Hisse Senedi Fiyat Hareket Yönü Tahmininde Teknik Analiz İndikatörlerin Kullanımı

On the Use of Technical Analysis Indicators for Stock Market Price Movement Direction Prediction

Ramazan Faruk Oğuz[1], Yasin Uygun[1], Mehmet S. Aktaş[1], İshak Aykurt[2]
[1]Bilgisayar Mühendisliği Bölümü, Yıldız Teknik Üniversitesi
[2]Finnet Elektronik, Yıldız Teknik Üniversitesi Teknopark
{ramazan.faruk.oguz,yasin.uygun}@std.yildiz.edu.tr, aktas@yildiz.edu.tr, ishak.aykurt@finnet.gen.tr

***Özetçe*—Teknik indikatörler, finansal zaman serisi verisi üzerinde matematik hesaplamalar yapan algoritmalardır. Teknik analistler, farklı teknik indikatörlerin ürettiği sonuçları yorumlayarak fiyatların gösterdiği eğilimi tahmin edebilmektedirler. Teknik indikatörlerden elde edilen bilgilerin öğrenme algoritmalarında da kullanılmasıyla fiyat hareket yönünün tahmin edilmesi, üzerinde çalışılan bir konudur. Ancak hangi teknik indikatörlerin birlikte çalıştıklarında en başarılı tahmini yapabildikleri bilinmemektedir. Bu bildiride hangi teknik indikatörlerin birlikte hangi makine öğrenmesi algoritmasında kullanıldığında en başarılı tahmin yaptığı kaba kuvvet yöntemi ile indikatörlerin tüm kombinasyonları makine öğrenmesi algoritmalarına verilerek incelenmiştir. Teknik indikatörleri makine öğrenmesi algoritmalarında kullanarak finansal zaman serisi verisi üzerinde fiyat hareket yönü tahmini yapan bir karar destek sistemi sunulmuştur.**

Anahtar Kelimeler — Finansal Zaman Serisi Verisi, Teknik İndikatör, Makine Öğrenmesi, Akan Veri Madenciliği

***Abstract*—Technical indicators are algorithms that take financial time series data as input and predict price movement directions based on mathematical calculations. Technical analysts can predict the stock price trends by interpreting the results of different technical indicators. In this study, we investigate the prediction of price movement directions based on the use of technical indicators in learning algorithms. We explore the technical indicators that provide the most successful prediction when they are used together in learning algorithms. In this paper, we investigate the technical indicators that lead to the most successful price movement direction prediction. To do this, we explore all possible combinations of indicators with various machine learning algorithms. Here, a decision support system is proposed to predict price movement direction on financial time series data by using technical indicators in machine learning algorithms.**

Keywords — Financial Time Series Data, Technical Indicator, Machine Learning, Data Stream Mining

I. GİRİŞ

Finansal zaman serisi verileri üzerinde makine öğrenmesi algoritmaları kullanılarak fiyat yönü hareketi tahmini yapılmaktadır. Teknik indikatörler bu veri üzerinde matematiksel hesaplamalar yaparak fiyat yönü hakkında bilgi veren algoritmalardır. Finansal zaman serisi verisi üzerinde teknik indikatörleri makine öğrenme algoritmalarında kullanarak tahmin yapan çalışmalar bulunmaktadır.

Yaptığımız literatür taramasında; finansal zaman serisi verisi üzerinde hangi teknik indikatör gruplarının makine öğrenmesi algoritmalarında kullanıldığı zaman daha başarılı öğrenme oluşturduğunu ve buna dayalı olarak daha başarılı fiyat yönü hareketi tahmini yaptığını araştıran bir çalışmaya rastlanmamıştır. Bu eksikliği gidermek amacıyla, bu çalışma kapsamında; birlikte çalıştıklarında en başarılı tahmini yapan teknik indikatör grubunun ne olduğunu ve bunların hangi makine öğrenmesi algoritmalarında en başarılı sonuçlar verdiği araştırılmaktadır.

