Ölçütü
ISCTR	RFESVM	45	ÇKP	0,3	0,1	i	0,763
ISCTR	RFESVM	40	ÇKP	0,9	0,5	a	0,712
ISCTR	mRMR	35	ÇKP	0,5	0,1	t	0,711
ISCTR	RFESVM	40	ÇKP	0,5	0,1	t	0,708
ISCTR	mRMR	35	ÇKP	0,9	0,1	i	0,706

Çizelge 4.7 (devam) : ISCTR hissesi için İVAY ile seçilen en iyi 20 model.

ISCTR	RFESVM	40	ÇKP	0,9	0,1	o	0,702
ISCTR	mRMR	40	ÇKP	0,5	0,7	a	0,698
ISCTR	RFESVM	45	ÇKP	0,3	0,7	i	0,698
ISCTR	RFESVM	40	ÇKP	0,7	0,5	t	0,693
ISCTR	mRMR	35	ÇKP	0,1	0,9	a	0,684
ISCTR	RFESVM	40	ÇKP	0,3	0,1	t	0,684
ISCTR	mRMR	40	ÇKP	0,9	0,3	i	0,684
ISCTR	mRMR	35	ÇKP	0,3	0,5	t	0,682
ISCTR	RFESVM	40	ÇKP	0,1	0,5	t	0,680
ISCTR	mRMR	40	ÇKP	0,9	0,3	t	0,675
ISCTR	RFESVM	40	ÇKP	0,7	0,5	i	0,675
ISCTR	mRMR	40	ÇKP	0,1	0,9	a	0,666
ISCTR	mRMR	40	ÇKP	0,9	0,5	a	0,664
ISCTR	RFESVM	40	ÇKP	0,7	0,3	i	0,664
ISCTR	mRMR	35	ÇKP	0,5	0,3	i	0,664

Çizelgelerde görüldüğü üzere, en iyi model belirleme adımlarında LINK gibi bazı hisselerde İY yaklaşımı daha iyi sonuç verirken, ISCTR gibi bazı hisselerde İVAY yaklaşımı daha iyi sonuç vermiştir. Her iki yaklaşım için de seçilen ilk 20 en iyi model, test verisi üzerinde sınanmıştır. Bir sonraki bölümde test ölçümleri detaylandırılacaktır.

4.7 Sınıflandırma Sonuçları

En iyi model belirleme adımından sonra; her hisse için seçilen, iki yaklaşıma ait 20'şer model 4 aylık eğitim verisi ile eğitilmiş, 1 aylık test verisi ile sınanmıştır. Buna göre İY ve İVAY yaklaşımlarına ait, hisselerin 15 dakikalık fiyat değişim yönü tahmin başarımları makro-ortalama F-ölçütü ile Çizelge 4.8'de belirtilmiştir.

Test sonuçları incelendiğinde, İY yaklaşımının daha başarılı tahminlerde bulunduğu görülmüştür. İY yaklaşımı ile elde edilen en iyi sonuç %100 makro-ortalama F-ölçütü ile LINK hissesine aitken, İVAY yaklaşımı ile en iyi sonuç %83 makro-ortalama F-ölçütü ile TEBNK hissesine ait olmuştur. Tüm hisselerin tahmin başarım ortalaması İY yaklaşımı için %67, İVAY yaklaşımı için %62 makro-ortalama F-ölçütü olarak hesaplanmıştır. Hisselerin detaylı model başarım çizelgeleri EK C'de verilmiştir.

Çizelge 4.8 : Hisselerin en iyi fiyat değişim yönü tahmin sonuçları.

Hisse	Yaklaşım	Makro-ortalama F-Ölçütü	ÖSA	En iyi N Öznitelik	Sınıflandırıcı	ÖK	MOM	SK
AKBNK	**İY**	**0,68**	mRMR	18	ÇKP	0,1	0,7	o
AKBNK	İVAY	0,64	mRMR	33	ÇKP	0,9	0,3	o
ALCTL	**İY**	**0,71**	RFESVM	5	ÇKP	0,3	0,7	a
ALCTL	İVAY	0,63	mRMR	23	ÇKP	0,5	0,1	i
ALNTF	İY	0,61	RFESVM	22	ÇKP	0,3	0,9	i
ALNTF	**İVAY**	**0,63**	mRMR	28	ÇKP	0,3	0,7	i
ANELT	**İY**	**0,71**	mRMR	24	ÇKP	0,9	0,3	o
ANELT	İVAY	0,60	RFESVM	40	ÇKP	0,7	0,3	o
ARENA	**İY**	**0,60**	RFESVM	21	ÇKP	0,9	0,7	a
ARENA	İVAY	0,55	RFESVM	45	ÇKP	0,7	0,7	o
ARMDA	İY	0,64	RFESVM	25	ÇKP	0,7	0,3	t
ARMDA	**İVAY**	**0,65**	RFESVM	27	ÇKP	0,1	0,5	o
ASYAB	**İY**	**0,76**	RFESVM	30	ÇKP	0,5	0,3	o
ASYAB	İVAY	0,72	RFESVM	28	ÇKP	0,7	0,5	o
DENIZ	İY	0,67	mRMR	7	ÇKP	0,7	0,9	i
DENIZ	**İVAY**	**0,71**	RFESVM	26	ÇKP	0,7	0,9	a
DESPC	**İY**	**0,68**	RFESVM	21	ÇKP	0,3	0,1	t
DESPC	İVAY	0,64	mRMR	33	ÇKP	0,3	0,1	o
ESCOM	**İY**	**0,69**	mRMR	13	ÇKP	0,5	0,9	t
ESCOM	İVAY	0,61	mRMR	22	ÇKP	0,9	0,5	a
FINBN	İY	0,55	RFESVM	15	ÇKP	0,5	0,3	t
FINBN	**İVAY**	**0,62**	RFESVM	33	ÇKP	0,5	0,3	o
GARAN	**İY**	**0,69**	mRMR	16	ÇKP	0,3	0,3	a
GARAN	İVAY	0,67	RFESVM	19	ÇKP	0,1	0,1	t

Çizelge 4.8 (devam) : Hisselerin en iyi fiyat değişim yönü tahmin sonuçları.

Hisse	Yaklaşım	Makro-ortalama F-Ölçütü	ÖSA	En iyi N Öznitelik	Sınıflandırıcı	ÖK	MOM	SK
HALKB	İY	0,68	RFESVM	13	ÇKP	0,1	0,5	i
HALKB	**İVAY**	**0,70**	mRMR	40	ÇKP	0,5	0,5	o
ISCTR	**İY**	**0,56**	RFESVM	33	ÇKP	0,7	0,3	t
ISCTR	**İVAY**	**0,56**	RFESVM	40	ÇKP	0,7	0,5	i
KLNMA	**İY**	**0,33**	mRMR	23	ÇKP	0,9	0,3	t
KLNMA	**İVAY**	**0,33**	mRMR	35	ÇKP	0,3	0,7	i
KRONT	**İY**	**0,60**	RFESVM	30	ÇKP	0,1	0,3	a
KRONT	İVAY	0,55	mRMR	40	ÇKP	0,3	0,9	a
LINK	**İY**	**1,00**	RFESVM	22	ÇKP	0,5	0,3	a
LINK	İVAY	0,67	mRMR	30	ÇKP	0,5	0,3	o
LOGO	**İY**	**0,50**	RFESVM	5	ÇKP	0,5	0,9	o
LOGO	İVAY	0,41	RFESVM	27	ÇKP	0,3	0,1	i
NETAS	**İY**	**0,72**	RFESVM	30	ÇKP	0,5	0,7	t
NETAS	İVAY	0,50	mRMR	28	ÇKP	0,7	0,9	t
SKBNK	**İY**	**0,78**	RFESVM	13	ÇKP	0,9	0,5	t
SKBNK	İVAY	0,77	RFESVM	25	ÇKP	0,7	0,3	i
TCELL	**İY**	**0,69**	mRMR	22	ÇKP	0,9	0,3	o
TCELL	İVAY	0,65	mRMR	33	ÇKP	0,7	0,3	o
TEBNK	**İY**	**0,95**	RFESVM	24	ÇKP	0,7	0,1	t
TEBNK	İVAY	0,83	mRMR	33	ÇKP	0,1	0,1	i
TTKOM	**İY**	**0,66**	RFESVM	15	ÇKP	0,1	0,1	a
TTKOM	İVAY	0,63	RFESVM	45	ÇKP	0,3	0,3	i
VAKBN	**İY**	**0,73**	RFESVM	16	ÇKP	0,3	0,7	t
VAKBN	İVAY	0,70	mRMR	28	ÇKP	0,1	0,1	i

5. SONUÇ VE ÖNERİLER

Yapılan bu tez çalışmasıyla, benzer sektörde yer alan Borsa İstanbul hisse senetlerinin fiyat değişim yönü; hissenin yalnızca kendi geçmiş fiyat bilgisini kullanan İY (İçerik Yaklaşımı) yöntemi ile oluşturulan modellerle %67, kendi geçmiş fiyat bilgilerinin yanı sıra diğer hisselerle olan ilişkilerinin bilgisini de kullanan İVAY (İçerik ve Ağ Yaklaşımı) yöntemi ile oluşturulan modellerle %62 makro-ortalama F-ölçütü başarımıyla tahmin edilmiştir. Çalışma kapsamında gün içi borsa işlem verisi ham bilgi olarak kullanılmış, hisseler arasındaki yönlü ve ağırlıklı ilişkiler bulunmuş, farklı öznitelik seçim yöntemleri ile farklı model parametrelerinin arasından en iyilerinin seçilmesi işlemi birlikte yapılarak en iyi model bütünü oluşturulmuştur. En iyi seçilen modellerle İY ve İVAY yaklaşımları ile sınıflandırma yapılmış; böylelikle hem yaklaşımların, hem de kullanılan yöntemlerin kıyaslanması sağlanmıştır.

Tez çalışmasının uygulama kısmında öncelikle Borsa İstanbul'un paylaştığı Temmuz – Kasım 2013 aralığındaki gün içi işlem verisi, seçilen 15 dakikalık aralıklar halinde vektörleştirilmiştir. İşlem verisinde yer alan hisse fiyat bilgisi anlık olarak kayıt altında tutulduğundan, her 15 dakika aralığına bir fiyat bilgisi atamak için, o aralıkta işlem gören son hisse senedi fiyatından yararlanılmıştır. Fiyat vektörleri oluşturulduktan sonra, her hisseye ait her aralık için önemli fiyat değişimleri, işlem hacmi ve fiyat değişimlerinin standart sapması baz alınarak hesaplanmıştır. Yapılan hesaba göre belirlenen eşiğin üzerinde yer alan değişimler artış {+1} olarak etiketlenmiş, eşiğin altında kalan değişimler düşüş {-1} olarak etiketlenmiş ve önemli bir değişim göstermeyen örnekler {0} olarak etiketlenmiştir.

Elde edilen vektörel fiyat bilgisi sonrasında, hissenin kendi geçmiş fiyat bilgisinden çıkarılan finansal göstergeler ile öznitelikler oluşturulmuştur. Finansal göstergeler, geçmiş çalışmalarda kullanılan istatistiksel metrikler arasından seçilmiştir. 11 çeşit finansal gösterge üzerinden, her gösterge için 3 farklı parametre ile elde edilen değerler öznitelik vektörüne eklenmiştir. İşlem hacmi bilgisinin de eklenmesiyle,

hissenin yalnızca kendi geçmiş fiyat bilgisini kullanan İY yaklaşımı için 34 adet öznitelik hesaplanmıştır.

İVAY yaklaşımında ise; finansal göstergelerin yanı sıra, hisseyi etkileyen diğer hisselerin geçmiş fiyat değişim yönleri de öznitelik vektörüne eklenmiştir. Hisseler arasındaki ilişkilerin bulunması için, hisselerin geçmiş fiyat değişim vektörleri arasındaki Pearson benzerlikleri $\mathbf{dt = \pm 15\ dk}$, $\mathbf{dt = \pm 30\ dk}$, $\mathbf{dt = \pm 1\ sa}$, $\mathbf{dt = \pm 2\ sa}$, $\mathbf{dt = \pm 1\ g\ddot{u}n}$ zaman kaymaları ile hesaplanmıştır. Bu hesaplamaya göre; bir hissenin fiyat değişimi, diğer bir hissenin fiyat değişimini bir zaman kaymasıyla takip ediyorsa, hissenin bu diğer hisseden zaman kayması süresi sonrasında etkilendiği bilgisi oluşturulmuştur. Bu etkililiklere benzerlik oranlarına göre ağırlık verilmiş, böylelikle incelenen tüm hisseler arası ilişkiler oluşturulurken, çizge üzerinde hangi hissenin hangi hisseyi (yönlülük), ne kadar (ağırlık) ve ne yönde (paralellik) etkilediği hesaplanmıştır. Öznitelik olarak, her hissenin en çok etkilendiği 5 hissenin, en çok etkilediği zaman kaymasına göre 3 farklı fiyat değişim yönü etiketi kullanılmıştır. Bu durumda İVAY yaklaşımı için 49 adet öznitelik hesaplanmıştır.

Her iki yaklaşım için de en iyi model parametrelerini belirlemek üzere, 4 aylık eğitim verisinin 1 aylık kısmı doğrulama verisi olarak kullanılmış ve her model parametresi kombinasyonu için doğrulama verisi üzerinde testler yapılmıştır. Çok sayıda kombinasyonla yapılan bu testler sayesinde, her hisse senedi için en iyi sonuç veren öznitelik seçim yöntemi, seçilen öznitelik sayısı, sınıflandırıcı, sınıflandırıcı parametreleri hesaplanmıştır. Doğrulama verisinin sonuçları sıralandığında makro-ortalama F-ölçütü ile en iyi sonucu veren 40 model (İY yaklaşımı için 20, İVAY yaklaşımı için 20) 1 aylık gerçek test verisi üzerinde sınanmıştır.

Yapılan testler sonucunda bazı hisse senetleri için İY yaklaşımının, bazı hisse senetleri için ise İVAY yaklaşımının daha iyi sonuç verdiği görülmüştür. İY yaklaşımıyla en iyi sonuç veren LINK hissesi için %100 makro-ortalama F-ölçütü hesaplanmıştır. İVAY yaklaşımı ile ise en iyi sonuç veren TEBNK hissesi için %83 makro-ortalama F-ölçütü hesaplanmıştır. Genele bakıldığında İY yaklaşımıyla en yüksek başarı üreten hisselerin sayısı, İVAY yaklaşımıyla en yüksek başarı üreten hisselerin sayısına oranla daha fazla olduğu gözlenmiştir.

Bu tez çalışması ile birlikte; hisselerin fiyat değişim yönü tahmin edilirken gün içi işlem verisinin kullanılmış, sektörel bazdaki hisseler arasındaki ilişkiler hesaplanarak borsa ağı oluşturulmuş, borsa ağı ile geçmiş fiyat bilgisinden birlikte yararlanılarak fiyat değişim yönü tahmin modeli hazırlanmış, modeli oluşturmak için en iyi öznitelik seçim yöntemlerinin ve sınıflandırıcı parametrelerinin birlikte ölçümlenmesi sağlanmıştır. Bu bilgiler ışığında, gelecek çalışmalarda daha geniş sektör gruplarına ait hisseler, hatta sektörler arasındaki ilişkiler hesaplanabilir ve bu ilişkiler borsa tahmini modellerinde kullanılabilir.

KAYNAKLAR

Abdullah, M.H.L. ve Ganapathy, V. (2000). Neural Network Ensemble for Financial Trend Prediction. *Proc. TENCON 3*, 157-161.

Abhyankar, A., Copeland, L.S., ve Wong, W. (1997). Uncovering nonlinear structure in real-time stock-market indexes: The S&P 500, the DAX, the Nikkei 225, and the FTSE-100. *Journal of Business & Economic Statistics, 15(1),* 1-14.

Abu-Mostafa, Y.S., ve Atiya, A.F. (1996). Introduction to Financial Forecasting. *Applied Intelligence 6,* 205-213.

Aktas, R., Doganay, M., ve Yildiz, B. (2003). Mali basarisizligin ongorulmesi: istatistiksel yontemler ve yapay sinir agi karsilastirmasi, *Ankara Universitesi SBF Dergisi, 58(4),* pp. 1-25.

Altay, E. ve Satman M.H. (2005). Stock market forecasting: Artificial neural networks and linear regression comparison in an emerging market. *Journal of Financial Management and Analysis, 18 (2),* pp. 18-33.

Avci, E. (2007). Forecasting Daily and Sessional Returns of the ISE-100 Index With Neural Network Models. *Dogus Universitesi Dergisi, 8 (2),* 128-142.

