



Deep learning based hybrid gold index (XAU/USD) direction forecast model

Onur Kantar^{ID}, Zeynep Hilal Kilimci*^{ID}

Department of Information Systems Engineering, Faculty of Technology, Kocaeli Üniversitesi, 41001, İzmit, Kocaeli, Türkiye

Highlights:

- High performance gold index (XAU/USD) direction forecast model
- Constructing a deep learning-based hybrid model for XAU/USD direction estimation
- Evaluation of deep learning models in sentiment and time series analysis

Keywords:

- Deep contextualized word representations
- Deep learning models
- Financial sentiment analysis
- Gold index forecast
- XAU/USD forecast

Article Info:

Research Article

Received: 01.03.2021

Accepted: 19.05.2022

DOI:

10.17341/gazimmfd.888456

Correspondence:

Author: Zeynep Hilal Kilimci
e-mail: zeynep.kilimci@kocaeli.edu.tr
phone: +90 262 303 2242

Graphical/Tabular Abstract

Forecasting the direction of the gold index (XAU/USD), which determines the value of 1 ounce of gold in dollars, as well as the direction of the stock market, exchange rate, cryptocurrency, has also been an attractive topic of research for investors, researchers and analysts. The aim of this study is to construct a model that predicts the direction of the gold index based on deep learning methodology. The proposed model is obtained as a result of blending textual data with real-time data belonging to the gold index, and also exhibits a hybrid forecasting model both in this aspect and in terms of hybrid deep learning methods used in direction forecasting. As far as we know, this is the first attempt in the literature to employ the social media platform as a source for financial sentiment analysis and to construct a deep learning-based direction prediction model for the gold index by blending it with numerical data.

Table A demonstrates the performance of the proposed model when sentiment analysis-based features are included to the dataset.

Table A. Performance of deep learning based time series models obtained by the inclusion of sentiment analysis-based features

	MLP	CNN	LSTM	CNN-LSTM	ConvLSTM
MAPE	3,7430	2,8611	4,4896	4,4249	4,1610
MAE	0,0646	0,0499	0,0776	0,0766	0,07197
MSE	0,0059	0,0036	0,0096	0,0094	0,0067
R ²	0,9420	0,9638	0,9051	0,9072	0,9338

Purpose:

The purpose of this study is to construct a hybrid XAU/USD direction prediction model by investigating the impact of sentiment analysis on gold index.

Theory and Methods:

The dataset is constructed by blending both sentiment analysis data and real word data in order to explore the effect of sentiment analysis on the prediction of direction of XAU/USD. To classify sentiments of users, CNN, RNN, LSTM, Word2Vec, GloVe, FastText, BERT, MBERT, DistilBERT, ELMo, ULMFiT, RoBERTa, ELECTRA, GPT-2 model are evaluated. Then, the results of the financial sentiment analysis are adapted and blended with the XAU/USD real-time data. Finally, MLP, CNN, LSTM, CNN-LSTM, ConvLSTM deep and hybrid deep learning models are constructed and the performance of the model in predicting the XAU/USD direction is observed.

Results:

DistilBERT model demonstrates superior performance with 95.99% of accuracy for sentiment analysis part of the study. After blending dataset with sentiment analysis-based features, CNN model outperforms others with 2.8611 of MAPE score when multilayer perceptron, deep and deep hybrid learning models are considered.

Conclusion:

As a result, the performance of the proposed model is significantly superior compared to the state-of-the-art studies with 2.8611 of MAPE value. Moreover, extending dataset with sentiment score related features improves the performance of deep learning based XAU/USD direction prediction system.



Derin öğrenme temelli hibrid altın endeksi (XAU/USD) yön tahmin modeli

Onur Kantar^{ID}, Zeynep Hilal Kilimci*^{ID}

Kocaeli Üniversitesi, Teknoloji Fakültesi, Bilişim Sistemleri Mühendisliği Bölümü, 41001, İzmit, Kocaeli, Türkiye

ÖNEÇIKANLAR

- Yüksek performanslı altın endeksi (XAU/USD) yön tahmin modeli
- XAU/USD yön tahmini için derin öğrenme temelli hibrid model oluşturulması
- Derin öğrenme modellerinin duygu analizi ve zaman serileri analizinde değerlendirilmesi

Makale Bilgileri

Araştırma Makalesi

Geliş: 01.03.2021

Kabul: 19.05.2022

DOI:

10.17341/gazimmfd.888456

Anahtar Kelimeler:

Altın endeksi tahmini,
derin bağlamsallaştırılmış
kelime temsilleri,
derin öğrenme modelleri,
finansal duygu analizi,
XAU/USD tahmini

ÖZ

1 ons altının dolar cinsinden değerini belirleyen altın endeksinin yönünün tahminlenmesi yatırımcılar, araştırmacılar ve analistler için cezbedici bir araştırma konusudur. Bu çalışmada, derin öğrenme temelli altın endeksinin yönünü tahmin eden bir model oluşturulması amaçlanmıştır. Önerilen model, altın endeksinin sayısal verileriyle metin içerikli verilerin harmanlanması sonucu elde edilmiştir. Hem bu yönüyle hem de yön tahmininde kullanılan hibrid derin öğrenme yöntemleri açısından hibrid bir tahmin modeli özelliği taşımaktadır. Bildiğimiz kadarıyla bu çalışma, sosyal medya platformunu finansal duygu analizi amacıyla kaynak olarak kullanan ve bunu sayısal verilerle harmanlayarak altın endeksi için derin öğrenme temelli yön tahmin modeli oluşturan literatürdeki ilk çalışma niteliğindedir. Çalışmanın literatüre katkısı dört aşamada özetlenebilir: İlk aşamada, duygu analizini gerçekleştirebilmek için Twitter ortamından toplanan verileri ayrıştırma, kelimelerin sözlükteki doğru hallerini bulma, kelimelerin köklerini bulma, kelimeleri normalize etme, kullanılmayan karakterleri temizleme gibi yöntemlerle veriler temizlenip modellenmeye hazır hale getirilmiştir. Sonrasında, veri kümesi 14 farklı derin öğrenme temelli yöntem kullanılarak sınıflandırılmıştır. İkinci olarak, XAU/USD sayısal verileriyle duygu analizinden elde edilen sonuçlar harmanlanmıştır. Üçüncü olarak, derin öğrenme modelleri ile XAU/USD yön tahmin modeli oluşturulmuştur. Dördüncü olarak, farklı beş tahmin modelinden alınan sonuçların XAU/USD yönünün tahminindeki performansı sunulmuştur. Sonuç olarak, önerilen modelin performansı literatür çalışmalarıyla kıyaslandığında yüksek doğrulukla kayda değer ölçüde üstünlük göstermektedir.

Deep learning based hybrid gold index (XAU/USD) direction forecast model

HIGHLIGHTS

- High performance gold index (XAU/USD) direction forecast model
- Constructing a deep learning-based hybrid model for XAU/USD direction estimation
- Evaluation of deep learning models in sentiment and time series analysis

Article Info

Research Article

Received: 01.03.2021

Accepted: 19.05.2022

DOI:

10.17341/gazimmfd.888456

Keywords:

Deep contextualized word
representations,
deep learning models,
financial sentiment analysis,
gold index forecast,
XAU/USD forecast

ABSTRACT

Forecasting the direction of the gold index, which determines the dollar value of 1 ounce of gold, is an attractive research topic for investors, researchers and analysts. In this study, it is aimed to construct a model that predicts the direction of the gold index based on deep learning. The proposed model is obtained as a result of blending the numerical dataset of the gold index with the textual data. This is a hybrid prediction model both in this aspect and in terms of hybrid deep learning methods used in direction prediction. As far as we know, this is the first attempt in the literature that uses the social media platform as a source for financial sentiment analysis and constructs a deep learning-based direction prediction model for the gold index by blending it with numerical data. The contribution of the study to the literature is summarized in four stages: In the first stage, in order to carry out the sentiment analysis, the dataset is cleaned and ready for modeling by methods such as parsing the dataset collected from the Twitter environment, finding the correct forms of the words in the dictionary, finding the roots of the words, normalizing the words, and cleaning the unused characters. Afterwards, the dataset is classified using 14 different deep learning-based methods. Secondly, the results of the sentiment analysis are blended with the numerical data of XAU/USD. Third, the XAU/USD direction prediction model is constructed with deep learning models. Fourth, the performance of the results from five different forecasting models in predicting the direction of XAU/USD is presented. As a result, the performance of the proposed model is significantly superior with high accuracy when compared to the state-of-the-art studies.

*Sorumlu Yazar/Yazarlar / Corresponding Author/Authors : onurkantar@gmail.com, *zeynep.kilimci@kocaeli.edu.tr / Tel: +90 262 303 2242

1. Giriş (Introduction)

Twitter, Facebook ya da Instagram gibi sosyal platformlar günlük hayatımızın içerisinde önemli bir yer edinmiştir. Bu platformlarda içeriklerin resim, yazı, video gibi farklı biçimlerde üretilmesi ve çok hızlı bir şekilde milyarlarca kişi tarafından paylaşılması, sosyal medya platformlarını araştırmacılar için çekici bir araştırma alanı ve veri kaynağı haline getirmiştir. Bu platformlardan Twitter'ın, diğer sosyal medya platformlarından ağırlıklı metin tabanlı veri içermesi, dünya genelinde günlük 500 milyondan fazla Türkiye genelinde günlük yaklaşık 7 milyondan fazla içeriğin paylaşılıyor olması ve verilerin sürekli, taze, çeşitli olması yönüyle ayrıştığı görülmektedir. Bu da, bizim çalışmamızda olduğu gibi diğer çalışmalarda da Twitter'ın gerçek bir veri kaynağı olarak tercih edilmesini sağlamaktadır.