Bu çalışma kapsamında, veri seti olarak, BIST-100 (İstanbul Borsasında en yüksek getiri yapan 100 şirket) hisse senetleri için elde ettiğimiz finansal zaman serisi verisi kullanılmıştır. Finansal zaman serisi verisi NoSQL ortamında modellenmiştir [1]. Finansal zaman serisi verileri üzerinde teknik analiz indikatör algoritmaları gerçekleştirilmiştir. [2]. Teknik analiz indikatörleri birer öznitelik olarak makine öğrenmesi algoritmalarında kullanılmıştır. Makine öğrenmesi algoritmaları olarak; Doğrusal Regresyon (Linear Regression), Lojistik Regresyon (Logistic Regression) ve Naif Bayes (Naïve Bayes) ikili sınıflandırma algoritmaları üzerinde çalışılmıştır. Algoritmalar kullanılarak, hisse senedi fiyat hareket yönü; "yukarı" ya da "aşağı" olarak belirlenmiş ikili etiket sınıf seti üzerinden tahmin edilmiştir.

İkili sınıflandırma algoritmalarıyla kullanıldığında hangi özniteliklerin başarılı öğrenme modelleri oluşturduğu deneysel araştırma sonucunda tespit edilmiştir. Bunun yanı sıra, tespit edilen teknik indikatör grupları, akan finansal zaman serisi verisi üzerinde de çalıştırılmıştır. Akan veriden üzerinde dinamik olarak öğrenme modeli oluşturan örnek-tabanlı öğrenme algoritmaları üzerinde çalışılmış ve gerçek zamanlı fiyat hareket yönü tahmini yapan bir karar destek sistemi gerçekleştirilmiştir. Elde edilen sonuçlara göre; doğru indikatörler ikili sınıflandırma algoritmalarında tahmin edici öznitelikler olarak kullanıldığında, %70'i aşan fiyat yönü hareketi tahmini doğruluk değerlerine ulaşılabilmektedir.

Bu bildirinin 2. bölümünde daha önceden yapılmış çalışmalar anlatılmaktadır. 3. bölümde, fiyat yönü hareketi tahmini için indikatörlerin seçimi konusunda önerdiğimiz metodoloji, 4. bölümde ise önerilen metodolojinin değerlendirmesi anlatılmaktadır. 5. bölümde sonuçların geçerliliğini tehlikeye sokabilecek konular, 6. bölümde elde ettiğimiz sonuçlar ve geleceğe dönük çalışmalar özetlenmektedir.

II. LİTERATÜR TARAMASI

Literatür incelendiğinde finansal zaman serisi verisi üzerinde fiyat hareket yönü tahmini yapılırken teknik indikatörlerin özellik olarak kullanıldığı algoritmalardan yararlanıldığı görülmektedir. En çok yararlanılan yöntemler; Destek Vektör Makinesi (SVM), Geri Yayılımlı Sinir Ağı (BPNN) ve Durum Tabanlı Çıkarsama (CBR) olarak sıralanabilir [3].

Kim [4] fiyat yönünü tahmin etmek için SVM'in kullanılabilirliğini araştırmış, BPNN ve CBR ile karşılaştırmış ve SVM'in diğer iki algoritmaya göre daha iyi tahmin yaptığı sonuçlar gözlemlemiştir. Choundhry ve Garg'ın [5] çalışmasında ise SVM ile birlikte Genetik Algoritma da kullanılmış ve Genetik Algoritma ile öznitelik olarak kullanılan teknik indikatörler içerisinden seçim yapılmıştır ve bu seçimin SVM'in tahmin performansını artırdığı görülmüştür. Vaiz'in [6] çalışmasında farklı türdeki teknik indikatörler karar ağacı sınıflandırmasında kullanılmış, indikatörlerin farklı hisse senetlerinin fiyat yönü tahmin etmekteki rolleri incelenmiştir. Çalışmada karar ağacı algoritmalarının ağaç oluşturma sürecinde iyi tahminde bulunan indikatörleri koruduğu, iyi tahminde bulunmayan indikatörleri ise ağaca dahil etmediği görülmüştür. Kumar'ın [7] çalışmasında fiyat yönü hareketi tahmini için SVM, Rastgele Orman (Random Forest), En Yakın K Komşu (KNN), Naif Bayes ve Softmax algoritmalarının etkileri karşılaştırılmış ve küçük veri kümeleri için Naif Bayes'in, büyük veri kümeleri içinse Rastgele Orman algoritmasının en iyi sonuç verdiği görülmüştür. Oriani'nin [8] çalışmasında farklı teknik indikatörlerin fiyat yönü tahminine etkisi incelenmiş ve artçı (lagging) teknik indikatörler öznitelik olarak kullanıldığında daha başarılı sonuçlar elde edilmiştir. Wang'ın [9] çalışmasında Evrişimli Sinir Ağları (CNN) ile tahmin yapılmış, CNN'in oluşturduğu modelin önceki makine öğrenmesi yaklaşımlarına göre daha genelleştirilebilir ve daha bilgilendirici özellikler çıkardığı görülmüştür.

