



Boyut İndirgeme Teknikleri ve LSTM Derin Öğrenme Ağı İle BIST100 Endeksi Fiyat Tahmini

Mehmet Sarıkoç^{1*}, Mete Çelik²

^{1*} Erciyes Üniversitesi, Uzaktan Eğitim Uygulama ve Araştırma Merkezi, Kayseri, Türkiye, (ORCID: 0000-0002-3081-1686), msarikoc@erciyes.edu.tr

² Erciyes Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Kayseri, Türkiye (ORCID: 0000-0002-1488-1502), mcelik@erciyes.edu.tr

(2nd International Conference on Applied Engineering and Natural Sciences ICAENS 2022, March 10-13, 2022)

(DOI: 10.31590/ejosat.1083255)

ATIF/REFERENCE: Sarıkoç, M. & Çelik, M. (2022). Boyut İndirgeme Teknikleri ve LSTM Derin Öğrenme Ağı İle BIST100 Endeksi Fiyat Tahmini. *Avrupa Bilim ve Teknoloji Dergisi*, (34), 519-524.

Öz

Son dönemde teknolojide gözlenen gelişim ile birlikte derin öğrenme yöntemlerinin çok farklı alanlarda kullanımı da hız kazanmıştır. Bu alanların en popülerlerinden biri de finansal piyasalardır. Birçok girdinin etken olduğu finansal veriler üzerinde gerçekleştirilen tahmin ve analizlerin, yatırımcıların ve kurumsal yapıların karar alma mekanizmalarına yardımcı etkisi büyük öneme sahiptir. Çalışmada bir derin öğrenme ağı ile Borsa İstanbul 100 (BIST100) endeksi tahmin edilmeye çalışılmaktadır. Ayrıca veri ön işleme aşamasında Faktör Analizi (FA), Temel Bileşen Analizi (PCA), Bağımsız Bileşen Analizi (ICA) gibi istatistiksel boyut indirgeme yöntemlerinin kullanımının, Uzun Kısa Süreli Bellek (LSTM) derin öğrenme ağı performansına olan etkisi araştırılmaktadır. Deneyler esnasında kullanılan veri seti; BIST100 endeksine ait günlük geçmiş verilere ve teknik analiz bilgilerine dayalı olarak hazırlanmaktadır. Veri ön işleme aşamasında, derin öğrenme ağına eklenen istatistiksel boyut indirgeme yöntemlerinden oluşturulan modeller, 5 gün sonraki fiyatı tahmin etmeye çalışırken, R^2 ve RMSE ölçütleri üzerinden karşılaştırılmıştır. Bu işlemler sırasında derin öğrenme hiper-parametreleri dışında kalan, teknik göstergelerin ve tahmin modelinin performansını etkileyeceği düşünülen parametreler iyileştirilmeye çalışılmıştır. Buna göre PCA+LSTM hibrit modeli, diğer boyut indirgeme yöntemleri ile oluşturulan hibrit modelleri geride bırakarak daha rekabetçi sonuçlar elde etmiştir. Aynı zamanda PCA+LSTM hibrit modelinin, LSTM modelinin tek başına elde ettiği sonuçları, R^2 ve RMSE için sırası ile %4.60 ve %13.35 oranlarında iyileştirdiği görülmüştür.

Anahtar Kelimeler: Finansal Zaman Serileri, BIST100, Fiyat Tahmini, Veri Ön İşleme, Faktör Analizi (FA), Temel Bileşen Analizi (PCA), Bağımsız Bileşen Analizi (ICA), Derin Öğrenme, Uzun-Kısa Süreli Bellek (LSTM).

BIST100 Index Price Prediction with Dimension Reduction Techniques and LSTM Deep Learning Network

Abstract

With the recent development in technology, the use of deep learning methods in many fields has gained momentum. One of the most popular of these areas is financial markets. The estimations and analyzes performed on financial data, where many inputs are effective, have great importance on the decision-making mechanisms of investors and institutional structures. In the study, Borsa Istanbul 100 (BIST100) index is tried to be estimated with a deep learning network. In addition, the effect of the use of statistical dimension reduction methods such as Factor Analysis (FA), Principal Component Analysis (PCA), Independent Component Analysis (ICA) in the data preprocessing stage on Long Short Term Memory (LSTM) deep learning network performance is investigated. The data set used during the experiments; is prepared based on daily historical data and technical analysis information of the BIST100 index. In the data preprocessing stage, the models created from the statistical dimension reduction methods added to the deep learning network were compared over the R^2 and RMSE criteria while trying to predict the price at the end of 5-days. During these processes, parameters other than deep learning hyper-parameters, which are thought to affect the performance of technical indicators and forecasting models, were

* Sorumlu Yazar: msarikoc@erciyes.edu.tr

tried to be improved. Accordingly, the PCA+LSTM hybrid model outperformed the hybrid models created by the other, dimensional reduction methods and achieved more competitive results. At the same time, it was observed that the PCA+LSTM hybrid model improved the results of the LSTM model alone by 4.60% and 13.35% for R^2 and RMSE, respectively.