Kıymetli bir maden olan altın, binlerce yıldır hem takas aracı, hem rezerv birimi, hem de mücevherat olarak toplumlar arasındaki popülerliğini yitirmemiştir. Altın madenin yapısı gereği dayanıklı olması, işlenebilirliği açısından sağladığı kolaylıklar ve diğer faydaları göz önüne alındığında üretimde sanayi için ve bir emtia olarak finansal piyasalar için önem arz etmektedir. Bu sebeple, altın fiyatı dünya finansal piyasalarda yaygın olarak takip edilmektedir. Altın endeksi yani ABD Doları (XAU/USD) cinsinden işlem gören bir ons altın fiyatı ise, bir altın ons satın almak için kaç ABD Doları gerektiğini ifade etmektedir. Altın, bir emtia olarak sadece dış dünya ile yakından iletişim halinde olan şirketler için değil aynı zamanda herhangi bir ülke için en önemli yatırım araçlarından biri olarak kabul edilmektedir. Ülkeler ve çok uluslu firmalar dış dünya ile olan bağlantılarını sağlamak için en önemli iktisadi değişkenlerden biri olan döviz kuruyla aynı zamanda altın rezervlerini de değişken olarak kullanmaktadırlar. Bu durum, altın endeksini ve altın piyasasını dünyanın en büyük ve önemli finansal piyasalarından biri haline getirmektedir. Bu sebeple, altın endeksi piyasalardan, ekonomiden ve siyasal politikalarından oluşabilecek birçok gelişmeden olumlu ya da olumsuz bir şekilde hızlıca etkilenebilmektedir. Dış faktörler de göz önüne alındığında altın endeksinin ve piyasasının gelecekteki seviyesini kontrol etmek neredeyse imkansızlaşmaktadır. Bu da altın endeksi tahminlemesini araştırmacılar ve yatırımcılar için daha cazip ve aktif bir araştırma alanı haline getirmektedir. Altın yönünün tahminlenmesinde her ne kadar birçok zaman serisi analizi ve makine öğrenmesi yöntemleri ile farklı sonuçlar elde edilse de oluşturulan modellerin zamanla daha karmaşık hale gelmesi ve altın fiyatlarındaki değişimin ardında yatan asıl faktörlerin doğru analiz edilemeyişi birçok yanlış algıyı da beraberinde getirmektedir. Hızlı bir değişkenlik içerisinde olan altın piyasasının etkilendiği dış etkenlerin yorumlanması için duygu analizinin de içinde olduğu birçok makine öğrenimi yönteminden faydalanılmaktadır. Bu çalışma kapsamında, derin öğrenme metodolojisi temelli altın endeksinin yönünü tahmin eden bir hibrid modelin oluşturulması amaçlanmıştır. Klasik finansal yöntemlerden farklı olarak sosyal medya platformunu finansal duygu analizi amacıyla kaynak olarak kullanan ve bunu altın endeksinin gerçek zamanlı verileriyle harmanlayarak altın endeksi için derin öğrenme temelli hibrid bir yön tahmin modeli önerilmektedir.

Önemi giderek artan makine öğrenmesi ve derin öğrenme disiplinlerinin etki ettiği farklı yöntemlerin günümüz ihtiyaçlarına çözümler sunması farklı araştırmaların da önünü açmaktadır. Duygu analizi amacıyla yapılan araştırmalarda doğal dil işleme yöntemlerinden faydalandığı gibi makine öğrenmesi, derin öğrenme ve çeşitli sınıflandırma algoritmalarından da faydalanılmaktadır. Bu araştırmada, bir duygu analizinin yapılabilmesi için gerekli olan aşamalar, ön işleme sürecinde kaynak verilerin ayrıştırılması, kelimelerin sözlükteki doğru hallerinin bulunması, kelimelerin köklerinin bulunması, kelimelerin normalizasyonu, kullanılmayan karakterlerin ve kelimelerin temizlenmesi gibi doğal dil işleme

yöntemlerinden faydalanılarak belirlenmiştir. Daha başarılı bir sınıflandırma sonucu elde etmek için dokümanlar, kelimelere ayrılıp bir vektör uzayına yerleştirilmiş sonrasında ayrıştırılan kelimelerin vektör uzayındaki bağlamsal benzerliklerini elde edebilmek amacıyla literatürde de sıkça kullanılan Word2Vec, GloVe ve FastText gibi kelime yerleştirme yöntemlerinden faydalanılmıştır. Dahası, çalışma kapsamında kelime temsillerini derin öğrenme yöntemleriyle harmanlayan Çift Yönlü Kodlayıcı Gösterimleri (BERT), Çok Dilli Çift Yönlü Kodlayıcı Gösterimleri (M-BERT), Damıtılmış Çift Yönlü Kodlayıcı Gösterimleri (DistilBERT), Dil Modellerinden Yerleştirme (ELMo), Evrensel Dil Modeli İnce Ayarı (ULMFIT), Sağlam Bir Şekilde Optimize Edilmiş BERT (RoBERTa), Kelime Değişimlerini Doğru Bir Şekilde Sınıflandıran Bir Kodlayıcıyı Etkin Bir Şekilde Öğrenme (ELECTRA), Üretken Ön Eğitilmiş Transformator 2 (GPT-2) modelleri derin bağlamsallaştırılmış kelime temsilleri olarak değerlendirilmiştir. Ayrıca, duygu analizini gerçekleştirmek için kelime yerleştirme ve derin bağlamsallaştırılmış kelime temsilleri yöntemlerinin yanı sıra derin öğrenme yöntemleri olarak Evrişimli Sinir Ağları (CNNs), Tekrarlayan Sinir Ağları (RNNs), Uzun Kısa Dönem Hafıza Ağları (LSTMs) modellerinden de faydalanılmıştır. Bu yöntemlerle, Twitter'dan toplanan veri kümesi üzerinde altın endeksi yön tahmini için duygu analizi yapan modeller inşa edilmiştir.

Derin öğrenme, yapay sinir ağları ile beyin yapısını, işlevini ve öğrenme şeklini taklit eden yöntemlerle ilgili makine öğrenmesi alt alanlarından biri olmakla beraber bu çalışmada önerilen modelin temelini oluşturmaktadır. Derin öğrenme yöntemlerinin son dönemlerde çokça tercih edilmesinin ardında yatan nedenler, donanımsal avantajları ve kolay ölçeklenebilirliğidir. Bunlara ek olarak, derin öğrenme modellerinin sunmuş olduğu bir başka avantaj ise özellik öğrenimi olarak da adlandırılan ham verilerden otomatik özellik çıkarma işlemini gerçekleştirebiliyor olmalarıdır. Bu çalışmada önerilen modelin de temelini oluşturan derin öğrenme yöntemleri CNN, RNN, LSTM iken CNN-LSTM, Evrişimli LSTM (ConvLSTM) hibrid derin öğrenme yöntemleri olarak değerlendirilmiştir. Yapılan diğer alanlardaki çalışmalarda, bizim çalışmamızda bir araya getirdiğimiz farklı yöntemlerin her biri ayrı olarak denenmiş ve farklı sonuçlar elde edilmiştir. Her ne kadar duygu analizi yer yer kullanılmış olsa da bu çalışmada yapmış olduğumuz gibi karma bir model oluşturulduğu gözlenmemiştir. Bu çalışmada, duygu analizi kısmında derin bağlamsal kelime temsillerinin kullanılması ve duygu analizi skorunun altın yön tahminine etki eden bir faktör olarak modele dahil edilmesi sebebiyle literatürdeki ilk çalışma niteliğindedir. Dahası önerilen model, altın endeksinde ait gerçek zamanlı verilerle metin içerikli verilerin harmanlanması sonucu elde edildiğinden hem bu yönüyle hem de yön tahmininde kullanılan hibrid derin öğrenme yöntemleri açısından hibrid bir tahmin modeli özelliği de taşımaktadır. Sonuç olarak, çalışmamızda önerilen hibrid yöntem ile literatür çalışmalarına kıyasla çok daha performanslı bir tahmin modeli oluşturulduğu gözlenmiştir.

Makalenin kalan kısmı şu şekilde düzenlenmiştir: Bölüm 2, duygu analizi ve döviz kuru, emtia, kripto para gibi finansal yatırım araçları üzerine yön tahmini yapan çalışmaların özetini sunmaktadır. Bölüm 3, önerilen modelin mimarisini ve sistemin inşası için kullanılan yöntemleri içermektedir. Deney sonuçları ve sonuçlar Bölüm 4 ve Bölüm 5' te sunulmaktadır.

2. Literatür Çalışmaları (Related Works)

Bu bölüm, duygu analizi ve döviz kuru, emtia, kripto para gibi finansal yatırım araçları üzerine yön tahmini yapan çalışmalar hakkında bir özet sunmaktadır. Sohagir vd. [1], derin öğrenme ve büyük veri analizinin veri biliminin odak noktaları olduğunu vurgulamışlardır. Bununla birlikte, internetin ve finansal sosyal

ağların popülaritesi sayesinde, dünyanın dört bir yanındaki yatırımcılar, deneyimlerini toplamak ve paylaşmak için bu tarz fırsatlara sahip olduğunu ve bu sayede borsanın da bu ağa dahil olduğundan bahsetmişlerdir. Bu çalışmada, StockTwits ortamında yayımlanan borsa görüşlerine uzun kısa dönem hafıza ağları, doc2vec ve evrişimli sinir ağları gibi çeşitli sinir ağı modellerini uyguladıklarını ve derin öğrenme modelinin finansal duygu analizi için etkili olduğundan bahsetmişlerdir. Diğer bir çalışma [2], finansal duygu analizinin, finansal piyasalara önemli bir araştırma alanı sağladığından bahsetmektedir. Day ve Lee, bu çalışmada farklı finansal kaynakların yatırım için kullanılmasının etkisini Derin öğrenme yoluyla yöntemlerini kullanarak incelemişlerdir. Bollen vd. [3], Twitter kullanıcılarının ruh halinin hisse hareketleri üzerinde etkisi olabileceğini belirtmişlerdir. Yaptıkları çalışmada, günlük hisse tahminlerinin Dow Jones sanayi endeksinin kapanış değerleriyle %86,7 oranında paralellik gösterdiğini kanıtlamışlardır. Başka bir çalışmada ise [4] finansal yatırım araçları üzerine paylaşılan Twitter yorumlarını destek vektör makinesi (SVM) sınıflandırıcısı kullanarak finansal duygu analizine odaklanmışlardır. Deneyler, pozitif duygu olasılığındaki değişikliklerin hisse senedi kapanış fiyatlarındaki değişikliklerin göstergesi olarak kullanılabileceğini göstermiştir. Benzer diğer bir çalışmada [5], NASDAQ ve New York borsasında yer alan 30 şirketin hisse senedi kapanış fiyatını, 15 milyon Twitter yorumuyla tahmin etmeye çalışmışlardır. Sonuç olarak, bazı şirketlerin kapanış fiyatlarını %76,12 gibi yüksek bir doğruluk oranıyla tahmin edilebilmesinin mümkün olduğunu göstermişlerdir. Kilimci ve Duvar [6], Twitter ve finansal haber sitelerini kullanarak İstanbul menkul kıymetler borsasının (BIST100) yönünü tahmin etmek için hibrid bir kelime yerleştirme ve derin öğrenme modeli önererek finansal duygu analizine odaklanmışlardır. Deney sonuçları, derin öğrenme tekniklerinin ve kelime yerleştirme yöntemlerinin harmanlamasının BIST100 yönünü tahmin etmede kayda değer sonuçlar elde edildiğini göstermiştir. Bir başka çalışmada Kilimci [7], BIST100 yönünü tahmin etmede derin topluluk yöntemlerinin etkili bir yöntem olduğu vurgulanmıştır. Önerilen yöntemin başarısını göstermek için Türkçe ve İngilizce Twitter veri kümeleri üzerinde finansal duygu analizi yapılmış deney sonuçlarının literatür çalışmalarına kıyasla daha iyi bir performans sergilediği belirtilmiştir. Diğer bir çalışmada Yaşar ve Kilimci [8], zaman serileri analizi ve derin öğrenme yöntemlerini birleştirerek Amerikan Doları/Türk Lirası döviz kuru yönünü tahminlemeyi amaçlamışlardır. Önerilen modelin kullanılmasıyla ABD Doları/Türk Lirası döviz kuru tahmini yapmak isteyen herhangi bir kullanıcının daha tutarlı ve güçlü bir döviz kuru tahmini yapabileceğini öne sürmüşlerdir. Kilimci [9], duygu analizi temelli Bitcoin yön tahmini yapan bir model sunmuştur. Çalışma kapsamında, İngilizce Twitter veri kümesi kullanılmış çeşitli kelime yerleştirme yöntemleri ve derin öğrenme metodları kıyaslanmıştır. Bir kelime yerleştirme modeli olarak, FastText tekniğinin Bitcoin yönünü tahmin etmede %89,13 doğruluk ile en iyi performansı sergilediği belirtilmiştir.