Dağıtık ortamda yerleşik ve büyük ölçekli veri yönetimi, yada web servis yönetimi üzerinde, farklı dağıtık sistem çözümleri literatürde önerilmiştir [10, 11, 12, 15, 16]. Bu çalışmada dağıtık veri işleme ve analizi için Spark platformu kullanılmaktadır. Verinin hayat döngüsünü takip etmek ve yönetmek için OPM yada PROV-O gibi provenans spesifikasyonlarını kullananan farklı çözümler sunulmaktadır [13, 14]. Bu çalışma kapsamında, zaman serisi verileri, veri işleme ve analizi için harcanan zamanı minimize edebilmek için JSON formatında modellenmektedir.

Bu araştırma kapsamında gerçekleştirdiğimiz deneysel çalışma; yukarıda belirttiğimiz araştırmalarda incelenmemiş olan 7 farklı teknik indikatör arasından hangilerinin, ikili sınıflandırma algoritmalarında kullanıldığında, daha başarılı fiyat yönü hareketi tahmini yaptığını ortaya koymaktadır.

III. METODOLOJİ: FİYAT YÖNÜ HAREKET TAHMİNİNDE TEKNİK ANALİZ İNDİAKATÖRLERİNİN ÖZNİTELİK OLARAK SEÇİMİ VE SPARK STREAMING KULLANILARAK GERÇEKELENEN PROTOTİP UYGULAMA

Bu çalışma kapsamında, fiyat yönü hareket tahmininde, literatürde henüz sınanmamış farklı teknik indikatör özellik setlerinin başarısı, deneysel araştırma yöntemi ile araştırılmaktadır. Şekil. 1.'de özellik seçimi için uyguladığımız akış şeması görülmektedir. Deneysel araştırmamız BIST Istanbul Borsası hisse senedi verileri üzerinde gerçekleştirilmiştir. Aşağıdaki bölümlerde, özellik seçimi için takip ettiğimiz metodoloji detaylı olarak verilmektedir.

A. Teknik İndikatörlerin Kullanımı ve Ön İşlemesi

Teknik İndikatör Kullanımı: MongoDB kümesinde tuttuğumuz finansal zaman serisi verileri üzerinde Basit Hareketli Ortalama (SMA), Ağırlıklı Hareketli Ortalama (WMA), Üstel Hareketli Ortalama (EMA), Hareketli Ortalamanın Yakınsama Iraksaması (MACD), Göreceli Güç Endeksi (RSI), Stokastik Osilatörü (STO) ve Williams' %R (WSR) indikatörleri gerçeklenmiştir.

Hareketli Ortalama indikatörleri (SMA, WMA, EMA) fiyatların belli bir zaman aralığında ortalamasını alarak dalgalı veriyi yumuşatır ve eğilimin daha kolay görülebilmesini sağlarlar. Ortalamanın hesaplanmasında son günlere verilen ağırlığın daha fazla olması veya her günün eşit ağırlıkta sonuca etki etmesine göre basit, hareketli ve üstel olmak üzere üçe ayrılmıştır.

Hareketli Ortalamanın Yakınsama Iraksaması indikatörü kısa periyot ile hesaplanmış üstel hareketli ortalamadan uzun periyot ile hesaplanmış üstel hareketli ortalamayı çıkartır, bu şekilde MACD çizgisini elde eder. Bu çizginin üstel hareketli ortalaması ile de tetik çizgisi elde edilir. Teknik analistlere göre MACD çizgisinin tetik çizgisinin üzerine çıkması alım yapılabileceğini, tersi durumun ise satış yapılabileceğini gösterir.

Göreceli Güç Endeksi belli bir tarih aralığında artış azalışlarını oranlar ve 0-100 arasında bir çıktı üretir. Teknik analistlere göre üretilen değerin 70'ten fazla olması aşırı alımı, 30'dan az olması ise aşırı satışı gösterir.

