



Derin öğrenme ve makine öğrenmesi yöntemleri kullanılarak gelişmekte olan ülkelerin finansal enstrümanlarının etkileşimi ile Bist 100 tahmini

Estimating Bist 100 with the interaction of financial instruments of developing countries using deep learning and machine learning methods

Serap Akbulut^{1,*} , Kemal Adem² 

¹ Aksaray Üniversitesi, Yönetim Bilişim Sistemleri, 68100, Aksaray, Türkiye

² Sivas Bilim ve Teknoloji Üniversitesi, Bilgisayar Mühendisliği Bölümü, 58100, Sivas, Türkiye

Öz

Döviz piyasaları, emtia piyasaları ve gelişmekte olan ülkelerin borsa endekslerinin Bist100 üzerindeki etkisi oldukça önemlidir. Ülke ekonomileri hem kendi hem de diğer ülkelerin ekonomilerine güçlü bir şekilde bağlıdır ve bu sebeple piyasalar etkilenmektedirler. Ekonomik açıdan piyasayı takip etmek kararları doğru verebilmek için tahmin yöntemleri kullanılmaktadır. Veri kümesi Ocak 2017 – Ekim 2021 tarihleri arasındaki kapanış verilerinden oluşmaktadır. Deneysel çalışmalarda objektifliğin sağlanması amacıyla k=5 ve 10 katlı çapraz geçerlilik modeli uygulanmıştır. Modellerin karşılaştırılmasında; Ortalama Mutlak Hata (MAE), Bağlı Mutlak Hata (RAE), Ortalama Karesel Hata Karekökü (RMSE) ve uzun kısa süreli bellek (LSTM) kullanılmıştır. Deneysel çalışmalar sonucunda, LSTM modelinin makine öğrenmesi modellerine göre daha iyi sonuç verdiği görülmüştür. LSTM modeli için test sonuçları incelendiğinde MAE değeri 10.27, RMSE değeri 14.15 ve RAE değeri ise 6.06'dır.

Anahtar kelimeler: Yapay zeka, Derin öğrenme, Veri madenciliği, Finansal tahmin

1 Giriş

Borsa kavramı genel olarak, alıcı ve satıcının ya da vekillerinin bir araya geldiği pazarlardır. Bu pazarlar da satıcılar/alıcılar, menkul kıymetler ile bu türden kıymet olarak kabul edilen değerler üzerinde alım satım işlemi gerçekleştirmek amacıyla bir araya gelirler. Alım satım işlemi yapılan pazarlar, belirli sürelerde ve yerlerde kurulan aynı zamanda belirli kurullarla organize edilen merkezi pazarları ifade etmektedir[1]. Borsa kavramı etimolojik açıdan Belçika'nın Bruges kentinde veya Anvers kentinde 1531 yılında ilk sürekli fuarı olan "Van Der Buers" ailesinin isminden türemiştir[2]. Öncelikle 16. yüzyılda Paris ve Londra'da, 17. yüzyılda Berlin'de, 18. yüzyılda Viyana ve New York'ta 19. yüzyılda ise Brüksel, Roma, Milano, Madrid, Tokyo ve İstanbul borsaları ortaya çıkmıştır. Finansal piyasalar, fon fazlası olan ve fon açığı olan ekonomik birimlerin karşı karşıya geldiği piyasalardır. Ülke ekonomileri hem kendi hem de diğer ülkelerin finans piyasalarına güçlü bir şekilde bağlıdır. Bu yüzden

Abstract

The effect of foreign exchange markets, commodity markets and stock market indices of developing countries on Bist100 is very important. The economies of the countries are strongly dependent on the economies of both their own and other countries, and therefore the markets are affected. Forecasting methods are used to follow the market economically and to make correct decisions. The dataset consists of closing data between January 2017 and October 2021. In order to ensure objectivity in experimental studies, a k=5 and 10-fold cross-validation model was applied. In comparison of models; Mean Absolute Error (MAE), Relative Absolute Error (RAE), Root Mean Square Error (RMSE) and long short-term memory (LSTM) were used. As a result of experimental studies, it has been seen that the LSTM model gives better results than machine learning models. When the test results for the LSTM model are examined, the MAE value is 10.27, the RMSE value is 14.15, and the RAE value is 6.06.

Keywords: Artificial intelligence, Deep learning, Data mining, Financial estimate

piyasalarda ortaya çıkan durumdan etkilenmektedirler. Bunun yanı sıra artık finansal piyasalar sadece stratejik yatırımcılar için değil tasarruflarını değerlendirmek isteyen bireyler için de cazebeli bir yatırım aracı haline gelmiştir. Para ve sermaye piyasalarındaki yatırımcıların amacı, finansal piyasaların hareketlerini inceleyerek analiz etmek ve piyasanın gidişatına göre doğru tahminler yaparak kontrol ettikleri bütçeyi bu doğrultuda kullanmaktır. Bunun için borsalardaki hisse senetleri hareketlerinin dinamikleri doğru anlaşılmalıdır. Söz konusu dinamikler, önceki verilerin değerlendirilerek geliştirilmesini ve gelecek dönemlerde farklı modeller aracılığıyla hisse senetlerinin ne yönde hareket sergileyeceğinin öngörülmesini sağlamaktadır.

Teknoloji ve bilgisayar alanında, sistemin geliştirilebilmesi için farklı öğrenme yaklaşımlarının benimsenmesi, çoğunlukla geleneksel makine öğrenme yaklaşımının kullanılmasının yanı sıra son yıllarda teknoloji ve bilgisayar donanımı konusundaki hızlı gelişmeler ile güçlü bilgisayarlar yaygın şekilde kullanılmaktadır.

* Sorumlu yazar / Corresponding author, e-posta / e-mail: serapaakbulut@gmail.com (S. Akbulut)
Geliş / Recieved: 16.06.2022 Kabul / Accepted: 10.10.2022 Yayınlanma / Published: 15.01.2023
doi: 10.28948/ngumuh.1131191

Geliştirilen modern öğrenme yaklaşımı olan “Derin Öğrenme” ile gerçek dünyadaki uygulama alanlarına yeni yaklaşımlar getirilmiş farklı algoritmalar kullanılarak çoklu soyutlama yapısı ile verilerin temsillerinin öğrenilmesi kolaylaşmıştır[3]. Derin öğrenme, bilgiye ulaşma süresini kısaltmakta ve en doğru bilgiye ulaştırmakta bir araç olarak kullanılmaktadır. Bununla birlikte derin öğrenme yöntemi finans alanında yeni bakış açıları oluşturarak, gelecekte piyasa mekanizması üzerine öngörülerin daha sağlam temellere oturmasını sağlayacaktır. Derin öğrenme verilerin birden fazla özellik seviyesinin ve temsillerinin öğrenilmesine dayanmaktadır. Üst düzey nitelikler, alt düzey niteliklerden türetilerek hiyerarşik bir temsil ortaya çıkartır. Söz konusu temsil, soyutlamanın farklı düzeylerine denk gelen birden çok temsil seviyesini öğrenmektedir. Temel anlamda derin öğrenme, verinin temsilinden öğrenmeye dayanmaktadır.

Borsalar hakkında yapılan çalışmalar hisse senedi fiyat davranışlarının önemli olduğunu, ayrıca borsaların piyasada bulunan bilgilerinin de birer ifadesi olduğunu göstermiştir. Literatürde, Uğur (2009) çalışmasında teknik ve temel analiz değişkenlerinden olan finansal oranları, makroekonomik değişkenler ve hisse senedi geçmiş fiyat verileri ile sanayi, mali ve hizmet sektöründeki hisse senetleri fiyatlarını tahmin etmeye çalışmıştır. Tek yönlü ve iki yönlü sabit yönlü etkiler panel veri ve Arellano-Bond ile Arellano-Bover dinamik panel veri regresyon modelleri kullanılmıştır. Kullanılan modeller sonucunda sanayi sektörü hisse senedi fiyatlarını belirleyen değişkenler; piyasa değeri/defter değeri oranı, enflasyon oranı, faiz oranı, hisse başına kazanç, dönen varlık devir hızı olduğu tespit edilmiştir[4]. Kara ve arkadaşları (2011) çalışmasında BİST 100 endeksinin günlük fiyatlarının yönünü öngörmeye çalışmıştır. İki farklı model geliştirilerek yapay sinir ağları ve destek vektör makineleri (SVM) kullanılmıştır. Endeksin günlük fiyatlarının yönünü tahmin etmedeki performansları karşılaştırılmıştır. Yapay sinir ağlar modelinin ortalama performansı %75.74 destek vektör makinelerinin ise %72,52’lik doğruluk payı söz konusudur. Yapay sinir ağları modelinin önemli ölçüde daha iyi bir performans gösterdiği tespit edilmiştir. Veri setinde belirli teknik indikatörler kullanılmıştır[5]. Akal çalışmasında (2013) BİST 100 endeksi ile Brezilya, Çin, Meksika, Endonezya, Hindistan, Güney Kore ve Rusya borsaları ile Kanada borsası arasındaki ilişkileri inceleyerek verileri analiz etmiştir. Bu çalışma neticesinde kısa dönem nedensellikleri açısından BİST 100 endeksi çoğunlukla Brezilya, Kanada, Meksika ve Çin borsalarının etkisinde kalırken Endonezya borsasının da BİST 100 endeksi altında olduğu ifade edilmiştir. Diğer taraftan BIST100 ile Güney Kore, Hindistan ve Rusya borsaları arasında ilişki bulunmamıştır. Bu borsaların birbirinden bağımsız olduğunu söylemek mümkündür[6]. Fischer ve Krauss (2017), çalışmalarında Uzun Kısa Süreli Bellek (LSTM) ağlarını kullanarak son teknoloji tekniğini ile 1992-2015 tarihleri arasında S&P 500 hisselerinin verilerini kullanarak bir model oluşturmuşlardır. Oluşturdukları LSTM modelinin sonucunda anlamlı Random Forest, Deep Neural Net ve Lojistik Regresyon modellerine göre daha başarılı olduğu sonucuna ulaşmışlardır[7]. Krauss ve arkadaşları (2017)