Keywords: Financial Time Series, BIST100, Price Prediction, Data Preprocessing, Factor Analysis (FA), Principal Component Analysis (PCA), Independent Component Analysis (ICA), Deep Learning, Long-Short Term Memory (LSTM).

1. Giriş

Günümüzde dünya finans piyasalarına ait bilgilere olan hızlı erişim, kullanılan araçların gelişimi ve çeşitliliği, birçok insanın ilgisini bu alana çekmektedir. Fakat finansal piyasalardaki karmaşık, derin ve öngörülemez yapı, yeterli finansal okul yazarlığı ve/veya deneyimi olmayan yatırımcı kitlesi için gerçekleştirilen işlemlerin ciddi risk barındırmasına sebep olmakta ve durum finansal piyasalardaki karar destek mekanizmalarının önemini ortaya koymaktadır. Bu nedenle geçmişten günümüze finansal verilerin analizi araştırılması popüler konulardan biri olmuştur. Finansal verilerin analizindeki temel amaç piyasa özelliklerinin etkilerini ve gelecekteki yönlerini, piyasa davranışlarına dayalı karar mekanizmaları için tahmin etmektir[1]. Özellikle finansal zaman serilerinin tahmini, finansal varlık piyasasında ileriye yönelik alınması gereken kararlar ve işlemlerin temelini oluşturmaktadır. Bu durum birçok araştırmacının dikkatini bu alana yoğunlaştırmasına sebep olmuştur. Son yıllarda bilindik istatistiksel yöntemler dışında derin öğrenmeye dayalı analiz ve tahmin modelleri başarılarından söz ettirmektedir. Özellikle LSTM derin öğrenme ağına dayalı olan modeller, zaman serileri ve benzer sıralı öğrenme görevlerinde oldukça başarılı sonuçlar elde ettiği görülmektedir[2].

Konuşma tanıma, dil çevirisi, hareket tanıma, el yazı tanıma gibi birçok alanda, hem uzun hem de kısa süreli bilgileri hatırlama yeteneği dolayısıyla avantajlı bir model olan LSTM ağları sıklıkla kullanılmaktadır. Finans araştırmalarında, hesaplama zekâsının önemli bir kısmı finansal zaman serilerinin analizine ve tahminine dayanmaktadır [3]. Yıllardır hisse senedi piyasaları gibi siyasi, ekonomik, toplumsal psikoloji, haber vb. birçok girdinin etken olabildiği yapılarda, çeşitli istatistiksel hesaplamalar ile elde edilen teknik göstergeler sayesinde piyasaların davranışları tahmin edilmeye çalışılmıştır. Hesaplama zekâsının büyük gelişim gösterdiği günümüzde, teknik göstergeler ve piyasa bilgileri (açılış, kapanış, yüksek, düşük, hacim vb.); LSTM derin öğrenme ağı modelleri için tahmin sistemlerine girdi olarak kullanılmaktadır [4-10]. Bunun yanında Borsa İstanbul endekslerine yönelik LSTM derin öğrenme ağı temelli farklı veri seti ve değerlendirme metrikleri için tahmin modelleri geliştirilmiştir [11-15].

Gerçekleştirilen bu çalışmada finansal varlıklardaki fiyat oynaklıklarını tahmin edebilmek amacıyla LSTM derin öğrenme ağına eklenen boyut indirgeme yöntemlerinin, derin öğrenme fiyat tahmin modelinin performansına olan etkisini incelemek üzerine kurgulanmıştır. Hisse senedi endeksleri ve hisse senedi fiyat bilgileri, tarihsel/zamansal verilere dayanması sebebiyle zaman serilerine güzel bir örnektir. Bu nedenle derin öğrenme fiyat tahmin modeli için zaman serileri gibi sıralı dizilere özel olarak tasarlanmış olan LSTM ağının kullanılması tercih edilmiştir. Bununla birlikte finansal varlıkların fiyatlanması sırasında toplumsal değerlendirmeler, haberler, finansal göstergeler, ekonomik göstergeler, siyasi etkenler vb. çok çeşitli değişkenler rol oynamaktadır. Veri setinde bu ve benzeri