Stokastik Osilatörü fiyatın kapanış değerini belli bir tarih aralığındaki en yüksek ve en düşük kapanış değerleri ile karşılaştırır. 0-100 arasında değeri değişen 3 çizgiden (Hızlı-K, Hızlı-D, Yavaş-D) oluşur ve teknik analistlere göre bu çizgilerin 20'nin altında olması aşırı satış, 80'nin üzerinde olması ise aşırı alış olduğunu gösterir.

Williams' %R ise Stokastik Osilatörü'ne benzer şekilde kapanış değerini en yüksek ve en düşük kapanış değerleri ile karşılaştırır ve -100-0 arasında değerler üretir. Teknik analistlere göre -20'nin üstü aşırı alışı, -80'nin altı ise aşırı satışı gösterir.

Bu indikatörlerin çalıştırılması sonucunda elde edilen veriler üzerinde öğrenme modelleri oluşturulmuştur.

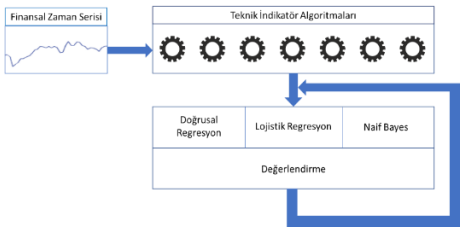
Veri Ön İşleme: SMA, WMA ve EMA indikatörlerinin değerleri bir önceki gün ile karşılaştırılarak artmış ise 1, artmamış ise 0 olarak işaretlenmiştir. MACD indikatörü; MACD çizgisi 0'ın ya da tetik çizgisinin altındaysa 0, diğer durumlarda 1 olarak işaretlenmiştir. Diğer indikatörlerin değerleri ise [0.0, 1.0] arasına normalize edilmiştir.

Indikatör Kümesi Sınıf Etiketi: Bu işlemlerden geçen teknik indikatör değerleri bir özellik vektörüne dönüştürülmüştür. Bu vektörde, etiket sınıfını oluşturan kapanış değeri ise önceki gün

ile karşılaştırılmıştır. Eğer artmış ise 1, artmamış ise 0 olarak işaretlenmiştir.

B. Özellik Seçimi

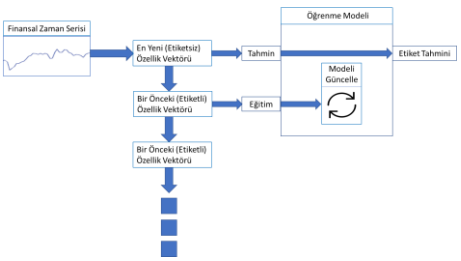
Şekil. 1.'de özellik seçimi için uyguladığımız akış şeması görülmektedir. Burada teknik indikatörler yukarıdaki bölümde bahsedildiği şekilde finansal zaman serisi verisinden çıkarılıp önişleme yapıldıktan sonra farklı kombinasyonları makine öğrenmesi algoritmalarına verilmektedir. Bahsedilen 7 teknik indikatörün birlikte kullanılabileceği 127 farklı indikatör seti vektörü bulunmaktadır. Her farklı özellik vektörü için AKBNK, TCELL ve YKBNK olmak üzere 3 farklı hisse senedi verisi üzerinde Doğrusal Regresyon, Lojistik Regresyon ve Naif Bayes ikili sınıflandırma algoritmaları kullanılarak öğrenme modelleri oluşturulmuştur. Oluşturulan modellerin başarısı, 10-katlamalı çapraz doğrulama (10-fold cross validation) ile sınanmıştır. Elde edilen sonuçlar doğrultusunda; farklı indikatör özellik vektörleri, F_1-skor değerlerine göre büyükten küçüğe sıralanarak, en başarılı tahmini yapan teknik indikatör grupları belirlenmiştir.