S&P 500 hisse senetlerinin gelecekteki fiyatlarını öngörebilmek için derin sinir ağlarının, gradyan artırılmış ağaçların, rastgele ormanların ve bu metodların topluluklarının performansını analiz etmişlerdir [8]. Nahil ve Lyhyaoui (2018), yatırımcıların parasını doğru zamanda değerlendirmesine ve kısa vadede daha fazla fayda sağlayabilmesine yardımcı olabilecek vektör makinesi (SVM) ile ilgili yeni bir borsa tahmini yöntemi önermiştir. Sermaye yatırımı endüstrisi açısından zaman serisi tahmininde önemli bir araçtır. Aynı zamanda sınıflandırma üzerine kurulan makine öğrenimi tekniği, finansal verileri daha doğru tahmin edebilmektedir[9]. Vuong, Dat, Mai, Uyen ve Bao (2021) çalışmalarında ilk olarak yüksek boyutlu zaman serisi verilerini ayırt ederek önemli olan özellikleri çıkarmak ve gereksiz özellikleri kaldırmak için aşırı gradyan artırma (XgBoost) uygulamışlardır. Fiyatlarını tahmin etmek için seçilen özellikleri derin öğrenme ağlarından uzun kısa süreli bellek ağına (LSTM) girdi olarak vermişlerdir. Veriler 01.01.2008-03.19.2018 arasında Forex EUR/USD paritesinin 5 dakikalık fiyat, hacim ve volatilitte içeren 200 civarında özellik verilerini kullanarak 60 dakikalık kapanış fiyatlarını tahmin etmişlerdir. Önerdikleri modeli ve ARIMA zaman serisi modelini karşılaştırmak için MAE, MSE ve RMSE ölçüm kriterlerine göre karşılaştırmışlar ve önerilen modelin ARIMA’dan daha iyi sonu verdiğini ortaya koymuşlardır[10]. Hu, Zhao ve Kushi (2021) çalışmalarında 2015-2021 tarihleri arasındaki derin öğrenme yöntemleri ile hisse senedi/forex fiyat hareketlerini tahmin eden 86 makaleyi incelemişlerdir. Yapılan incelemede CNN, LSTM, DNN, RNN, pekiştirmeli öğrenme ve diğer derin öğrenme yöntemleri HAN, NLP ve Wavenet gibi 58 teknik kullanılmıştır. Yapılan araştırma ile sonuçları her bir tekniğe göre karşılaştırmış ve analiz etmişlerdir. (RMSE, MAPE, MAE, MSE, doğruluk, Sharpe oranı ve geri dönüş oranı) ölçüt olarak kullanılmıştır. Sonuç olarak Çoklu derin öğrenme metodlarının kombinasyonunun (melez) eksik olduğuna ve gelecek araştırmalarda hibrid ağları kullanmanın umut verici olduğuna kanaat etmişlerdir[11]. Gavcar ve Metin (2021) Hisse Senedi Değerlerinin Makine Öğrenimi (Derin Öğrenme) ile Tahmini, adlı çalışmalarında derin öğrenme modellerinden LSTM mimarisini kullanılarak Vestel şirketinin hisse senedi açılış fiyatlarının tahminine yönelik bir model geliştirmişlerdir. 2016 ile 2021 yılları arasındaki değerler kullanılarak belirli bir döneme ait hisse senedi değerleri 0,0050 hata ile tahmin edilmiştir[12]. Aker (2022) çalışmasında BİST100 endeksine ait verilerin tahmin edilmesi için LSTM ve Fbprophet yöntemlerini kullanılmıştır. Çalışma sonucunda LSTM modelinin her üç parametrede de düşük hata oranı ile Fbprophet modelinden daha başarılı olduğu tespit edilmiştir[13]. Dalkıran ve Ozan (2022) Derin öğrenme teknikleri kullanılarak BIST 30 ve Borsa İstanbul Bankacılık endeksi (BANKX) içerisinde işlem gören Türkiye İş Bankası A.Ş. ye ait ISCTR hissesine ilişkin gün sonu kapanış fiyatlarını günlük olarak tahmin etmeye çalışmışlardır[14].

Bu çalışmada, döviz piyasaları (Dolar, Euro, Pound), emtia piyasaları (Petrol, Altın, Gümüş, Doğal Gaz, Pamuk) ve gelişmekte olan ülkelerin borsa endekslerini (Shanghai (Çin), Ipc (Meksika), Sensex (Hindistan), RTSI (Rusya),

Bovespa (Brezilya) ve BİST100 (Türkiye) temel olarak Ocak 2017 - Ekim 2021 tarihleri arasındaki değerler ile veri seti oluşturulmuştur. Bu veri seti Weka ve Python programlama dili üzerinde makine öğrenmesi ve derin öğrenme yöntemleriyle analiz edilerek BİST100 piyasa hareketleri tahmin edilmektedir. Gelişmekte olan ülkelerin borsa endekslerinin incelenmesi ve tahminlenmesine ilişkin algoritmaların kullanıldığı bu çalışma bilişim teknolojilerinin gerçekleşmesine paralel olarak gelecekte gerçekleştirilebilecek olan çalışmalara referans niteliğinde olacaktır. Farklı makine öğrenme ve derin öğrenme yöntemlerinin birlikte kullanımı ayrıca farklı piyasalarda kullanılabilir olması ile beraber performansının test edilebilmesi, yöntemlerin araştırılması ve geliştirilmesi sonucunda gelişmekte olan ülkelerde tahminlere dayalı kısa ve uzun vadeli politikalara katkı sağlayacağı görülmektedir.

2 Materyal ve metod

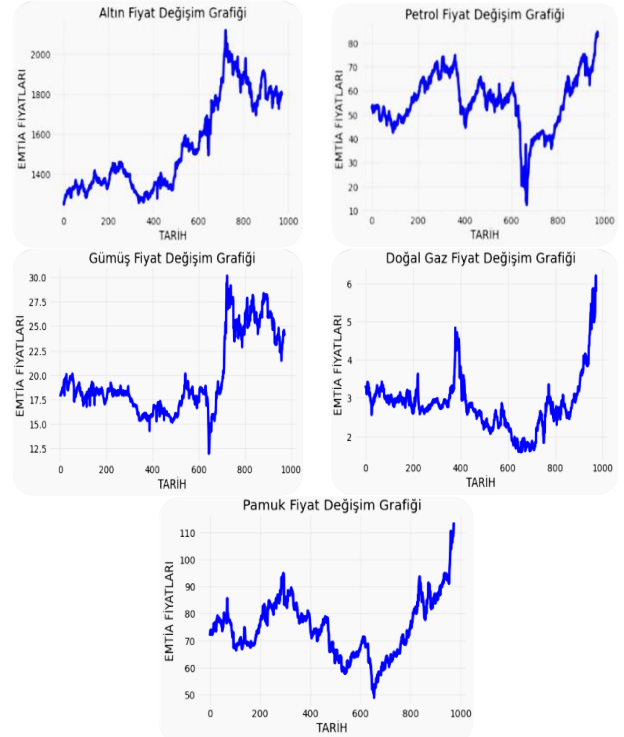
Döviz piyasaları (Dolar, Euro, Pound), emtia piyasaları (Petrol, Altın, Gümüş, Doğalgaz, Pamuk) ve gelişmekte olan ülkelerin borsa endekslerini (Shanghai (Çin), İpc (Meksika), Sensex (Hindistan), RTSI (Rusya), Bovespa (Brezilya) ve BİST100 (Türkiye) temel olarak oluşturulan veri setleri değerlendirilerek analiz yapılacak; bu verilerin Ocak 2017 – Ekim 2021 tarihleri arasındaki değerleri Python programlama dili kullanılarak derin öğrenme yöntemleriyle bağ kurularak, gelişmekte olan ülkelerin borsa endekslerine paralel olarak açıklanmaya çalışılacaktır. Söz konusu hisse senetlerine ait veriler “<https://tr.investing.com/>” üzerinden elde edilmiştir. Kullanılan verilerde hafta sonları ve tatil günleri göz önüne alınmamıştır. Ayrıca gelişmekte olan ülkelerin borsa tatil günleri borsanın kapalı olması nedeniyle ayrıştırılarak ele alınmıştır. Ayrıştırmalar sonucunda 14 öz nitelikli veri seti ile çalışma planlanmıştır. Çalışmada Borsa endeksleri, Emtia piyasaları ve Döviz Piyasalarının kapanış verileri ile veri setleri oluşturulmuştur.

Veri setinden borsa verilerinin eksik olduğu günler ayrıştırılarak Ocak 2017 - Ekim 2021 tarihleri arasında 973 günlük fiyat bilgisi elde edilmiştir. Düzenlenen veri setinden 10 adet örnek Tablo 1’de yer almaktadır.


