



Derin Öğrenme Tabanlı Görüntü Sınıflandırma Yaklaşımı ile Borsa İstanbul 100 Endeks Yönünün Tahmini

Prediction of Borsa Istanbul 100 Index Direction via Deep Learning Based Image Classification Approach

Yahya ALTUNTAŞ^{*1} , Adnan Fatih KOCAMAZ² 

^{1,2}Bilgisayar Mühendisliği Bölümü, İnönü Üniversitesi, Malatya, Türkiye

(yahyaaltuntas@gmail.com, fatih.kocamaz@inonu.edu.tr)

Received:Dec.4, 2023

Accepted:Dec.13, 2023

Published:Dec.20, 2023

Özetçe— Borsa endeksleri, genel ekonomik performansı yansıttıkları için yatırımcılar tarafından yatırım kararları alırken önemli bir referans olarak kullanılırlar. Ayrıca, portföy yönetim şirketlerinin endeksleri replike eden yatırım fonları, hisse senetleri gibi gerçek zamanlı olarak alınıp satılabilir. Bu nedenle, borsa endeksinin gelecekteki yönünü tahmin etmek, yatırımcılar için kritik bir öneme sahiptir. Bu çalışmada, Borsa İstanbul 100 (BIST100) endeksinin yön tahmininde derin öğrenme tabanlı bir görüntü sınıflandırma yaklaşımı önerilmiştir. İlk olarak, günlük BIST100 endeks değerleri bir sonraki günün endeks değeri ile karşılaştırılarak yukarı ve aşağı şeklinde etiketlendi. Etiketlenen veriler daha sonra teknik analiz göstergeleri kullanılarak grafik görüntülerine dönüştürüldü. Tahmin modeli için, ön-egitilmiş evrimsel sinir ağı (CNN) modelleri olan AlexNet, GoogLeNet ve ResNet-50, problemle uyumlu hale getirilmek üzere ince ayarlandı. Eğitim dışı bırakılan üç yıllık dönem boyunca ince-ayarlama yapılmış AlexNet, GoogLeNet ve ResNet-50 modelleri sırasıyla %54,22, %53,01 ve %54,62 doğruluk değerleri ile BIST100 endeks yönünü tahmin edebilmiştir. Ayrıca, modellerin performansını değerlendirmek için Naive karşılaştırma yöntemi kullanıldı. Deneysel sonuçlar, ince ayarlı her üç CNN modelinin Naive karşılaştırma yönteminden daha iyi sonuçlar elde ettiğini göstermektedir.

Anahtar Kelimeler : BIST100, Finansal zaman serisi analizi, Derin öğrenme, Evrimsel sinir ağları, Transfer öğrenme.

Abstract— Stock market indices are used as a significant reference by investors when making investment decisions, as they reflect the overall economic performance. Additionally, portfolio management companies' investment funds that replicate indices can be bought and sold in real time, similar to stocks. Therefore, predicting the future direction of the stock market index is of critical importance for investors. In this study, a deep learning-based image classification approach is proposed for predicting the direction of the Borsa Istanbul 100 (BIST100) index. Initially, daily BIST100 index values were labeled as up or down by comparing them with the index value of the following day. The labeled data was then transformed into graphic images using technical analysis indicators. For the prediction model, pre-trained Convolutional Neural Network (CNN) models, namely AlexNet, GoogLeNet, and ResNet-50, were fine-tuned to adapt to the problem. Fine-tuned AlexNet, GoogLeNet, and ResNet-50 models achieved accuracy values of 54.22%, 53.01%, and 54.62%, respectively, in predicting the direction of the BIST100 index during the three-year out-of-sample period. Additionally, the Naive comparison method was used to evaluate the performance of the models. Experimental results indicate that all three fine-tuned CNN models outperformed the Naive comparison method.

Keywords : BIST100, Financial time series analysis, Deep learning, Convolutional neural networks, Transfer learning.

1. Giriş

Finansal varlıkların fiyatları politik olaylar, haberler, yatırımcı psikolojisi gibi çok sayıda değişkenden etkilenmeleri nedeniyle kaotik, doğrusal-olmayan, karmaşık bir yapıya sahiptir (Cavalcante ve diğerleri, 2016). Bu durum, finansal zaman serisi tahminini zorlu bir görev haline getirmektedir. Uzun yıllardır araştırmacılar, finansal zaman serisi tahmini için geleneksel olarak ekonometrik ve istatistiksel araştırmalar gerçekleştirenken son

yıllarda daha çok makine öğrenmesi temelli çalışmalar yapmışlardır. Albuquerque ve diğerleri (2022) her iki yaklaşımı değerlendirmiş ve geleneksel yöntemlerin tahmin için uygun olmadığını, öte yandan, makine öğrenmesi modellerinin, eğitim için kullanılan kullanıcı tanımlı hiper-parametrelerdeki küçük değişikliklere bile son derece duyarlı olduğu için oldukça farklı sonuçlara yol açabileceğini ve modelin genel tahmin performansını etkileyebileceğini belirtmişlerdir.