değişkenlerin çokluğu, verinin boyutunu etkilemekte dolayısıyla tahmin modelinin performansı da etkilenmektedir. Veri boyutu düşürülmesi ile tahmin modellerinin eğitim sürelerinin kısaltılabileceği yanında, tahmin modelinin performansının yükseltilebileceği yönünde çeşitli çalışmalar bulunmaktadır. Bu çalışmalardan yola çıkarak, yapılan çalışmada Faktör Analizi, Temel Bileşen Analizi, Bağımsız Bileşen Analizi gibi istatistiksel boyut indirgeme yöntemlerinin, LSTM derin öğrenme tahmin modelinin performansına olan etkisi değerlendirilmektedir. Bunun için veri ön işleme aşamasında derin öğrenme fiyat tahmin modeline dâhil edilen boyut indirgeme yöntemleri ile oluşturulan hibrit FA+LSTM, PCA+LSTM ve ICA+LSTM tahmin modelleri, LSTM derin öğrenme fiyat tahmin modeli ile karşılaştırılmaktadır. Bunun için Borsa İstanbul 100 (BIST100) endeksine ait Eylül 2002 ve Temmuz 2020 tarihleri arasındaki endeks fiyat bilgisi kullanılmaktadır. Elde edilen sonuçlar hibrit PCA+LSTM modelinin, diğer hibrit modelleri geride bırakarak LSTM fiyat tahmin modelinin performansını iyileştirmede daha başarılı olduğunu göstermektedir. Literatür taramamıza göre Türk borsaları için boyut indirgeme yöntemleri kullanan tahmin modelleri ile ilgili araştırmalar olsa bile bu çalışmamızda olduğu gibi doğrudan hibrit FA+LSTM, PCA+LSTM ve ICA+LSTM tahmin yöntemlerinin performansını karşılaştıran bir çalışmaya rastlanılmamıştır. Bu ise çalışmamızın özgün yönünü ortaya koymaktadır. Böylece, literatürdeki tahmin yöntemlerinin performansını karşılaştırılması konusundaki boşluk doldurulmuş olacaktır.

Bu çalışmanın ana hatları şu şekildedir: Bölüm 2’ de, kullanılan materyal ve yöntemler hakkında bilgi verilmektedir. Elde edilen araştırma sonuçları ve tartışmalar Bölüm 3’ de paylaşılmaktadır. Bölüm 4’ de ise sonuçlar ve gelecekteki çalışmalar özetlenmektedir.

2. Materyal ve Metot

2.1. Veri Seti



Şekil 1. BIST100 veri setinin tarihsel fiyat grafiği

Çalışma kapsamında Borsa İstanbul 100 endeksi günlük verileri kullanılmaktadır. Öncelikle ham veri seti için Yahoo Finance [16]’tan 20/09/2002 tarihinden 24/07/2020 tarihine kadar ki 4422 günlük veriye ait açılış, kapanış, yüksek, düşük,

düzeltilmiş kapanış ve hacim bilgileri elde edilmiştir. Bu bilgilerin ayırt edici özelliklerinin düşük olması sebebiyle, BIST100 endeks fiyat bilgisindeki eğilimlerin daha iyi ayırt edilebilmesine destek olabilecek bir takım teknik göstergeler (EMA, SMA, MOM, RSI, ATR, FIBO düzeltme seviyeleri vb.) eklenerek toplamda 49 öznelikten oluşan yeni bir veri seti oluşturulmuştur. Hazırlanan veri seti, tahmin modeline uygulanmadan önce, eğitim seti için yaklaşık %70, doğrulama seti için %10 ve test seti için %20'lik parçalara ayrılmıştır. Buna ait gösterim ve kullanılan veri setinin tarihsel fiyat grafiği Şekil 1' de verilmektedir. Yeşil renkte gösterilen çizgiler eğitim setini, mavi renkte gösterilen çizgiler doğrulama setini ve kırmızı renkte gösterilen çizgiler test seti göstermektedir.