Finansal duygu analizinin yanı sıra, finansal piyasalardaki dijital para, hisse senedi, altın gümüş gibi madeni emtialar, tahvil, fon ve bu gibi ürünlerin fiyat tahminlerinin yapılması üzerine de yoğunlaşan birçok çalışma bulunmaktadır. Yakut vd. [10], çalışmalarında Borsa İstanbul (BIST) endeksinin tahmin edilmesi için bir, iki ve üç gün öncesine ait kapanış değerlerin yanında Amerikan dolar kuru, gecelik faiz oranı ve 2005–2012 tarihleri arasındaki Japon Borsası (NIKKEI), Brezilya Borsası (BOVESPA), İngiltere Borsası (FTSE), Fransa Borsası (CAC), Almanya Borsası (DAX) borsa endeksi değerlerini kullanmışlardır. BIST endeks değerini ileri beslemeli yapay sinir ağları ve destek vektör makinesi yöntemleriyle tahmin etmişlerdir. Çalışmanın sonucunda, yapay sinir ağları ve destek vektör makinesi yöntemleriyle borsa endeksi tahminlemesinin kayda değer sonuçlar verdiğini belirtmişlerdir. Benzer diğer bir çalışma [11], 2001–2006 tarihleri arasındaki BIST verileri kullanılarak endeks değerinin ileri

beslemeli yapay sinir ağları ile de başarılı bir şekilde modellenebileceği gösterilmiştir. Finansal piyasa hareketini tahmin etmek için tek boyutlu evrişimli sinir ağları (CNN) modelini öneren çalışmada [12], 2010-2017 tarihleri arasındaki altı endeksin vadeli işlemini değerlendirmişlerdir. Deney sonuçları, CNN modelinin geleneksel teknik göstergelere göre daha genelleştirilmiş ve bilgilendirici özellikleri etkili bir şekilde çıkarabildiğini ve geleneksel makine öğrenimi yaklaşımlarından daha sağlam ve karlı finansal performans elde edilebileceği göstermiştir. Bir diğer çalışmada [13], destek vektör makinesi (SVM) yöntemi yardımıyla ertesi gün hisse senedi trendini tahmin etmek için küresel borsalar ve çeşitli finansal ürünler arasındaki zamansal korelasyonu kullanan yeni bir tahmin yöntemi sunulmuştur. Deney sonuçlarında, NASDAQ endeksinde %74,4, S&P500 endeksinde %76 ve DJIA endeksinde %77,6 doğruluk değerleri elde edilmiştir. Tsai ve Wang [14], hisse senedi fiyatı tahmin modeli oluşturmak için yapay sinir ağları (ANN) ve karar ağaçlarını (DT) birleştirmeye odaklanan hibrid bir makine öğrenmesi tekniği önermişlerdir. Deneysel sonuçlar, hibrid karar ağacı ve yapay sinir ağları yönteminin, tek başına kullanımlarına göre daha iyi bir performans sergilediğini ve bu performansın %77 doğruluğa sahip olduğunu göstermiştir. Livieris vd. [15], kısa ve uzun vadeli bağımlılıkları tanımlamak için uzun kısa vadeli bellek (LSTM) ağlarının etkinliğinin yanı sıra, yararlı bilgileri çıkarmak ve zaman serisi verilerinin temsilini öğrenmek amacıyla evrişimli sinir ağlarını kullanan CNN-LSTM modelini altın fiyatını tahminlemede kullanmışlardır. LSTM katmanlarının evrişimli katmanlarla birlikte kullanılmasının, tahmin performansını artırmada önemli bir artış sağlayabileceğini bildirmişlerdir.

Bizim çalışmamız ise, diğer tüm çalışmaların denediği yöntemlerden farklı olarak finansal duygu analizinden elde edilen sonuçları bir girdi olarak derin öğrenme yöntemlerine veren, böylece duygu analizinin altın endeksinin yönünü tahmin etmedeki etkisini gösteren bir çalışmadır. Önerdiğimiz model, hem altın endeksinin yönünü tahmin etmede kullanılan indikatörlerin çeşitliliğinin duygu analizinden elde edilen skorlarla harmanlanması hem de kullanılan hibrid derin öğrenme modelleri nedeniyle hibrid bir tahmin modeli özelliği de taşımaktadır. Bu açıdan bakıldığında altın endeksinin yönünü tahmin etmede kullanılan modellerin ve özelliklerin çeşitliliği ve bunların harmanlayan hibrid bir yapıya sahip olması sebebiyle literatürdeki ilk çalışma niteliğindedir.

3. Önerilen Çerçeve (Proposed Framework)

Çalışmamızın bu bölümünde, kelime uzayını temsil etmek için değerlendirilen kelime yerleştirme yöntemlerinden, derin öğrenme modellerinden, derin bağlamsallaştırılmış kelime temsillerinden, duygu analizinden ve önerilen modelin mimarisinden bahsedilmektedir.

3.1. Kelime Yerleştirme Yöntemleri (Word Embedding Models)

Kelime yerleştirme teknikleri ya da diğer bilenen adıyla kelime vektörleri, dokümanlar içerisindeki benzer anlamı olan kelimelerin ve kelime öbeklerinin benzer bir gösterim ile sunulmasını sağlayan bir tür temsil yöntemidir. Bu yöntemler ile kelimeler, bir vektör uzayında temsil edilir. Bir kelime yerleştirme tekniği, bir dokümanda yer alan kelimelerin her birinin bir vektör uzayını çıkarıp tüm sayısal değerlerini bu vektör uzayının üzerine taşır ve bir dizi sayısal veri üretir. Kısaca kelime yerleştirme teknikleri, metinleri sayısal verilere dönüştüren yöntemlerdir.

Pennington vd. [16] önerdikleri GloVe diğer bir adıyla kelime gösterimleri için global vektörler kelime yerleştirme modeli ile açık kaynak olarak geliştirilmiş olan bir denetimsiz öğrenme algoritması sunmuşlardır. GloVe, bir tahmin modelinden daha çok bir kelimenin

bir bağlamda ne sıklıkla görüldüğünü hesaplayan bir kelime yerleştirme yöntemidir. Çoğu kelime vektör metodu, kelimelerin birbirlerine olan uzaklıklarını hesaplayarak benzerlikler bulmaktadır. Terim frekansı-ters belge frekansı (TF-IDF) ya da gizli semantik analiz (LSA) gibi yöntemler kosinüs benzerliği hesaplama yöntemini kullanarak benzerlikler ve vektör uzayı çıkarırken GloVe, Word2Vec' in temelini oluşturan skip-gram modeli ile matris faktörleştirme yöntemlerinden biri olan LSA yöntemini birleştirmektedir. Kelimelerin birlikte oluşturma olasılıkları yerine kelimelerin eşzamanlı olma olasılıklarının oranını, içerdiği bilgiyi ve bu bilgiyi vektör farklılıkları hesaplayarak oluşturmayı amaçlayan bir yöntemdir. Word2vec, kelime yerleştirme tekniklerinden en popüler olanıdır. Hesaplama açısından oldukça elverişli, zengin kütüphane tercihleri ile uygulaması kolay, iki katmanlı bir yapay sinir ağı kullanan, frekansa dayalı olmaktan ziyade bir tahmin modelidir. Word2Vec, LSA ve gizli Dirichlet tahsisi (LDA) gibi yöntemleri kullanmak yerine sinir ağları tarafından öğrenilen kelimelerin dağılım temsillerini sağlamaktadır. Mikolov vd. [17], Word2Vec ile sürekli bag-of-words (CBOW) ve devamlı skip-gram adlı iki farklı model sunmaktadır. CBOW modeli, giriş düğümlerinden, varsa gizli düğümlere ve çıkış düğümlerine doğru sadece bir yönde ilerleyen ileri beslemeli dil modeline benzerdir. Devamlı skip-gram modeli ise CBOW modeli ile benzerlik göstermektedir. Fakat mevcut kelimeyi içeriğe dayalı olarak tahmin etmek yerine her bir mevcut sözcüğü, sürekli iz düşünüm katmanına sahip bir doğrusal log sınıflandırıcısına girdi olarak vererek mevcut sözcükten önce ve sonra belirli bir aralıktaki sözcükleri tahmin eder. FastText, Word2Vec modelinin bir uzantısı olarak Facebook tarafından 2016 yılında geliştirilmiş açık kaynaklı, hızlı ve etkili bir kelime yerleştirme çözümdür. FastText, kelimelerin birbirinden bağımsız olduğunu varsaymak yerine, bir kelimenin temsiliğini hesaplarken tüm karakter olasılıklarını n-gram vektörler oluşturarak hesaplamaktadır. Bunu yaparken vektör gösterimlerini denetimli ve denetimsiz olarak sağlar. FastText, etiket tahmini ve duyarlılık analizi olarak üzere iki farklı işlem sunmaktadır [18]. FastText' in kullandığı model, ortadaki kelimenin bir sınıf ile değiştirilmesi yönünden [17]' deki CBOW modeli ile benzerlik göstermektedir. Fakat, FastText modelinde belirli sınıflar üzerinden tanımlanmış olan olasılık dağılımının hesaplanması için, N sayıda doküman için sınıflar üzerinde oluşan negatif log olasılığı en aza indiren *softmax* fonksiyonundan yararlanmaktadır. Bu çalışmada, her kelime yerleştirme modelinin çıktısı, girdi olarak yapay sinir ağına beslenir. Böylece, yapay sinir ağına girdi olarak göndermek için büyük bir korpustan yoğun vektörlerle temsil edilen özellikler çıkarılır. Çıkarılan özellikler, yapay sinir ağı ile işlenerek sınıflandırma işlemi gerçekleştirilir.