Emtia piyasası, özellikle hammadde ya da üretilmiş durumda ticarete konu olan gümüş, altın, petrol, bakır, doğalgaz, pamuk, mısır, şeker, buğday, kahve gibi malların alınıp satılmasıyla oluşan piyasalardır. Altın Spot, Ham Petrol, Gümüş Spot, Doğalgaz ve Pamuk temel alınarak veri seti oluşturulmuştur. Şekil 1’de, Altın, Petrol, Gümüş, Doğal Gaz ve Pamuk Ocak 2017 – Ekim 2021 yılları arasındaki fiyat değişim grafikleri gösterilmektedir. Fiyat hareketlerinin eğimleri altın ve gümüş grafiklerinde aynı yönlü hareket ederken petrol doğal gaz ve pamuk içinde kendi aralarında aynı yönde hareket ettiği görülmektedir.

Döviz piyasaları, yabancı ülke paralarının alınıp satıldığı piyasalar ya da bir ulusal para başka bir ulusal paraya çevrimi sonucu oluşan piyasalardır. Amerikan Doları / Türk Lirası, Euro / Türk Lirası, İngiliz Sterlini / Türk Lirası temel alınarak veri seti oluşturulmuştur. Şekil 2’de, Amerikan Doları, Euro ve İngiliz Sterlini Ocak 2017 – Ekim 2021 yılları arasındaki fiyat değişim grafikleri yer

almaktadır. Fiyat hareketlerinin eğimleri seçilen paritelerde birbirleri ile aynı yönde hareket ettiği görülmektedir.



Şekil 1. Altın, petrol, gümüş, doğal gaz ve pamuk fiyat değişimi

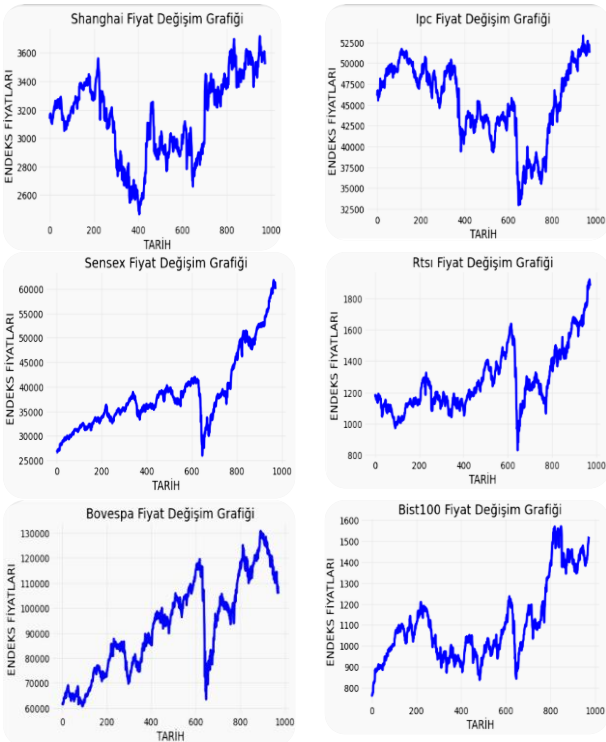


Şekil 2. Amerikan Doları, Euro ve İngiliz Sterlini fiyat değişimi

Borsa endeksleri, birçok veriyi içerebilen ve bu verilerden hesaplamalar sonucunda yaklaşık değerler ile hızlı bilgiye ulaşmamızı sağlayan göstergelerdir. Bist100, Çin, Hindistan, Meksika, Rusya, Brezilya borsa endeksleri temel alınarak veri seti oluşturulmuştur.

Tablo 1. Veri setinden örnek değerler

Tarih	Altın	Petrol	Gümüş	Doğalgaz	Pamuk	Dolar	Euro	Pound	Shanghai	IPC	SENSEX	RTSI	BOVESPA	BİST100
2017-01-03 00:00:00	1244.7	52.33	17.81	3.327	71.75	3.5944	3.7403	4.3991	3135.92	46123.36	26643.24	1189.32	61814	766.18
2017-01-04 00:00:00	1247.1	53.26	17.955	3.267	73.47	3.5713	3.746	4.4005	3158.79	46587.74	26633.13	1176.69	61589	761.44
2017-01-05 00:00:00	1262.1	53.76	18.037	3.273	73.81	3.5927	3.8108	4.4618	3165.41	46719.99	26878.24	1180.31	62071	763.86
2017-01-06 00:00:00	1255.7	53.99	17.921	3.285	73.94	3.6445	3.8388	4.478	3154.32	46071.57	26759.23	1172.59	61665	771.07
2017-01-09 00:00:00	1267.6	51.96	18.096	3.103	73.01	3.7129	3.926	4.5158	3171.24	45553.51	26726.55	1160.27	61700	773.94
2017-01-10 00:00:00	1268.5	50.82	18.282	3.278	73.08	3.7885	3.9987	4.6132	3161.67	45886.27	26899.56	1175.01	62132	773.94
2017-01-11 00:00:00	1280	52.25	18.275	3.224	73.17	3.8647	4.0899	4.7196	3136.75	45933.65	27140.41	1155.5	62446	776.67
2017-01-12 00:00:00	1283.3	53.01	18.271	3.386	72.39	3.7597	3.99	4.5718	3119.29	46060.98	27247.16	1175.28	63954	808.91
2017-01-13 00:00:00	1281.3	52.37	18.209	3.419	72.25	3.723	3.9628	4.534	3112.76	46182.43	27238.06	1158.19	63652	815.24
2017-01-17 00:00:00	1297.4	52.48	18.593	3.412	72.14	3.761	4.0293	4.6687	3108.77	46002.56	27235.66	1156.47	63831	823.
2017-01-18 00:00:00	1295.7	51.08	18.718	3.302	72.27	3.7966	4.0359	4.6543	3113.01	46360.63	27257.64	1151.65	64354	827.79
2017-01-19 00:00:00	1285.5	51.37	18.438	3.368	72.78	3.8273	4.0815	4.7237	3101.3	46265.26	27308.6	1136.62	63951	823
2017-01-20 00:00:00	1289.2	52.42	18.471	3.204	73	3.7655	4.0302	4.6598	3123.14	46331.6	27034.5	1138.99	64521	830.67



Şekil 3. Çin, Hindistan, Meksika, Rusya, Brezilya ve Türkiye borsa döviz grafiği

Makine öğrenmesine girdi olarak verilen Shanghai (Çin), Ipc (Meksika), Sensex (Hindistan), RTSI (Rusya), Bovespa (Brezilya) ve BIST (Türkiye)'nin Borsalarının verileri Ocak 2017 ile Ekim 2021 tarihleri arasındaki endekslerin kapanış değerlerini Şekil 3'te grafik üzerinde gösterilmektedir.

2.1 Makine öğrenmesi

Makine öğrenmesi bilgisayarların insanlar gibi öğrenme yeteneğinin olabilmesi için çeşitli algoritma, modelleme ve teknikleri geliştirmek amaçlı kullanılan bilimsel bir çalışma alanıdır [15]. Arthur Samuel 1959 yılında makine öğrenmesini "Açıkça programlanmadığı halde makineler öğrenme yeteneği kazandıran disiplin" olarak tanımlamıştır. Makine öğrenmesi 1990'larda gelişmeye başlamıştır [16]. Makine öğrenimi, veriden öğrenebilen öğrendikleriyle tahminde bulunabilen algoritmalarıdır. Bilgisayarlara veriler yüklenip bu verilerden çıkarım yapan bu çıkarımla tahminde bulunabilen, programlanan bilgilerin dışındaki bilgileri de ortaya çıkarabilen ve kendi kendini geliştirebilen sistemlerdir. Makine öğrenimi, yapay zekanın bir alt alanı/alt tipidir. Bilgisayarların analitik veri modelleri oluşturmasına ve net bir şekilde kodlanmadan otomatik olarak gizli iç görüler bulmasına izin verir. Amaç, veriler üzerine matematiksel ve istatistiksel işlemler uygulayarak tahminlerden çıkarımlar yaparak öğrenme metotları ve bu metotların performansı ile ilgilidir [15]. Çözüme ulaşmak için farklı matematiksel ve istatistiksel yöntemler kullanılır. Her bir yöntem makine öğrenmesinde kullanılan veri kümesine uygun olarak seçilmelidir [17].

2.1.1 K-En Yakın Komşu (K-nearestneighbor – K-en yakın komşuluk)

K En Yakın Komşu algoritması 1950'lerin başında ortaya çıkmıştır. Bu yöntem, büyük eğitim setlerinde öğrenme işlemi zaman kaybedilmesine yol açmaktadır. Bu sebeple, bilgi işlem gücü kullanılabilir hale dönüşene kadar popülerlik kazanmamıştır. 1960'lardan sonra hazırlanan minimum uzaklık sınıflayıcı üzerine çalışmalarla geliştirilerek 1967'de T. Cover ve P. Hart'ın sunumunu gerçekleştirdiği yakın komşular örüntü sınıflama çalışmalarıyla netliğe kavuşmuştur [18].