Bedo, J., Sanderson, C., ve Kowalczyk, A. (2006). An efficient alternative to svm based recursive feature elimination with applications in natural language processing and bioinformatics. *Advances in Artificial Intelligence.* Springer Berlin Heidelberg. 170-180.

Bernstein A., Clearwater S., Perlich C., ve Provost F. (2002). Discovering Knowledge from Relational Data Extracted from Business News, NYU Working Paper No. 2451/14157.

Bildirici, M, ve Ersin, O.O. (2009). Improving forecasts of GARCH family models with the artificial neural networks: An Application to the daily returns in Istanbul Stock Exchange. *Expert Systems with Applications 36,* 7355-7362.

Black, A.J., ve McMillan, D.G. (2004). Long run trends and volatility spillovers in daily exchange rates. *Applied Financial Economics, 14(12),* 895-907.

Bollerslev, T., Ray Y.C., ve Kenneth F.K. (1992). ARCH modelling in finance: A review of the theory and empirical evidence. *Journal of econometrics 52.1*: 5-59.

Bonanno G., Caldarelli G., Lillo F., ve Mantegna R.N. (2008). *Topology of Correlation Based Minimal Spanning Trees in Real and Model Markets*.

Bonanno G., Vandewalle N., ve Mantegna R. N. (2000). Phys. Rev. E 62, R7615.

Caetano, L., Antonio M., ve Yoneyama, T. (t.y.). *Forecasting short term abrupt changes in the stock market with wavelet decomposition and graph theory*.

Castiglione, F. (2001). Forecasting price increments using an artificial neural network. *Advances in Complex Systems, 4(1),* 45-56.

Chang, P.C, ve Liu, C.H. (2006). A TSK type fuzzy rule based system for stock price prediction. *Expert Systems with Applications*.

Çataltepe, Z., Özer, S. Ve Barın, V.U. (2011). *Feature selection for price change prediction.*

Davis, J. ve Goadrich, M. (2006). The relationship between precision-recall and ROC curves, *In Proceedings of the International Conference on Machine Learning*.

Diler, A.İ. (2003). IMKB Ulusal-100 endeksinin yönünün yapay sinir ağları hata geriye yayma yöntemi ile tahmin edilmesi, *IMKB Dergisi, 25-26,* pp.65-81.

Donaldson, R.G., ve Kamstra, M. (1997). An artificial neural network-GARCH model for international stock return volatility. *Journal of Empirical Finance, 4*, 17–46.

Dunis, C.L., ve Huang, X. (2002). Forecasting and trading currency volatility: An application of recurrent neural regression and model combination. *Journal of Forecasting, 13,* 317-354.

Egeli, B., Ozturan, M., ve Badur B. (2003). Stock market prediction using artificial neural networks. Proceedings of *the 3rd Hawaii International Conference on Business*, Hawaii, USA.

Elkan, C. (1999). *Notes on discovering trading strategies*.

Gardner, M.W., ve Dorling, S.R. (1998). Artificial neural networks (the multilayer perceptron) a review of applications in the atmospheric sciences. *Atmospheric environment 32*.14-15: 2627-2636.

Chaudhuri, B.B., Bhattacharya, U. (2000). Efficient Training and Improved Performance of Multilayer Perceptron in Pattern Classification, *Neurocomputing, Vol 34*, 11-27.

Gidófalvi, G. (2001). *Using News Articles to Predict Stock Price Movements*.

Guyon, I., Weston, J., Barnhill, S., ve Vapnik, V. (2002). Gene Selection for Cancer Classification using Support Vector Machines. *Kluwer Academic Publishers, Machine Learning, 46,* 389-422.

Gündüz, H. (2013). *Borsa İstanbul (BIST) 100 Endeksi Yönünün Ekonomi Haberleri ile Tahmin Edilmesi*. Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, pp. 41.

Gysels, E., Renevey, P., ve Celka, P. (2005). SVM-based recursive feature elimination to compare phase synchronization computed from broadband and narrowband EEG signals in brain–computer interfaces. *Signal Processing 85*: 2178-2189.

Hamid, S.A., ve Iqbal, Z. (2004). Using neural networks for forecasting volatility of S&P 500 Index futures prices. *Journal of Business Research, 57,* 1116-1125.

Huang, W., Nakamori, Y, ve Wang, S.Y. (2005). Forecasting stock market movement direction with support vector machine. *Computers and Operations Research, 32,* 2513-2522.

Huang, C.J., Yang, D.X, Chuang, Y.T. (2008). Application of wrapper approach and composite classifier to the stock trend prediction. *Expert Systems with Applications, 34,* 2870-2878.

Jasic, T., ve Wood, D. (2004). The profitability of daily stock market indices trades based on neural network predictions: Case study for the S&P 500, the DAX, the TOPIX and the FTSE in the period 1965-1999. *Applied Financial Economics, 14,* 285-297.

Kanas, A. (2001). Neural network linear forecasts for stock returns. *International Journal of Finance & Economics, 13,* 317-354.

Kanas, A., ve Yannopoulos, A. (2001). Comparing linear and nonlinear forecasts for stock returns. *International Review of Economics & Finance, 10,* 383-398.

Kara, Y., Boyacioglu, M.A., ve Baykan, O.K. (2011). Predicting direction of stock price index movement using artificial neural networks and support vector machines: The sample of the Istanbul Stock Exchange. *Expert Systems with Applications, 38,* 5311-5319.

Kim, S.H., v Chun, S.H. (1998). Graded forecasting using an array of bipolar predictions: Application of probabilistic neural networks to a stock market index. *International Journal of Forecasting, 14,* 323-337.

Kim H.-J, ve Kim I.-M. (2001). *Scale-Free Network in Stock Markets*.

Kullman L., Kertézs J., ve Kaski K. (2008). *Time Dependent Cross Correlations Between Different Stock Returns: A Directed Network of Influence*, Budapest, Hungary.

Laloux L., Cizeau P., Bouchaud J.-P. ve Potters M. (1999). Phys. Rev. Lett. 83, 1467.

Leung, M.T., Chen, A.S., ve Daouk, H. (2000). Forecasting exchange rates using general regression neural networks. *Computers and Operations Research, 27(11),* 1093-1110.

Liu, Y., ve Yao, X. (2001). Evolving neural networks for Hang Seng stock index forecast. In Proceedings of *the 2001 congress on evolutionary computation* (Vol. 1, pp. 256-260).

Manish, K., ve Thenmozhi, M. (2006). Support vector machines approach to predict the S&P CNX NIFTY index returns. Proceedings of *the 10th Indian institure of capital markets conference.*

Mantegna R. N. (1999). Eur. Phys. J. B 11, 193.

Mantegna R.N., ve H.E. Stanley. (2000). *An Introduction to Econophysics: Correlations and Complexity in Finance*. (Cambridge Univ., Cambridge).

Mundra, P.A., ve Jagath, C.R. (2010). "SVM-RFE with mRMR filter for gene selection." *NanoBioscience*, IEEE Transactions on 9.1. 31-37.

Pai, P.F., ve Lin, C.S. (2005). A hybrid ARIMA and support vector machines model in stock price forecasting. *Omega, 33,* 497-505.

Pavithra, A., Saravanan, P., ve Venkataraman, N. L. (2014). Gender Classification Based on Selecting Features LBP, Intensity, and Shape. *International Journal of Engineering Research and Technology*. Vol. 3. No. 3. ESRSA Publications.

Peng, H., Long, F., ve Ding, C. (2005). Feature selection based on mutual information: Criteria of max-dependency, max-relevance, and min-redundancy. *IEEE Trans Pattern Anal and Mach Intell*. 27:1226-1238.

Phua, P.K.H., Zhu, X., ve Koh, C. (2003). Forecasting stock index increments using neural networks with trust region methods. In Proceedings of *IEEE international joint conference on neural networks* (Vol. 1, pp. 260-265).

Saad, E.W., Prokhorov, D.,C., ve Wunsch, D.C. (1998). Comparative study of stock trend prediction using time delay, recurrent and probabilistic neural networks. *IEEE Transactions on Neural Networks, 9,* 1456-1470.

Salık, M. (2014). *Computation, Visualization and Graph Properties of Heterogeneous, Directed and Weighted Stock Networks,* Lisans Bitirme Tezi, İstanbul Teknik Üniversitesi.

Shively, P.A. (2003). The nonlinear dynamics of stock prices. Quarterly Review of Economics and Finance, 13, 505-517.

Schumaker, R.P. ve Chen, H. (2009). A Quantitative Stock Prediction System based on Financial News, *Information Processing and Management: an International Journal,* Volume 45 Issue 5, September, 571-583.

Schwert, G. (1989). Why does stock market volatility change over time?. *The journal of finance 44.5*: 1115-1153.

Senol, D., ve Ozturan, M. (2008). Stock Price Direction Prediction Using Artificial Neural Network Approcah: The Case of Turkey. *Journal of Artificial Intelligence 1 (2)*: 70-77.

Soni, S. (2011). Applications of ANNs in Stock Market Prediction: A Survey. *International Journal of Computer Science & Engineering Technology*.

Tay, F.E.H., ve Cao, L.J. (2002). Modified support vector machines in financial time series forecasting. *Neurocomputing, 48,* 847-861.

Tse, C.K., Liu J. ve Lau F.C.M. (2010). A network perspective of the stock market. *Journal of Empirical Finance 17,* 659-667.

Vural, B.B. (2007). *Yapay Sinir Ağları ile Finansal Tahmin*. Yüksek Lisans Tezi, Ankara Üniversitesi Sosyal Bilimler Enstitüsü İşletme Anabilim Dalı, Ankara.

Wilson, R., ve Sharda, R. (1997). Business failure prediction using neural networks. *Encyclopedia of Computer Science and Technology, 37(22),* 193-204.

Yang, Y. (1997). An evaluation of statistical approaches to text categorization, Technical Report CMU-CS-97-127, Carnegie Mellon University.

Yumlu, S., Gurgen, F., ve Okay, N. (2005). A Comparison of Global, Recurrent and Smoothed-Piecewise Neural Models for Istanbul Stock Exchange (ISE) Prediction. *Pattern Recognition Letters, 26,* 2093–2103.

Zhang, X. (2006). Recursive SVM feature selection and sample classification for mass-spectrometry and microarray data. *BMC bioinformatics 7.1:* 197.

Zhu, X., Wang, H., Xu, L., ve Li, H. (2008). Predicting stock index increments by neural networks: The role of trading volume under different horizons. *Expert Systems with Applications 34*, 3043-3054.

Chih-Wei H., Chih-Chung C., ve Chih-Jen L. (2010). *A Practical Guide to Support Vector Classification.* Department of Computer Science. National Taiwan University, Taipei 106, Taiwan.

Url-1:<*http://www.borsaistanbul.com*>, alındığı tarih: 30.03.2014.

Url-2:<*http://www.metastock.com/Customer/Resources/TAAZ/default.aspx?p=6*>, alındığı tarih: 07.04.2014.

Url-3:<*http://www.healthdiscoverycorp.com/rfe.php*>, alındığı tarih: 13.04.2014.

Url-4:<*http://ta-lib.org/*>, alındığı tarih: 01.05.2014.

Url-5:<*http://java-ml.sourceforge.net*>, alındığı tarih: 01.05.2014.

Url-6:<*http://www.cs.waikato.ac.nz/ml/weka/*>, alındığı tarih: 01.05.2014.

EKLER

EK A: Veri örnekleri
EK B: Örnek öznitelik puanları
EK C: Hisse bazlı en iyi model sonuçları

EK A

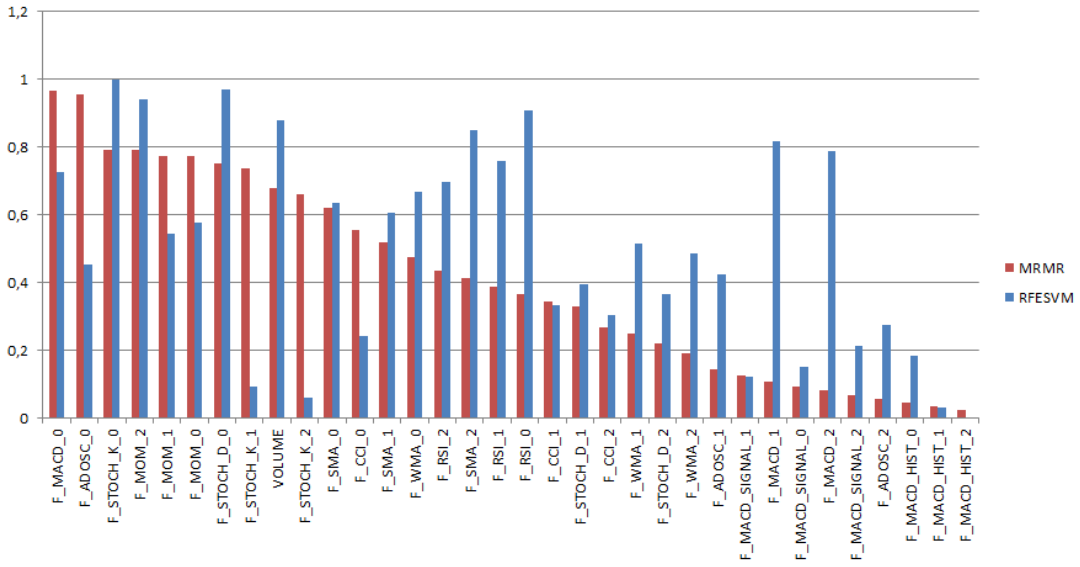
Çizelge A.1 : Gün içi işlem ham verisi örneği.

Hisse ismi	İşlem zamanı	İşlem fiyatı	İşlem adeti
AKBNK	09.09.2013 15:22:30	7,18	39
GARAN	09.09.2013 15:19:24	7,58	1
ISCTR	09.09.2013 15:42:14	4,95	1
HALKB	09.09.2013 15:42:15	13,65	1
HALKB	09.09.2013 15:42:15	13,7	7178
GARAN	09.09.2013 15:42:16	7,56	33
AKBNK	09.09.2013 15:42:16	7,16	1
HALKB	09.09.2013 15:42:17	13,65	1
VAKBN	09.09.2013 15:42:18	4,26	400
TCELL	09.09.2013 15:42:31	10,7	15
DESPC	09.09.2013 15:42:32	1,37	2
NETAS	09.09.2013 15:42:33	7,1	368
NETAS	09.09.2013 15:42:33	7,1	140
VAKBN	09.09.2013 15:42:35	4,25	1
NETAS	09.09.2013 15:42:36	7,1	2
AKBNK	09.09.2013 15:47:16	7,16	1
GARAN	09.09.2013 15:47:02	7,54	651
TTKOM	09.09.2013 15:43:18	6,24	2765
TTKOM	09.09.2013 15:43:18	6,24	260
ISCTR	09.09.2013 15:43:21	4,95	400
GARAN	09.09.2013 15:41:58	7,56	2
ISCTR	09.09.2013 15:41:59	4,96	100
ASYAB	09.09.2013 15:18:10	1,84	2201
VAKBN	09.09.2013 15:18:10	4,26	2000
GARAN	09.09.2013 15:18:12	7,56	11729

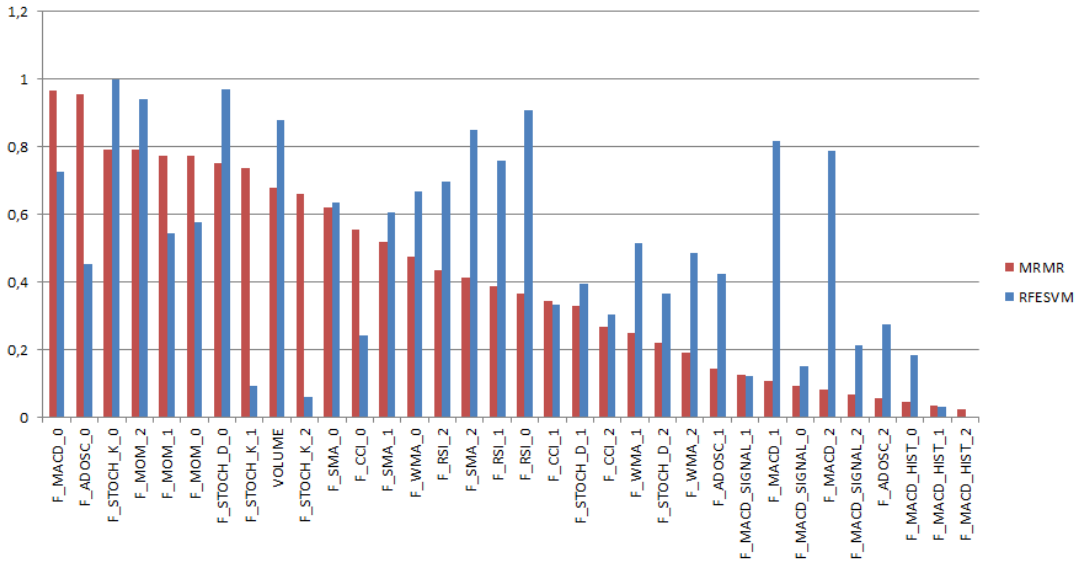
Çizelge A.2 : 15 dakikalık gün içi işlem verisi örneği.