3.2. Çok Katmanlı Algılayıcı (Multilayer Perceptron)

Çok Katmanlı Algılayıcı (MLP), ileri beslemeli bir yapay sinir ağı sınıfıdır. Bir MLP, en az üç düğüm katmanı olmak üzere giriş, gizli ve çıktı katmanlarından oluşur. Giriş düğümleri dışında, her düğüm doğrusal olmayan bir aktivasyon işlevi kullanan bir nörondur. MLP, eğitim için geri yayılım adı verilen denetimli bir öğrenme tekniğini kullanır. Çoklu katmanlı ve doğrusal olmayan aktivasyonu MLP' yi doğrusal bir algılayıcıdan ayırır. Doğrusal olarak ayrılamayan verileri ayırt edebilir. MLP yöntemi, zaman serileri analizinde, yaya yürünge tahmininde, finansal veriler üzerinde tahminleme gibi özellikle sınıflandırma ve genelleme yapma durumlarında sıklıkla kullanılmaktadır.

3.3. Derin Öğrenme Modelleri (Deep Learning Models)

Derin öğrenme, temelde insan beyninin sinir yapısını taklit ederek yeni bir yöntem oluşturması olarak bilinmektedir. Bu sebeple, derin öğrenme daha çok yapay sinir ağlarının gelişimi sonrası popülerlik kazanmıştır. Derin öğrenme modelleri ile makine öğrenmesi

yöntemlerinden yararlanılarak daha çok insan müdahalesi gerektiren özellik çıkarım işlemleri ya da parametre tanımlama adımları bu modellere yapılmaktadır. Bu nedenle, derin öğrenme modelleri büyük miktarda veri işleyen, kendi kendine öğrenebilen, bir hesaplama modeli oluşturan sistemler olarak adlandırılmaktadır. Bu çalışmada RNN, CNN ve LSTM algoritmaları derin öğrenme yöntemleri olarak kullanılmıştır.

RNN olarak da bilinen tekrarlayan sinir ağları, sıralı yani bir dizi bilgiden yararlanan ve ağ üzerindeki bir önceki katmandan gelen çıktıları girdi olarak kullanan bir sinir ağıdır [19]. Tekrarlayan bir sinir ağı, dizilerden gelen bir elemanı bir seferde işlemektedir ve bu adım öncesinde de hangi özellik geldiyse onun değerini bir sonraki adımda hatırlayabilecek şekilde hafızada tutmaktadır. Bu tipteki sinir ağları, gelinen noktaya kadar yapılmış tüm hesapları hafızasında tutmaktadır ve bir sonraki adımda bunu hatırlayarak bilgi çıkarımı yapmaktadır. Basit bir tekrarlayan sinir ağ modelinin alacağı herhangi bir karar ya da bir çıkarım o ona kadar verilmiş tüm kararların tamamından etkilenebilmektedir. CNN [20], bir giriş katmanından, bir çıkış katmanından, bir veya daha fazla evrişimli katmandan oluşan bir sinir ağı modelidir. Bir CNN modeli, evrişimli, havuzlama ve tam bağlı olmak üzere üç farklı tipte katmanın bir araya gelmesiyle oluşturulmaktadır. Evrişimli katman, eşlemelerin sayısı ve boyutu, çekirdek boyutları, atlama faktörlerini ve bağlantı tablosu tarafından parametrelenen ve bu yüklü hesaplama işinden sorumlu olan katmandır. Girdi, bu katmana ulaştığında her filtreyi girdinin uzamsal boyutsallığı boyunca bükerek iki boyutlu bir aktivasyon eşleşmesi üretmektedir. Evrişimli katman, katmandan çıkan verinin karmaşıklığının azaltılması ve optimize edilebilmesi için hiperparametre, derinlik, adım ve sıfır dolgusu kullanılmaktadır. Havuz katmanı, hesaplama karmaşıklığını azaltmak amacıyla aşırı uyumluluğu kontrol altına alarak modelin boyutluluğunu ve çok parametreliliğini daha da azaltmaya çalışmaktadır. Havuz katmanı, giriş katmanındaki her bir aktivasyon eşleşmesi üzerinde maksimum havuzlama işlevini kullanarak mekansal olarak yeniden boyutlandırılmaktadır. Tam bağlı katman, önceki katmanlara ait olan tüm aktivasyonlara bağlantılara sahip olan nöronları içermektedir. Evrişimli ve havuzlama katmanında yapılan birçok hesaplamadan sonra sinir ağındaki karar tamamen birbirine bağlı katmanlar ile verilmektedir. Uzun kısa süreli bellek (LSTM) [21], uzun süreli bağımlılıkları anlayabilen tekrarlı sinir ağı modeli üzerine geliştirilmiş standart beslemeli sinir ağlarının aksine, geri bildirim bağlantıları bulunan bir derin öğrenme modelidir. LSTM, bir RNN modeli gibi çalışıyor olsa da hafıza, yinelenen gizli katman blokları adı verilen özel bileşenler ile geçit adı verilen birimlerle bilgi akışını kontrol etmektedir ve ağı durumunu kayıt eden hafıza hücreleri barındırmaktadır. Hafıza blokları bir ya da daha fazla hafıza hücrelerinden oluşan ve bu hücrelerin paylaştığı toplamsal ve çarpımsal geçit birimlerinden oluşan temel birimdir. Her LSTM birimi, hangi bilgi bölümlerinin hatırlanacağını, unutulacağını ve bir sonraki adıma geçeceğini kontrol etmek için giriş, unutma ve çıkış geçitleri içermektedir. Bir LSTM ağı, giriş katmanından gelen veri dizisinden ağ aktivasyonlarını hesaplayarak çıkış katmanının veri dizisine iletilmek üzere hesaplama yapar. Evrişimli Uzun Kısa Dönem Hafıza Ağı (ConvLSTM) [22], hem girdiden duruma hem de durumdan duruma geçişlerde evrişimli yapılara sahip olan uzay-zamansal tahmin için tekrarlayan bir sinir ağı türüdür. ConvLSTM, evrişimdeki belirli bir hücrenin gelecekteki durumunu, yerel komşularının girdileri ve geçmiş durumlarıyla belirler. Bu, durumdan duruma ve girişten duruma geçişlerde bir evrişim operatörü kullanılarak kolayca başarılabilir. ConvLSTM modelinin yağış tahmini, nesne algılama, trafik kazası tahmini, Covid-19 vaka sayısı tahmini gibi uygulama alanları bulunmaktadır. CNN uzun kısa süreli bellek ağı veya kısaca CNN-LSTM [15], zaman serileri, görüntüler, videolar gibi mekansal girdilerle ilgili dizi tahmin problemleri için özel olarak tasarlanmış bir LSTM mimarisidir. CNN-LSTM mimarisi,

dizi tahminini desteklemek için LSTM ile birlikte giriş verilerinde özellik çıkarımı için konvolüsyonel sinir ağı katmanlarının kullanılmasını içermektedir. CNN-LSTM yapıları, zaman serilerini görsel olarak tahmin etmek ve video gibi görüntü dizilerinden video gibi metin açıklamaları oluşturmak için tasarlanmıştır. Özellikle, bir dizi görüntüde gösterilen bir aktivitenin metinsel bir tanımını oluşturmada, tek bir görüntü için bir metin açıklamasını oluşturmada, bir dizi görüntünün metinsel bir açıklamasını oluşturmada tercih edilen yöntemlerden birisidir. Özetle, CNN-LSTM mimarisi hem mekansal hem de zamansal olarak sıralı giriş ve çıkışları içeren çeşitli görevlere uygulanacak esnekliğe sahip bir modeldir.

3.4. Derin Bağlamsallaştırılmış Kelime Temsilleri (Deep Contextualized Word Representations)

Kelime kullanımının söz dizimi, semantik gibi karmaşık özelliklerini ve bu kullanımların dil bağlamları arasında nasıl değiştiğini modelleyen yöntemler derin bağlamsallaştırılmış kelime temsilleri olarak bilinmektedir. Yeni nesil kelime temsilleri olarak bilinen yöntemler arasında, Çift yönlü kodlayıcı gösterimleri (BERT), çok dilli çift yönlü kodlayıcı gösterimleri (MBERT), damıtılmış çift yönlü kodlayıcı gösterimleri (DistilBERT), dil modellerinden yerleştirme yöntemi (ELMo), evrensel dil ince ayar modeli (ULMFiT), Kelime Değişimlerini Doğru Bir Şekilde Sınıflandıran Bir Kodlayıcıyı Etkin Bir Şekilde Öğrenen ELECTRA modeli, Sağlam Bir Şekilde Optimize Edilmiş BERT Ön Eğitim Yaklaşımı (RoBERTa), Üretken Ön Eğitimli Transformatör 2 (GPT-2) modeli gibi birçok model yer almaktadır. BERT [23], kökenlerini yarı denetimli sıralı öğrenme, üretken ön eğitim, ELMo ve ULMFiT dahil olmak üzere eğitim öncesi bağlamsal temsillerden almaktadır. Önceki modellerden farklı olarak, BERT, yalnızca düz bir metin külliyatı kullanılarak önceden eğitilmiş, çift yönlü, denetimsiz bir dil temsilidir. Word2Vec veya GloVe gibi bağlamdan bağımsız modeller, kelime haznesindeki her kelime için tek bir kelime gömme oluşturur. BERT ise belirli bir kelimenin her bir oluşumu için bağlamı dikkate alır. Duygu analizi, metin sınıflandırma, hikâye sonu tahmini gibi birçok konu üzerinde BERT ile modellemeler yapılmaktadır. Ayrıca, hisse senedi getirisi tahmini, borsa için duygu analizi, finansal metinlerde anahtar bilgilerin çıkarımı gibi yapılan finans alanındaki çalışmalarda da yüksek başarı elde edilmiştir. Çok dilli çift yönlü kodlayıcı gösterimleri (MBERT) [24] ise yüzden fazla dilde çalışabilen çok dilli bir BERT sürümüdür. MBERT modeli, evrensel bir dil modeli oluşturmak ve cümleleri kodlamak için bir araç görevi görmesi amacıyla 104 dilde eğitilmiştir. Yapılan çalışmalar, MBERT modelinin tek dilli versiyonlarına kıyasla daha düşük performans sergilediğini ve çoğu durumda iyi eğitilmiş tek dilli bir modelin yerini tutamayacağını göstermiştir.