Örnek tabanlı olup aynı mesafe ölçüsünü kullanan K-en yakın komşular sınıflandırma algoritmasıdır. Hem sınıflandırma hem de regresyon problemleri için kullanılır. Çapraz doğrulamaya dayalı olarak uygun k değerini seçebilir. Mesafe ağırlıklandırması da yapabilir. Denetimli sınıflandırma algoritmalarından k en yakın komşu algoritmasında sınıflandırma işlemi sırasında kaç adet k değerine bakılarak sınıflandırma yapılacağına karar verilir. Gelen değer sınıflandırmasında k değerine bakılarak o değere en yakın k adet değer karşılaştırılır ve en çok sınıfı olan değer sınıflandırılır. K en yakın nokta hesaplaması sırasında çeşitli uzaklık hesaplama fonksiyonlarından faydalanılır. Aşağıdaki fonksiyonlar bunların başlıcalarıdır:

- Manhattan Hesaplama
- Minkowski Hesaplama
- Öklid Hesaplama

Ağırlık belirleme yöntemi ile $W=1/(d*d)$ ile her uzaklığın ağırlığı bulunarak seçilen k değerine göre sınıf karşılaştırması yapılır [19].

2.1.2 Random forest (Rastgele orman)

Rastgele orman sınıflandırma ve regresyon problemlerinde kullanılan, karar ağacı algoritmalarından oluşan denetimli bir öğrenme algoritmasıdır. Karar ağaçları rastgele bir orman algoritmasının yapı taşlarıdır. Rastgele orman algoritması tarafından oluşturulan orman, torbalama veya önyükleme toplama yoluyla eğitilir. Torbalama, tek bir örnek yerine farklı eğitim veri örneklerinin kullanılmasını içerir [20]. Davranış ve sonuçları tahmin eder ve daha çok sınıflandırma problemleri için kullanılır. Rastgele orman algoritması, veri örnekleri üzerinde karar ağaçları oluşturur. Regresyon hesaplamak için tek tek karar ağaçlarının tahminlerinin ortalaması alınır. Karar ağaçlarının tahminlerine dayanarak sonuç belirlenir. Ağaç sayılarının artması ile sonucun kesinliği artar. Rastgele oluşan bir orman, karar ağacı algoritmalarının sınırlılıklarını ortadan kaldırır. Hassasiyeti artırır ve tahminler üretir.

Rastgele orman algoritması öncelikle veri kümesinden rastgele örnekler seçer ve seçilen her bir örnek için bir karar ağacı oluşturur. Oluşturulan her bir karar ağacından bir tahmin sonucu üretir. Daha sonra tahmin edilen her sonuç için ortalama hesaplanır ve en çok oylanan tahmin sonucunu seçecektir.

2.1.3 Random committee (Rastgele komite)

Veri içerisinde rastgele seçilen temel sınıflandırıcılar komitesini oluşturmak için kullanılan bir sınıflandırıcıdır. Aynı verilere dayalı olarak seçilen her temel sınıflandırıcı, farklı bir rasgele sayı çekirdeği kullanılarak oluşturulur. Bireysel temel sınıflandırıcılar ile üretilebilen tahminlerin düz bir ortalaması olarak nihai tahmin hesaplanır [21].

2.1.4 Kstar (K yıldız -K*)

K^* , regresyon için geliştirilmiş örnek tabanlı bir sınıflandırıcıdır, yani bir test örneğinin sınıfı, bazı benzerlik işlevleriyle belirlendiği üzere, ona benzer eğitim örneklerinin sınıfına dayanır. Entropi tabanlı bir uzaklık ölçütü işlevi kullanması açısından diğer örnek tabanlı

öğrencilerden farklıdır. Veri madenciliğinde kullanılan öğrenme algoritmalarından biri olan bu yöntemde amaç, test veri setinde yer alan özniteliği belirli olmayan bir örneğin, veri tabanı içerisinde daha önceden kategorize edilen fakat ortaya çıkmamış eğitim veri setindeki örnekler ile karşılaştırılması esasına göre sınıflandırma gerçekleştirmektir [22]. Kstar ve random forest algoritmalarının en iyi sınıflandırıcı algoritmalar oldukları bilinmektedir. Bunun yanında en az hata oranına sahip algoritmalar içerisinde sırasıyla Random Forest ve Kstar sıralanabilmektedir.

2.2 Derin öğrenme

Beynin sinir yapısından ve yapay sinir ağları işlevlerinden esinlenen makine öğrenme algoritması olan derin öğrenmede, biyolojik nöronlarda olduğu gibi yapay nöronlar giriş sinyallerini almaktadır ve bu sinyaller toplanarak işlenmiş olan çıkışlara iletilmektedir. Son yıllarda küreselleşmenin etkisiyle donanım ve bilişim teknolojisinin gelişmesiyle dijital ortamda her an milyonlarca veri büyük boyutlarda üretilerek depolanmaktadır. Eğitim için kullanılan veriler çoğaldıkça, klasik makine öğrenme algoritmalarının büyük verileri karşılamadaki performansı yetersiz kalmıştır. Makine öğrenme algoritmalarında hızlı gelişmeler gerçekleşmektedir; günümüzde internetin yaygın şekilde kullanılması ile verilere ulaşma kolaylaşmıştır. Sonuca hızlı ulaşmanın yanı sıra, ulaşılan sonucun performans değerinin yüksek olması son derece önemlidir. Derin öğrenme yöntemleri söz konusu verileri etkin bir şekilde kullanarak, verimli sonuçlara ulaşmayı kolaylaştırmıştır. Derin öğrenme sınıflandırma niteliklerini ve görevlerini doğrudan veriden gerçekleştirmeyi öğrenmesi yönüyle diğer alanlarda ayrılmaktadır. Derin öğrenme modelleri, farklı ve çok sayıda sinir ağı kullanarak insan düzeyinde öğrenme ve bu seviyeye aşan bir performans göstermektedir [23]. Geleneksel makine öğrenme metodları ve derin öğrenme yöntemleri karşılaştırıldığında geleneksel yöntemler veri işleme noktasında sınırlı kalmaktadır. Derin öğrenme yöntemleri ise çoklu işlem katmanlarının hesaplamalarında kullanılmaktadır. Derin sinir ağları ise, klasik yapay sinir ağları yerine, çok fazla katman ve nörondan oluşan bir yapıya sahiptir. Bu yapıya sahip ardışık katman bir önceki katmandaki çıktıyı girdi olarak kullanmaktadır [24]. Kullanıldığı alana göre farklı modellerde tasarlanan derin öğrenme ağları probleme uygun öznitelikleri çıkarmakta ve çıkarılan öznitelikler ağı öğrenmesiyle oluşmaktadır. Kendine sunulan bilgiyi kullanmak yerine hangi bilgiden öğreneceğine kendi kendine karar veren derin öğrenme ağları klasik yöntemlere göre daha başarılı sonuçlar üretebilmekte olup zaman içerisinde farklı problemlerin çözümleri içinde farklı yapıda derin sinir ağları geliştirilmiştir. Bunlar çok katmanlı derin yapay sinir ağları, tekrarlamalı sinir ağları, uzun kısa vadeli hafıza, sınırlı Boltzmann makinesi, otomatik kodlayıcı, konvolüsyonel derin sinir ağları literatürde geliştirilen derin sinir ağları modelleridir.

Derin yineleme denklemleri vasıtasıyla karmaşık zamansal dinamikleri öğrenebilmektedir. İnsanlar bilgiyi işlerken, daha önceden öğrendikleri bilgileri, tecrübe

ettikleri olayları, yeni durum ile analiz edip öyle tepki vermektedirler. RNN'ler pek çok görevde başarılı olduklarını kanıtlamıştır, ancak kısmen tekrar eden ağıın birçok katmanı (zaman karşılık gelen) boyunca geçişlerin neden olabileceği yok olma ve patlama eğilimlerine bağlı olarak uzun vadeli dinamikleri öğrenmede sorunlar çıkarmaktadır.


2.2.1 Uzun kısa süreli bellek (LSTM)

Uzun kısa süreli bellek tekrarlayan sinir ağlarının alt dalı olarak RNN'deki sorunların ortadan kaldırılmasına yardımcı olmak amacıyla geliştirilmiştir. Uzun kısa süreli bellek yapısında giriş, çıkış ve unut olmak üzere üç kapı bulunmaktadır. Bu kapılar sırasıyla; yazma, okuma ve sıfırlamadır. Hücre durumlarındaki değişiklikler üç kapı tarafından denetlenmektedir. Hücrelere iletilebilecek bilgilerin seçimi, bu bilgilerin çıktı olarak nasıl kullanılacağı ve ne kadarının kullanılacağı gibi seçimlerin gerçekleşmesini sağlayan kapı mekanizmalarını sisteme dahil ederek RNN'deki sorunların çözülmesine olanak tanımaktadır [23].

Uzun kısa süreli bellek yapısında giriş kapısı(yazma), çıkış kapısı(okuma) ve unut kapısı(sıfırlama) olmak üzere üç kapı yer almaktadır. Bu kapılar sırasıyla; yazma, okuma ve sıfırlamadır. Hücre durumlarındaki değişiklikler kapılar tarafından denetlenmektedir. Hücrelere iletilebilecek bilgilerin seçimi, bu bilgilerin çıktı olarak nasıl kullanılacağı ve kullanılacak miktar gibi seçimlerin gerçekleşmesini sağlayan kapı mekanizmalarıdır. Giriş kapısı belleğe eklenecek bilgileri kontrol ederken unut kapısı, eski bilgilerin hangi oranda sonraki aşamaya taşınacağını kontrol etmektedir. Çıkış kapısı ise bellekte bulunan verinin ne oranda çıktı aşamasında kullanılacağını kontrol etmektedir [20]. İleri faz, giriş ve önsel verileri uzun-kısa süreli bellek hücresi içerisinde işlemlerden geçirerek çıkış üretmektedir. Giriş verisi olarak uzun-kısa süreli bellek girişine x_t verisi gelir ve bir önceki çıkışı ifade eden O_{t-1} verisi ile birleştirilerek kullanılırlar. Veri sıralaması birleşmede bir önceki verinin değeri ile hesaplandığı için önem arz etmektedir. Hesaplanan değerler sonucunda oluşan veri Unutma Kapısı Ağırlıkları (W_f) ile çarpılarak kullanılır. Daha sonra sonucun üzerine bu kısma özgü Unutma Kapısı Sapma Değerleri (b_f) eklenir. En sonda sigmoid fonksiyonundan geçilerek unutma kapısı çıkışına ulaşılır. Bütün işlemlerin tamamlanmasının arkasından tek bir uzun-kısa süreli bellek hücresi için Unutma Kapısı Alanı çıkışı elde edilir. Söz konusu çıkış ilerleyen adımlardaki çıkışlarla birleştirilerek sonuca gidilir [24].