2.2. Metotlar

2.2.1. Faktör Analizi (FA)

Faktör analizi birçok farklı alanda kullanılabilen çok değişkenli istatistiksel analiz yöntemlerinden bir tanesidir. Bu analiz yöntemi m değişkenli bir yapıda birbirleri ile ilişkili değişkenlerden arındırılmış daha az sayıdaki n değişkeni bulmak için kullanılır. Kısacası faktör analizinin temel amacı, boyutu indirgeyerek kullanılan veri kümesini kolay anlaşılabilir hale getirmeye çalışmaktır. Bununla beraber faktör analizi ölçülmesi veya gözlemlenmesi zor olan gizli boyutları ortaya çıkarmak için kullanılmakta ve korelasyon, regresyon, ayırıcı fonksiyon analizi vb. birçok farklı analizler için fayda sağlamaktadır [17,18].

2.2.2. Temel Bileşen Analizi (PCA)

Temel bileşen analizi Karl Pearson (1901) tarafından tanıtılan sınıflandırma, sıkıştırma, yüz ve hareket tanıma gibi farklı alanlarda kullanılabilen istatistiksel bir yöntemdir [19]. Esasında faktör analizinin bir türevi olarak, benzer şekilde yüksek boyutlu verilerin boyutunu düşürmek için kullanılmaktadır. Temel bileşenler maksimum varyans miktarını açıklarken, faktör analizi verilerdeki kovaryansı açıklamaktadır. Temel bileşen analizi ile boyut indirgeme işlemi gerçekleştirilirken veri setinde mümkün olan en çok çeşitliliği sağlayan ve temel bileşen olarak isimlendirilen orijinal değişken sayısına eşit ya da daha az sayıda yepyeni bir değişken setinin oluşturulması amaçlanmaktadır.


2.2.3. Bağımsız Bileşen Analizi (ICA)

Bağımsız Bileşen Analizi (ICA), olarak isimlendirilen ve bir veri kümesindeki ilk iki dereceden bağımlılıkları azaltarak istatistiksel olarak bağımsız yeni özellikler türeten bir özellik çıkarma yöntemidir [20]. Özellikle kaynak sinyal ve karıştırma mekanizmaları hakkında herhangi bir ön bilgiye sahip olmadan karmaşık sinyallerden bilinmeyen ve bağımsız sinyalleri ayırtmayı sağlayan sinyal işleme mekanizmaları ve problemleri için kullanılmaktadır. Bu yönüyle sayısal ses, sayısal görüntü, biyo-dalga bilgileri ve zaman serileri gibi birçok farklı veri türünün analizinde bu yöntemden faydalanılmaktadır. Yöntemin temel çalışma prensibi normal dağılım olmayan verilerin, birbirinden bağımsız olan yonlerini araştırması üzerinedir.

2.2.4. Uzun Kısa Süreli Bellek (LSTM)

LSTM ağları, tekrarlayan sinir ağları (RNN) gibi peş peşe bağlanmış sinir hücrelerinden meydana gelmektedir. Hochreiter ve Schmidhuber (1997) tarafından RNN' lerin bir türevi olarak tasarlanmıştır [21]. RNN' lerde gözlenen kaybolan gradyan sorununa çözüm getirebilmesi sebebiyle zaman serilerinde etkili

bir şekilde kullanılabilir. Bunu sinir hücresi içerisinde kapı olarak isimlendirilen yapılar vasıtasıyla gerçekleştirmektedir. Bu kapılar ve görevleri şu şekilde özetlenebilir: İstenilen bilgilerin güncellenmesinden sorumlu Giriş Kapısı, sinir hücresi tarafından kullanılması istenilmeyen bilgilerin yok edildi Unutma Kapısı ve sinir hücresine ait çıkış bilgisinin tutulduğu Çıkış Kapısıdır.



Şekil 2. Bir LSTM Hücresi[7]

Şekil 2' de LSTM ağındaki bir sinir hücresine ait yapı gösterilmekle birlikte bahsedilen kapı yapılarına ait matematiksel eşitlikler aşağıda paylaşılmaktadır[7]:

Giriş Kapısı:

$$i_t = \sigma(w_i \times [h_{t-1}, x_t] + b_i) \quad (1)$$

$$\bar{c}_t = \tanh(w_c \times [h_{t-1}, x_t] + b_c) \quad (2)$$

Unutma Kapısı:

$$f_t = \sigma(w_f \times [h_{t-1}, x_t] + b_f) \quad (3)$$

Çıkış Kapısı:

$$c_t = f_t * c_{t-1} + i_t * \bar{c}_t \quad (4)$$


$$o_t = \sigma(w_o \times [h_{t-1}, x_t] + b_o) \quad (5)$$

$$h_t = o_t * \tanh(c_t) \quad (6)$$

2.3. Oluşturulan LSTM Hibrit Modeller

BIST100 Endeksi için kullanacağımız fiyat tahmin modeli, Thakkar vd. yapmış oldukları karşılaştırmalı çalışmadaki LSTM tahmin modeli temel alınarak hazırlanmıştır [22]. Buna göre LSTM tahmin modelinde; 64 ve 128 sinir hücresinden oluşan 2 LSTM katmanına, 256 ve 512 sinir hücresinden oluşan iki tam bağlı katman eşlik etmekte ve son olarak bir sinir hücresinden oluşan çıkış katmanı ile model mimarisi oluşturulmaktadır. Her bir katman arasında bırakma (dropout) işlemi uygulanmaktadır. Tahmin modelinin hiper-parametreleri için bırakma işlemi değeri 0.3, yığın boyutu 50, her bir eğitim turu 125, optimizasyon algoritması ADAM, aktivasyon fonksiyonu doğrusal ve parametre güncellemeleri için hata fonksiyonu ortalama karesel hata (MSE) olarak önerilmiştir. BIST100 ham veri setine

sonradan eklenen bir takım teknik göstergelerden sonra meydana gelen yeni veri seti, veri ön işleme sürecinde boyut indirgeme yöntemlerine (FA, PCA, ICA) tabi tutulmaktadır. Boyut indirgeme işleminden sonra elde edilen yeni veri kümesi 5 katmandan oluşan bu LSTM ağına sokularak, 5 gün sonraki fiyatı tahmin etmeye çalışılmaktadır.



Şekil 3. Oluşturulan hibrit derin öğrenme tahmin modelinin çalışma çerçevesi

2.4. Değerlendirme Ölçütleri

Çalışmada oluşturulan modellerin performanslarını değerlendirebilmek amacıyla Belirleme Katsayısı (R^2) ve Kök Ortalama Karesel Hata (RMSE) değerlendirme ölçütleri tercih edilmektedir. Belirleme katsayısının bire yaklaşan yüksek değerleri ve kök ortalama hata oranının sıfıra yaklaşan düşük değerleri fiyat tahmin modelinin ne kadar başarılı olduğuna işaret etmektedir.

$$R^2 = 1 - \frac{\sum_i (y_i - f_i)^2}{\sum_i (y_i - \bar{y})^2} \quad (7)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i' - y_i)^2} \quad (8)$$

3. Araştırma Sonuçları ve Tartışma

3.1. Bulgular

Deneyel çalışmalar, Intel Core i7-3.4 GHz CPU ve 12 GB RAM'e sahip bir sistem üzerinde, Google Colaboratory ortamında Python programlama dili ve Keras derin öğrenme kütüphanesi kullanılarak gerçekleştirilmiştir. Belirlenen tarihten 5 gün sonraki fiyatı tahmin etmek için kullanılan LSTM fiyat tahmin modeli, daha önce belirtilen çalışmadaki [22] derin öğrenme yapısı ve hiper-parametre düzeni birebir alınarak hazırlanmıştır. Deneyel çalışmalar sırasında her model 5 kez çalıştırılmış ve elde edilen sonuçların ortalaması paylaşılmıştır. Ayrıca gerek kullanılan teknik göstergelerin özelliklerini gerekse tahmin modelinin performansını etkileyecek olan dönüştürme penceresi, geriye bakış penceresi ve boyut indirgeme yönteminde kullanılacak olan bileşen (öznitelik) sayısı gibi parametrelerin modelin performansına katkısını izleyebilmek amacıyla bu parametreler üzerinde ince ayarlamalar yapılmıştır. Buradaki amaç boyut indirgeme yöntemleri kullanılmadan önce LSTM fiyat tahmin modeli için en üstün performansı sağlayacak şekilde belirtilen parametrelerin en uygun değerlere ayarlanmasıdır. Sırasıyla en uygun değerleri bulunan parametre modele uygulanarak bir sonraki parametrenin belirlenmesi adımına geçilmektedir. En uygun parametre değerlerinin belirlenmesinde LSTM modeli için en yüksek R^2 ve en düşük RMSE değerlerini veren parametre değerleri gözetilmektedir.

İlk olarak teknik göstergelerin hesaplanmasında ve kullanımında doğrudan etkin olan dönüştürme penceresi (transforming window) parametresinin en uygun değerinin

belirlenmesi için, piyasada sık kullanılan teknik gösterge değerleri ile ilgili bir dizi denemeler yapılmıştır. Elde edilen sonuçlar en uygun dönüştürme pencere boyutu değerinin 12 seçildiği durumlarda LSTM fiyat tahmin modelinin en iyi performansı sağladığını göstermektedir. İlgili sonuçlar Tablo 1'de paylaşılmaktadır.