Hisse ismi	İşlem zamanı	İşlem fiyatı	İşlem adeti
ASYAB	09.09.2013 15:30:00	1,83	104710
FINBN	09.09.2013 15:30:00	2,65	104
HALKB	09.09.2013 15:30:00	13,55	1636132
SKBNK	09.09.2013 15:30:00	1,89	1000
KLNMA	09.09.2013 15:30:00	5,7	0
TEBNK	09.09.2013 15:30:00	2,18	0
VAKBN	09.09.2013 15:30:00	4,23	1928134
ARENA	09.09.2013 15:30:00	2,16	5000
ARMDA	09.09.2013 15:30:00	1,58	412
DESPC	09.09.2013 15:30:00	1,37	19
TCELL	09.09.2013 15:30:00	10,65	106226
ESCOM	09.09.2013 15:45:00	1	0
LOGO	09.09.2013 15:45:00	4,21	1502
TCELL	09.09.2013 15:45:00	10,65	74894
TTKOM	09.09.2013 15:45:00	6,24	55156
ALCTL	09.09.2013 15:45:00	3,07	3241
ANELT	09.09.2013 15:45:00	2,87	110
KRONT	09.09.2013 15:45:00	0,94	1350
NETAS	09.09.2013 15:45:00	7,08	32599
GARAN	09.09.2013 15:45:00	7,54	3444065
TEBNK	09.09.2013 15:45:00	2,18	0
LINK	09.09.2013 15:45:00	2,26	826
AKBNK	09.09.2013 15:45:00	7,16	697435
ALNTF	09.09.2013 15:45:00	2,87	0
ASYAB	09.09.2013 15:45:00	1,84	143915

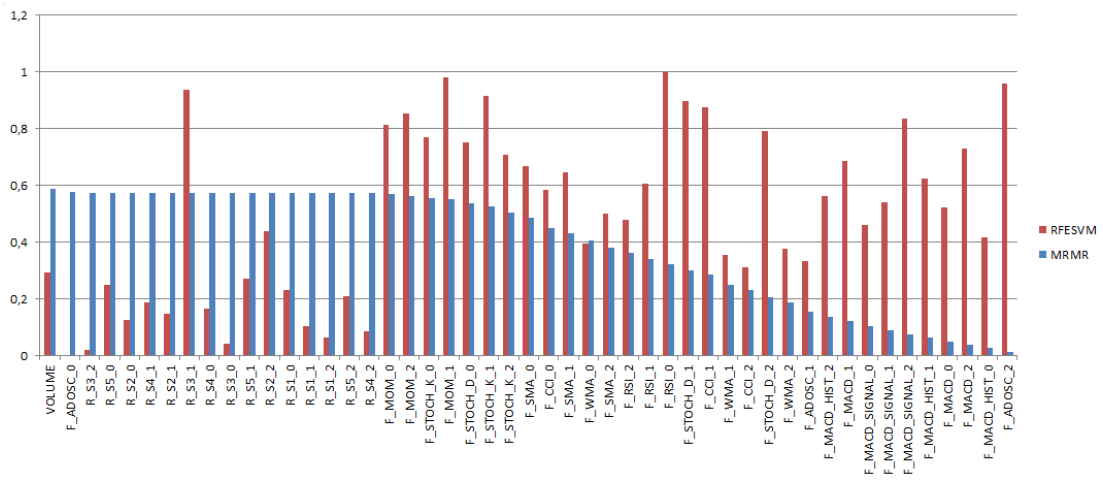
EK B



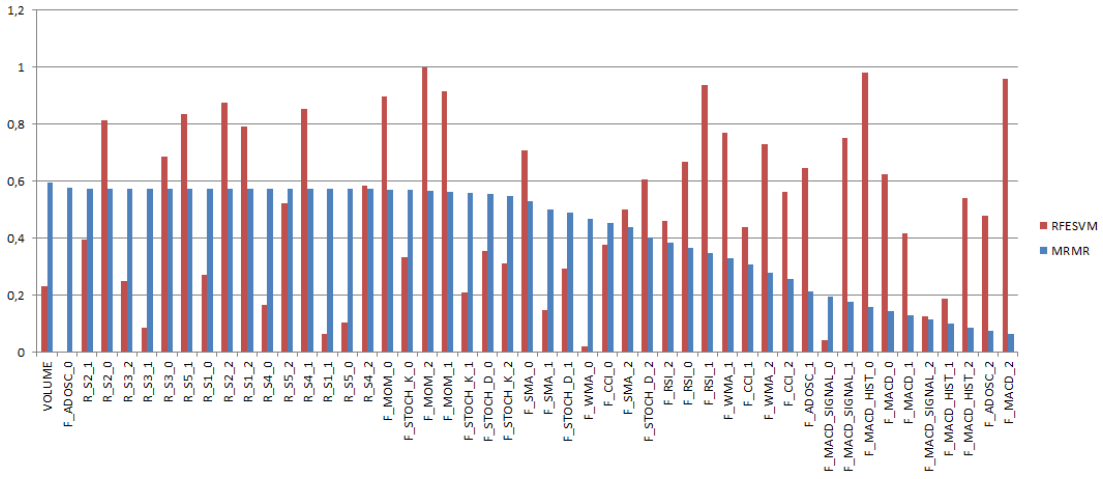
Şekil B.1 : LINK hissesine ait İY öznitelik puanları.



Şekil B.2 : TEBNK hissesine ait İY öznitelik puanları.



Şekil B.3 : LINK hissesine ait İVAY öznitelik puanları.



Şekil B.4 : TEBNK hissesine ait İVAY öznitelik puanları.

EK C

Çizelge C.1 : AKBNK hissesi için en başarılı 40 tahmin modeli.

Hisse	Yaklaşım	Makro-ortalama F-Ölçütü	ÖSA	En iyi N Öznitelik	Sınıf-landı-rıcı	Ö K	MOM	S K
AKBNK	İY	0,677	mRMR	18	ÇKP	0,1	0,7	o
AKBNK	İY	0,653	RFESVM	18	ÇKP	0,3	0,3	o
AKBNK	İY	0,644	RFESVM	17	ÇKP	0,7	0,3	o
AKBNK	İY	0,64	RFESVM	21	ÇKP	0,5	0,7	o
AKBNK	İVAY	0,638	mRMR	33	ÇKP	0,9	0,3	o
AKBNK	İY	0,637	mRMR	23	ÇKP	0,1	0,3	o
AKBNK	İY	0,637	mRMR	23	ÇKP	0,1	0,1	o
AKBNK	İY	0,63	RFESVM	17	ÇKP	0,1	0,3	o
AKBNK	İY	0,63	RFESVM	16	ÇKP	0,5	0,5	o
AKBNK	İVAY	0,63	mRMR	33	ÇKP	0,9	0,1	o
AKBNK	İY	0,63	RFESVM	16	ÇKP	0,9	0,1	o
AKBNK	İVAY	0,627	mRMR	45	ÇKP	0,1	0,1	o
AKBNK	İVAY	0,617	mRMR	35	ÇKP	0,1	0,1	o
AKBNK	İVAY	0,616	RFESVM	45	ÇKP	0,1	0,9	o
AKBNK	İVAY	0,611	mRMR	33	ÇKP	0,5	0,5	o
AKBNK	İVAY	0,607	RFESVM	45	ÇKP	0,1	0,1	t
AKBNK	İVAY	0,601	mRMR	45	ÇKP	0,1	0,3	o
AKBNK	İY	0,6	mRMR	16	ÇKP	0,1	0,3	o
AKBNK	İY	0,592	RFESVM	23	ÇKP	0,9	0,3	o
AKBNK	İVAY	0,589	mRMR	33	ÇKP	0,5	0,7	o
AKBNK	İVAY	0,589	mRMR	40	ÇKP	0,9	0,7	t
AKBNK	İY	0,58	mRMR	25	ÇKP	0,9	0,7	i
AKBNK	İVAY	0,579	RFESVM	45	ÇKP	0,5	0,9	o
AKBNK	İVAY	0,579	mRMR	40	ÇKP	0,7	0,7	i
AKBNK	İVAY	0,569	mRMR	35	ÇKP	0,5	0,9	a
AKBNK	İVAY	0,564	RFESVM	45	ÇKP	0,9	0,5	o
AKBNK	İVAY	0,563	mRMR	35	ÇKP	0,5	0,7	o
AKBNK	İY	0,563	mRMR	20	ÇKP	0,5	0,9	o
AKBNK	İY	0,557	RFESVM	20	ÇKP	0,7	0,3	i
AKBNK	İVAY	0,554	mRMR	35	ÇKP	0,5	0,9	o
AKBNK	İVAY	0,552	RFESVM	45	ÇKP	0,7	0,7	o
AKBNK	İVAY	0,549	mRMR	29	ÇKP	0,5	0,3	i
AKBNK	İY	0,546	RFESVM	13	ÇKP	0,5	0,9	t
AKBNK	İY	0,546	RFESVM	7	ÇKP	0,5	0,1	a
AKBNK	İY	0,541	RFESVM	7	ÇKP	0,3	0,3	o
AKBNK	İY	0,54	mRMR	17	ÇKP	0,5	0,1	o
AKBNK	İVAY	0,538	mRMR	45	ÇKP	0,5	0,7	t
AKBNK	İY	0,537	RFESVM	7	ÇKP	0,3	0,5	a
AKBNK	İY	0,524	RFESVM	7	ÇKP	0,1	0,7	o
AKBNK	İVAY	0,469	mRMR	45	ÇKP	0,5	0,9	i

Çizelge C.2 : ALCTL hissesi için en başarılı 40 tahmin modeli.

Hisse	Yaklaşım	Makro-ortalama F-Ölçütü	ÖSA	En iyi N Öznitelik	Sınıf-landı-rıcı	Ö K	MOM	S K
ALCTL	İY	0,709	RFESVM	5	ÇKP	0,3	0,7	a
ALCTL	İY	0,704	RFESVM	5	ÇKP	0,9	0,5	i
ALCTL	İY	0,681	RFESVM	5	ÇKP	0,3	0,9	t
ALCTL	İY	0,68	RFESVM	5	ÇKP	0,1	0,9	a
ALCTL	İY	0,667	RFESVM	5	ÇKP	0,5	0,3	t
ALCTL	İY	0,663	RFESVM	5	ÇKP	0,5	0,3	a
ALCTL	İY	0,661	RFESVM	5	ÇKP	0,9	0,1	t
ALCTL	İY	0,656	RFESVM	5	ÇKP	0,7	0,1	t
ALCTL	İY	0,653	RFESVM	5	ÇKP	0,5	0,7	i
ALCTL	İY	0,653	RFESVM	5	ÇKP	0,1	0,9	t
ALCTL	İY	0,645	mRMR	22	ÇKP	0,7	0,1	i
ALCTL	İVAY	0,634	mRMR	23	ÇKP	0,5	0,1	i
ALCTL	İY	0,621	RFESVM	22	ÇKP	0,1	0,9	o
ALCTL	İY	0,621	RFESVM	5	ÇKP	0,3	0,7	i
ALCTL	İY	0,621	RFESVM	10	ÇKP	0,5	0,9	a
ALCTL	İY	0,617	RFESVM	5	ÇKP	0,1	0,9	i
ALCTL	İY	0,616	RFESVM	19	ÇKP	0,3	0,9	t
ALCTL	İVAY	0,615	mRMR	45	ÇKP	0,5	0,5	o
ALCTL	İVAY	0,612	RFESVM	45	ÇKP	0,5	0,3	o
ALCTL	İY	0,61	RFESVM	5	ÇKP	0,9	0,1	i
ALCTL	İVAY	0,606	mRMR	23	ÇKP	0,5	0,3	i
ALCTL	İY	0,596	RFESVM	19	ÇKP	0,3	0,9	i
ALCTL	İY	0,591	RFESVM	24	ÇKP	0,7	0,5	o
ALCTL	İVAY	0,589	mRMR	45	ÇKP	0,3	0,7	o
ALCTL	İVAY	0,586	mRMR	23	ÇKP	0,3	0,5	i
ALCTL	İY	0,586	RFESVM	20	ÇKP	0,9	0,7	o
ALCTL	İVAY	0,582	mRMR	40	ÇKP	0,5	0,9	o
ALCTL	İVAY	0,575	mRMR	45	ÇKP	0,1	0,9	o
ALCTL	İVAY	0,575	mRMR	23	ÇKP	0,7	0,7	i
ALCTL	İVAY	0,561	mRMR	23	ÇKP	0,3	0,1	i
ALCTL	İVAY	0,561	mRMR	25	ÇKP	0,7	0,7	o
ALCTL	İVAY	0,552	mRMR	33	ÇKP	0,3	0,5	o
ALCTL	İVAY	0,543	RFESVM	33	ÇKP	0,9	0,9	o
ALCTL	İVAY	0,537	mRMR	40	ÇKP	0,3	0,3	o
ALCTL	İVAY	0,524	mRMR	33	ÇKP	0,5	0,1	o
ALCTL	İVAY	0,519	mRMR	30	ÇKP	0,9	0,9	a
ALCTL	İVAY	0,516	mRMR	16	ÇKP	0,7	0,9	o
ALCTL	İVAY	0,504	mRMR	27	ÇKP	0,9	0,5	i
ALCTL	İVAY	0,5	RFESVM	45	ÇKP	0,9	0,1	o
ALCTL	İVAY	0,482	mRMR	24	ÇKP	0,5	0,9	o

Çizelge C.3 : ALNTF hissesi için en başarılı 40 tahmin modeli.

Hisse	Yaklaşım	Makro-ortalama F-Ölçütü	ÖSA	En iyi N Öznitelik	Sınıf-landı-rıcı	Ö K	MOM	S K
ALNTF	İVAY	0,632	mRMR	28	ÇKP	0,3	0,7	i
ALNTF	İY	0,61	RFESVM	22	ÇKP	0,3	0,9	i
ALNTF	İY	0,594	RFESVM	19	ÇKP	0,7	0,5	a
ALNTF	İVAY	0,576	mRMR	28	ÇKP	0,9	0,5	i
ALNTF	İY	0,561	RFESVM	15	ÇKP	0,5	0,7	o
ALNTF	İVAY	0,561	mRMR	33	ÇKP	0,3	0,1	o
ALNTF	İY	0,561	mRMR	24	ÇKP	0,7	0,9	o
ALNTF	İY	0,561	mRMR	24	ÇKP	0,9	0,5	o
ALNTF	İY	0,554	mRMR	24	ÇKP	0,3	0,3	a
ALNTF	İY	0,554	RFESVM	23	ÇKP	0,5	0,9	i
ALNTF	İY	0,531	mRMR	18	ÇKP	0,3	0,1	a
ALNTF	İY	0,526	RFESVM	19	ÇKP	0,7	0,7	i
ALNTF	İY	0,523	RFESVM	22	ÇKP	0,9	0,5	a
ALNTF	İY	0,523	RFESVM	16	ÇKP	0,3	0,9	i
ALNTF	İVAY	0,523	RFESVM	25	ÇKP	0,3	0,5	o
ALNTF	İY	0,523	RFESVM	21	ÇKP	0,7	0,7	i
ALNTF	İY	0,513	mRMR	18	ÇKP	0,1	0,7	a
ALNTF	İY	0,499	RFESVM	25	ÇKP	0,3	0,3	i
ALNTF	İVAY	0,499	RFESVM	25	ÇKP	0,3	0,3	o
ALNTF	İVAY	0,498	RFESVM	25	ÇKP	0,1	0,7	o
ALNTF	İVAY	0,477	mRMR	28	ÇKP	0,5	0,5	i
ALNTF	İVAY	0,465	mRMR	26	ÇKP	0,5	0,9	a
ALNTF	İY	0,461	RFESVM	23	ÇKP	0,9	0,5	a
ALNTF	İVAY	0,456	mRMR	28	ÇKP	0,1	0,9	i
ALNTF	İVAY	0,443	mRMR	35	ÇKP	0,1	0,3	a
ALNTF	İY	0,443	mRMR	30	ÇKP	0,5	0,3	o
ALNTF	İY	0,443	RFESVM	10	ÇKP	0,9	0,3	i
ALNTF	İVAY	0,441	mRMR	27	ÇKP	0,7	0,5	i
ALNTF	İVAY	0,434	mRMR	28	ÇKP	0,5	0,5	t
ALNTF	İVAY	0,427	mRMR	26	ÇKP	0,3	0,1	i
ALNTF	İVAY	0,427	mRMR	28	ÇKP	0,7	0,7	a
ALNTF	İY	0,415	RFESVM	10	ÇKP	0,7	0,5	i
ALNTF	İVAY	0,414	mRMR	28	ÇKP	0,9	0,1	t
ALNTF	İVAY	0,405	mRMR	28	ÇKP	0,7	0,3	t
ALNTF	İVAY	0,383	mRMR	28	ÇKP	0,5	0,7	i
ALNTF	İVAY	0,343	mRMR	28	ÇKP	0,3	0,7	t
ALNTF	İY	0,332	RFESVM	21	ÇKP	0,3	0,9	o
ALNTF	İVAY	0,332	mRMR	33	ÇKP	0,1	0,7	o
ALNTF	İY	0,331	mRMR	20	ÇKP	0,9	0,9	t
ALNTF	İVAY	0,324	mRMR	26	ÇKP	0,1	0,9	t

Çizelge C.4 : ANELT hissesi için en başarılı 40 tahmin modeli.