Şekil. 1. Kaba Kuvvet Yöntemi ile Özellik Seçimi

C. Spark Streaming ile Geliştirilen Prototip Uygulama

Spark Streaming kütüphanesi kullanılarak; teknik analiz indikatör verileri, akan bir formatta, farklı örnek-tabanlı öğrenme algoritmaları için öğrenme modelleri oluşturulmasında kullanılmıştır. Örnek-tabanlı olarak gerçeklenmiş Doğrusal Regresyon ve Lojistik Regresyon algoritmaları kullanılarak, gerçek zamanlı fiyat hareket yönü tahmini yapan bir karar destek sistemi oluşturulmuştur. Geliştirilen karar destek sisteminde, bir önceki aşamada tespiti yapılan ve en uygun tahmin sonuçlarını veren, teknik indikatör özellik vektörü kullanılmıştır. Geliştirilen karar destek sisteminde, makine öğrenmesi algoritmalarına veri gönderildikçe oluşturulmuş olan öğrenme modeli sürekli güncellenmektedir. Geliştirilen prototip uygulama Şekil-2' de resmedilmektedir.



Şekil. 2. Spark Streaming ile Modelin Veri Geldikçe Güncellenmesi

IV. METODOLOJİNİN DEĞERLENDİRİLMESİ

Bir sınıflandırıcının ne derece doğru sınıflandırma yaptığının gerçek veri seti üzerinde uygulanmasından önce belirlenmesi gereklidir. Sınıflandırıcılar, farklı eğitim veri setleri ile eğitildiklerinde, farklı sonuçlar üretebilmektedir. Aynı eğitim veri seti için, farklı sınıflandırıcılar farklı sonuçlar üretebilmektedir. Bu nedenle, farklı sınıflandırıcıların denenerek, en doğru sonuçlar üretenin seçilmesi gereklidir.

Sınıflandırıcıların kullanım amaçlarına, problemin büyüklüğüne ve beklenen doğruluk düzeyine göre farklı skor değerleri kullanılarak sınıflandırıcılar kendi aralarında karşılaştırmalı olarak denenebilir.

Gerçekleştirdiğimiz deneysel araştırmada, BIST Istanbul Hisse Senedi Piyasasından, 3 farklı hisse senedi (Turkcell, Akbank, Yapı Kredi Bankası) verileri eğitim verileri olarak kullanılmıştır. Sınıflandırıcı olarak ise 3 farklı ikili sınıflandırma algoritması (Lineer Regresyon, Lojistik Regresyon Regresyon ve Naif Bayes) üzerinde çalışılmıştır. Farklı indikatöre vektörlerinin özellik seti olarak kullanılması durumunda, bu sınıflandırıcıların, fiyat yönü hareketi tahmindeki başarıları F_1-skorlama ve Doğruluk başarı ölçütleri ile değerlendirilmiştir. Farklı hisse senetleri için ve öğrenme algoritmalarında indikatörlerin en yüksek F_1-skor değeri ürettiği, özellik seti grupları Tablo II'de verilmektedir. Bu tabloda Doğrusal Regresyon "LR" ile, Lojistik Regresyon "LogR" ile, Naif Bayes ise "NB" ifadeleriyle gösterilmiştir. Bununla beraber aynı hisse senedinde ama farklı öğrenme algoritmalarında ortalama olarak en yüksek F_1-skorunu veren indikatör grupları ise Tablo III'te verilmiştir. Tablolarda "A" ile algoritma, "F1" ile F_1-skoru, "D" ile doğruluk (accuracy) değerleri ifade edilmektedir. Tablolarda bulunan büyüklükler yüzde cinsinden verilmektedir.

TABLO I. ALGORİTMALARA ÖZEL EN BAŞARILI İNDİKATÖR GRUPLARI

	A	F1	D	İndikatör Grubu
AKBNK	LR	76,7	70,7	EMA, STO
	LogR	76,3	71,2	SMA, WMA, EMA, WSR, STO
	NB	77,2	67,3	SMA, WMA, EMA, WSR, STO
TCELL	LR	76,5	71,5	SMA, EMA, RSI, WSR, STO
	LogR	76,4	71,2	EMA, MACD, RSI, WSR
	NB	76,9	65,6	EMA, MACD, RSI, WSR
YKBNK	LR	76,3	70,9	WMA, EMA, MACD, WSR
	LogR	76,5	71,5	WMA, EMA, MACD, RSI, WSR, STO
	NB	77	66,5	EMA, RSI, WSR, STO