Tablo 1. Dönüştürme Penceresi Parametre Değer Seçimi ve LSTM Tahmin Modeli Performansı

Dönüştürme Penceresi	R^2	RMSE
3	0,914027	0,023168
5	0,92145	0,022145
9	0,915381	0,022985
12	0,926545	0,021415
14	0,917394	0,02271
20	0,920712	0,022249

Bir sonraki adımda geriye bakış penceresi (lookback window) parametresinin en uygun değerinin belirlenmesi için bir dizi değerlerle benzer bir çalışma yapılmaktadır. Bu parametre kaç günlük geçmiş verilere bakılarak tahmin yapılacağına belirlendiği parametredir. Dönüştürme penceresi 12'ye ayarlandıktan sonra, en uygun geriye bakış pencere değeri 3 olarak belirlenmektedir. İlgili deneye ait sonuçlar Tablo 2'de gösterilmektedir.

Tablo 2. Geriye Bakış Penceresi Parametre Değer Seçimi ve LSTM Tahmin Modeli Performansı

Geriye Bakış Penceresi	R^2	RMSE
3	0,844015	0,031169
5	0,778225	0,037117
8	0,656869	0,046108
11	0,561294	0,052051
14	0,426816	0,059399
21	0,16454	0,071311

Dönüştürme penceresi ve geriye bakış pencere parametreleri belirlendikten sonra LSTM derin öğrenme modeli boyut indirgeme yöntemleri kullanmaksızın performansı belirli olmuştur. Buna göre LSTM derin öğrenme fiyat tahmin modeli dönüştürme penceresi=12 ve geriye bakış penceresi=3 iken 5 gün sonraki fiyatı tahmin etmek istediğinde; 0,844015 R^2 puanı ve 0,031169 RMSE puanı elde etmektedir. Hibrit olmayan LSTM modeline ait sonucun grafiksel gösterimi Şekil 4'te görülmektedir.

Sonrasında aynı parametre değerleri için veri ön işleme adımında boyut indirgeme yöntemleri dâhil edilerek hibrit LSTM derin öğrenme tahmin modelleri olan FA-LSTM, PCA-LSTM ve ICA-LSTM elde edilmiştir. Bu noktada piyasa bilgileri ve teknik göstergelerle birlikte 49 öznitelikten meydana gelen BIST100 veri setimizin öznitelik sayıları 5, 8 ve 12'ye indirgenmesi durumunda hibrit LSTM modellerin performansları incelenmeye

çalışılmaktadır. Deneysel sonuçları hibrit PCA+LSTM fiyat tahmin modelinin veri seti boyutu 8'e düşürüldüğünde, LSTM modelini ve diğer hibrit modelleri geride bırakarak en başarılı performansı sergilediğini göstermektedir. Yapılan deneysel çalışma ile ilgili sonuçlar Tablo 3'de paylaşılmaktadır.



Şekil 1. LSTM modeline ait sonuç

Deneysel sonuçlarının grafiksel gösterimi Şekil 5'de verilmektedir. Buna göre yeşil ile gösterilen çizgi BIST100 endeksine ait test setinde kullanılan gerçek değeri gösterirken, kırmızı çizgi ilgili hibrit derin öğrenme modeli tarafından tahmin edilen değeri temsil etmektedir.

Tablo 3. İndirgenen Öznitelik Sayısı ve Hibrit LSTM Modellerinin Performansları

Modeller	Öznitelik Sayısı	R ²	RMSE
FA+LSTM	5	0,868382	0,028631
	8	0,838533	0,031712
	12	0,830556	0,032486
PCA+LSTM	5	0,868896	0,028575
	8	0,882893	0,027007
	12	0,869224	0,028539
ICA+LSTM	5	0,850839	0,030480
	8	0,867977	0,028675
	12	0,861679	0,029351

3.2. Tartışma

Çalışma amacının BIST100 endeks fiyat oynaklıklarını tahmin edebilmek için LSTM derin öğrenme ağına eklenen boyut indirgeme yöntemlerinin, derin öğrenme fiyat tahmin modelinin performansına olan etkisini incelemek olması ve literatürdeki çalışmaların belirli bir görev için farklı veri setleri veya farklı değerlendirme metrikleri ile kullanılması sebebiyle doğrudan karşılaştırma yapmak güçtür. Bu nedenle çalışma kapsamında elde edilen sonuçlar değerlendirilmektedir.