Hisse	Yaklaşım	Makro-ortalama F-Ölçütü	ÖSA	En iyi N Öznitelik	Sınıf-landı-rıcı	Ö K	MOM	S K
ANELT	İY	0,708	mRMR	24	ÇKP	0,9	0,3	o
ANELT	İVAY	0,602	RFESVM	40	ÇKP	0,7	0,3	o
ANELT	İY	0,589	mRMR	25	ÇKP	0,5	0,3	o
ANELT	İY	0,577	mRMR	25	ÇKP	0,7	0,7	a
ANELT	İY	0,573	mRMR	25	ÇKP	0,7	0,1	o
ANELT	İVAY	0,558	RFESVM	29	ÇKP	0,5	0,1	o
ANELT	İY	0,546	mRMR	33	ÇKP	0,7	0,7	a
ANELT	İY	0,546	RFESVM	33	ÇKP	0,7	0,7	a
ANELT	İVAY	0,533	RFESVM	20	ÇKP	0,3	0,9	a
ANELT	İVAY	0,53	RFESVM	29	ÇKP	0,5	0,3	o
ANELT	İVAY	0,519	RFESVM	33	ÇKP	0,1	0,3	o
ANELT	İY	0,517	mRMR	23	ÇKP	0,9	0,5	a
ANELT	İY	0,51	mRMR	24	ÇKP	0,7	0,9	o
ANELT	İVAY	0,507	RFESVM	29	ÇKP	0,1	0,5	o
ANELT	İVAY	0,471	RFESVM	29	ÇKP	0,3	0,5	a
ANELT	İY	0,467	mRMR	17	ÇKP	0,7	0,7	o
ANELT	İY	0,466	mRMR	21	ÇKP	0,9	0,3	a
ANELT	İVAY	0,459	mRMR	30	ÇKP	0,7	0,9	o
ANELT	İY	0,457	mRMR	10	ÇKP	0,9	0,7	t
ANELT	İY	0,446	mRMR	23	ÇKP	0,5	0,1	o
ANELT	İY	0,444	mRMR	25	ÇKP	0,5	0,7	o
ANELT	İY	0,435	mRMR	25	ÇKP	0,3	0,9	a
ANELT	İVAY	0,431	mRMR	29	ÇKP	0,7	0,1	o
ANELT	İVAY	0,427	mRMR	27	ÇKP	0,5	0,3	o
ANELT	İVAY	0,426	RFESVM	29	ÇKP	0,9	0,1	o
ANELT	İVAY	0,423	mRMR	27	ÇKP	0,7	0,1	o
ANELT	İY	0,413	mRMR	21	ÇKP	0,3	0,1	o
ANELT	İY	0,413	mRMR	21	ÇKP	0,1	0,7	o
ANELT	İY	0,411	mRMR	21	ÇKP	0,3	0,3	o
ANELT	İY	0,408	mRMR	21	ÇKP	0,5	0,1	o
ANELT	İVAY	0,408	mRMR	28	ÇKP	0,5	0,5	o
ANELT	İVAY	0,408	mRMR	27	ÇKP	0,9	0,1	o
ANELT	İVAY	0,408	mRMR	29	ÇKP	0,5	0,7	o
ANELT	İVAY	0,402	mRMR	29	ÇKP	0,3	0,5	o
ANELT	İVAY	0,4	mRMR	29	ÇKP	0,5	0,3	o
ANELT	İY	0,387	mRMR	17	ÇKP	0,7	0,9	i
ANELT	İY	0,382	mRMR	17	ÇKP	0,3	0,9	o
ANELT	İVAY	0,381	mRMR	30	ÇKP	0,9	0,9	a
ANELT	İVAY	0,358	mRMR	35	ÇKP	0,1	0,3	o
ANELT	İVAY	0,356	mRMR	35	ÇKP	0,1	0,5	o

Çizelge C.5 : ARENA hissesi için en başarılı 40 tahmin modeli.

Hisse	Yaklaşım	Makro-ortalama F-Ölçütü	ÖSA	En iyi N Öznitelik	Sınıf-landı-rıcı	Ö K	MOM	S K
ARENA	İY	0,599	RFESVM	21	ÇKP	0,9	0,7	a
ARENA	İY	0,582	RFESVM	23	ÇKP	0,7	0,7	t
ARENA	İY	0,582	mRMR	19	ÇKP	0,5	0,5	i
ARENA	İY	0,582	mRMR	21	ÇKP	0,7	0,5	a
ARENA	İY	0,574	RFESVM	15	ÇKP	0,9	0,3	i
ARENA	İY	0,554	mRMR	19	ÇKP	0,3	0,7	i
ARENA	İY	0,554	RFESVM	19	ÇKP	0,9	0,5	a
ARENA	İY	0,554	RFESVM	17	ÇKP	0,3	0,9	t
ARENA	İVAY	0,554	RFESVM	45	ÇKP	0,7	0,7	o
ARENA	İY	0,522	mRMR	21	ÇKP	0,7	0,3	i
ARENA	İVAY	0,521	RFESVM	29	ÇKP	0,9	0,5	t
ARENA	İY	0,514	RFESVM	17	ÇKP	0,9	0,7	a
ARENA	İY	0,498	RFESVM	19	ÇKP	0,3	0,9	a
ARENA	İY	0,498	RFESVM	16	ÇKP	0,7	0,7	i
ARENA	İVAY	0,452	mRMR	20	ÇKP	0,7	0,5	i
ARENA	İY	0,443	RFESVM	19	ÇKP	0,5	0,7	a
ARENA	İY	0,443	RFESVM	7	ÇKP	0,5	0,5	i
ARENA	İY	0,442	mRMR	18	ÇKP	0,5	0,5	t
ARENA	İVAY	0,427	mRMR	30	ÇKP	0,5	0,1	o
ARENA	İY	0,426	RFESVM	21	ÇKP	0,5	0,9	a
ARENA	İVAY	0,426	mRMR	27	ÇKP	0,1	0,5	i
ARENA	İVAY	0,415	mRMR	30	ÇKP	0,3	0,5	o
ARENA	İVAY	0,414	mRMR	30	ÇKP	0,7	0,7	i
ARENA	İVAY	0,405	mRMR	30	ÇKP	0,9	0,1	o
ARENA	İVAY	0,405	mRMR	30	ÇKP	0,3	0,7	o
ARENA	İY	0,332	RFESVM	16	ÇKP	0,9	0,7	o
ARENA	İVAY	0,332	mRMR	30	ÇKP	0,7	0,3	o
ARENA	İVAY	0,332	mRMR	27	ÇKP	0,1	0,3	t
ARENA	İVAY	0,332	mRMR	27	ÇKP	0,1	0,3	i
ARENA	İVAY	0,331	mRMR	29	ÇKP	0,1	0,3	t
ARENA	İY	0,331	RFESVM	7	ÇKP	0,1	0,9	t
ARENA	İVAY	0,331	mRMR	27	ÇKP	0,1	0,5	t
ARENA	İVAY	0,331	mRMR	26	ÇKP	0,1	0,3	t
ARENA	İVAY	0,331	mRMR	29	ÇKP	0,1	0,3	i
ARENA	İVAY	0,331	mRMR	30	ÇKP	0,5	0,3	o
ARENA	İVAY	0,331	mRMR	26	ÇKP	0,1	0,3	i
ARENA	İY	0,331	RFESVM	16	ÇKP	0,7	0,9	i
ARENA	İVAY	0,331	mRMR	28	ÇKP	0,1	0,3	t
ARENA	İY	0,331	RFESVM	10	ÇKP	0,7	0,7	t
ARENA	İVAY	0,33	mRMR	30	ÇKP	0,5	0,5	o

Çizelge C.6 : ARMDA hissesi için en başarılı 40 tahmin modeli.

Hisse	Yaklaşım	Makro-ortalama F-Ölçütü	ÖSA	En iyi N Öznitelik	Sınıf-landı-rıcı	Ö K	MOM	S K
ARMDA	İVAY	0,649	RFESVM	27	ÇKP	0,1	0,5	o
ARMDA	İVAY	0,648	RFESVM	26	ÇKP	0,7	0,1	o
ARMDA	İY	0,637	RFESVM	25	ÇKP	0,7	0,3	t
ARMDA	İVAY	0,626	RFESVM	27	ÇKP	0,9	0,1	o
ARMDA	İVAY	0,626	RFESVM	30	ÇKP	0,7	0,5	a
ARMDA	İVAY	0,624	RFESVM	28	ÇKP	0,1	0,7	o
ARMDA	İVAY	0,624	RFESVM	28	ÇKP	0,3	0,1	o
ARMDA	İY	0,623	RFESVM	17	ÇKP	0,5	0,1	i
ARMDA	İVAY	0,619	RFESVM	29	ÇKP	0,9	0,3	a
ARMDA	İVAY	0,619	RFESVM	28	ÇKP	0,9	0,1	a
ARMDA	İY	0,617	RFESVM	25	ÇKP	0,3	0,3	a
ARMDA	İY	0,616	RFESVM	19	ÇKP	0,9	0,5	t
ARMDA	İVAY	0,616	RFESVM	20	ÇKP	0,3	0,1	a
ARMDA	İY	0,615	RFESVM	23	ÇKP	0,1	0,3	a
ARMDA	İY	0,615	RFESVM	23	ÇKP	0,1	0,1	a
ARMDA	İVAY	0,611	RFESVM	27	ÇKP	0,5	0,7	a
ARMDA	İY	0,61	RFESVM	15	ÇKP	0,7	0,3	a
ARMDA	İVAY	0,609	RFESVM	28	ÇKP	0,9	0,3	a
ARMDA	İVAY	0,605	RFESVM	20	ÇKP	0,5	0,3	a
ARMDA	İY	0,599	RFESVM	30	ÇKP	0,7	0,3	a
ARMDA	İY	0,599	RFESVM	16	ÇKP	0,7	0,1	a
ARMDA	İVAY	0,598	RFESVM	30	ÇKP	0,9	0,5	a
ARMDA	İVAY	0,597	RFESVM	20	ÇKP	0,3	0,7	a
ARMDA	İVAY	0,595	RFESVM	20	ÇKP	0,3	0,5	a
ARMDA	İVAY	0,593	RFESVM	28	ÇKP	0,5	0,7	a
ARMDA	İVAY	0,589	RFESVM	29	ÇKP	0,1	0,9	a
ARMDA	İY	0,588	RFESVM	15	ÇKP	0,5	0,5	a
ARMDA	İVAY	0,587	RFESVM	25	ÇKP	0,7	0,1	a
ARMDA	İY	0,583	RFESVM	10	ÇKP	0,1	0,7	t
ARMDA	İY	0,581	RFESVM	15	ÇKP	0,5	0,1	a
ARMDA	İVAY	0,581	RFESVM	27	ÇKP	0,3	0,9	o
ARMDA	İVAY	0,573	RFESVM	29	ÇKP	0,7	0,5	a
ARMDA	İY	0,571	RFESVM	15	ÇKP	0,3	0,3	a
ARMDA	İY	0,567	RFESVM	22	ÇKP	0,9	0,5	a
ARMDA	İY	0,563	RFESVM	33	ÇKP	0,5	0,3	a
ARMDA	İY	0,563	mRMR	33	ÇKP	0,5	0,3	a
ARMDA	İY	0,556	RFESVM	22	ÇKP	0,9	0,3	i
ARMDA	İY	0,488	mRMR	17	ÇKP	0,5	0,1	o
ARMDA	İY	0,486	mRMR	17	ÇKP	0,3	0,5	o
ARMDA	İY	0,473	mRMR	17	ÇKP	0,5	0,3	o

Çizelge C.7 : ASYAB hissesi için en başarılı 40 tahmin modeli.

Hisse	Yaklaşım	Makro-ortalama F-Ölçütü	ÖSA	En iyi N Öznitelik	Sınıf-landı-rıcı	Ö K	MOM	S K
ASYAB	İY	0,756	RFESVM	30	ÇKP	0,5	0,3	o
ASYAB	İY	0,738	RFESVM	25	ÇKP	0,1	0,7	o
ASYAB	İY	0,728	RFESVM	25	ÇKP	0,1	0,5	o
ASYAB	İVAY	0,723	RFESVM	28	ÇKP	0,7	0,5	o
ASYAB	İVAY	0,716	RFESVM	25	ÇKP	0,3	0,5	o
ASYAB	İVAY	0,714	RFESVM	33	ÇKP	0,9	0,3	o
ASYAB	İY	0,708	mRMR	23	ÇKP	0,7	0,1	o
ASYAB	İVAY	0,705	RFESVM	40	ÇKP	0,9	0,3	o
ASYAB	İY	0,7	mRMR	22	ÇKP	0,5	0,1	o
ASYAB	İY	0,696	RFESVM	25	ÇKP	0,1	0,3	o
ASYAB	İVAY	0,694	RFESVM	40	ÇKP	0,9	0,1	i
ASYAB	İY	0,688	mRMR	21	ÇKP	0,1	0,1	i
ASYAB	İVAY	0,687	RFESVM	40	ÇKP	0,1	0,1	a
ASYAB	İY	0,687	mRMR	19	ÇKP	0,1	0,5	i
ASYAB	İY	0,658	mRMR	22	ÇKP	0,7	0,1	o
ASYAB	İY	0,658	mRMR	18	ÇKP	0,3	0,1	o
ASYAB	İY	0,656	RFESVM	23	ÇKP	0,9	0,1	t
ASYAB	İY	0,653	RFESVM	25	ÇKP	0,3	0,1	o
ASYAB	İVAY	0,651	mRMR	45	ÇKP	0,9	0,1	o
ASYAB	İY	0,649	RFESVM	33	ÇKP	0,5	0,1	o
ASYAB	İVAY	0,647	RFESVM	27	ÇKP	0,9	0,1	o
ASYAB	İVAY	0,645	RFESVM	26	ÇKP	0,1	0,9	o
ASYAB	İVAY	0,644	RFESVM	27	ÇKP	0,5	0,5	o
ASYAB	İVAY	0,644	RFESVM	25	ÇKP	0,7	0,7	i
ASYAB	İVAY	0,639	mRMR	45	ÇKP	0,7	0,3	o
ASYAB	İY	0,626	RFESVM	22	ÇKP	0,5	0,5	o
ASYAB	İY	0,622	mRMR	26	ÇKP	0,3	0,3	a
ASYAB	İVAY	0,622	RFESVM	25	ÇKP	0,5	0,9	o
ASYAB	İVAY	0,618	RFESVM	33	ÇKP	0,7	0,5	o
ASYAB	İY	0,617	mRMR	25	ÇKP	0,1	0,7	t
ASYAB	İY	0,612	mRMR	19	ÇKP	0,1	0,7	i
ASYAB	İY	0,607	mRMR	24	ÇKP	0,5	0,1	i
ASYAB	İVAY	0,603	RFESVM	33	ÇKP	0,7	0,3	o
ASYAB	İVAY	0,603	RFESVM	25	ÇKP	0,9	0,5	a
ASYAB	İVAY	0,59	RFESVM	35	ÇKP	0,3	0,9	o
ASYAB	İVAY	0,584	RFESVM	45	ÇKP	0,9	0,5	o
ASYAB	İY	0,57	mRMR	19	ÇKP	0,7	0,5	i
ASYAB	İVAY	0,567	RFESVM	35	ÇKP	0,3	0,3	o
ASYAB	İVAY	0,547	RFESVM	30	ÇKP	0,7	0,7	o
ASYAB	İY	0,5	RFESVM	25	ÇKP	0,5	0,1	o

Çizelge C.8 : DENIZ hissesi için en başarılı 40 tahmin modeli.