DistilBERT [25], BERT' i damıtılarak eğitilmiş küçük, hızlı, ucuz ve hafif bir transformer modelidir. BERT'ten %40 daha az parametreye sahiptir ve %60 daha hızlı çalışır. Yüksek performansı ve hızı sebebiyle birçok araştırmacı DistilBERT'i çalışmalarında kullanmış olup bu çalışmalar çoğunlukla haber sınıflandırma, cevap seçimi, duygu tanıma gibi alanlarda yürütülmüştür. RoBERTa [25], BERT modelini iyileştiren doğal dil işleme sistemlerini önceden eğitmek için sağlam bir şekilde optimize edilmiş bir yöntemdir. Belirli bir görev için özel olarak etiketlenmiş bir dil külliyatının aksine, internetten alınan açıklamasız metinleri baz alır. RoBERTa özellikle doğal dil işlemede yaygın olarak kullanılan genel dil anlama değerlendirme (GLUE) üzerinde başarılı sonuçlar üretmektedir. ELMo [26], hem kelime kullanımının karmaşık özelliklerini hem de bu kullanımların dilbilimsel bağlamları arasında nasıl değiştiğini modelleyen derin bağlamsal bir kelime temsilidir. Bu kelime vektörleri, büyük bir metin külliyatı üzerinde önceden eğitilmiş derin bir çift yönlü dil modelinin iç durumlarının öğrenilmiş işlevleridir. Mevcut modellere kolayca eklenebilirler ve soru cevaplama, metin düzenleme, duygu analizi dahil olmak üzere çok çeşitli zorlu doğal dil işleme problemlerinde

başarılı şekilde çalışır. GPT-2 [26] modeli, 8 milyon internet sayfasından oluşan bir veri kümesi üzerinde eğitilmiş 1,5 milyar parametreye sahip büyük bir transformatör tabanlı dil modelidir. GPT-2, bir metinde önceki tüm kelimeler verildiğinde bir sonraki kelimeyi tahmin etme gibi basit bir amaç için eğitilmiştir. Veri kümesinin çeşitliliği, bu hedefin, çeşitli alanlardaki birçok görevin doğal olarak meydana gelen gösterimlerini içermesine neden olmuştur. ULMFiT modeli, en gelişmiş dil modeli olan LSTM mimarisini kullanır. LSTM ağının bu mimaride üç katmanı bulunmaktadır. Bu tek mimari, baştan sona eğitimin yanı sıra ince ayar için de kullanılır. Yöntem, birçok metin sınıflandırma görevinde son teknoloji yöntemleri önemli ölçüde geride bırakarak, veri kümelerinin çoğunda hatayı %18-24 oranında azaltmaktadır [27]. Kullanım kolaylığı ve performansı açısından çoğu araştırmacı tarafından metin sınıflandırma ve duygu analizi alanlarında uygulanmaktadır. BERT gibi maskelenmiş dil modelleme (MLM) ön eğitim yöntemleri, bazı simgeleri maskeleyip değiştirerek girdiyi bozmakta ve ardından orijinal simgeleri yeniden yapılandırmak için bir model eğitmektedir. Bu yöntemler, doğal dil görevlerinde iyi sonuçlar verirken, genellikle etkili olmak için büyük miktarda hesaplama gerektirirler. Alternatif olarak, kelime değişimlerini doğru bir şekilde sınıflandıran kodlayıcıyı etkin şekilde öğrenme modeli olan ELECTRA [28] ile değiştirilen simge tespiti açısından daha verimli bir ön eğitim gerçekleştirilir. Öğrenilen bağlamsal temsiller, aynı model boyutu ve veriler sunulduğunda BERT tarafından öğrenilenlerden önemli ölçüde daha iyi performans sergilediği ve ELECTRA'nın özellikle küçük modeller için güçlü olduğu vurgulanmıştır.

3.5. Duygu Analizi (Sentiment Analysis)

Duygu analizi, temelde, metinlerin içerisinde gizlenmiş olan görüşlerin ve duyguların anlaşılması, bu görüşlerin uygun yöntemler ile olumlu, olumsuz ya da tarafsız olarak etiketlenmesini amaçlamaktadır. Çalışmamızda, 11 Temmuz 2019 ve 11 Temmuz 2020 tarihleri arasında #XAU/USD etiketiyle Twitter ortamından paylaşılan İngilizce yorumlar toplanmış ve veri kümesi üzerinde finansal duygu analizi gerçekleştirebilmek için ilk aşamada naif Bayes modelinden yararlanılmıştır. Naif Bayes modelinin eğitilmesinden önce tüm veri kümesini alıntılara ve etiket temizleme, noktalama işaretlerinin temizlenmesi, kaçış karakterlerinin temizlenmesi, bağlantıların ve diğer web sitesi adreslerinin temizlenmesi, HTML öğelerinin temizlenmesi, yüz ve diğer ifade öğelerinin temizlenmesi, elektronik posta adreslerinin temizlenmesi gibi ön işleme aşamalarından geçerek temizlenmiş ve etiketlenmek üzere hazır hale getirilmiştir. Naif Bayes algoritması, özellikle duygu analizi ve benzeri sınıflandırma problemlerinde kullanılan [29, 30], uygulaması basit ve hızlı, olasılıkları ve koşullu olasılıkları hesaplamak için Bayes Teorisi'ni kullanan bir sınıflandırma modelidir. Naif Bayes, şartlı bir olasılık modeli olduğundan modelin eğitilmesi için bir dizi etiketli veriye ihtiyaç duymaktadır. Çalışmamızda, bu algoritmayı uygulayan ve İngilizce dili için ön eğitimli bir model sağlayan TextBlob kütüphanesinin sunmuş olduğu sınıflardan naif Bayes' in yanı sıra CNN, RNN, LSTM, Word2Vec, Glove, fastText, BERT, M-BERT, DistilBERT, ELMo, ULMFiT, RoBERTa, ELECTRA, GPT-2 modelleriyle de etiketleme işlemi gerçekleştirilmiştir. Her bir modelden elde edilen doğruluk sonuçlarından Bölüm 4' te bahsedilmektedir. Toplamda 37,668 adet doküman modelleme sonucunda etiketlenmiştir. Tablo 1'de ön işleme uygulandıktan sonra elde edilen metinlerin bir kısmına ait kategori bilgisi sunulmuştur.

3.6. Önerilen Model (Proposed Model)

Önerilen modelin temelinde, duygu analizinden elde edilen sonuçlarla altın endeksinin yönüne etki eden indikatör değerlerinin harmanlanması ve derin öğrenme yöntemleriyle modellenerek altın

endeksine dair yön tahmininde bulunulması hedeflenmektedir. Bu amaçla ilk aşamada, 11 Temmuz 2019-11 Temmuz 2020 tarihleri arasında XAU/USD etiketiyle Twitter ortamından toplanmıştır. Bölüm 3.1’de bahsedilen ön işleme adımları uygulandıktan sonra toplamda 37,668 adet yorum elde edilmiştir. Yorumları, pozitif ve negatif olarak kategorize edebilmek için 15 farklı algoritma kullanılmıştır. Bu algoritmalarından, en iyi performansı %95,99 doğrulukla DistilBERT algoritması sergilemiştir. Etiketleme işlemi ile toplamda 37,668 dokümandan 23,152 adet pozitif ve 14,516 adet negatif yorum elde edilmiştir. Veri kümesi incelendiğinde doküman başına ortalama kelime sayısı 36,17 iken ortalama kelime uzunluğu 6,72 olarak tespit edilmiştir. İkinci aşamada, duygu analizinin gerçekleştirildiği 11 Temmuz 2019-11 Temmuz 2020 tarih aralığıyla aynı olacak şekilde günlük olarak altın endeksinin yönüne etki eden indikatörlerin değerleri toplanmıştır. XAU/USD endeksinin yönünü belirlemede etkili olabilecek göstergeler, yine Selenium kütüphanesi yardımıyla investing.com internet sitesi üzerinden toplanmıştır. Özellikler içerisinde yer alan XAUUSD_Class ve DXY_Class parametrelerinin değeri, gün içi açılış değerinin gün içi kapanış değerinden çıkartılmasıyla elde edilmektedir. Elde edilen değer, 0’ dan büyükse negatif, 0’ dan küçük ise o günkü etiket değeri pozitif olarak etiketlenmiştir. Veri kümesinin özellik çeşitliliğini arttırmak için 1 ons altının bazı indikatörleri de özellik kümesine eklenmiştir. Bu indikatörler 5, 10, 20, 50 ve 100 günlük basit hareketli ortalama (SMA), 14 günlük göreceli güç endeksi (RSI) ve Bollinger bandının üst, orta ve alt değerlerinden oluşmaktadır. İlgili tarih aralığındaki altın ve

dolar endeksine dair açılış ve kapanış değerlerini Selenium aracılığıyla toplamakta sıkıntı yaşanmamasına rağmen indikatörlerin değerleri elde edilememiştir. Bu sebeple, geçmişe yönelik indikatör değerlerinin elde edilmesi için TA-lib isimli teknik analiz kütüphanesinde faydalanılmış ve yukarıda bahsedilen indikatörlerin değerleri hesaplanmıştır. Altın ve dolar endeksiyle ilgili değerler toplandıktan sonra, duygu analizinden elde edilen duygu skoru, yorum adedi ve duygu yüzdesi olmak üzere 3 adet özellik veri kümesine parametre olarak eklenmiş ve altın endeksinin yönünü tahminlemedeki başarısı gözlemlenmek istenmiştir. Sonuç olarak, duygu analizinden elde edilen özelliklerle altın endeksinin yönüne etki eden indikatörler harmanlanarak derin öğrenme temelli zaman serisi modellerinde kullanılacak veri kümesi elde edilir. Modellemede kullanılacak veri kümesinin detayları Tablo 2’de sunulmuştur. Modellemeye hazır olan veri kümesi kullanılarak derin öğrenme tabanlı zaman serisi modelleriyle 1 ons altının gelecek değer tahmininde ne kadar etkili olabileceği gözlemlenmek istenmiştir. Bu amaçla, çalışmada çok katmanlı algılayıcı (MLP), evrişimli sinir ağları (CNN), uzun kısa dönem hafıza ağları (LSTM), CNN-LSTM, evrişimli uzun kısa dönem hafıza ağları (ConvLSTM) olmak üzere 5 farklı derin öğrenme temelli zaman serisi modeli değerlendirilmiştir. Bunlardan CNN-LSTM ve ConvLSTM hibrid modeller olarak önerilen modelde değerlendirilmiştir.