Deneysel çalışmalarımız LSTM fiyat tahmin modeli ve veri setinde kullanılan bir takım teknik göstergelerin hesaplanmasında kullanılan parametrelerin, modelin performansına doğrudan etki ettiğini gösterebilmektedir. Tahmin modelinde teknik göstergelerin hesaplanmasında kullanılan dönüştürme penceresi parametresi, kullanılan değerler arasında en yüksek başarımlı değerlerini 12 gün için vermektedir.

Benzer şekilde geçmişteki ne kadar sürelik bilgiyi referans alarak tahmin yapmamızı sağlayan geriye bakış pencere parametresi en yüksek başarımlı değerlerini 3 günlük geriye dönük değerler için vermektedir. Burada dikkat çeken nokta bu parametre değeri ne kadar büyürse başarımlı oranı da o oranda düşmektedir.



Şekil 5. Hibrit LSTM Modellerine ait sonuçlar

Bir diğer önemli parametre boyut indirgeme yöntemlerinde kullanılan bileşen (öznitelik) sayısı parametresidir. Veri seti piyasa bilgisi ve teknik göstergelerden oluşması sebebiyle 49 farklı öznitelik taşımaktadır. Fakat bu özniteliklerin hepsi ayırt edici özellikte olamamaktadır. Öyle ki 5 öznitelikte temel bileşenlerin toplam varyansı %95'i bulmaktadır. Bu sebeple tercih edilecek öznitelik sayısının tahmin modeline etkisini görebilmek için 3 farklı öznitelik sayısı ile etki, incelenmek istenmiştir. Bu noktada PCA ve ICA yöntemleri 8 öznitelik seçtiğinde tahmin modeli en iyi performansları verirken, FA yöntemi ile 5 öznitelikte tahmin modeli en iyi performansı sergilemiştir. Hibrit modellerin en iyi performansı verdikleri öznitelik sayıları üzerinde karşılaştırması yapıldığında PCA+LSTM modelinin 8 öznitelikle tahmin gerçekleştirdiğinde

daha başarılı sonuçlar elde ettiği ve hibrit olmayan LSTM modelinin performansını yukarı taşıdığı görülebilmektedir.

4. Sonuç

Bu çalışmada LSTM derin öğrenme ağına dayanan fiyat tahmin modeli vasıtasıyla çok bilinen bazı istatistiksel boyut indirgeme yöntemlerinin etkinliği araştırılmıştır. Faktör analizi, temel bileşenler analizi ve bağımsız bileşenler analizi gibi istatistiksel teknikler, LSTM derin öğrenme ağı ile birlikte kullanılarak BIST100 endeks fiyatına etki eden özniteliklerin seçimi gerçekleştirilmiştir. Bu durum veri setinde gereksiz tekrar eden bir takım verilerin sadeleşmesine dolayısıyla kullanılan veri seti boyutunun düşmesine ve tahmin modelinin performansında artış görülmesini sağlamaktadır. Deneysel çalışmamız bu tespiti doğrulamaktadır. PCA+LSTM modeli diğer boyut indirgeme yöntemlerinden daha başarılı bir performans göstererek, hibrit olmayan LSTM modelinin elde ettiği sonuçları, R^2 puanı için %4.60 ve RMSE için %13.35 iyileştirmektedir. Bunun yanında deneysel çalışma, derin öğrenme ağı hiper-parametreleri dışında kullanılan dönüştürme penceresi, geriye bakış penceresi ve tercih edilecek öznitelik sayısı gibi bazı parametrelerin tahmin modelinin performansındaki etkisini de göstermektedir.

Elbette bu sonuçlar, LSTM derin öğrenme ağı optimize edilerek daha ileriye taşınabilir. İleriki çalışmalarda fiyat tahmin modeli için farklı derin öğrenme modelleri ve boyut indirgeme yöntemleri kullanılarak karşılaştırmalar yapılabileceği gibi uygulama diğer ülkelerin endekslerine uyarlanarak genişletilebilir.