TABLO II. ORTALAMADA EN BAŞARILI İNDİKATÖR GRUPLARI

	A	F1	D	İndikatör Grubu
AKBNK	LR	72,5	67,9	SMA, WMA, EMA, WSR, STO
	LogR	76,3	71,2	
	NB	77,2	67,3	
TCELL	LR	73,1	67,6	EMA, MACD, RSI, WSR
	LogR	76,4	71,2	
	NB	76,9	65,6	
YKBNK	LR	71,5	65,8	EMA, MACD, RSI, STO
	LogR	72,7	67,6	
	NB	75	64,2	

Sonuçların Analizi: Elde edilen F_1-skorlarına göre indikatör gruplarının farklı öğrenme algoritmalarında farklı sonuçlar verdiği ve en iyi tahmini yapan teknik indikatör grubunun hisse senedine göre değiştiği görülmektedir. Bu tespitle birlikte; EMA teknik indikatörünün bütün güçlü indikatör grupları içerisinde yer aldığı anlaşılmaktadır. Makine öğrenmesi algoritmalarına bakıldığında, F_1-skor değerlerine göre 3 algoritmanın da birbirine yakın sonuçlar verdiği anlaşılmaktadır. Algoritmaların fiyat yönü hareket tahminindeki doğruluk oranlarında %71' e varan değerlere ulaşabildiği görülmektedir. Ancak, BIST Istanbul hisse senedi piyasasına ait finansal zaman serisi verisi üzerinde, Naif Bayes'in doğruluk değerlerinin diğer iki algoritmadan daha düşük olduğu görülmektedir.

V. Sonuçların Geçerliliğini Tehlikeye Sokabilecek Konular

Her bir teknik indikatörün en iyi tahmin yaptığı parametreler farklı algoritmalar kullanılarak bulunabilmektedir. Her bir teknik indikatör için optimize edilmiş parametrelerin bulunması durumunda, indikatörün tahmin yeteneği artacağından, birlikte çalıştıklarında iyi tahmin yapabilecek ve bu çalışmada bulunan gruplardan farklı olabilecek indikatör grupları da bulunabilecektir. Sonuç olarak bu araştırma kapsamında yaptığımız tespitler, özellik vektöründeki özelliklerin en iyi tahmin yapan bir alt kümesini bulmaktadır. Bu yüzden özellik vektörünün değişmesi bulunacak olan alt kümenin de değişmesine neden olacaktır. Bu çalışmada, tüm teknik indikatörler, teknik analistler tarafından, en yaygın olarak kullanılan parametreler ile çalıştırılmıştır. Elde ettiğimiz tespitler, teknik analistlerin yıllara dayanan deneyime dayalı olarak kullandıkları indikatör parametreleri üzerinden yapıldığından, gerçeğe en yakın sonuçları yansıtmaktadır.

VI. Sonuçlar ve Gelecekteki Çalışmalar

Bu çalışma kapsamında; finansal zaman serisi verisi üzerinde hareket yönü tahmini için, literatürde henüz sınanmamış teknik analiz indikatör setlerinden, hangilerinin makine öğrenmesi algoritmalarında, daha başarılı sonuçlar verdiği, Spark'ın makine öğrenmesi kütüphanesi kullanılarak incelenmiştir. Gerçekleştirdiğimiz deneysel araştırma, finansal zaman serisi verisi üzerinde, fiyat hareket yönü tahmininde artçı bir teknik indikatör olan EMA'nın, iyi bir tahmin edici öznitelik olduğunu [8]'de olduğu gibi bu çalışmada da ortaya koymaktadır. Elde ettiğimiz sonuçlar, uygun indikatör seti kullanıldığında, ikili sınıflandırma algoritmalarının yüksek doğruluk yüzdelerinde tahminler yapabildiğini ortaya koymaktadır. Araştırmamız kapsamında incelenen ikili sınıflandırma algoritmalarından, Naif Bayes'in Doğrusal Regresyon ve Lojistik Regresyon'a göre daha başarısız tahminler yaptığıda tespit edilmektedir.

Tespiti yapılan indikatörler özellik seti olarak kullanılarak, akan veri formatında gelen indikatör değerleri üzerinde örnek-tabanlı öğrenme algoritmaları çalıştırılmıştır. Akan verilerin öğrenme modelini sürekli güncellediği bir karar destek sisteminin prototip uygulaması geliştirilmiştir. Geliştirilen prototip uygulama, araştırmamızın teknolojik katkısı olarak GitHub kod paylaşım platformunda paylaşılmıştır (Bağlantı: https://github.com/fiyatyonutahmini/FinancialForecastingDS).