Şekil 1’de önerilen modelin mimarisi sunulmuştur. Önerilen modellerin doğruluğunu test etmek için eğitim aşaması öncesi veri

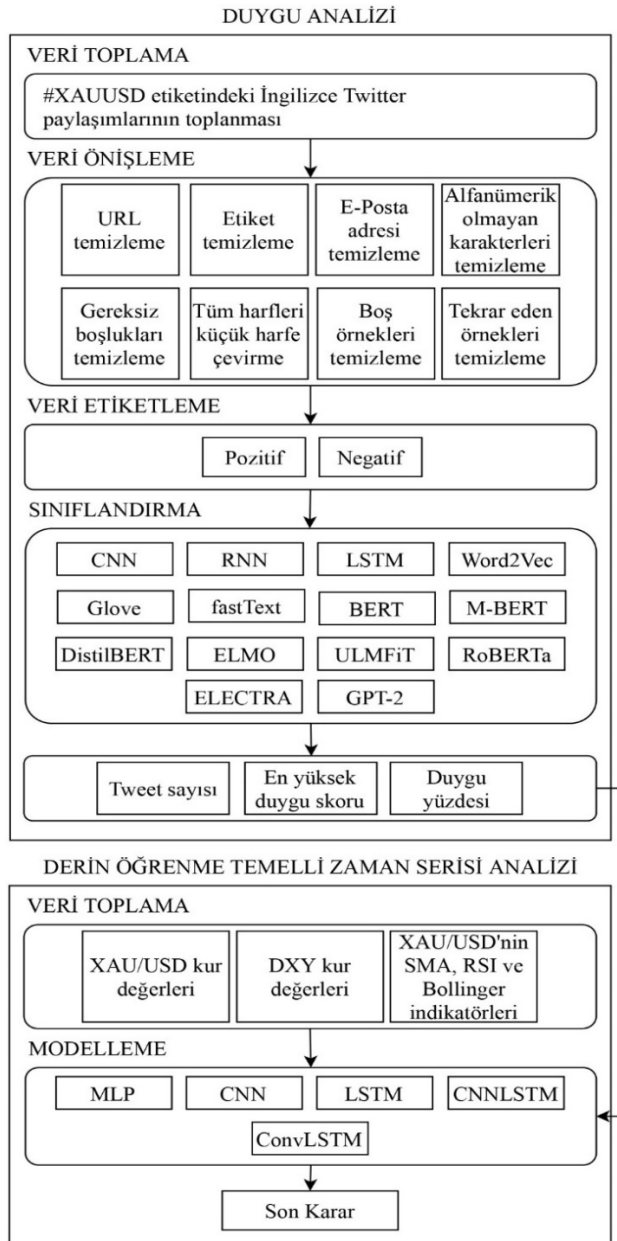
Tablo 1. Ön işleme sonrası veri kümesinin içeriği (Content of the data set after preprocessing.)

İçerik	Kategori
risk appetite is rising on positive news as the surges let s see what else is going on in today	Pozitif
trying to touch the under stoploss	Negatif
gold much better	Pozitif
gold looking to short around area 1615 1625	Negatif
gold is safe heaven tradingview	Pozitif
sell xau usd on 4h time frame current price 1 421 72 bulls power 0 bears power 91	Negatif

Tablo 2. Modellemede kullanılacak veri kümesinin özellikleri (Characteristics of the data set to be used in modeling)

Özellik	Açıklama
Date	Tarih bilgisi
XAUUSD_Price	1 ons altının o günkü kapanış değeri.
XAUUSD_Open	1 ons altının o günkü açılış değeri.
XAUUSD_High	1 ons altının o günkü en yüksek değeri.
XAUUSD_Low	1 ons altının o günkü en düşük değeri.
XAUUSD_Class	1 ons altının o günü pozitif kapatıp kapatmadığını gösteren değer.
DXY_Price	Dolar endeksinin o günkü kapanış değeri.
DXY_Open	Dolar endeksinin o günkü açılış değeri.
DXY_High	Dolar endeksinin o günkü en yüksek değeri.
DXY_Low	Dolar endeksinin o günkü en düşük değeri.
DXY_Class	Dolar endeksinin o günü pozitif kapatıp kapatmadığını gösteren değer.
XAUUSD_SMA_5	1 ons altının 5 günlük basit hareketli ortalaması.
XAUUSD_SMA_10	1 ons altının 10 günlük basit hareketli ortalaması.
XAUUSD_SMA_20	1 ons altının 20 günlük basit hareketli ortalaması.
XAUUSD_SMA_50	1 ons altının 50 günlük basit hareketli ortalaması.
XAUUSD_SMA_100	1 ons altının 100 günlük basit hareketli ortalaması.
XAUUSD_SMA_200	1 ons altının 200 günlük basit hareketli ortalaması.
XAUUSD_RSI_14	1 ons altının 14 günlük göreceli güç endeksi.
XAUUSD_UpperBand	1 ons altının Bollinger bandının üst bant değeri.
XAUUSD_MiddleBand	1 ons altının Bollinger bandının orta bant değeri.
XAUUSD_LowerBand	1 ons altının Bollinger bandının alt bant değeri.
Sentiment_Score	O gün paylaşılan yorumlardan en başarılı modelin elde ettiği doğruluk değeri.
Tweet_Count	O gün paylaşılan yorum sayısı.
Sentiment_Percentage	O gün paylaşılan yorumların olumluluk yüzde oranı.

kümesi %80' i eğitim, %20' si test kümesi olmak üzere ayrılmıştır. MLP modeli, 8 nöron ve 1 adet dense katmanından oluşmaktadır. Katmanda kullanılan aktivasyon fonksiyonu olarak ReLU seçilmiştir. Buna ek olarak, regülarizatör olarak ADAM, kayıp değeri olarak ise ortalama hata karesi (MSE) seçilmiştir. Bunun yanında, yığın boyutu olarak 8, iterasyon değeri ise 500 atanmıştır. CNN modeli hem duygu analizi hem de önerilen modelin inşasında kullanıldığından parametre değerleri de farklılık göstermektedir. Duygu analizi kısmında, 3 tane tek boyutlu konvolüsyon katmanı ve global maksimum tipinde havuzlama katmanı kullanılmıştır. Tek boyutlu 3 adet konvolüsyon katmanının ilkinde 16, ikincisinde 8, üçüncüsünde ise 4 filtre kullanılmıştır. Ayrıca tüm konvolüsyon katmanlarının çekirdek boyutu 16, aktivasyon fonksiyonları ise ReLU olarak ayarlanmıştır. Son konvolüsyon katmanından sonra global maksimum tipinde havuzlama katmanı yerleştirilmiştir ve boyutu varsayılan olarak ayarlanmıştır. Aktivasyon fonksiyonu sigmoid, regülarizatör tipi ADAM olarak atanmıştır.



Şekil 1. Önerilen modelin mimarisi (Architecture of the proposed model)

Buna ek olarak yığın boyutu 16, iterasyon sayısı ise ezberleme başladığı anda duracak şekilde ayarlanmıştır (early stopping). Zaman serisi analizinde önerilen model için kullanılan CNN modelinin inşasında 4 adet konvolüsyon katmanı, global maksimum tipinde havuzlama katmanı, düzleştirme katmanı (flatten layer) ve tamamen bağlı katman (fully connected layer) ve çıkış katmanı kullanılmıştır. Birinci konvolüsyon katmanı 64, ikincisi 32, üçüncüsü 16, dördüncüsü 8 filtreden oluşmaktadır. Çekirdek boyutu 2, aktivasyon fonksiyonu ise ReLU olarak ayarlanmıştır. Sonuncu konvolüsyon katmanından sonra duygu analizindeki gibi global maksimum tipinde havuzlama katmanı kullanılmıştır ve boyutu 2 olarak ayarlanmıştır. Onu düzleştirme katmanı ve ardından 4 nöronlu aktivasyon fonksiyonu ReLU olan tamamen bağlı katman takip etmektedir. Ezberlemeyi önlemek için regülarizatör tipi ADAM olarak atanmış kayıp değeri MLP modelindeki gibi MSE seçilmiştir. Buna ek olarak yığın boyutu 8 ve iterasyon sayısı 1000 olarak ayarlanmıştır. RNN modelinde duygu analizinde kullanılmış olup 3 adet basit RNN katmanı ve çıkış katmanı ile inşa edilmiştir. Birinci basit RNN katmanında 16, ikincisinde 8 ve üçüncüsünde ise 4 nöron bulunmaktadır. Ayrıca tüm basit RNN katmanlarında aktivasyon fonksiyonu olarak ReLU seçilmiştir. Çıkış katmanı olarak 2 nöronlu tam bağlı katman oluşturulmuş aktivasyon fonksiyonu olarak sigmoid, regülarizatör tipi ADAM olarak ayarlanmıştır. Modelin yığın boyutu parametresine 32 değeri atanmış ve ezberlemenin önüne geçmek için erken durdurma kriteri kullanılmıştır.

LSTM modeli, tıpkı CNN gibi hem duygu analizinde hem de zaman serisi modellemede kullanılmaktadır. Duygu analizinde, 3 adet LSTM katmanı kullanılmış olup diğer parametreler RNN modeliyle aynıdır. Zaman serileri analizinde 1 adet LSTM katmanı ve tam bağlı çıkış katmanı kullanılmıştır. LSTM katmanı, 256 nöron, ReLU aktivasyon fonksiyonu, ADAM regülarizatörü kullanılarak 16 yığın boyutu ve 50 iterasyon değerleriyle inşa edilmiştir. CNN-LSTM modelinin oluşturulmasında sırasıyla 1 adet konvolüsyon katmanı, global maksimum tipinde havuzlama katmanı, düzleştirme katmanı ve tam bağlı katman kullanılmıştır. Konvolüsyon katmanında filtre sayısı 64, çekirdek boyutu 8, aktivasyon fonksiyonu olarak ise ReLU seçilmiştir. Ardından gelen global maksimum tipinde havuzlama katmanının boyutu 2 olarak atanmıştır. Ayrıca konvolüsyon, havuzlama ve düzleştirme katmanlarına katman sarıcı olarak TimeDistributed uygulanmıştır. 64 nöronlu ve aktivasyon fonksiyonu ReLU, regülarizatörü ADAM olan LSTM katmanı ile birlikte CNN-LSTM modelinin inşası çıkış katmanı ile tanımlanmıştır. Buna ek olarak yığın boyutu 32, iterasyon değeri ise 500 olarak ayarlanmıştır. ConvLSTM modelinde, 2 adet ConvLSTM katmanı kullanılmış onu takip eden düzleştirme katmanı ve çıkış katmanı ile model inşa edilmiştir. Birinci ConvLSTM katmanında filtre sayısı olarak 64, ikinci ConvLSTM katmanında ise 32 olarak ayarlanmıştır. Bu iki katmanda da çekirdek boyutu olarak sırasıyla 1 ve 2, aktivasyon fonksiyonu ise ReLU, regülarizatörü ADAM olarak kullanılmıştır. Yığın boyutu ve iterasyon sayısı ConvLSTM modeliyle aynıdır. Duygu analizi için değerlendirilen BERT, MBERT, RoBERTa, ELECTRA ve DistilBERT modelleri HuggingFace' in simple transformers kütüphanesiyle eğitilmiştir. Oluşturulan modellerde, BERT için bert-base-uncased, MBERT için bert-base-multilingual-uncased, RoBERTa için roberta-base, ELECTRA için google/electra-base-discriminator ve DistilBERT için ise distilbert-base-uncased isimli modeller kullanılmıştır. Varsayılan değerler haricinde eğitim iterasyon değeri 3 olarak ayarlanmıştır. Öte yandan duygu analizinde kullanılan kelime yerleştirme modellerinden Word2Vec modelinin boyutu 150, window parametresi için 3, min_count parametresi için 1 ve workers parametresi için 16 değerleri atanmıştır. Modelin inşa edilme aşamasında, Word2Vec yerleştirme katmanı, LSTM katmanı ve çıkış katmanı kullanılmıştır. Word2Vec yerleştirme katmanı, Word2Vec nesnesinin get_keras_embedding fonksiyonu kullanılarak oluşturulmuş ve varsayılan parametreler kullanılmıştır. LSTM katmanında 32 nöronlu bir yapı oluşturulmuş aktivasyon fonksiyonu