Kaynakça

- [1] Cavalcante, R. C., Brasileiro, R. C., Souza, V. L., Nobrega, J. P., & Oliveira, A. L. (2016). Computational intelligence and financial markets: A survey and future directions. *Expert Systems with Applications*, 55, 194-211.
- [2] Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural networks*, 61, 85-117.
- [3] Ozbayoglu, Ahmet Murat, Mehmet Ugur Gudelek, and Omer Berat Sezer. "Deep learning for financial applications: A survey." *Applied Soft Computing* 93 (2020): 106384.
- [4] Gao, T., Chai, Y., & Liu, Y. (2017, November). Applying long short term memory neural networks for predicting stock closing price. In 2017 8th IEEE international conference on software engineering and service science (ICSESS) (pp. 575-578). IEEE.
- [5] Roondiwala, M., Patel, H., & Varma, S. (2017). Predicting stock prices using LSTM. *International Journal of Science and Research (IJSR)*, 6(4), 1754-1756.
- [6] Pang, X. W., Zhou, Y., Wang, P., Lin, W., & Chang, V. (2018, March). Stock Market Prediction based on Deep Long Short Term Memory Neural Network. In COMPLEXIS (pp. 102-108).
- [7] Wen, Y., Lin, P., & Nie, X. (2020, March). Research of stock price prediction based on PCA-LSTM model. In IOP Conference Series: Materials Science and Engineering (Vol. 790, No. 1, p. 012109). IOP Publishing.
- [8] Liu, W., Wang, Z., Liu, X., Zeng, N., Liu, Y., & Alsaadi, F. E. (2017). A survey of deep neural network architectures and their applications. *Neurocomputing*, 234, 11-26.
- [9] Zhuge, Q., Xu, L., & Zhang, G. (2017). LSTM Neural Network with Emotional Analysis for prediction of stock price. *Engineering letters*, 25(2).
- [10] Faurina, R., Winduratna, B., & Nugroho, P. (2018). Predicting stock movement using unidirectional LSTM and feature reduction: the case of an Indonesia stock. In *2018 International Conference on Electrical Engineering and Computer Science (ICEECS)*. Bali, Indonesia (pp. 180-5).
- [11] Unal, B., & Aladag, C. H. (2019). Stock Exchange Prediction via Long Short-Term Memory Networks. *Proceedings Book*, 246.
- [12] Santur, Y. Deep Learning Based Regression Approach for Algorithmic Stock Trading: A Case Study of the Bist30. *Gümüşhane Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 10(4), 1195-1211.
- [13] Demirel, U., Handan, Ç. A. M., & Ramazan, Ü. N. L. Ü. (2021). Predicting stock prices using machine learning methods and deep learning algorithms: The sample of the Istanbul Stock Exchange. *Gazi University Journal of Science*, 34(1), 63-82.
- [14] Kilimci, H., Kilimci, Z. H., & Yıldırım, M. (2021, November). Deep Learning-based Decision Integration Strategy for the Price Prediction of Istanbul Stock Exchange (BIST100). In 2021 13th International Conference on Electrical and Electronics Engineering (ELECO) (pp. 411-414). IEEE.
- [15] Selçuk, A. L. P., Yiğit, Ö. E., & Ersoy, Ö. Z. (2020). Prediction of bist price indices: a comparative study between traditional and deep learning methods. *Sigma Journal of Engineering and Natural Sciences*, 38(4), 1693-1704.
- [16] YahooFinance. <https://finance.yahoo.com/quote/XU100.IS/history?p=XU100.IS>. Erişim: 23 Şubat 2022.
- [17] Yaşlıoğlu, M. M. (2017). Sosyal bilimlerde faktör analizi ve geçerlilik: Keşfedici ve doğrulayıcı faktör analizlerinin kullanılması. *İstanbul Üniversitesi İşletme Fakültesi Dergisi*, 46, 74-85.
- [18] Johnson, R. A., & Wichern, D. W. (2014). *Applied multivariate statistical analysis* (Vol. 6). London, UK:: Pearson.
- [19] Pearson, K. (1901). LIII. On lines and planes of closest fit to systems of points in space. *The London, Edinburgh, and Dublin philosophical magazine and journal of science*, 2(11), 559-572.
- [20] Anowar, F., Sadaoui, S., & Selim, B. (2021). Conceptual and empirical comparison of dimensionality reduction algorithms (PCA, KPCA, LDA, MDS, SVD, LLE, ISOMAP, LE, ICA, t-SNE). *Computer Science Review*, 40, 100378.
- [21] Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8), 1735-1780.
- [22] Thakkar, A., & Chaudhari, K. (2021). A Comprehensive Survey on Deep Neural Networks for Stock Market: The Need, Challenges, and Future Directions. *Expert Systems with Applications*, 114800.