Unutma kapısı çıkış değerlerinin hesaplanmasının ardından, "Giriş Kapısı" ve "Aktivasyon Kapısı" çıkış değerleri hesaplanır. Çıkış değerleri hesaplanırken "Unutma Kapısı" bölümünde yer alan x_t ve O_{t-1} değerleri ile birleştirilerek kullanılırlar. Şekil 4'te giriş kapısı değerlerini hesaplarken daha önce oluşan değerler, Giriş Kapısı Ağırlıkları ile çarpılır ve oluşan değere Giriş Kapısı Sapma Değerleri (b_i) eklenir. Bu bölümde oluşan değer sigmoid fonksiyonuna tabi tutularak Giriş Kapısı çıkışları oluşur. İkinci bölümde birleştirilen x_t ve O_{t-1} değerleri önce Aktivasyon Kapısı Ağırlıkları (W_a) ile çarpılır, sonucun üzerine Aktivasyon

Kapısı Sapma (b_a) değerleri eklenir. Oluşan sonuç tanh fonksiyonuna dahil edilerek Aktivasyon Kapısı çıkışları oluşur. Son olarak, Giriş Kapısı çıkışları ve Aktivasyon Kapısı çıkışları çarpılarak bu alanın asıl çıktı değeri elde edilir.

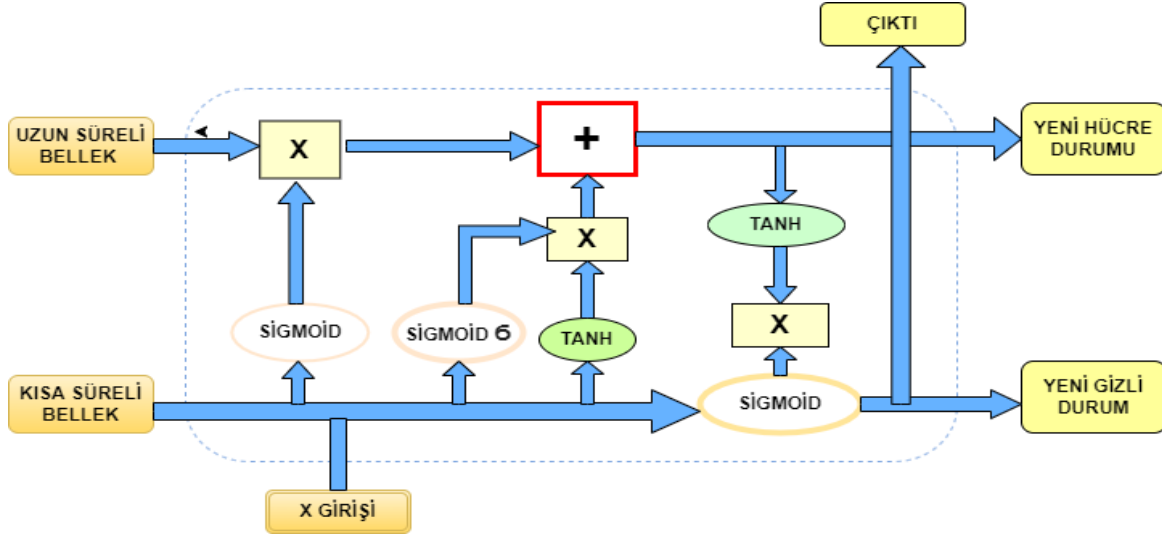


Şekil 4. LSTM modeli

Sıradaki adımda Giriş Kapısı, Aktivasyon Kapısı ve Unutma Kapısı çıkışları kullanılarak Bağlam Çıkışları değerleri elde edilir. Bu değerler bir sonraki uzun-kısa süreli bellek hücresi için kullanılacaktır ve amacı veri sırası arasında bağlantı kurarak sıralamayı gözetmektir. Şekil 5'de yer aldığı gibi son olarak uzun kısa süreli bellek çıkışları hesaplanmalıdır. Çıkışları hesaplamak için bir önceki çıkışlar ile giriş verisi birleştirilerek sigmoid fonksiyonu ile işleme alınır ve bu değer ile bir önceki adımda elde edilen bağlam çıkışlarını tanh fonksiyonundan geçirerek işleme alır. Elde edilen değer uzun-kısa süreli bellek hücresinin çıkışıdır.

Birden fazla çıkış olması halinde bağlam çıkışları ve hücre çıkışları bağlanarak uzun-kısa süreli bellek ağ yapısı oluşturulur. Tüm uzun-kısa süreli bellek hücreleri için çıkışlar hesaplandıktan sonra güncelleme değerleri için geri faz başlamaktadır. İleri fazda hesaplamalar en soldaki uzun-kısa süreli bellek hücresinden başlayarak en sağdaki hücrenin çıkışı elde edilene kadar sürer. Bundan sonra geri faz başlar. Geri faz ise ters yönde ilerletilerek en sağdan en sola doğru yani çıkıştan girişe doğru yönelir.

Bellek birimlerini bir araya getirerek bir çözüm sağlayan belirli bir tekrarlayan ağ biçimidir. Bu, ağın önceki gizli durumları ne zaman unutması gerektiğini ve yeni bilgiler verildiğinde gizli durumları ne zaman güncelleyeceğini öğrenmesine olanak tanır. Bir LSTM modeli, önceki dönemlerin oynaklık modellerini ezberleyerek geçmişe ait verileri kullanarak tahminleri potansiyel olarak artırabilir. LSTM modeli, eğitilecek daha büyük parametreler setinin maliyeti ile verilerdeki zamansal ilişkilerin tanımlanmasını otomatikleştirebilir. LSTM modellerinin sayısız finans uygulama alanları mevcuttur. Bunlar, varlık geri dönüş hareketlerinin altında yatan ve uzun bellek etkileri yakalayabilen yeni bir değişkenlik sınıfı modeli sağlarlar.



Şekil 5. LSTM (Unut kapısı ve çıkış kapısı)

Öğrenme sürecinin verimli bir şekilde sonuçlanabilmesi amacıyla derin öğrenme uygulamalarında hata fonksiyonunun mutlak minimum değerinin hesaplanması gerekmektedir. Söz konusu süreç, optimizasyon yöntemleriyle gerçekleştirilmektedir. Optimizasyon, ağız ürettiği çıkış değeri ile gerçek değer arasındaki farkı düşürmek ayrıca ortaya çıkabilecek hatayı en düşük seviyeye indirmek için kullanılır. Yapay sinir ağlarının optimizasyonun sağlanabilmesi için en yaygın kullanılan yöntemlerden biri gradyan inişidir. Veri setinin büyüklüğüne göre üç adet gradyan iniş yöntemi (Batch Gradient Descent, Stochastic Gradient Descent, Mini-Batch Gradient Descent) bulunmaktadır. Gradyan iniş yöntemini temel alan çeşitli algoritmalar (Rmsprop, Adagrad, Adam, Nadam) mevcuttur. Optimizasyon algoritmalarında öğrenme katsayısının ayarlanması modelin geliştirilmesinde önemli bir yere sahiptir. Fakat her algoritma ile modeldeki öğrenme katsayısını tam olarak ayarlayabilmek mümkün değildir. Bu sorunu çözebilmek için gradyan yöntemlerinin farklı çeşitleri kullanılabilir. Adam düşük dereceli momentlerin uyarlanabilir tahminlerine dayanan, stokastik amaç fonksiyonlarının birinci dereceden gradyan tabanlı bir algoritmasıdır. Adam, makine öğrenmesini birçok uygulayıcısı tarafından kullanılan teknoloji optimizasyon algoritmalarından birisidir. İkinci an ile normalize edilen ilk an güncellenen yönünü vermektedir. Adam optimizasyonu yönteminde, Rmsprop'ta gerçekleştiği gibi geçmiş eğitimlerin karelerinin üssel olarak ağırlıklandırılmış ortalamalarının (Vt) kullanılmasıdır. Ayrıca, momentum değişikliklerini (mt) de önbellekte saklar. Rmsprop ve momentumu birleştirir. Varsayılan değer β_1 için 0.9; β_2 için 0.999 ve ϵ için 10⁻⁸ olarak belirtilmiştir [25].