Hisse	Yaklaşım	Makro-ortalama F-Ölçütü	ÖSA	En iyi N Öznitelik	Sınıf-landı-rıcı	Ö K	MOM	S K
DENIZ	İVAY	0,707	RFESVM	26	ÇKP	0,7	0,9	a
DENIZ	İVAY	0,695	RFESVM	25	ÇKP	0,9	0,9	i
DENIZ	İVAY	0,671	mRMR	20	ÇKP	0,7	0,5	o
DENIZ	İY	0,67	mRMR	7	ÇKP	0,7	0,9	i
DENIZ	İVAY	0,655	RFESVM	27	ÇKP	0,7	0,9	o
DENIZ	İY	0,641	mRMR	10	ÇKP	0,3	0,9	t
DENIZ	İY	0,628	mRMR	10	ÇKP	0,9	0,5	t
DENIZ	İY	0,628	mRMR	10	ÇKP	0,7	0,7	t
DENIZ	İVAY	0,619	RFESVM	30	ÇKP	0,7	0,9	o
DENIZ	İY	0,586	mRMR	10	ÇKP	0,5	0,9	t
DENIZ	İVAY	0,582	mRMR	27	ÇKP	0,7	0,3	o
DENIZ	İY	0,58	mRMR	13	ÇKP	0,7	0,9	a
DENIZ	İVAY	0,573	mRMR	25	ÇKP	0,9	0,9	o
DENIZ	İY	0,569	mRMR	10	ÇKP	0,9	0,3	t
DENIZ	İY	0,559	mRMR	10	ÇKP	0,7	0,1	i
DENIZ	İVAY	0,557	mRMR	29	ÇKP	0,5	0,9	t
DENIZ	İY	0,553	mRMR	10	ÇKP	0,9	0,3	i
DENIZ	İVAY	0,551	RFESVM	26	ÇKP	0,5	0,9	o
DENIZ	İVAY	0,535	mRMR	28	ÇKP	0,5	0,3	o
DENIZ	İY	0,529	mRMR	10	ÇKP	0,5	0,7	t
DENIZ	İY	0,522	mRMR	10	ÇKP	0,9	0,1	t
DENIZ	İY	0,522	mRMR	10	ÇKP	0,5	0,5	t
DENIZ	İY	0,516	mRMR	10	ÇKP	0,7	0,5	t
DENIZ	İVAY	0,516	mRMR	26	ÇKP	0,3	0,5	o
DENIZ	İY	0,516	mRMR	10	ÇKP	0,3	0,9	i
DENIZ	İY	0,516	mRMR	10	ÇKP	0,3	0,9	a
DENIZ	İY	0,511	mRMR	10	ÇKP	0,9	0,5	i
DENIZ	İVAY	0,506	mRMR	26	ÇKP	0,5	0,1	o
DENIZ	İY	0,502	mRMR	10	ÇKP	0,9	0,7	i
DENIZ	İVAY	0,49	mRMR	29	ÇKP	0,3	0,3	o
DENIZ	İVAY	0,482	mRMR	27	ÇKP	0,9	0,1	o
DENIZ	İVAY	0,469	mRMR	27	ÇKP	0,1	0,9	o
DENIZ	İVAY	0,469	mRMR	27	ÇKP	0,5	0,5	o
DENIZ	İVAY	0,469	mRMR	27	ÇKP	0,3	0,7	o
DENIZ	İVAY	0,464	mRMR	33	ÇKP	0,9	0,7	o
DENIZ	İY	0,461	mRMR	10	ÇKP	0,5	0,7	i
DENIZ	İY	0,461	mRMR	10	ÇKP	0,7	0,5	i
DENIZ	İY	0,442	mRMR	10	ÇKP	0,7	0,9	t
DENIZ	İVAY	0,442	RFESVM	27	ÇKP	0,9	0,9	i
DENIZ	İVAY	0,436	RFESVM	25	ÇKP	0,9	0,9	o

Çizelge C.9 : DESPC hissesi için en başarılı 40 tahmin modeli.

Hisse	Yaklaşım	Makro-ortalama F-Ölçütü	ÖSA	En iyi N Öznitelik	Sınıf-landı-rıcı	Ö K	MOM	S K
DESPC	İY	0,679	RFESVM	21	ÇKP	0,3	0,1	t
DESPC	İY	0,654	RFESVM	21	ÇKP	0,3	0,5	i
DESPC	İVAY	0,645	mRMR	33	ÇKP	0,3	0,1	o
DESPC	İY	0,638	mRMR	18	ÇKP	0,3	0,1	t
DESPC	İVAY	0,633	RFESVM	35	ÇKP	0,9	0,5	o
DESPC	İVAY	0,63	mRMR	25	ÇKP	0,1	0,9	i
DESPC	İY	0,615	RFESVM	19	ÇKP	0,9	0,3	t
DESPC	İY	0,615	RFESVM	18	ÇKP	0,1	0,5	a
DESPC	İVAY	0,615	RFESVM	35	ÇKP	0,7	0,3	a
DESPC	İVAY	0,61	mRMR	35	ÇKP	0,3	0,1	o
DESPC	İVAY	0,609	RFESVM	35	ÇKP	0,9	0,7	a
DESPC	İY	0,608	RFESVM	16	ÇKP	0,9	0,1	a
DESPC	İVAY	0,593	RFESVM	35	ÇKP	0,3	0,5	a
DESPC	İVAY	0,593	RFESVM	35	ÇKP	0,5	0,1	a
DESPC	İY	0,592	RFESVM	21	ÇKP	0,5	0,7	a
DESPC	İY	0,59	mRMR	18	ÇKP	0,5	0,3	i
DESPC	İY	0,589	mRMR	23	ÇKP	0,1	0,1	a
DESPC	İY	0,587	mRMR	21	ÇKP	0,1	0,5	a
DESPC	İVAY	0,582	RFESVM	35	ÇKP	0,9	0,1	a
DESPC	İVAY	0,58	RFESVM	35	ÇKP	0,7	0,3	o
DESPC	İY	0,578	RFESVM	19	ÇKP	0,9	0,3	a
DESPC	İY	0,563	RFESVM	17	ÇKP	0,5	0,9	o
DESPC	İVAY	0,559	RFESVM	35	ÇKP	0,3	0,3	a
DESPC	İY	0,557	RFESVM	24	ÇKP	0,5	0,3	i
DESPC	İVAY	0,548	mRMR	33	ÇKP	0,7	0,1	o
DESPC	İVAY	0,546	mRMR	25	ÇKP	0,3	0,3	i
DESPC	İVAY	0,52	RFESVM	35	ÇKP	0,1	0,7	t
DESPC	İY	0,518	mRMR	18	ÇKP	0,3	0,7	a
DESPC	İY	0,515	mRMR	18	ÇKP	0,5	0,1	o
DESPC	İY	0,514	RFESVM	21	ÇKP	0,7	0,5	t
DESPC	İVAY	0,509	mRMR	33	ÇKP	0,9	0,7	o
DESPC	İY	0,498	RFESVM	17	ÇKP	0,9	0,5	i
DESPC	İY	0,496	mRMR	19	ÇKP	0,5	0,7	o
DESPC	İY	0,49	RFESVM	30	ÇKP	0,9	0,1	o
DESPC	İVAY	0,489	mRMR	26	ÇKP	0,5	0,9	o
DESPC	İVAY	0,463	mRMR	27	ÇKP	0,1	0,1	o
DESPC	İY	0,459	mRMR	17	ÇKP	0,7	0,1	t
DESPC	İVAY	0,451	mRMR	35	ÇKP	0,7	0,5	o
DESPC	İVAY	0,436	RFESVM	35	ÇKP	0,9	0,1	o
DESPC	İVAY	0,408	RFESVM	35	ÇKP	0,3	0,7	o

Çizelge C.10 : ESCOM hissesi için en başarılı 40 tahmin modeli.

Hisse	Yaklaşım	Makro-ortalama F-Ölçütü	ÖSA	En iyi N Öznitelik	Sınıf-landı-rıcı	Ö K	MOM	S K
ESCOM	İY	0,688	mRMR	15	ÇKP	0,9	0,7	a
ESCOM	İY	0,688	mRMR	13	ÇKP	0,5	0,9	t
ESCOM	İY	0,688	mRMR	15	ÇKP	0,3	0,9	i
ESCOM	İY	0,666	mRMR	13	ÇKP	0,3	0,3	a
ESCOM	İY	0,666	mRMR	13	ÇKP	0,1	0,9	a
ESCOM	İVAY	0,61	mRMR	22	ÇKP	0,9	0,5	a
ESCOM	İY	0,499	mRMR	15	ÇKP	0,9	0,9	t
ESCOM	İY	0,499	mRMR	13	ÇKP	0,7	0,7	t
ESCOM	İVAY	0,499	mRMR	22	ÇKP	0,9	0,3	a
ESCOM	İVAY	0,499	mRMR	22	ÇKP	0,5	0,7	a
ESCOM	İY	0,499	mRMR	13	ÇKP	0,3	0,1	a
ESCOM	İY	0,499	mRMR	13	ÇKP	0,1	0,7	a
ESCOM	İY	0,499	mRMR	15	ÇKP	0,7	0,9	t
ESCOM	İVAY	0,499	mRMR	23	ÇKP	0,9	0,9	a
ESCOM	İVAY	0,499	mRMR	27	ÇKP	0,9	0,9	a
ESCOM	İVAY	0,498	RFESVM	33	ÇKP	0,7	0,9	o
ESCOM	İY	0,466	mRMR	22	ÇKP	0,5	0,9	a
ESCOM	İY	0,466	mRMR	25	ÇKP	0,9	0,9	a
ESCOM	İVAY	0,466	mRMR	27	ÇKP	0,5	0,9	i
ESCOM	İVAY	0,466	mRMR	21	ÇKP	0,9	0,5	i
ESCOM	İVAY	0,466	mRMR	20	ÇKP	0,5	0,3	a
ESCOM	İVAY	0,466	mRMR	20	ÇKP	0,3	0,3	a
ESCOM	İVAY	0,466	mRMR	29	ÇKP	0,5	0,7	i
ESCOM	İY	0,466	RFESVM	21	ÇKP	0,9	0,9	t
ESCOM	İY	0,466	mRMR	13	ÇKP	0,9	0,3	i
ESCOM	İY	0,466	mRMR	13	ÇKP	0,1	0,9	i
ESCOM	İVAY	0,444	mRMR	20	ÇKP	0,5	0,1	a
ESCOM	İVAY	0,444	mRMR	20	ÇKP	0,5	0,9	i
ESCOM	İVAY	0,444	mRMR	21	ÇKP	0,5	0,9	i
ESCOM	İVAY	0,444	mRMR	21	ÇKP	0,9	0,7	i
ESCOM	İVAY	0,428	mRMR	13	ÇKP	0,3	0,9	a
ESCOM	İVAY	0,399	mRMR	20	ÇKP	0,7	0,5	t
ESCOM	İY	0,332	mRMR	7	ÇKP	0,7	0,9	i
ESCOM	İVAY	0,332	mRMR	25	ÇKP	0,9	0,9	t
ESCOM	İY	0,332	mRMR	13	ÇKP	0,7	0,7	i
ESCOM	İVAY	0,332	mRMR	27	ÇKP	0,7	0,5	a
ESCOM	İVAY	0,332	mRMR	27	ÇKP	0,9	0,9	i
ESCOM	İY	0,332	RFESVM	16	ÇKP	0,9	0,9	t
ESCOM	İY	0,332	mRMR	13	ÇKP	0,7	0,5	i
ESCOM	İY	0,332	mRMR	13	ÇKP	0,7	0,9	t

Çizelge C.11 : FINBN hissesi için en başarılı 40 tahmin modeli.

Hisse	Yaklaşım	Makro-ortalama F-Ölçütü	ÖSA	En iyi N Öznitelik	Sınıf-landı-rıcı	ÖK	MOM	SK
FINBN	İVAY	0,621	RFESVM	33	ÇKP	0,7	0,1	o
FINBN	İVAY	0,621	RFESVM	33	ÇKP	0,5	0,3	o
FINBN	İVAY	0,615	RFESVM	40	ÇKP	0,9	0,1	o
FINBN	İVAY	0,59	RFESVM	40	ÇKP	0,3	0,7	o
FINBN	İVAY	0,553	mRMR	40	ÇKP	0,3	0,1	o
FINBN	İVAY	0,553	mRMR	40	ÇKP	0,1	0,7	o
FINBN	İVAY	0,552	RFESVM	45	ÇKP	0,3	0,5	o
FINBN	İVAY	0,549	mRMR	45	ÇKP	0,3	0,5	o
FINBN	İY	0,548	RFESVM	15	ÇKP	0,3	0,5	t
FINBN	İY	0,548	RFESVM	15	ÇKP	0,5	0,3	t
FINBN	İY	0,541	RFESVM	19	ÇKP	0,3	0,3	a
FINBN	İY	0,536	RFESVM	16	ÇKP	0,1	0,9	a
FINBN	İY	0,535	RFESVM	17	ÇKP	0,3	0,3	t
FINBN	İVAY	0,53	RFESVM	40	ÇKP	0,7	0,3	o
FINBN	İVAY	0,527	mRMR	40	ÇKP	0,3	0,5	o
FINBN	İY	0,526	RFESVM	18	ÇKP	0,3	0,3	a
FINBN	İY	0,525	RFESVM	16	ÇKP	0,5	0,5	a
FINBN	İY	0,521	RFESVM	19	ÇKP	0,5	0,3	a
FINBN	İY	0,521	RFESVM	19	ÇKP	0,5	0,1	a
FINBN	İY	0,521	RFESVM	19	ÇKP	0,5	0,5	a
FINBN	İY	0,521	RFESVM	19	ÇKP	0,3	0,5	a
FINBN	İVAY	0,516	mRMR	40	ÇKP	0,5	0,1	o
FINBN	İVAY	0,516	mRMR	40	ÇKP	0,5	0,3	o
FINBN	İY	0,509	RFESVM	19	ÇKP	0,1	0,9	a
FINBN	İVAY	0,509	mRMR	27	ÇKP	0,7	0,1	o
FINBN	İY	0,507	RFESVM	19	ÇKP	0,3	0,7	a
FINBN	İVAY	0,497	mRMR	40	ÇKP	0,3	0,3	o
FINBN	İY	0,494	RFESVM	15	ÇKP	0,5	0,1	t
FINBN	İY	0,484	RFESVM	19	ÇKP	0,7	0,1	a
FINBN	İY	0,477	RFESVM	7	ÇKP	0,9	0,5	a
FINBN	İY	0,475	RFESVM	16	ÇKP	0,9	0,1	a
FINBN	İY	0,475	RFESVM	16	ÇKP	0,7	0,3	a
FINBN	İVAY	0,474	RFESVM	28	ÇKP	0,9	0,9	o
FINBN	İVAY	0,473	mRMR	40	ÇKP	0,5	0,9	o
FINBN	İVAY	0,464	mRMR	45	ÇKP	0,5	0,1	o
FINBN	İVAY	0,464	mRMR	33	ÇKP	0,7	0,9	o
FINBN	İVAY	0,448	mRMR	33	ÇKP	0,1	0,5	o
FINBN	İY	0,433	RFESVM	7	ÇKP	0,5	0,7	a
FINBN	İY	0,425	RFESVM	7	ÇKP	0,7	0,5	a
FINBN	İVAY	0,397	RFESVM	33	ÇKP	0,9	0,9	o

Çizelge C.12 : GARAN hissesi için en başarılı 40 tahmin modeli.