Gelecekte, literatürde henüz sınanmamış daha fazla teknik indikatörün, fiyat hareket yönü tahmininde, makine öğrenmesi algoritmalarıyla kullanımı üzerinde yapılacak çalışmalar planlanmıştır.

Kaynaklar

[1] Oğuz R.F., Aktaş M.S., Kalipsiz O., Aykurt İ., Yaka M.B., "On the Comparison of SQL and NoSQL Storage Platforms for Financial Time Series Data: A Case Study", *Akademik Bilişim, TÜRKİYE,* 2019.

[2] Uygun Y., Erboy M.O., Aktaş M.S., Kalipsiz O., Aykurt İ., "Technical Analysis on Financial Time Series Data based on Map-Reduce Programming Model: A Case Study", *Internation Congress on Big Data, Deep Learning, ANKARA, TÜRKİYE, 3-4 Aralık* 2018.

[3] Bjoern, K., Vanstone, B., Finnie, G., "Financial time series forecasting with machine learning techniques: A survey.", *ESANN-2010, Belgium,* 2010.

[4] Kim, Kyoung-jae. "Financial time series forecasting using support vector machines." *Neurocomputing 55.1-2: 307-319*, 2003.

[5] Choudhry, Rohit, and Kumkum Garg. "A hybrid machine learning system for stock market forecasting." *World Academy of Science, Engineering and Technology 39.3: 315-318,* 2008.

[6] Vaiz, J. Sharmila, and Dr M. Ramaswami. "A Study on Technical Indicators in Stock Price Movement Prediction Using Decision Tree Algorithms." *American Journal of Engineering Research, e-ISSN: 2320-0847 p-ISSN: 2320-0936; 5 (12,* 2016.

[7] Kumar, Indu, et al. "A comparative study of supervised machine learning algorithms for stock market trend prediction." *2018 IEEE Second International Conference on Inventive Communication and Computational Technologies*, 2018.

[8] Oriani, Felipe Barboza, and Guilherme P. Coelho. "Evaluating the impact of technical indicators on stock forecasting." *2016 IEEE Symposium Series on Computational Intelligence (SSCI)*, 2016.

[9] J. Wang, T. Sun, B. Liu, Y. Cao and D. Wang, "Financial Markets Prediction with Deep Learning," *2018 17th IEEE International Conference on Machine Learning and Applications (ICMLA), Orlando, FL, USA, pp. 97-104,* 2018.

[10] Yildiz, B., Wu, K., Byna, S., Shoshani, A., "Parallel membership queries on very large scientific data sets using bitmap indexes," *Journal of Concurrency and Computation: Practice & Experience, 2019. DOI: 10.1002/cpe.5157*, 2019.

[11] Yildiz, B., Fox, G., "Toward a modular and efficient distribution for web service handlers," *Journal of Concurrency and Computation: Practice & Experience, vol. 25 iss. 3, pp. 410-426, DOI: 10.1002/cpe.2854,* 2013.

[12] Aktas, MS., Fox, GC., Pierce, M., "Information services for dynamically assembled semantic grids", *First International Conference on Semantics, Knowledge and Grid,* 2015.

[13] Jensen, S., Plale, B., Aktas, MS, Luo, Y, Chen, P, Conover, H., "Provenance capture and use in a satellite data processing pipeline", *IEEE Transactions on Geoscience and Remote Sensing 51 (11), 5090-5097,* 2013.

[14] Aktas, MS., Plale, B., Leake, D., Mukhi, NK., "Unmanaged workflows: Their provenance and use", *Data Provenance and Data Management in eScience, 59-81,* 2013.

[15] Aktas, MS, Pierce, M., "High-performance hybrid information service architecture", *Concurrency and Computation: Practice and Experience 22 (15), 2095-2123,* 2010.

[16] Aktas, M.S., Pierce, M., Fox, G.F., "Designing ontologies and distributed resource discovery services for an earthquake simulation grid", *Proc. of the GGF11 Semantic Grid Applications Workshop, Honolulu, USA,* 2004.