3 Bulgular ve tartışma

Finansal piyasalarda geleceğe yönelik tahmin için birçok yöntem geliştirilmiştir. Son dönemde makine öğrenmesi, derin öğrenme yapay zekâ başlıkları altında birçok çalışma yapılmaktadır [26-28]. Bu çalışmada da emtia, döviz fiyatları ve gelişmekte olan ülkelerin borsa endeks verileri makine

öğrenmesi ve derin öğrenme modelleri Weka programı ve python yazılım dili yardımıyla incelenmiştir. Makine öğrenmesi yöntemleri ve Uzun Kısa Süreli Bellek (LSTM) yönteminin tahmin değeri karşılaştırılmıştır. BİST100 endeksinin kapalı olduğu günlere ilişkin olarak veri setlerinde ayrıştırma yapılmıştır.

Verileri tahmin etmek ve değerlendirmek için makine öğrenmesi modelleri Weka programı ile analiz edilmiştir. Makine öğrenmesi modelleri değerlendirilerek en yüksek başarı oranını veren 10 farklı makine öğrenmesi yöntemi ile 5 ve 10 fold (k katmanlı çapraz doğrulama) kullanılarak deneysel çalışmalar yapılmıştır. Makine öğrenmesi modellerinin performansında hata oranları ortalama mutlak hata (Mean Absolute Error-MAE), ortalama karesel hata karekökü (Root Mean Squarederror-RMSE) ve (Relative Absolute Error-RAE) değerlendirme ölçütleri ile incelenmiştir.

Ortalama Mutlak Hata (Mean Absolute Error-MAE)

$$MAE = \frac{\sum_{i=1}^n |x - x'|}{n}$$

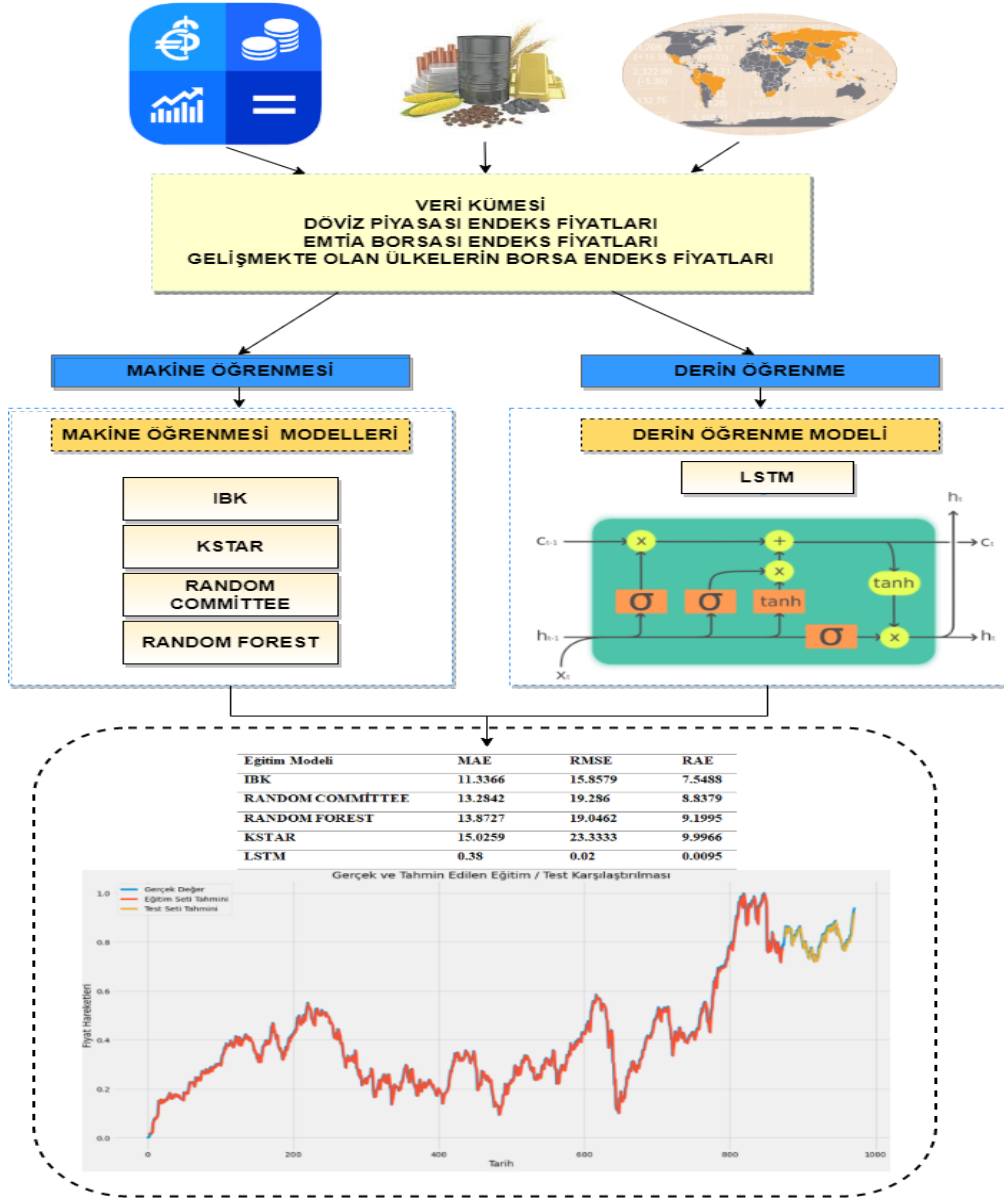
Ortalama Karesel Hata Karekökü (Root Mean Square Error-RMSE)

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (x - x')^2}{n}}$$

Bağıl Mutlak Hata (Relative Absolute Error-RAE)

$$RAE = \frac{\sum_{i=1}^n (P_i - A_i)}{\sum_{i=1}^n (A_i - A_m)}$$

Uygulanan veri setinin 14 öznetiliği bulunmaktadır. Analizler için Intel(R) Core™ i5-5300U CPU @ 2.30GHz ve 8 GB belleğe sahip bilgisayar kullanılmıştır. Çalışmada aynı veri seti üzerinde makine öğrenmesi ve derin öğrenme modelleri ile analiz yapılmıştır. Çalışmada oluşturulan veri seti üzerinde yapılan farklı deneyler ile düşük hata oranına sahip modelinin belirlenmesi hedeflenmiştir.



Şekil 6. Çalışmanın mimarisi

Şekil 6'da çalışmanın mimarisi yer almaktadır. Veri kümesinde gelişmekte olan ülkelerin borsa endeksleri, emtia borsa endeksleri ve gelişmekte olan ülkelerin borsa endeksleri kullanılmıştır. Derin öğrenme ve makine öğrenmesi ile verilerin analizi yapılmış ve eğitim modeli oluşturulmuştur.

Makine öğrenmesi modelleriyle tahmin yapma ve performans karşılaştırmasına ilişkin sonuçlar Tablo 2'de yer almaktadır. Tabloda, 5 ve 10 fold ile hesaplanan hata oranları yer almaktadır.

Tablo 2'de makine öğrenmesi algoritmalarının ile weka üzerinde yapılan analizlerin hata değerleri gösterilmiştir. Makine öğrenmesi yöntemlerine 5 fold ve 10 fold çapraz doğrulama kullanılarak yapılan tüm analizlerden 10 başarılı yöntemde detaylı olarak tabloda yer almaktadır. Algoritmaların performansları incelendiğinde en başarılı 5

öğrenme yönteminin sırası ile IBk, KStar, Random Forest, Random Committee'dir. Sonuçların objektif değerlendirilebilmesi için yöntemlere ayrıca 10 fold çapraz geçerlilik uygulanarak analizler yapılmıştır. İki farklı çapraz geçerlilik ile yapılan hata oranlarının ortalaması alınarak sonuçların objektif olarak değerlendirilmesi sağlanmıştır

Tablo 3'de en başarılı beş yöntem ve iki farklı çapraz doğrulama uygulanması sonucunda oluşan değerler yer almaktadır. 5 ve 10 fold çapraz doğrulama uygulanan modellerin içerisinde IBk, Kstar, Random Committee, Random Forest modellerinin hata oranı diğer modellere göre daha düşük olduğu görülmektedir. Verilere en uygun parametreleri bulmak için çok sayıda deneme yapılmıştır. Denemeler sonucunda en az hata oranlarına sahip modellerin gerçek değer, tahmin değeri ve hata değerlerinin grafik olarak görselleştirilmiş hali verilmiştir.

Tablo 2. Makine öğrenmesi 5 ve 10 çapraz doğrulama ile performans karşılaştırması

Sınıf	MAE5	RMSE5	RAE5	MAE10	RMSE10	RAE10
Multilayer Perceptron	24.9645	31.6093	16.617	24.556	31.1729	16.3285
IBk	11.5213	16.1133	7.6689	11.172	15.6026	7.4288
KStar	15.0876	23.1503	10.0427	14.9643	23.5164	9.9505
Bagging	19.1072	26.5804	12.7182	18.2429	25.2856	12.1306
Random Committee	13.5368	19.9514	9.0104	13.0316	18.6206	8.6654
Randomizable Filtered Classifier	15.8639	24.3361	10.5594	15.1916	23.4192	10.1016
Random Sub Space	19.1738	26.2277	12.7625	18.4208	24.9351	12.2489
M5Rules	21.8232	30.2389	14.5261	20.3456	28.0132	13.5288
MSP	19.8036	26.9053	13.1818	19.4991	26.5143	12.9659
Random Forest	14.1467	19.5171	9.4164	13.5987	18.5753	8.9826

Tablo 3. Makine öğrenmesi performans karşılaştırması

Sınıf	Çapraz geçerlilik	MAE	RMSE	RAE
IBk	5 Fold	11.5213	16.1133	7.6689
	10 Fold	11.172	15.6026	7.4288
	Ortalama	11.3366	15.8579	7.5488
KStar	5 Fold	15.0876	23.1503	10.0427
	10 Fold	14.9643	23.5164	9.9505
	Ortalama	15.0259	23.3333	9.9966
Random Committee	5 Fold	13.5368	19.9514	9.0104
	10 Fold	13.0316	18.6206	8.6654
	Ortalama	13.2842	19.286	8.8379
Random Forest	5 Fold	14.1467	19.5171	9.4164
	10 Fold	13.5987	18.5753	8.9826
	Ortalama	13.8727	19.0462	9.1995

IBk sınıflandırma yönteminde, en yakın komşulara göre sınıflandırma yapılmaktadır. K en yakın komşulardaki k değeri değişken bir özellik göstermekte olup belli olmayan bir durumun ne şekilde sınıflandırılacağına karar vermek için kullanılmaktadır. Kendine komşu olarak kaç değer seçilebileceğini belirler. Performansı parametreler etkiler. Çalışmada farklı parametreler sonucunda oluşan yüksek performanslar baz alınmıştır. KNN= 2, batchSize=100 parametreleri ve numDecimalPlaces = 2, windowSize=0 olarak kullanılmıştır.