Hisse	Yaklaşım	Makro-ortalama F-Ölçütü	ÖSA	En iyi N Öznitelik	Sınıf-landı-rıcı	Ö K	MOM	S K
GARAN	İY	0,691	mRMR	16	ÇKP	0,3	0,3	a
GARAN	İY	0,683	RFESVM	19	ÇKP	0,1	0,1	i
GARAN	İY	0,681	RFESVM	17	ÇKP	0,1	0,5	a
GARAN	İY	0,678	RFESVM	19	ÇKP	0,1	0,7	a
GARAN	İY	0,671	RFESVM	17	ÇKP	0,3	0,1	o
GARAN	İY	0,67	RFESVM	19	ÇKP	0,1	0,3	t
GARAN	İVAY	0,67	RFESVM	19	ÇKP	0,1	0,1	t
GARAN	İY	0,668	RFESVM	16	ÇKP	0,7	0,7	a
GARAN	İVAY	0,667	RFESVM	16	ÇKP	0,5	0,9	i
GARAN	İY	0,666	RFESVM	16	ÇKP	0,1	0,1	o
GARAN	İY	0,665	RFESVM	19	ÇKP	0,9	0,7	o
GARAN	İVAY	0,656	RFESVM	16	ÇKP	0,3	0,3	i
GARAN	İY	0,656	RFESVM	16	ÇKP	0,1	0,9	o
GARAN	İY	0,655	RFESVM	20	ÇKP	0,3	0,7	o
GARAN	İY	0,655	RFESVM	16	ÇKP	0,5	0,7	a
GARAN	İVAY	0,651	RFESVM	15	ÇKP	0,5	0,3	t
GARAN	İY	0,651	RFESVM	17	ÇKP	0,1	0,1	i
GARAN	İY	0,651	mRMR	18	ÇKP	0,7	0,1	i
GARAN	İY	0,65	RFESVM	20	ÇKP	0,7	0,5	i
GARAN	İVAY	0,649	RFESVM	23	ÇKP	0,1	0,3	a
GARAN	İY	0,648	mRMR	25	ÇKP	0,9	0,3	o
GARAN	İVAY	0,647	RFESVM	20	ÇKP	0,1	0,3	i
GARAN	İY	0,647	mRMR	20	ÇKP	0,5	0,1	t
GARAN	İVAY	0,641	RFESVM	16	ÇKP	0,5	0,9	t
GARAN	İVAY	0,638	RFESVM	18	ÇKP	0,5	0,5	t
GARAN	İY	0,635	RFESVM	22	ÇKP	0,9	0,3	o
GARAN	İVAY	0,629	RFESVM	13	ÇKP	0,5	0,1	i
GARAN	İVAY	0,623	RFESVM	13	ÇKP	0,7	0,1	t
GARAN	İVAY	0,62	RFESVM	16	ÇKP	0,5	0,1	i
GARAN	İVAY	0,619	RFESVM	19	ÇKP	0,5	0,9	i
GARAN	İY	0,616	RFESVM	13	ÇKP	0,3	0,1	a
GARAN	İVAY	0,613	RFESVM	21	ÇKP	0,9	0,5	i
GARAN	İVAY	0,611	RFESVM	18	ÇKP	0,5	0,3	t
GARAN	İVAY	0,609	RFESVM	33	ÇKP	0,1	0,9	a
GARAN	İVAY	0,607	mRMR	35	ÇKP	0,1	0,1	i
GARAN	İVAY	0,607	RFESVM	29	ÇKP	0,5	0,5	t
GARAN	İY	0,6	RFESVM	15	ÇKP	0,7	0,7	o
GARAN	İVAY	0,597	RFESVM	23	ÇKP	0,3	0,5	i
GARAN	İVAY	0,553	RFESVM	28	ÇKP	0,5	0,9	t
GARAN	İVAY	0,539	RFESVM	22	ÇKP	0,5	0,9	a

Çizelge C.13 : HALKB hissesi için en başarılı 40 tahmin modeli.

Hisse	Yaklaşım	Makro-ortalama F-Ölçütü	ÖSA	En iyi N Öznitelik	Sınıf-landı-rıcı	Ö K	MOM	S K
HALKB	İVAY	0,7	mRMR	40	ÇKP	0,5	0,5	o
HALKB	İY	0,676	RFESVM	13	ÇKP	0,1	0,5	i
HALKB	İY	0,642	RFESVM	20	ÇKP	0,1	0,3	a
HALKB	İY	0,631	RFESVM	20	ÇKP	0,1	0,1	t
HALKB	İVAY	0,627	mRMR	45	ÇKP	0,1	0,5	a
HALKB	İVAY	0,627	mRMR	40	ÇKP	0,7	0,1	o
HALKB	İVAY	0,626	RFESVM	45	ÇKP	0,3	0,7	o
HALKB	İY	0,621	RFESVM	15	ÇKP	0,1	0,1	a
HALKB	İVAY	0,621	mRMR	40	ÇKP	0,5	0,3	o
HALKB	İY	0,621	RFESVM	23	ÇKP	0,1	0,3	t
HALKB	İY	0,62	RFESVM	15	ÇKP	0,3	0,7	i
HALKB	İVAY	0,62	mRMR	45	ÇKP	0,7	0,9	o
HALKB	İVAY	0,614	RFESVM	45	ÇKP	0,7	0,5	o
HALKB	İVAY	0,612	mRMR	35	ÇKP	0,7	0,7	a
HALKB	İVAY	0,606	RFESVM	45	ÇKP	0,3	0,1	o
HALKB	İVAY	0,605	mRMR	40	ÇKP	0,7	0,1	t
HALKB	İVAY	0,605	mRMR	45	ÇKP	0,3	0,7	o
HALKB	İVAY	0,593	RFESVM	45	ÇKP	0,1	0,9	o
HALKB	İY	0,589	RFESVM	21	ÇKP	0,3	0,5	a
HALKB	İY	0,58	RFESVM	20	ÇKP	0,1	0,1	i
HALKB	İVAY	0,575	RFESVM	45	ÇKP	0,9	0,1	o
HALKB	İY	0,574	RFESVM	10	ÇKP	0,1	0,3	a
HALKB	İVAY	0,572	mRMR	40	ÇKP	0,9	0,7	t
HALKB	İY	0,57	RFESVM	10	ÇKP	0,1	0,1	a
HALKB	İY	0,567	RFESVM	24	ÇKP	0,1	0,5	t
HALKB	İY	0,565	RFESVM	21	ÇKP	0,1	0,7	i
HALKB	İVAY	0,561	mRMR	40	ÇKP	0,5	0,7	i
HALKB	İVAY	0,561	RFESVM	45	ÇKP	0,7	0,3	i
HALKB	İVAY	0,56	mRMR	45	ÇKP	0,3	0,3	i
HALKB	İVAY	0,56	RFESVM	45	ÇKP	0,3	0,9	i
HALKB	İY	0,558	RFESVM	13	ÇKP	0,1	0,3	t
HALKB	İY	0,558	RFESVM	24	ÇKP	0,3	0,3	o
HALKB	İVAY	0,541	mRMR	45	ÇKP	0,1	0,7	i
HALKB	İY	0,539	RFESVM	19	ÇKP	0,9	0,1	a
HALKB	İVAY	0,538	mRMR	45	ÇKP	0,1	0,3	a
HALKB	İY	0,536	RFESVM	18	ÇKP	0,1	0,3	i
HALKB	İY	0,511	RFESVM	19	ÇKP	0,1	0,3	i
HALKB	İY	0,503	RFESVM	24	ÇKP	0,5	0,1	a
HALKB	İY	0,491	RFESVM	17	ÇKP	0,1	0,3	i
HALKB	İY	0,436	RFESVM	19	ÇKP	0,1	0,5	a

Çizelge C.14 : ISCTR hissesi için en başarılı 40 tahmin modeli.

Hisse	Yaklaşım	Makro-ortalama F-Ölçütü	ÖSA	En iyi N Öznitelik	Sınıf-landı-rıcı	Ö K	MOM	S K
ISCTR	İVAY	0,562	RFESVM	40	ÇKP	0,7	0,5	i
ISCTR	İY	0,555	mRMR	33	ÇKP	0,7	0,3	t
ISCTR	İY	0,555	RFESVM	33	ÇKP	0,7	0,3	t
ISCTR	İVAY	0,547	mRMR	40	ÇKP	0,9	0,3	t
ISCTR	İVAY	0,546	RFESVM	45	ÇKP	0,3	0,1	i
ISCTR	İY	0,545	RFESVM	22	ÇKP	0,3	0,7	i
ISCTR	İY	0,541	mRMR	23	ÇKP	0,9	0,3	i
ISCTR	İY	0,541	RFESVM	18	ÇKP	0,1	0,3	t
ISCTR	İVAY	0,533	RFESVM	40	ÇKP	0,5	0,1	t
ISCTR	İVAY	0,532	RFESVM	40	ÇKP	0,9	0,1	o
ISCTR	İY	0,528	mRMR	30	ÇKP	0,1	0,5	i
ISCTR	İY	0,526	mRMR	25	ÇKP	0,1	0,5	t
ISCTR	İY	0,525	RFESVM	22	ÇKP	0,7	0,1	i
ISCTR	İY	0,523	RFESVM	15	ÇKP	0,7	0,1	a
ISCTR	İVAY	0,522	mRMR	40	ÇKP	0,1	0,9	a
ISCTR	İVAY	0,519	mRMR	40	ÇKP	0,9	0,3	i
ISCTR	İVAY	0,516	mRMR	35	ÇKP	0,3	0,5	t
ISCTR	İVAY	0,514	mRMR	40	ÇKP	0,5	0,7	a
ISCTR	İVAY	0,512	mRMR	35	ÇKP	0,5	0,1	t
ISCTR	İY	0,511	RFESVM	22	ÇKP	0,7	0,5	t
ISCTR	İVAY	0,507	mRMR	35	ÇKP	0,1	0,9	a
ISCTR	İY	0,504	RFESVM	16	ÇKP	0,3	0,5	i
ISCTR	İY	0,504	RFESVM	16	ÇKP	0,7	0,1	t
ISCTR	İVAY	0,503	RFESVM	40	ÇKP	0,7	0,3	i
ISCTR	İY	0,503	RFESVM	25	ÇKP	0,3	0,5	t
ISCTR	İVAY	0,503	RFESVM	45	ÇKP	0,3	0,7	i
ISCTR	İVAY	0,5	RFESVM	40	ÇKP	0,3	0,1	t
ISCTR	İY	0,498	RFESVM	23	ÇKP	0,3	0,3	i
ISCTR	İVAY	0,498	mRMR	40	ÇKP	0,9	0,5	a
ISCTR	İVAY	0,496	RFESVM	40	ÇKP	0,9	0,5	a
ISCTR	İY	0,492	mRMR	30	ÇKP	0,9	0,7	t
ISCTR	İVAY	0,49	RFESVM	40	ÇKP	0,1	0,5	t
ISCTR	İY	0,489	mRMR	33	ÇKP	0,9	0,5	t
ISCTR	İY	0,489	RFESVM	33	ÇKP	0,9	0,5	t
ISCTR	İY	0,486	mRMR	21	ÇKP	0,5	0,7	t
ISCTR	İVAY	0,482	RFESVM	40	ÇKP	0,7	0,5	t
ISCTR	İY	0,48	RFESVM	30	ÇKP	0,3	0,7	a
ISCTR	İVAY	0,479	mRMR	35	ÇKP	0,9	0,1	i
ISCTR	İVAY	0,475	mRMR	35	ÇKP	0,5	0,3	i
ISCTR	İY	0,47	RFESVM	24	ÇKP	0,9	0,5	t

Çizelge C.15 : KLNMA hissesi için en başarılı 40 tahmin modeli.

Hisse	Yaklaşım	Makro-ortalama F-Ölçütü	ÖSA	En iyi N Öznitelik	Sınıf-landı-rıcı	Ö K	MOM	S K
KLNMA	İY	0,333	RFESVM	23	ÇKP	0,9	0,7	a
KLNMA	İVAY	0,333	mRMR	35	ÇKP	0,1	0,9	i
KLNMA	İY	0,333	mRMR	22	ÇKP	0,9	0,1	i
KLNMA	İY	0,333	mRMR	22	ÇKP	0,7	0,3	i
KLNMA	İY	0,333	mRMR	21	ÇKP	0,5	0,5	i
KLNMA	İY	0,333	RFESVM	24	ÇKP	0,3	0,5	a
KLNMA	İY	0,333	mRMR	21	ÇKP	0,7	0,7	a
KLNMA	İY	0,333	mRMR	21	ÇKP	0,5	0,9	t
KLNMA	İY	0,333	mRMR	21	ÇKP	0,9	0,5	a
KLNMA	İY	0,333	mRMR	21	ÇKP	0,7	0,5	a
KLNMA	İY	0,333	mRMR	21	ÇKP	0,5	0,7	a
KLNMA	İY	0,333	mRMR	21	ÇKP	0,3	0,3	a
KLNMA	İY	0,333	mRMR	21	ÇKP	0,7	0,3	i
KLNMA	İY	0,333	mRMR	21	ÇKP	0,7	0,9	i
KLNMA	İY	0,333	mRMR	21	ÇKP	0,3	0,7	a
KLNMA	İY	0,333	mRMR	21	ÇKP	0,9	0,3	a
KLNMA	İY	0,333	mRMR	21	ÇKP	0,7	0,3	a
KLNMA	İY	0,333	mRMR	25	ÇKP	0,1	0,7	o
KLNMA	İY	0,333	mRMR	23	ÇKP	0,5	0,7	t
KLNMA	İY	0,333	mRMR	21	ÇKP	0,5	0,5	a
KLNMA	İVAY	0,333	mRMR	35	ÇKP	0,3	0,7	i
KLNMA	İVAY	0,333	mRMR	35	ÇKP	0,3	0,5	i
KLNMA	İVAY	0,333	RFESVM	45	ÇKP	0,1	0,5	i
KLNMA	İVAY	0,333	RFESVM	35	ÇKP	0,1	0,5	a
KLNMA	İVAY	0,333	RFESVM	35	ÇKP	0,9	0,9	o
KLNMA	İVAY	0,333	RFESVM	29	ÇKP	0,9	0,9	o
KLNMA	İVAY	0,333	RFESVM	27	ÇKP	0,9	0,9	a
KLNMA	İVAY	0,333	mRMR	40	ÇKP	0,7	0,1	o
KLNMA	İVAY	0,333	mRMR	35	ÇKP	0,9	0,5	i
KLNMA	İVAY	0,333	mRMR	35	ÇKP	0,9	0,3	i
KLNMA	İVAY	0,333	mRMR	35	ÇKP	0,9	0,1	i
KLNMA	İVAY	0,333	mRMR	35	ÇKP	0,5	0,7	o
KLNMA	İVAY	0,333	mRMR	35	ÇKP	0,5	0,7	i
KLNMA	İVAY	0,333	mRMR	35	ÇKP	0,5	0,3	i
KLNMA	İVAY	0,333	mRMR	35	ÇKP	0,7	0,3	i
KLNMA	İVAY	0,333	mRMR	35	ÇKP	0,5	0,5	i
KLNMA	İVAY	0,333	mRMR	35	ÇKP	0,7	0,1	i
KLNMA	İVAY	0,333	mRMR	35	ÇKP	0,7	0,5	i
KLNMA	İVAY	0,333	mRMR	35	ÇKP	0,5	0,1	i
KLNMA	İY	0,333	mRMR	23	ÇKP	0,9	0,3	t

Çizelge C.16 : KRONT hissesi için en başarılı 40 tahmin modeli.

Hisse	Yaklaşım	Makro-ortalama F-Ölçütü	ÖSA	En iyi N Öznitelik	Sınıf-landı-rıcı	Ö K	MOM	S K
KRONT	İY	0,596	RFESVM	30	ÇKP	0,1	0,3	a
KRONT	İY	0,583	RFESVM	20	ÇKP	0,5	0,7	t
KRONT	İY	0,573	RFESVM	30	ÇKP	0,9	0,3	t
KRONT	İY	0,563	RFESVM	19	ÇKP	0,7	0,5	o
KRONT	İY	0,555	RFESVM	16	ÇKP	0,1	0,3	o
KRONT	İY	0,554	RFESVM	20	ÇKP	0,9	0,3	t
KRONT	İVAY	0,551	mRMR	40	ÇKP	0,3	0,9	a
KRONT	İY	0,545	RFESVM	19	ÇKP	0,1	0,5	a
KRONT	İVAY	0,545	RFESVM	45	ÇKP	0,3	0,5	a
KRONT	İY	0,544	RFESVM	21	ÇKP	0,3	0,7	o
KRONT	İVAY	0,534	mRMR	29	ÇKP	0,5	0,7	t
KRONT	İVAY	0,532	mRMR	35	ÇKP	0,7	0,3	t
KRONT	İVAY	0,531	mRMR	27	ÇKP	0,7	0,3	i
KRONT	İY	0,529	RFESVM	20	ÇKP	0,5	0,5	t
KRONT	İY	0,528	RFESVM	18	ÇKP	0,5	0,1	t
KRONT	İY	0,525	RFESVM	16	ÇKP	0,3	0,1	a
KRONT	İY	0,518	RFESVM	18	ÇKP	0,3	0,1	t
KRONT	İY	0,515	RFESVM	20	ÇKP	0,5	0,1	o
KRONT	İVAY	0,515	mRMR	26	ÇKP	0,7	0,1	i
KRONT	İY	0,514	RFESVM	18	ÇKP	0,1	0,7	o
KRONT	İVAY	0,51	RFESVM	33	ÇKP	0,1	0,3	o
KRONT	İY	0,51	RFESVM	20	ÇKP	0,1	0,7	a
KRONT	İVAY	0,507	mRMR	35	ÇKP	0,7	0,1	o
KRONT	İVAY	0,504	mRMR	26	ÇKP	0,5	0,7	i
KRONT	İVAY	0,499	mRMR	29	ÇKP	0,1	0,5	a
KRONT	İVAY	0,495	mRMR	33	ÇKP	0,9	0,3	a
KRONT	İY	0,492	RFESVM	18	ÇKP	0,3	0,5	a
KRONT	İVAY	0,491	RFESVM	33	ÇKP	0,3	0,9	a
KRONT	İY	0,486	RFESVM	13	ÇKP	0,1	0,9	i
KRONT	İVAY	0,486	mRMR	28	ÇKP	0,7	0,7	o
KRONT	İVAY	0,485	mRMR	27	ÇKP	0,5	0,9	i
KRONT	İVAY	0,482	mRMR	30	ÇKP	0,7	0,3	o
KRONT	İVAY	0,48	mRMR	27	ÇKP	0,5	0,3	i
KRONT	İY	0,478	RFESVM	17	ÇKP	0,7	0,3	i
KRONT	İY	0,47	RFESVM	20	ÇKP	0,3	0,5	i
KRONT	İVAY	0,459	mRMR	33	ÇKP	0,3	0,9	o
KRONT	İVAY	0,452	mRMR	27	ÇKP	0,3	0,7	a
KRONT	İY	0,45	RFESVM	16	ÇKP	0,3	0,9	t
KRONT	İVAY	0,425	mRMR	26	ÇKP	0,7	0,9	o
KRONT	İVAY	0,392	mRMR	29	ÇKP	0,9	0,5	a

Çizelge C.17 : LINK hissesi için en başarılı 40 tahmin modeli.