olarak ReLU ayarlanmıştır. Çıkış katmanında ise 2 nöronlu tam bağlı katman kullanılıp aktivasyon fonksiyonu softmax ve ADAM regülarizatörü seçilmiştir. Yığın boyutu 16 olarak ayarlanmış ve erken durdurma kriteri uygulanmıştır. GloVe modelinin inşa edilme aşamasında, yerleştirme katmanı, LSTM katmanı ve çıkış katmanı kullanılmıştır. Girdi boyutu parametresi, kelime hazinesinin boyutu ve çıkış boyutu parametresi 5 olarak ayarlanmıştır. Yerleştirme katmanından sonra gelen LSTM katmanı ise 32 nörondan oluşmaktadır. Çıkış katmanında kullanılan regülarizatör, aktivasyon fonksiyonu ve yığın boyutları Word2Vec ile birebir aynıdır. FastText modelinin oluşturulmasının öğrenme katsayısı 1.0, iterasyon sayısı 5, kelime n-gram değeri 1, kova değeri 200,000 ve boyut için 50 değeri kullanılmıştır. ULMFiT modelinde, öğrenme katsayısı $1e-2$ olarak değerlendirilip diğer parametreler varsayılan olarak kullanılmıştır. ELMO modelinin inşa aşamasında sırasıyla yerleştirme, LSTM, tam bağlı katman, bırakma katmanı (dropout), tam bağlı katman, bırakma katmanı ve çıkış katmanı kullanılmıştır. Yerleştirme katmanı daha önceden hazırlanmış hazır ELMO modelinden oluşmaktadır. Ardından gelen LSTM, çift yönlü (bidirectional) katmanına sarılmıştır ve 1024 nörondan oluşmaktadır. İlk tam bağlı katman, 512 nörondan ikinci tam bağlı katman ise 256 nörondan oluşmaktadır. Aktivasyon fonksiyonu ReLU regülarizatör olarak ADAM kullanılmıştır. Her tam bağlı katmandan sonra gelen bırakma katmanının parametresi 0,5 olarak ayarlanmıştır. Bunun yanında, yığın boyutu olarak 32, iterasyon sayısı ise 3' tür. GPT-2 modelinin inşasında kullanılan doldurma taraf değeri (padding side) sol ve doldurma kelime (pad token) değeri 50,256 olarak ayarlanmıştır. Oluşturulan hibrid model ile altın endeksi tahmini yapmak isteyen herhangi bir kullanıcı, yatırımcı veya analist, toplumun nabzını tutan Twitter ortamından edilen duygu analizini gerçek verilerden elde edilen çıkarım ile harmanlayarak daha tutarlı ve kuvvetli bir kur tahmini yapabilmektedir. Sadece zaman serileri analiziyle altın endeksi yönünü tahmin etmektense bireylerin altın endeksinin yönüyle ilgili tahminlerini de dahil etmek, hibrid tahmin modelinin güçlenmesini sağlamaktadır. Ayrıca, önerilen hibrid model, herhangi bir döviz kurunu ya da hisse senedinin yönünü tahmin etmede kullanılabilirliğinden esnek bir yapıya da sahiptir.

4. Deneysel Sonuçları (Experiment Results)

Çalışmamızın bu bölümünde derin öğrenme temelli modellerin altın endeksinin yönünü tahmin etmedeki performansı sunulmaktadır. İlk aşamada, Bölüm 3.6'da da bahsedildiği üzere önerilen model üzerindeki etkisini sergilemek üzere duygu analizine dair özelliklerin veri kümesine eklenerek altın endeksinin yönünün tahmin edilmesi önerilmiştir. Bu amaçla, evrişimli sinir ağları (CNN), tekrarlayan sinir ağları (RNN), uzun kısa dönem hafıza ağları (LSTM), Word2Vec, GloVe, fastText, çift yönlü kodlayıcı gösterimleri (BERT), çok dilli çift yönlü kodlayıcı gösterimleri (MBERT), damıtılmış çift yönlü kodlayıcı gösterimleri (DistilBERT), dil modellerinden yerleştirme yöntemi (ELMo), evrensel dil ince ayar modeli (ULMFiT), Kelime

Değişimlerini Doğru Bir Şekilde Sınıflandıran Bir Kodlayıcıyı Etkin Bir Şekilde Öğrenen model (ELECTRA), Sağlam Bir Şekilde Optimize Edilmiş BERT Ön Eğitim Yaklaşımı (RoBERTa), Üretken Ön Eğitimli Transformatör 2 (GPT-2) gibi kelime yerleştirme, derin öğrenme ve yeni nesil derin bağlamsal kelime temsilleri kullanıcıların altın endeksinin yönüne dair duygu skorlarını gerçekleştirmek amacıyla kullanılmıştır. Deneysel sonuçları, 11 Temmuz 2019 ve 11 Temmuz 2020 tarihlerini kapsayan aralıkta %95,99 doğruluk ile DistilBert modelinin duygu analizini en iyi performansla gerçekleştirdiğini göstermektedir. Onu, %95,85 ile BERT, %95,81 ile M-BERT, %94,80 ile ELECTRA, %93,94 ile Roberta, %93,40 ile ULMFiT, %92,95 ile FastText, %84,24 ile GPT-2, %69,79 ile RNN, %69,69 ile LSTM, %68,54 ile CNN, %62,55 ile GloVe, %61,86 ile Word2Vec, %47,76 ile Elmo ve %56,28 naif Bayes modeli takip etmektedir. Bu nedenle, duygu analizini kapsayan özelliklerin veri kümesine dahil edilmesi aşamasında DistilBert modelinden elde edilen duygu skorları kullanılmıştır.

Sonrasında önerdiğimiz derin öğrenme temelli zaman serileri analizi ile altın endeksinin yönünü tahminlemeyi hedefliyoruz. Bu amaçla kullanılan yöntemler çok katmanlı algılayıcı (MLP), CNN ve LSTM derin öğrenme modelleri, CNN-LSTM ve Conv-LSTM hibrid derin öğrenme modelleridir. Altın endeksinin yönünü tahmin etmede önerilen modelin başarısını göstermek amacıyla ortalama mutlak hatası (MAE), ortalama mutlak yüzde hatası (MAPE), ortalama kare hatası (MSE) ve R kare puanı (R^2) değerlendirme metrikleri kullanılmıştır. Tablo 3'te kullanılan modellerin yukarıda bahsedilen değerlendirme metrikleriyle performansları duygu analizine dayalı özelliklerin dahil edildiği durumda sunulmuştur. Tablo 4'te ise duygu analizine dayalı özelliklerin veri kümesine dahil edilmediği durumda derin öğrenme temelli zaman serisi modellerinin performansları sergilenmiştir. Böylece, duygu analizini ifade eden duygu skoru parametrelerinin önerilen modele de etkisi de incelenmiştir. Tablo 3 ve Tablo 4'teki sonuçlar dikkate alındığında duygu skoru özelliklerinin modele dahil edildiği durumda sonuçlarda kayda değer iyileşme gözlenmiş CNN modelin her iki durumda da en iyi performansa sahip derin öğrenme modeli olduğu görülmüştür. Tablo 3 ve Şekil 2'den de açıkça görüldüğü üzere MLP modeli yapay sinir ağlarının temelini oluşturan bir yapı olmasına rağmen zaman serisi tahminleri için kullanıldığında diğer modellerin sonuçlarına yakın bir performans sergileyerek rekabetçi bir model olduğu gözlenmektedir. Tablo 3'teki ortalama mutlak yüzde hatası sonuçları değerlendirildiğinde MLP modelinin LSTM ve CNN-LSTM modellerine kıyasla önerilen modele daha uygun olduğu fakat CNN modeliyle kıyaslandığında modelin yeterli olmadığı görülmektedir. Daha fazla katman sayısına ve karmaşıklığa sahip LSTM, CNN-LSTM ve Conv-LSTM modelleri düşünüldüğünde MLP modeli hem daha basit hem de daha iyi bir tahmin performansı sergilemesi nedeniyle diğer modellerden üstündür.