Random Committee, veri içerisinde rastgele seçilen temel sınıflandırıcılar komitesini oluşturmak için kullanılan bir sınıflandırıcıdır. BatchSize = 100 parametreleri ve numDecimalPlaces = 2, numIterations = 10, seed = 1 olarak kullanılmıştır. Rastgele orman algoritması, veri örnekleri üzerinde karar ağaçları oluşturur. Karar ağaçlarının tahminlerinin ortalaması alınarak hesaplanır. Çalışmada farklı parametreler sonucunda oluşan yüksek performanslar baz alınmıştır. BagSizePercent =100, batchSize =100 parametreleri ve numDecimalPlaces =2, numIterations = 100, seed =3 olarak kullanılmıştır. Kstar sınıflandırma yönteminde sınıflandırıcı bazı benzerlik özelliklerine göre ona benzeyen eğitim örneklerinin sınıfına dayanır. Burada parametre olarak batchSize =100 ve globalBlend = 5, numDecimalPlaces =2 olarak kullanılmıştır. Şekil 7’de kullanılan parametre oluşan değerler görselleştirilmiştir.

```

Model: "sequential_1"
-----
Layer (type)                Output Shape              Param #
-----
lstm_1 (LSTM)                (None, 15)                1020
-----
dense_1 (Dense)              (None, 1)                  16
-----
Total params: 1,036
Trainable params: 1,036
Non-trainable params: 0

```

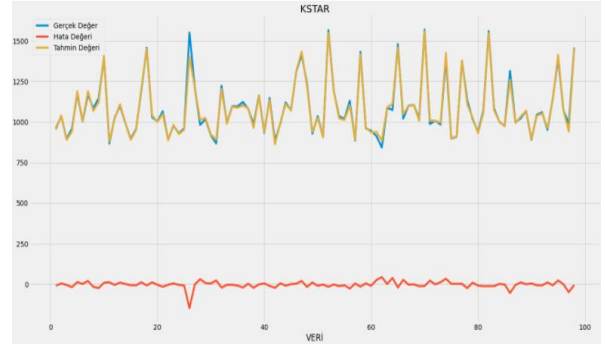
Şekil 8. Kullanılan modeller ve parametreler

Şekil 8’de LSTM yapısı yer almaktadır. Tek katmanlı LSTM modeli ve tek bir çıkış ile düğüm kullanılmıştır. Makine öğrenmesi ve derin öğrenme modelleri kullanılarak aynı veri kümesi üzerinde yapılan çalışmaların sonucu Tablo 4’te yer almaktadır.

Tablo 4. Performans değerleri

Eğitim Modeli	MAE	RMSE	RAE
IBk	11.3366	15.8579	7.5488
Random Committee	13.2842	19.286	8.8379
Random Forest	13.8727	19.0462	9.1995
KStar	15.0259	23.3333	9.9966
LSTM	10.27	14.15	6.06

Tablo 4’de kullanılan makine öğrenmesi teknikleri ve LSTM modelinin ölçüm değerleri sonucu yer almaktadır. IBk modelinin MAE değeri 11.3366, RMSE değeri 15.8579, RAE değeri 7.5488’dir. Random Committee modelinin MAE 13.2842 değeri RMSE değeri 19.286, RAE değeri 8.8379’dir. Random Forest modelinin MAE 13.8727 değeri RMSE değeri 19.0462, RAE değeri 9,1995’dir. KStar için MAE değeri 15.0259, RMSE değeri 23.3333 ve RAE değeri 9.9966’dir. LSTM modelinin MAE değeri 10.27, RMSE değeri 14.15 ve RAE değeri 6.06’dur. Sonuçlar incelendiğinde aynı veri seti üzerinde yapılan çalışmada sonuçlar incelendiğinde LSTM modelinin en yüksek başarıya ulaştığı görülmektedir.

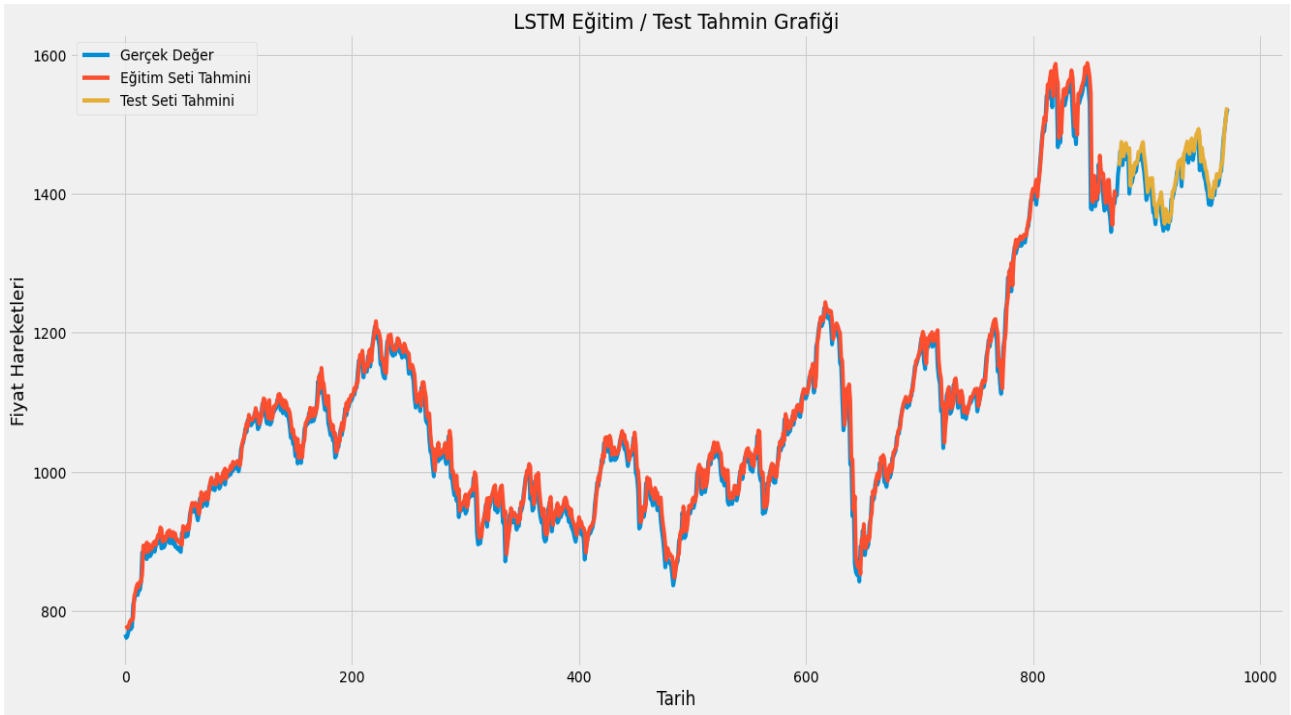


Şekil 7. IBk, Random Committee, Random Forest, KStar tahmin grafiği

Şekil 9’de LSTM modelinin MAE değeri 10.27, RMSE değeri 14.15 ve RAE değeri 6.06 ile oluşan hataların grafik modeli yer almaktadır. İşlenmemiş veri(True Value) grafikte mavi renkte, eğitim verisi(Training Set Prediction) grafikte kırmızı renkte ve test verisine uygulanan eğitilmiş model(Test Set Prediction) sarı renk ile gösterilmektedir. Toplam 973 günlük kapanış verininin 875 tanesi eğitim verisi 98 tanesi test verisi olarak kullanılmıştır. Grafik ayrıca hata oranları dikkate alındığında mavi ve sarı ile oluşan trend oldukça uyumlu ve hata oranları da düşüktür.

4 Sonuçlar ve öneriler

Finansal piyasalarda uygulanmak üzere, geleceğe yönelik tahmin için birçok yöntem geliştirilmiştir. Geleceği ön görmek doğru finansal kararlar vermemizi sağlamaktadır. Tahminleme için farklı yöntemlerle birçok tahmin teorisi hesaplanabilmektedir.