Hisse	Yaklaşım	Makro-ortalama F-Ölçütü	ÖSA	En iyi N Öznitelik	Sınıf-landı-rıcı	ÖK	MOM	SK
LINK	İY	1	RFESVM	20	ÇKP	0,1	0,7	a
LINK	İY	1	RFESVM	23	ÇKP	0,7	0,5	i
LINK	İY	1	RFESVM	20	ÇKP	0,3	0,1	a
LINK	İY	1	RFESVM	20	ÇKP	0,9	0,7	a
LINK	İY	1	RFESVM	24	ÇKP	0,5	0,3	a
LINK	İY	1	RFESVM	22	ÇKP	0,5	0,3	a
LINK	İY	0,889	mRMR	25	ÇKP	0,5	0,5	o
LINK	İY	0,889	mRMR	25	ÇKP	0,3	0,7	o
LINK	İY	0,889	RFESVM	13	ÇKP	0,1	0,3	a
LINK	İY	0,889	mRMR	25	ÇKP	0,7	0,3	o
LINK	İY	0,889	mRMR	18	ÇKP	0,7	0,1	o
LINK	İY	0,889	mRMR	18	ÇKP	0,7	0,7	o
LINK	İVAY	0,666	mRMR	30	ÇKP	0,5	0,3	o
LINK	İY	0,556	RFESVM	24	ÇKP	0,7	0,1	a
LINK	İY	0,556	mRMR	25	ÇKP	0,5	0,5	t
LINK	İY	0,555	mRMR	24	ÇKP	0,1	0,1	t
LINK	İY	0,555	mRMR	24	ÇKP	0,1	0,1	i
LINK	İY	0,555	mRMR	24	ÇKP	0,1	0,1	a
LINK	İY	0,555	mRMR	16	ÇKP	0,7	0,3	o
LINK	İY	0,555	mRMR	16	ÇKP	0,9	0,1	o
LINK	İY	0,5	mRMR	18	ÇKP	0,1	0,1	a
LINK	İVAY	0,5	RFESVM	40	ÇKP	0,7	0,3	o
LINK	İVAY	0,333	RFESVM	45	ÇKP	0,1	0,7	a
LINK	İVAY	0,333	mRMR	40	ÇKP	0,1	0,1	a
LINK	İVAY	0,333	RFESVM	45	ÇKP	0,5	0,3	a
LINK	İVAY	0,333	RFESVM	45	ÇKP	0,7	0,1	a
LINK	İVAY	0,333	RFESVM	45	ÇKP	0,1	0,3	a
LINK	İVAY	0,333	RFESVM	40	ÇKP	0,1	0,5	a
LINK	İVAY	0,333	RFESVM	40	ÇKP	0,1	0,7	t
LINK	İVAY	0,333	RFESVM	40	ÇKP	0,1	0,3	a
LINK	İVAY	0,333	RFESVM	40	ÇKP	0,1	0,3	t
LINK	İVAY	0,333	RFESVM	40	ÇKP	0,1	0,5	t
LINK	İVAY	0,333	RFESVM	40	ÇKP	0,1	0,1	t
LINK	İVAY	0,333	RFESVM	40	ÇKP	0,1	0,1	a
LINK	İVAY	0,333	mRMR	45	ÇKP	0,1	0,7	a
LINK	İVAY	0,333	mRMR	45	ÇKP	0,3	0,1	a
LINK	İVAY	0,333	mRMR	45	ÇKP	0,1	0,3	a
LINK	İVAY	0,333	mRMR	45	ÇKP	0,1	0,5	a
LINK	İVAY	0,333	mRMR	40	ÇKP	0,1	0,5	a
LINK	İVAY	0,333	RFESVM	45	ÇKP	0,1	0,7	i

Çizelge C.18 : LOGO hissesi için en başarılı 40 tahmin modeli.

Hisse	Yaklaşım	Makro-ortalama F-Ölçütü	ÖSA	En iyi N Öznitelik	Sınıf-landı-rıcı	Ö K	MOM	S K
LOGO	İY	0,499	RFESVM	5	ÇKP	0,5	0,9	o
LOGO	İY	0,499	RFESVM	5	ÇKP	0,5	0,7	o
LOGO	İY	0,427	RFESVM	5	ÇKP	0,9	0,7	o
LOGO	İVAY	0,408	RFESVM	27	ÇKP	0,3	0,1	i
LOGO	İVAY	0,408	RFESVM	27	ÇKP	0,1	0,7	i
LOGO	İY	0,4	RFESVM	15	ÇKP	0,1	0,7	t
LOGO	İVAY	0,386	RFESVM	28	ÇKP	0,1	0,7	o
LOGO	İY	0,385	RFESVM	10	ÇKP	0,9	0,5	i
LOGO	İVAY	0,384	RFESVM	28	ÇKP	0,3	0,1	o
LOGO	İY	0,38	RFESVM	13	ÇKP	0,5	0,5	t
LOGO	İY	0,379	RFESVM	10	ÇKP	0,9	0,3	t
LOGO	İY	0,379	RFESVM	10	ÇKP	0,5	0,3	i
LOGO	İY	0,377	RFESVM	10	ÇKP	0,3	0,9	t
LOGO	İY	0,376	RFESVM	13	ÇKP	0,9	0,3	t
LOGO	İY	0,376	RFESVM	13	ÇKP	0,7	0,3	t
LOGO	İY	0,372	RFESVM	13	ÇKP	0,9	0,1	t
LOGO	İY	0,371	RFESVM	10	ÇKP	0,7	0,5	i
LOGO	İY	0,369	RFESVM	10	ÇKP	0,9	0,3	i
LOGO	İVAY	0,366	RFESVM	26	ÇKP	0,1	0,7	i
LOGO	İVAY	0,366	RFESVM	26	ÇKP	0,3	0,1	i
LOGO	İY	0,365	RFESVM	13	ÇKP	0,7	0,5	t
LOGO	İY	0,362	RFESVM	13	ÇKP	0,9	0,3	i
LOGO	İVAY	0,362	RFESVM	25	ÇKP	0,5	0,5	o
LOGO	İVAY	0,358	RFESVM	25	ÇKP	0,7	0,1	o
LOGO	İVAY	0,357	RFESVM	25	ÇKP	0,3	0,5	o
LOGO	İVAY	0,357	RFESVM	25	ÇKP	0,7	0,3	o
LOGO	İVAY	0,357	RFESVM	25	ÇKP	0,1	0,5	o
LOGO	İVAY	0,355	RFESVM	25	ÇKP	0,3	0,3	o
LOGO	İVAY	0,355	RFESVM	25	ÇKP	0,5	0,1	o
LOGO	İVAY	0,354	RFESVM	25	ÇKP	0,5	0,3	o
LOGO	İVAY	0,354	RFESVM	25	ÇKP	0,3	0,1	o
LOGO	İVAY	0,331	RFESVM	26	ÇKP	0,3	0,3	o
LOGO	İY	0,331	RFESVM	13	ÇKP	0,1	0,3	t
LOGO	İY	0,331	RFESVM	7	ÇKP	0,9	0,9	a
LOGO	İY	0,331	RFESVM	5	ÇKP	0,3	0,3	o
LOGO	İY	0,331	RFESVM	5	ÇKP	0,1	0,5	o
LOGO	İVAY	0,331	mRMR	25	ÇKP	0,9	0,9	a
LOGO	İVAY	0,33	RFESVM	25	ÇKP	0,9	0,1	o
LOGO	İVAY	0,329	RFESVM	25	ÇKP	0,1	0,9	o
LOGO	İVAY	0,329	RFESVM	25	ÇKP	0,3	0,7	o

Çizelge C.19 : NETAS hissesi için en başarılı 40 tahmin modeli.

Hisse	Yaklaşım	Makro-ortalama F-Ölçütü	ÖSA	En iyi N Öznitelik	Sınıf-landı-rıcı	Ö K	MOM	S K
NETAS	İY	0,722	RFESVM	30	ÇKP	0,5	0,7	t
NETAS	İY	0,65	RFESVM	23	ÇKP	0,5	0,9	i
NETAS	İY	0,65	RFESVM	25	ÇKP	0,3	0,3	i
NETAS	İY	0,638	RFESVM	22	ÇKP	0,7	0,3	t
NETAS	İY	0,638	RFESVM	23	ÇKP	0,7	0,7	i
NETAS	İY	0,638	RFESVM	24	ÇKP	0,9	0,5	t
NETAS	İY	0,638	RFESVM	22	ÇKP	0,9	0,1	t
NETAS	İY	0,638	RFESVM	22	ÇKP	0,5	0,5	t
NETAS	İY	0,638	RFESVM	22	ÇKP	0,3	0,7	t
NETAS	İY	0,554	RFESVM	33	ÇKP	0,9	0,9	a
NETAS	İVAY	0,499	mRMR	45	ÇKP	0,3	0,5	t
NETAS	İY	0,499	RFESVM	25	ÇKP	0,5	0,1	a
NETAS	İVAY	0,499	mRMR	28	ÇKP	0,7	0,9	t
NETAS	İY	0,499	RFESVM	25	ÇKP	0,3	0,5	a
NETAS	İVAY	0,499	RFESVM	35	ÇKP	0,5	0,7	i
NETAS	İVAY	0,499	RFESVM	45	ÇKP	0,7	0,1	i
NETAS	İVAY	0,499	RFESVM	40	ÇKP	0,7	0,9	i
NETAS	İVAY	0,499	RFESVM	45	ÇKP	0,5	0,3	i
NETAS	İVAY	0,48	mRMR	45	ÇKP	0,5	0,3	t
NETAS	İVAY	0,48	mRMR	45	ÇKP	0,1	0,1	a
NETAS	İVAY	0,48	mRMR	45	ÇKP	0,3	0,1	t
NETAS	İVAY	0,48	mRMR	45	ÇKP	0,1	0,5	a
NETAS	İVAY	0,48	mRMR	45	ÇKP	0,7	0,1	t
NETAS	İVAY	0,48	mRMR	45	ÇKP	0,1	0,3	a
NETAS	İVAY	0,48	mRMR	45	ÇKP	0,3	0,3	t
NETAS	İVAY	0,48	mRMR	45	ÇKP	0,1	0,7	t
NETAS	İY	0,443	RFESVM	25	ÇKP	0,9	0,9	o
NETAS	İVAY	0,443	RFESVM	45	ÇKP	0,9	0,9	o
NETAS	İVAY	0,443	RFESVM	29	ÇKP	0,9	0,9	i
NETAS	İY	0,428	RFESVM	25	ÇKP	0,7	0,7	a
NETAS	İY	0,427	RFESVM	25	ÇKP	0,1	0,9	a
NETAS	İY	0,427	RFESVM	25	ÇKP	0,7	0,3	a
NETAS	İVAY	0,427	RFESVM	35	ÇKP	0,9	0,9	a
NETAS	İY	0,427	RFESVM	20	ÇKP	0,9	0,9	a
NETAS	İVAY	0,427	RFESVM	40	ÇKP	0,1	0,1	a
NETAS	İY	0,427	RFESVM	23	ÇKP	0,9	0,9	i
NETAS	İY	0,416	RFESVM	33	ÇKP	0,9	0,9	o
NETAS	İY	0,415	RFESVM	24	ÇKP	0,7	0,7	t
NETAS	İVAY	0,415	RFESVM	45	ÇKP	0,1	0,7	a
NETAS	İVAY	0,332	mRMR	28	ÇKP	0,9	0,9	t

Çizelge C.20 : SKBNK hissesi için en başarılı 40 tahmin modeli.

Hisse	Yaklaşım	Makro-ortalama F-Ölçütü	ÖSA	En iyi N Öznitelik	Sınıf-landı-rıcı	Ö K	MOM	S K
SKBNK	İY	0,777	RFESVM	13	ÇKP	0,9	0,5	t
SKBNK	İVAY	0,773	RFESVM	25	ÇKP	0,7	0,3	i
SKBNK	İVAY	0,773	RFESVM	25	ÇKP	0,5	0,5	i
SKBNK	İVAY	0,745	RFESVM	25	ÇKP	0,7	0,5	i
SKBNK	İVAY	0,722	RFESVM	20	ÇKP	0,1	0,7	i
SKBNK	İVAY	0,722	RFESVM	20	ÇKP	0,3	0,1	i
SKBNK	İY	0,721	RFESVM	10	ÇKP	0,7	0,5	t
SKBNK	İY	0,714	RFESVM	19	ÇKP	0,7	0,5	o
SKBNK	İY	0,703	RFESVM	7	ÇKP	0,7	0,5	i
SKBNK	İVAY	0,694	mRMR	45	ÇKP	0,3	0,9	i
SKBNK	İY	0,69	RFESVM	13	ÇKP	0,1	0,3	i
SKBNK	İY	0,69	RFESVM	23	ÇKP	0,9	0,7	t
SKBNK	İY	0,69	RFESVM	13	ÇKP	0,1	0,7	t
SKBNK	İY	0,666	RFESVM	17	ÇKP	0,7	0,9	o
SKBNK	İY	0,656	RFESVM	23	ÇKP	0,9	0,3	o
SKBNK	İY	0,656	RFESVM	18	ÇKP	0,9	0,3	o
SKBNK	İVAY	0,656	RFESVM	25	ÇKP	0,5	0,9	o
SKBNK	İVAY	0,634	mRMR	26	ÇKP	0,5	0,3	i
SKBNK	İVAY	0,634	mRMR	26	ÇKP	0,5	0,5	i
SKBNK	İVAY	0,634	mRMR	26	ÇKP	0,7	0,1	i
SKBNK	İVAY	0,633	RFESVM	20	ÇKP	0,3	0,5	i
SKBNK	İY	0,632	RFESVM	10	ÇKP	0,5	0,3	o
SKBNK	İY	0,632	RFESVM	10	ÇKP	0,7	0,1	o
SKBNK	İY	0,632	RFESVM	24	ÇKP	0,7	0,1	o
SKBNK	İY	0,632	RFESVM	19	ÇKP	0,7	0,9	o
SKBNK	İVAY	0,632	RFESVM	20	ÇKP	0,3	0,1	o
SKBNK	İVAY	0,613	mRMR	40	ÇKP	0,3	0,7	o
SKBNK	İY	0,61	RFESVM	13	ÇKP	0,7	0,3	o
SKBNK	İVAY	0,61	mRMR	26	ÇKP	0,5	0,1	i
SKBNK	İY	0,595	RFESVM	21	ÇKP	0,3	0,3	t
SKBNK	İVAY	0,594	mRMR	26	ÇKP	0,9	0,3	a
SKBNK	İVAY	0,561	RFESVM	35	ÇKP	0,5	0,5	o
SKBNK	İVAY	0,554	mRMR	35	ÇKP	0,5	0,5	o
SKBNK	İVAY	0,548	RFESVM	29	ÇKP	0,7	0,7	o
SKBNK	İVAY	0,538	mRMR	26	ÇKP	0,5	0,5	a
SKBNK	İY	0,523	RFESVM	10	ÇKP	0,7	0,7	a
SKBNK	İY	0,523	RFESVM	10	ÇKP	0,5	0,9	a
SKBNK	İVAY	0,523	RFESVM	26	ÇKP	0,7	0,9	o
SKBNK	İY	0,514	RFESVM	5	ÇKP	0,7	0,3	t
SKBNK	İY	0,466	RFESVM	10	ÇKP	0,1	0,9	o

Çizelge C.21 : TCELL hissesi için en başarılı 40 tahmin modeli.