Tablo 3. Duygu analizine dayalı özelliklerin dahil edilmesiyle elde edilen derin öğrenme temelli zaman serisi modellerinin performansı (Performance of deep learning based time series models obtained by the inclusion of sentiment analysis-based features)

	MLP	CNN	LSTM	CNN-LSTM	ConvLSTM
MAPE	3,7430	2,8611	4,4896	4,4249	4,1610
MAE	0,0646	0,0499	0,0776	0,0766	0,07197
MSE	0,0059	0,0036	0,0096	0,0094	0,0067
R^2	0,9420	0,9638	0,9051	0,9072	0,9338

Tablo 4. Duygu analizine dayalı özelliklerin dahil edilmediği durumda derin öğrenme temelli zaman serisi modellerinin performansı (Performance of deep learning based time series models when sentiment analysis based features are not included)

	MLP	CNN	LSTM	CNN-LSTM	ConvLSTM
MAPE	4,9893	4,9630	5,9920	5,5944	6,4993
MAE	0,0858	0,0850	0,1042	0,0969	0,1130
MSE	0,0098	0,0096	0,1681	0,1365	0,1806
R^2	0,9036	0,9054	0,8353	0,8663	0,8158

Şekil 2’de altının ons fiyatının 11 Temmuz 2019 ve 11 Temmuz 2020 tarihleri arasındaki hareketleri altının gerçek değeri ve MLP modeliyle tahmin edilen değerleri ile gözlenmektedir. Veri

kümemizin yaklaşık 3 aylık zaman dilimini kapsayan test kümesinin gerçek altın değeri ve MLP modeliyle elde edilen tahmin değeri ile örtüşebildiği ve altın endeksinin yönünü tahminlemede oldukça



Şekil 2. MLP yöntemi ile altın endeksi fiyat tahmini (Gold index price estimation by MLP method)



Şekil 3. CNN yöntemi ile altın endeksi fiyat tahmini (Gold index price estimation by CNN method)



Şekil 4. LSTM yöntemi ile altın endeksi fiyat tahmini (Gold index price estimation by LSTM method)



Şekil 5. CNN-LSTM yöntemi ile altın endeksi fiyat tahmini (Gold index price estimation by CNN-LSTM method)



Şekil 6. ConvLSTM yöntemi ile altın endeksi fiyat tahmini (Gold index price estimation by ConvLSTM method)

başarılı olduğu açıkça gözlenmektedir. Tablo 3 ve Şekil 3 incelendiğinde CNN yönteminin 2,8611 ortalama mutlak yüzde hatası ile altın yönünü ve fiyatını tahmin etmede en başarılı model olduğu görülmektedir. Test verisi üzerinde belirtilen aralıklarda altın ons fiyatının tahmin edilen fiyat değeriyle neredeyse bire bir örtüştüğü gözlenmiştir. Modelin sunduğu bu sonuçlara dayanarak 1 ons altının gelecek değerini tahminlemede CNN modelinin kayda değer sonuçlar sunduğu araştırmacı ve yatırımcılara teknik anlamda destek sağlayabileceği öngörülmektedir. Şekil 4, Şekil 5 ve Şekil 6 incelendiğinde LSTM derin öğrenme modeli ile CNN-LSTM ve Conv-LSTM hibrid derin öğrenme modellerinin performanslarının birbirine çok yakın olduğu gözlenmektedir. Conv-LSTM modeli CNN-LSTM ve LSTM modeline göre daha az hata payına sahip olsa da CNN modelinin gerisinde kalmıştır. Ayrıca çalışmada kullanılan modellerin her birinin R^2 değerleri incelendiğinde en az yaklaşık 0,9 civarında bir performans sergilediği ve hiçbir modelin bu değer altını sarkmadığı görülmektedir. Bu da altın fiyat endeksinin yön tahmini için seçilen modellerin, problemin çözümüne uygun modeller olduğunu göstermektedir. Çalışmamızda kullanılan derin öğrenme temelli modellerin genel başarı sıralaması CNN> MLP> ConvLSTM>

CNN-LSTM> LSTM şeklindedir. Bu durumda önerdiğimiz altın endeksi yönü tahmini için en uygun yöntem CNN modelidir.

5. Sonuçlar (Conclusion)

Bu çalışmada, derin öğrenme metodolojisi temelli altın endeksinin yönünü tahmin eden bir modelin oluşturulması amaçlanmıştır. Önerilen model, altın endeksine ait gerçek zamanlı verilerle metin içerikli verilerin harmanlanması sonucu elde edilmiş olup hem bu yönüyle hem de yön tahmininde kullanılan hibrid derin öğrenme yöntemleri açısından hibrid bir tahmin modeli özelliği de taşımaktadır. Bildiğimiz kadarıyla bu çalışma, sosyal medya platformunu finansal duygu analizi amacıyla kaynak olarak kullanan ve bunu sayısal verilerle harmanlayarak altın endeksi için derin öğrenme temelli yön tahmin modeli oluşturan literatürdeki ilk çalışma niteliğindedir. Kapsamlı deneyler sonucunda, duygu analizinde en iyi performansı sergileyen DistilBERT modelinin ürettiği duygu skorlarıyla altın endeksinin çeşitli indikatörlerden oluşan değerler harmanlanmış ve harmanlanan veri kümesi MLP, CNN, LSTM, CNN-LSTM ve ConvLSTM yöntemleriyle modellendiğinde CNN

yönteminin altın endeksinin yönünü tahmin etmeden kayda değer bir potansiyelinin olduğu görülmüştür.

Kaynaklar (References),

- Sohangir S., Wang D., Pomeranets A., Khoshgoftaar T.M., Big Data: Deep learning for financial sentiment analysis, *J Big Data* 5 (1), 1-25, 2018.
- Day M., Lee C., Deep learning for financial sentiment analysis on finance news providers, *IEEE/ACM International Conference on Advances in Social Networks Analysis and Mining*, San Francisco, California, 1127-1134, 18-21 Ağustos, 2016.
- Bollen J., Mao H., Zeng X., Twitter mood predicts the stock market, *Journal of Computational Science*, 2 (1), 1-8, 2011.
- Smailović J., Grčar M., Lavrač N., Žnidaršič M., Stream-based active learning for sentiment analysis in the financial domain, *Information Sciences*, 285, 181-203, 2014.
- Bing L., Chan K.C.C., Ou C., Public sentiment analysis in twitter data for prediction of a company's stock price movements, *IEEE 11th International Conference on E-Business Engineering*, Guangzhou, China, 232-239, 5-7 Kasım, 2014.
- Kilimci Z.H., Duvar R., An efficient word embedding and deep learning based model to forecast the direction of stock exchange market using twitter and financial news sites: A case of Istanbul stock exchange (BIST 100), *IEEE Access*, 8, 188186-188198, 2020.
- Kilimci Z.H., Financial sentiment analysis with deep ensemble models (DEMs) for stock market prediction, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 35 (2), 635-650, 2019.
- Yasar H., Kilimci Z.H., US Dollar/Turkish Lira exchange rate forecasting model based on deep learning methodologies and time series analysis, *Symmetry*, 12 (9), 1553-1571, 2020.
- Kilimci Z.H., Sentiment analysis based direction prediction in bitcoin using deep learning algorithms and word embedding models, *International Journal of Intelligent Systems and Applications in Engineering*, 8 (2), 60-65, 2020.
- Yakut E., Elmas B., Yavuz S., Yapay sinir ağları ve destek vektör makineleri yöntemleriyle borsa endeksi tahmini, *Süleyman Demirel Üniversitesi İktisadi İdari Bilimler Fakültesi Dergisi*, 19 (1), 139-157, 2014.
- Kutlu B., Badur B., Yapay sinir ağları ile borsa endeksi tahmini, *Yönetim Dergisi*, 20 (63), 25-40, 2009.
- Wang J., Sun T., Liu B., Cao Y., Wang D., Financial markets prediction with deep learning, *17th IEEE International Conference on Machine Learning and Applications*, Orlando, Florida, 97-104, 17-20 Aralık, 2018.
- Shen S., Jiang H., Zhang T., Stock market forecasting using machine learning algorithms, *Proje*, Stanford University, Department of Electrical Engineering, Stanford, 2012.
- Tsai C. F., Wang S. P., Stock price forecasting by hybrid machine learning techniques, *Proceedings of the International Multiconference of Engineers and Computer Scientists*, Hong Kong, China, 755-760, 18-20 Mart, 2009.
- Livieris I. E., Pintelas E., Pintelas P., A CNN-LSTM model for gold price time-series forecasting, *Neural Computing and Applications*, 32 (23), 17351-17360, 2020.
- Pennington J., Socher R., Manning C.D., Glove: Global vectors for word representation, *International Conference on Empirical Methods in Natural Language Processing*, Doha-Qatar, 1532-1543, 25-29 Ekim, 2014.
- Mikolov T., Sutskever I., Chen K., Corrado G.S., Dean J., Distributed representations of words and phrases and their compositionality, *International Conference on Neural Information Processing Systems*, Harrahs and Harveys-Lake, Tahoe, 3111-3119, 5-10 Aralık, 2013.
- Bojanowski P., Grave E., Joulin A., Mikolov T., Enriching word vectors with subword information, *Transactions of the Association for Computational Linguistics*, 5, 135-146, 2017.
- Lipton Z.C., Berkowitz J., Elkan C.A. Critical review of recurrent neural networks for sequence learning. <https://arxiv.org/abs/1506.00019>. Ekim 17, 2015. Kasım 11, 2009. Temmuz 25, 2019.
- O'Shea K. ve Nash R. An introduction to convolutional neural networks. <https://arxiv.org/abs/1511.08458>. Aralık 2, 2015. Temmuz 30, 2019.
- Sak H., Senior A., Beaufays F., Long short-term memory recurrent neural network architectures for large scale acoustic modeling, *Annual Conference of the International Speech Communication Association*, Singapore, 338-342, 14-18 Eylül, 2014.
- Kelotra A., Pandey P., Stock market prediction using optimized Deep-ConvLSTM model, *Big Data*, 8 (1), 5-24, 2020.
- Gao Z., Feng A., Song X., Wu X., Target-dependent sentiment classification with BERT, *IEEE Access*, 7, 154290-154299, 2019.
- Rönnqvist S., Kanerva J., Salakoski T., Ginter F., Is multilingual BERT fluent in language generation?, *Proceedings of the First NLPL Workshop on Deep Learning for Natural Language Processing*, Turku-Finland, 29-36, 30 Eylül, 2019.
- Acheampong F., Nunoo-Mensah H., Wenyu C., Comparative analyses of BERT, RoBERTa, DistilBERT, and XLNet for text-based emotion recognition, *17th International Computer Conference on Wavelet Active Media Technology and Information Processing*, Chengdu, China, 117-121, 18 Eylül, 2020.
- Ethayarajh K., How contextual are contextualized word representations? comparing the geometry of BERT, ELMo, and GPT-2 embeddings, *Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing*, Hong Kong-China, 55-65, 3-7 Kasım, 2019.
- Howard J., Ruder S., Universal language model fine-tuning for text classification, *Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers)*, Melbourne-Australia, 328-339, 15-20 Temmuz, 2018.
- Clark K., Luong M., Le Q.V., Manning C.D., ELECTRA: Pre-training text encoders as discriminators rather than generators, *International Conference on Learning Representations*, Addis Ababa, Ethiopia, 1-18, 26 Nisan-1 Mayıs, 2020.
- Gökdemir A., Çalhan A., Deep learning and machine learning based anomaly detection in internet of things environments, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 37 (4), 1945-1956, 2022.
- Noyan T., Kuncan F., Tekin R., Kaya Y., A new content-free approach to identification of document language: Angle patterns, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 37 (3), 1277-1292, 2022.