Şekil 9. LSTM tahmin grafiği

Son dönemde makine öğrenmesi ve yapay zekâ hakkında birçok çalışma yapılmaktadır. Bu çalışmalar ile finansal tahminlere, makine öğrenmesi ve derin öğrenme modelleri ile ulaşılabilmektedir. Uygulamalar sonucunda makine öğrenmesinde başarılı sonucu IBk algoritması verirken derin öğrenmede kullanılan LSTM modelinin IBk algoritmasına göre daha düşük hata oranı verdiği görülmüştür. LSTM için test sonuçları incelendiğinde MAE değeri 10.27, RMSE değeri 14.15 ve RAE değeri 6.06'dır. Çalışmada emtia ve döviz kurları ve gelişmekte olan ülkelerin borsa endeksleri arasındaki ilişki uzun-kısa süreli hafıza modelinin etkili bir tahmin edici olduğu ortaya çıkmıştır. Dolayısıyla bu modelin borsalar başta olmak üzere konu ile ilgili olan herkese ve bu alanda yapılacak olan bilimsel çalışmalar için katkı sağlayacağı öngörülmektedir. Özellikle ekonomik kriz dönemlerinde yapılacak olan başarılı endeks tahminleri ile yatırımcılar piyasanın geleceği hakkında öngörü sahibi olacaklardır.

Çalışmada kullanılan veri seti belli bir dönemi 2017 Ocak ayı ve 2021 Ekim ayını kapsamaktadır. Bu veriler farklı ülke borsalarının farklı dönemlerini ele alarak uygulamış olduğumuz model ile incelenerek gelecekte ortaya çıkabilecek değişimler tahmin edilebilir. Bu değişimler pozitif olarak ortaya çıkması yatırımcıların gerçekleştirecekleri yatırımlar konusunda daha doğru kararlara ulaşmalarına, negatif olarak ortaya çıkması halinde yatırımcıların zarar etmemeleri konusunda tedbir almalarına yardımcı olacaktır. Teknolojinin gelişmesi finans piyasaları üzerinde etkinliğinin her geçen gün artması ve insan faktörü yerine geçmesi hayalden öte bir gerçeklik olarak son yıllarda karşımıza çıkmaktadır. Bu bağlamda bu çalışmanın ortaya koymaya çalıştığı model ile bunun mümkün olduğu kanıtlanmış oldu. Uygulama sonucunda LSTM modelinin Bist 100 endeks fiyatını tahmin etmekte etkili bir yöntem olduğu sonucuna ulaşılmıştır.

Bazı algoritmalar farklı koşullarda devamlı olarak gerçek değerlerin altında veya üzerinde tahminler yapmaktadır. Bu algoritmaların birlikte kullanılması daha üstün performans göstermesini sağlayabilecektir. Farklı öğrenme süreleri ve farklı piyasalar üzerinde her bir algoritmanın performansının en üst seviyeye ulaşabileceği süreler araştırma konusu yapılarak farklı sonuçlara da ulaşılabilir. Çalışmanın sınırlılığı belirli tarihsel aralıktaki (Ocak 2017- Ekim 2021) menkul değerleri kapsamaktadır. Hedef çalışma olarak farklı finansal veri setleri ve farklı algoritmaların kullanılması ile başarı oranının artırılması düşünülmektedir

Çıkar çatışması

Yazarlar çıkar çatışması olmadığını beyan etmektedir.

Benzerlik oranı (iThenticate): %19

Kaynaklar

- [1] M. Karslı ve H. Karaman, İslam açısından borsa. İstanbul: Ensar Neşriyat, 1994.
- [2] A. Fertekligil, Türkiye'de borsanın tarihçisi. İstanbul: İMKB Yayınları, 2000.
- [3] U. Erkan, A. Toktas ve D. Ustun, Hyperparameter optimization of deep CNN classifier for plant species identification using artificial bee colony algorithm. J Ambient Intell Human Comput, 2022. <https://doi.org/10.1007/s12652-021-03631-w>
- [4] A. Uğur, Hisse senedi getirilerinin panel veri analizi ile tahmini: İstanbul menkul kıymetler borsasında bir inceleme. (Doktora Tezi), İnönü Üniversitesi, Sosyal Bilimler Enstitüsü, Malatya, 2009.
- [5] Y. Kara, M. A. Boyacioglu ve Ö. K. Baykan, 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, 2011.
- [6] M. Akal, BİST 100 endeksi ile GSPTSE ve yükselen borsalar arası etkileşim. Akademik Bakış Uluslararası Hakemli Sosyal Bilimler E-Dergisi, 38, 1-20, 10.09.2021.
- [7] T. Fischer ve C. Kraus, Deep learning with long-short term memory networks for financial market predictions. European Journal of Operational Research, 000,1-16, 2018.
- [8] C. Krauss, X. A. Do ve N. Huck, Deep neural networks, gradient-boosted trees, random forest: statistical arbitrage on the S&P 500. European Journal of Operational Research, 259(2), 689-702, 2017.
- [9] A. Nahil ve A. Lyhyaoui, Short-term stock price forecasting using kernel principal component analysis and support vector machines: the case of casablanca stock Exchange. Procedia Computer Science, 127, 161-169, 2018.
- [10] P. H. Vuong, T. T. Dat, T. K. Mai, P. H. Uyen ve Pham The Bao, Stock Price Forecasting Based on XGBoost and LSTM. Computer Systems Science and Engineering, 40(1), 237-246, E, 2022.
- [11] Z. Hu, Y. Zhao ve M. Khushi, A survey of forex and stock price prediction using deep learning. Applied System Innovation, 4(1), 9, 2021.
- [12] E. Gavcar, ve H. M. Metin, Hisse Senedi Değerlerinin Makine Öğrenimi (Derin Öğrenme) ile Tahmini. Ekonomi ve Yönetim Araştırmaları Dergisi, 10(2), 1-11, 2021. Retrieved from <https://dergipark.org.tr/pub/eyad/issue/68049/1056795>
- [13] Y. Aker, Analysis of Price Volatility in BIST 100 Index With Time Series: Comparison of Fbprophet and LSTM Model. Avrupa Bilim ve Teknoloji Dergisi, (35), 89-93. DOI: 10.31590/ejosat.1066722, 2022.
- [14] İ. Dalkıran ve M. Ozan, Derin Öğrenme Teknikleri Kullanılarak Borsadaki Hisse Değerlerinin Tahmin Edilmesi. Avrupa Bilim ve Teknoloji Dergisi, ICAENS, 143-148. DOI: 10.31590/ejosat.1145949, 2022.
- [15] E. Alpaydın, Introduction to machine learning. The MIT Press, 3-6, 2004.
- [16] H. Akpınar, Data veri madenciliği veri analizi. İstanbul: Papatya Bilim, 2014.
- [17] U. Erkan, A precise and stable machine learning algorithm: eigenvalue classification (EigenClass). Neural Comput and Applic 33, 5381–5392, 2021. <https://doi.org/10.1007/s00521-020-05343-2>

- [18] G. Dilki ve Ö. Deniz Başar, İşletmelerin finans tahmininde k – en yakın komşu algoritması üzerinden uzaklık ölçütlerinin karşılaştırılması. İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi, 19(38), 224-233, 2020.
- [19] Y. Kirelli, E-Ticaret siteleri için sahtekarlık tespit sistemleri. (Yüksek Lisans Tezi), İstanbul ticaret üniversitesi, Bilgisayar Mühendisliği Ana Bilim Dalı, İstanbul, 2016.
- [20] Ş. Sakarya ve Ü. Yılmaz, Derin öğrenme mimarisi kullanılarak BİST30 indeksinin tahmini. European Journal of Educational & Social Sciences, 4(2), 2654-6621, 2019.
- [21] Ş.E. Kara ve R. Şamlı, Yazılım Projelerinin Maliyet Tahmini için Weka’da Makine Öğrenmesi Algoritmalarının Karşılaştırılması Analizi. Avrupa Bilim ve Teknoloji Dergisi, 415-42, 2021.
- [22] K. Vursavuş, F. Üçkardeş, K-star, rastgele orman ve karar ağacı (C.4.5) sınıflandırma algoritmaları ile domatesin renk olgunluğu üzerinde bazı mekanik özelliklerin etkisinin belirlenmesi. Article in Turkish Journal of Agriculture Food Science and Technology, 2015.
- [23] G. Şişmanoğlu, F. Koçer, M.A. Önde ve Ö. K. Şahinsöz, Derin öğrenme yöntemleri ile borsada fiyat tahmini. BEU Fen Bilimleri Dergisi, 9(1), 434-455, 2020.
- [24] S. Turan, Uzun Kısa Süreli Hafıza ve Geçitli Yinelenebilir Birim İle Borsa İstanbul 100 Endeks Değeri Tahmini Üzerine Bir Uygulama. (Yüksek Lisans Tezi), Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, 2019.
- [25] R. C. Staudemeyer, E. Rothstein Morris, Understanding LSTM a tutorial into long-short term memory recurrent neural networks. Faculty of Computer Science Schmalkalden University of Applied Sciences, Germany, 2019.
- [26] K. Adem ve C. Közkurt, Defect detection of seals in multilayer aseptic packages using deep learning. Turkish Journal of Electrical Engineering and Computer Sciences, 27(6), 4220-4230, 2019.
- [27] K. Adem, Prediction of Gold Prices Using Artificial Neural Networks. Uluslararası Mühendislik Araştırma ve Geliştirme Dergisi, 9(3), 83-89, 2021.
- [28] K. Adem, N. Zengin, M. Hekim, ve S. S. Karaca, Prediction of the relationship between the bist 100 index and advanced stock market indices using artificial neural network:(2011-2015). Journal of New Theory, (13), 86-95, 2016.