Hisse	Yaklaşım	Makro-ortalama F-Ölçütü	ÖSA	En iyi N Öznitelik	Sınıf-landı-rıcı	Ö K	MOM	S K
TCELL	İY	0,691	mRMR	22	ÇKP	0,9	0,3	o
TCELL	İY	0,662	mRMR	19	ÇKP	0,5	0,7	o
TCELL	İVAY	0,651	mRMR	33	ÇKP	0,7	0,3	o
TCELL	İVAY	0,643	RFESVM	33	ÇKP	0,1	0,1	o
TCELL	İVAY	0,637	RFESVM	33	ÇKP	0,1	0,3	o
TCELL	İVAY	0,637	RFESVM	35	ÇKP	0,3	0,3	o
TCELL	İVAY	0,631	RFESVM	35	ÇKP	0,1	0,3	o
TCELL	İY	0,621	RFESVM	5	ÇKP	0,1	0,5	o
TCELL	İY	0,621	RFESVM	5	ÇKP	0,1	0,3	o
TCELL	İY	0,611	RFESVM	17	ÇKP	0,9	0,5	o
TCELL	İVAY	0,607	RFESVM	35	ÇKP	0,1	0,5	o
TCELL	İVAY	0,605	RFESVM	30	ÇKP	0,1	0,1	o
TCELL	İY	0,6	mRMR	21	ÇKP	0,1	0,7	o
TCELL	İVAY	0,591	mRMR	33	ÇKP	0,9	0,7	o
TCELL	İVAY	0,582	mRMR	35	ÇKP	0,5	0,3	o
TCELL	İVAY	0,582	RFESVM	35	ÇKP	0,7	0,7	o
TCELL	İY	0,579	RFESVM	17	ÇKP	0,3	0,7	o
TCELL	İY	0,578	RFESVM	17	ÇKP	0,7	0,3	o
TCELL	İY	0,578	RFESVM	17	ÇKP	0,5	0,5	o
TCELL	İVAY	0,575	RFESVM	26	ÇKP	0,5	0,7	o
TCELL	İY	0,575	RFESVM	16	ÇKP	0,9	0,1	o
TCELL	İVAY	0,569	RFESVM	35	ÇKP	0,5	0,5	o
TCELL	İY	0,568	mRMR	21	ÇKP	0,7	0,3	o
TCELL	İVAY	0,566	RFESVM	35	ÇKP	0,1	0,9	o
TCELL	İVAY	0,564	RFESVM	20	ÇKP	0,3	0,7	o
TCELL	İY	0,554	RFESVM	18	ÇKP	0,7	0,1	o
TCELL	İY	0,551	RFESVM	30	ÇKP	0,9	0,3	o
TCELL	İY	0,548	RFESVM	16	ÇKP	0,7	0,3	o
TCELL	İY	0,548	RFESVM	16	ÇKP	0,5	0,5	o
TCELL	İY	0,545	RFESVM	18	ÇKP	0,3	0,7	o
TCELL	İVAY	0,535	mRMR	33	ÇKP	0,3	0,9	a
TCELL	İY	0,533	RFESVM	5	ÇKP	0,5	0,9	a
TCELL	İVAY	0,531	RFESVM	35	ÇKP	0,9	0,1	o
TCELL	İVAY	0,531	RFESVM	30	ÇKP	0,1	0,5	i
TCELL	İY	0,527	mRMR	21	ÇKP	0,5	0,1	o
TCELL	İVAY	0,523	RFESVM	29	ÇKP	0,5	0,5	o
TCELL	İY	0,516	mRMR	22	ÇKP	0,9	0,1	o
TCELL	İVAY	0,496	RFESVM	28	ÇKP	0,5	0,5	o
TCELL	İVAY	0,455	RFESVM	27	ÇKP	0,9	0,3	o
TCELL	İY	0,444	mRMR	18	ÇKP	0,9	0,3	o

Çizelge C.22 : TEBNK hissesi için en başarılı 40 tahmin modeli.

Hisse	Yaklaşım	Makro-ortalama F-Ölçütü	ÖSA	En iyi N Öznitelik	Sınıf-landı-rıcı	Ö K	MOM	S K
TEBNK	İY	0,952	RFESVM	24	ÇKP	0,7	0,1	t
TEBNK	İY	0,933	RFESVM	30	ÇKP	0,5	0,7	i
TEBNK	İY	0,888	RFESVM	18	ÇKP	0,1	0,3	t
TEBNK	İVAY	0,833	mRMR	40	ÇKP	0,1	0,5	i
TEBNK	İVAY	0,833	mRMR	40	ÇKP	0,1	0,7	i
TEBNK	İVAY	0,833	mRMR	33	ÇKP	0,1	0,1	i
TEBNK	İVAY	0,833	mRMR	40	ÇKP	0,5	0,3	i
TEBNK	İVAY	0,833	mRMR	40	ÇKP	0,3	0,3	i
TEBNK	İVAY	0,833	mRMR	40	ÇKP	0,9	0,3	i
TEBNK	İVAY	0,799	mRMR	40	ÇKP	0,1	0,7	t
TEBNK	İVAY	0,799	mRMR	40	ÇKP	0,3	0,1	t
TEBNK	İY	0,777	RFESVM	17	ÇKP	0,5	0,9	t
TEBNK	İVAY	0,666	mRMR	45	ÇKP	0,3	0,1	t
TEBNK	İVAY	0,666	mRMR	45	ÇKP	0,1	0,7	t
TEBNK	İVAY	0,666	mRMR	45	ÇKP	0,1	0,9	i
TEBNK	İVAY	0,666	RFESVM	45	ÇKP	0,3	0,3	i
TEBNK	İVAY	0,666	mRMR	35	ÇKP	0,7	0,1	i
TEBNK	İVAY	0,666	RFESVM	45	ÇKP	0,5	0,3	t
TEBNK	İY	0,6	RFESVM	30	ÇKP	0,3	0,5	a
TEBNK	İVAY	0,555	mRMR	19	ÇKP	0,9	0,5	o
TEBNK	İVAY	0,555	mRMR	16	ÇKP	0,3	0,5	t
TEBNK	İY	0,555	RFESVM	24	ÇKP	0,9	0,1	a
TEBNK	İY	0,555	RFESVM	10	ÇKP	0,7	0,3	a
TEBNK	İY	0,555	RFESVM	10	ÇKP	0,9	0,1	a
TEBNK	İY	0,555	RFESVM	18	ÇKP	0,7	0,5	t
TEBNK	İVAY	0,523	mRMR	16	ÇKP	0,5	0,1	t
TEBNK	İY	0,499	RFESVM	30	ÇKP	0,3	0,1	t
TEBNK	İY	0,466	mRMR	20	ÇKP	0,3	0,7	a
TEBNK	İVAY	0,466	mRMR	35	ÇKP	0,3	0,5	i
TEBNK	İY	0,444	mRMR	19	ÇKP	0,1	0,5	a
TEBNK	İY	0,444	mRMR	25	ÇKP	0,7	0,5	i
TEBNK	İY	0,333	RFESVM	33	ÇKP	0,7	0,7	a
TEBNK	İVAY	0,333	RFESVM	45	ÇKP	0,1	0,7	t
TEBNK	İVAY	0,333	mRMR	45	ÇKP	0,3	0,1	i
TEBNK	İY	0,333	mRMR	33	ÇKP	0,7	0,7	a
TEBNK	İY	0,332	mRMR	33	ÇKP	0,1	0,9	i
TEBNK	İY	0,332	mRMR	30	ÇKP	0,1	0,9	i
TEBNK	İY	0,332	RFESVM	33	ÇKP	0,9	0,3	a
TEBNK	İY	0,332	mRMR	33	ÇKP	0,9	0,3	a
TEBNK	İY	0,332	RFESVM	21	ÇKP	0,9	0,7	a

Çizelge C.23 : TTKOM hissesi için en başarılı 40 tahmin modeli.

Hisse	Yaklaşım	Makro-ortalama F-Ölçütü	ÖSA	En iyi N Öznitelik	Sınıf-landı-rıcı	Ö K	MOM	S K
TTKOM	İY	0,66	RFESVM	15	ÇKP	0,1	0,1	a
TTKOM	İY	0,646	RFESVM	18	ÇKP	0,3	0,7	o
TTKOM	İY	0,646	RFESVM	17	ÇKP	0,3	0,5	a
TTKOM	İY	0,636	RFESVM	20	ÇKP	0,1	0,7	a
TTKOM	İY	0,635	RFESVM	23	ÇKP	0,7	0,5	o
TTKOM	İY	0,63	RFESVM	23	ÇKP	0,1	0,5	o
TTKOM	İVAY	0,628	RFESVM	45	ÇKP	0,3	0,3	i
TTKOM	İY	0,627	RFESVM	18	ÇKP	0,7	0,1	o
TTKOM	İY	0,623	RFESVM	17	ÇKP	0,9	0,5	t
TTKOM	İY	0,617	RFESVM	19	ÇKP	0,1	0,9	o
TTKOM	İY	0,612	RFESVM	19	ÇKP	0,3	0,7	o
TTKOM	İVAY	0,612	RFESVM	45	ÇKP	0,7	0,1	i
TTKOM	İY	0,61	RFESVM	22	ÇKP	0,1	0,3	i
TTKOM	İY	0,609	mRMR	30	ÇKP	0,1	0,5	t
TTKOM	İY	0,609	RFESVM	24	ÇKP	0,1	0,5	i
TTKOM	İY	0,609	RFESVM	19	ÇKP	0,5	0,5	o
TTKOM	İY	0,606	RFESVM	25	ÇKP	0,7	0,7	t
TTKOM	İY	0,604	RFESVM	16	ÇKP	0,5	0,7	o
TTKOM	İY	0,604	mRMR	24	ÇKP	0,1	0,5	i
TTKOM	İVAY	0,603	mRMR	40	ÇKP	0,5	0,7	a
TTKOM	İVAY	0,601	RFESVM	40	ÇKP	0,1	0,3	o
TTKOM	İY	0,6	RFESVM	19	ÇKP	0,9	0,1	o
TTKOM	İY	0,599	RFESVM	22	ÇKP	0,1	0,9	o
TTKOM	İY	0,596	RFESVM	15	ÇKP	0,3	0,7	t
TTKOM	İVAY	0,592	mRMR	35	ÇKP	0,1	0,3	a
TTKOM	İVAY	0,589	mRMR	45	ÇKP	0,9	0,3	i
TTKOM	İVAY	0,58	mRMR	35	ÇKP	0,5	0,1	a
TTKOM	İVAY	0,58	mRMR	35	ÇKP	0,9	0,3	t
TTKOM	İVAY	0,572	RFESVM	45	ÇKP	0,9	0,1	t
TTKOM	İVAY	0,562	RFESVM	45	ÇKP	0,5	0,3	a
TTKOM	İVAY	0,56	mRMR	35	ÇKP	0,3	0,1	o
TTKOM	İVAY	0,554	RFESVM	45	ÇKP	0,9	0,7	o
TTKOM	İVAY	0,554	RFESVM	45	ÇKP	0,7	0,7	o
TTKOM	İVAY	0,553	mRMR	35	ÇKP	0,7	0,3	i
TTKOM	İVAY	0,55	mRMR	40	ÇKP	0,7	0,7	a
TTKOM	İVAY	0,545	mRMR	33	ÇKP	0,1	0,7	o
TTKOM	İVAY	0,542	mRMR	33	ÇKP	0,3	0,1	a
TTKOM	İVAY	0,529	RFESVM	45	ÇKP	0,1	0,7	a
TTKOM	İVAY	0,515	RFESVM	45	ÇKP	0,7	0,5	a
TTKOM	İVAY	0,482	mRMR	33	ÇKP	0,5	0,1	o

Çizelge C.24 : VAKBN hissesi için en başarılı 40 tahmin modeli.

Hisse	Yaklaşım	Makro-ortalama F-Ölçütü	ÖSA	En iyi N Öznitelik	Sınıf-landı-rıcı	Ö K	MOM	S K
VAKBN	İY	0,729	RFESVM	16	ÇKP	0,3	0,7	t
VAKBN	İVAY	0,697	mRMR	28	ÇKP	0,1	0,1	i
VAKBN	İY	0,678	RFESVM	17	ÇKP	0,1	0,5	i
VAKBN	İVAY	0,675	RFESVM	40	ÇKP	0,7	0,5	i
VAKBN	İVAY	0,663	RFESVM	40	ÇKP	0,3	0,7	t
VAKBN	İY	0,661	RFESVM	7	ÇKP	0,1	0,9	i
VAKBN	İY	0,661	RFESVM	7	ÇKP	0,9	0,1	i
VAKBN	İY	0,658	RFESVM	17	ÇKP	0,1	0,5	t
VAKBN	İY	0,658	RFESVM	25	ÇKP	0,5	0,7	i
VAKBN	İY	0,655	RFESVM	19	ÇKP	0,3	0,1	t
VAKBN	İVAY	0,652	RFESVM	40	ÇKP	0,3	0,1	t
VAKBN	İY	0,647	RFESVM	20	ÇKP	0,9	0,3	a
VAKBN	İVAY	0,644	RFESVM	40	ÇKP	0,5	0,1	i
VAKBN	İY	0,641	mRMR	18	ÇKP	0,1	0,3	i
VAKBN	İY	0,639	RFESVM	7	ÇKP	0,7	0,3	i
VAKBN	İY	0,635	mRMR	16	ÇKP	0,9	0,3	a
VAKBN	İY	0,632	RFESVM	7	ÇKP	0,5	0,5	i
VAKBN	İY	0,629	mRMR	17	ÇKP	0,5	0,5	i
VAKBN	İY	0,615	mRMR	15	ÇKP	0,9	0,5	i
VAKBN	İVAY	0,614	mRMR	28	ÇKP	0,7	0,7	i
VAKBN	İY	0,608	RFESVM	18	ÇKP	0,7	0,1	t
VAKBN	İVAY	0,602	RFESVM	35	ÇKP	0,1	0,5	a
VAKBN	İVAY	0,599	RFESVM	45	ÇKP	0,7	0,1	t
VAKBN	İVAY	0,595	mRMR	30	ÇKP	0,7	0,3	t
VAKBN	İVAY	0,591	mRMR	45	ÇKP	0,7	0,7	a
VAKBN	İVAY	0,579	mRMR	45	ÇKP	0,9	0,5	t
VAKBN	İY	0,574	RFESVM	7	ÇKP	0,3	0,7	i
VAKBN	İVAY	0,556	mRMR	35	ÇKP	0,9	0,7	t
VAKBN	İVAY	0,553	mRMR	28	ÇKP	0,9	0,5	i
VAKBN	İVAY	0,541	mRMR	45	ÇKP	0,3	0,9	i
VAKBN	İVAY	0,537	mRMR	33	ÇKP	0,1	0,3	t
VAKBN	İVAY	0,536	RFESVM	40	ÇKP	0,1	0,3	t
VAKBN	İY	0,53	RFESVM	10	ÇKP	0,5	0,5	a
VAKBN	İVAY	0,53	RFESVM	45	ÇKP	0,5	0,9	o
VAKBN	İY	0,527	RFESVM	15	ÇKP	0,9	0,3	t
VAKBN	İY	0,511	RFESVM	19	ÇKP	0,7	0,3	i
VAKBN	İVAY	0,507	mRMR	45	ÇKP	0,3	0,5	t
VAKBN	İY	0,503	RFESVM	20	ÇKP	0,5	0,7	i
VAKBN	İVAY	0,484	RFESVM	45	ÇKP	0,3	0,3	t
VAKBN	İVAY	0,478	mRMR	33	ÇKP	0,1	0,5	t

ÖZGEÇMİŞ



Ad Soyad: Bircan Ergür

Doğum Yeri ve Tarihi: Denizli, 05/06/1989

E-Posta: bircanergur@gmail.com

Lisans: İstanbul Teknik Üniversitesi, Bilgisayar Mühendisliği

Mesleki Deneyim ve Ödüller:

2010- … : Turkcell Teknoloji Ar-Ge A.Ş. Yazılım Geliştirme.

2013, Turkcell İnovasyon Platformu Sponsorlu Fikir Ödülü.

Yayın ve Patent Listesi:

- (Patent başvurusu) Mobil Uygulama Üzerinden SMS Kanalıyla SIM Tetikleme.
- (Patent başvurusu) Hassas Verilerin Güvenli Bir Şekilde Mobil Cihaz veya SD Kart Üzerinde Saklanmasını Sağlayan Yöntem.

TEZDEN TÜRETİLEN YAYINLAR/SUNUMLAR

- Ergür, B., Çataltepe, Z. (2013). İlişkisel Borsa Ağı Analizi. IEEE Sinyal İşleme ve İletişim Uygulamaları Konferansı, Girne, KKTC.