Finansal varlıkların fiyat hareketleri doğrusal olmayan çok değişkenli bir yapıya sahip oldukları için makine öğrenmesi yöntemleri, algoritmik ticaret, yatırım yönetimi, servet yönetimi ve risk yönetiminde geleneksel yöntemlere göre daha iyi sonuçlar vermektedir (Dixon ve diğerleri, 2020). Bununla birlikte, geleneksel makine öğrenmesi yöntemlerinde model başarımı kullanılan özniteliklere bağlıdır. Finansal zaman serisi verileri için uygun öznitelikleri belirlemek ise, neredeyse imkânsız bir görevdir. Ancak öznitelik çıkarımını ağ katmanları boyunca kendiliğinden gerçekleştiren derin öğrenme tekniklerinin kullanılması sayesinde bu zorlu görevi başarmak daha mümkün hale gelmiştir. Bu sebeple, finansal zaman serisi tahmini için derin öğrenme tabanlı çalışmalar öne çıkmaya başlamış ve son yıllarda artan bir ilgiyle devam etmektedir.

Derin öğrenme tabanlı finansal zaman serisi tahmini konusunda yayınlanmış derleme makaleler, en çok kullanılan derin öğrenme modelinin Özyineli Sinir Ağları (RNN) ve bir varyasyonu olan Uzun Kısa Süreli Bellek Ağları (LSTM) olduğunu ortaya koymaktadır (Durairaj ve Mohan, 2019; Li ve Bastos, 2020; Ozbayoglu ve diğerleri, 2020; Sezer ve diğerleri, 2020). Moghar ve Hamiche (2020), gelecekteki borsa değerlerini tahmin etmek için RNN ve LSTM kullanarak bir model oluşturmayı amaçlamışlardır. Yazarlar yaptıkları çalışmada 19/08/2004 ile 19/12/2019 tarihleri arasındaki NKE ve GOOGL hisselerine ait fiyat değişim verileri üzerinde çalışarak önerdikleri yöntemle klasik metotlara göre daha başarılı sonuçlar elde edildiğini ortaya koymuşlardır. Bukhari ve diğerleri (2020) finansal piyasa tahmini için Otoregresif Kesirli Entegre Hareketli Ortalama (ARFIMA) ve LSTM modellerinin bir kombinasyonuna dayanan hibrit ARFIMA-LSTM modelini önermişlerdir. Bu hibrit model, piyasa değişkenleri yardımıyla veriden potansiyel bilgileri çıkarır ve her iki modelin öneri kümesinin kesişimini alarak tahmin doğruluğu açısından daha iyi performans elde eder. Yoo ve diğerleri (2021) piyasa verilerindeki değişim noktalarını tahmin etmek için Gürültü Giderici Otomatik Kodlayıcı (DAE) ve LSTM modelini kullanmışlardır. Yazarlar, çeşitli sektörlerdeki piyasa verilerini ampirik olarak ele almış, DAE kullanarak veriyi önemsiz özniteliklerden arındırılmış ve bu veriyi LSTM modeli ile eğitmişlerdir. Elde ettikleri sonuçlar genel olarak dikkat çekicidir. Bhandari ve diğerleri (2022) S&P 500 endeksinin ertesi gün kapanış fiyatını tahmin etmek için tek katmanlı ve çok katmanlı LSTM modellerini karşılaştırmışlardır. Bu karşılaştırma sonunda tek katmanlı modellerin tahmin yeteneğinin daha üstün olduğunu tespit etmişlerdir.

Bilgisayarlı görü problemlerinin çözümünde üstün performans göstermesi nedeniyle Evrimsel Sinir Ağları (CNN) en çok kullanılan derin öğrenme modellerinden biridir. CNN modellerinin bilgisayarlı görü çalışmalarındaki üstün performansı doğal dil işleme ve zaman serisi analizi gibi farklı alanlardan araştırmacıların da dikkatini çekmiş ve kendi problemlerine adapte etmişlerdir (Fawaz ve diğerleri, 2019). Finansal zaman serisi tahmini çalışmalarında CNN modelleri tek başlarına ya da hibrit modellerde çözümün bir parçası olarak kullanılmışlardır. Ve bu alandaki kullanımları artan bir ilgiyle devam etmektedir. Ozbayoglu ve diğerleri (2020) finansal zaman serisi tahmininde derin öğrenme kullanımını inceledikleri derleme çalışmalarında, finansal zaman serisi verilerinin görüntü temsillerinin CNN ile modellenmesinin yenilikçi bir alan olduğunu belirtmişlerdir. Khodae ve diğerleri (2022) hisse senedi dönüm noktalarının tahmin edilmesi için LSTM ve CNN modellerini birleştiren hibrit bir yöntem önermişlerdir. Yazarlar bu hibrit modeli ResNet ağında eğiterek daha güçlü hale getirmiş ve Dow-30'da ortalama %60,19 ve ETF'lerde %63,62'lik ortalama doğru tahmin başarıları göstermişlerdir. Mehtab ve Sen (2022), CNN ve LSTM tabanlı derin öğrenme modeli oluşturarak bu modeli piyasa verileri üzerinde test etmiş ve yürütme süresi, ortalama hata gibi metriklerle performans sonuçlarını sunmuşlardır. Kirişçi ve Yolcu (2022) finansal zaman serisi tahminine yönelik olarak CNN tabanlı model önererek bu modeli TAIEX ve FTSE borsalarının verileriyle eğitmişlerdir. Yazarlar, CNN yapısının, farklı yapay sinir ağı türleri, LSTM, bulanık tabanlı yaklaşımlar ve bazı geleneksel yöntemlere göre daha başarılı olduğunu belirtmişlerdir. Gong ve diğerleri (2022) AAPL hisse senedi üzerinde teknik analiz göstergelerini temel alan üç katmanlı bir tahmin modeli oluşturmak için CNN kullanmıştır. Bu üç katman; (i) öz nitelikleri çıkararak evrim katmanı, (ii) doğrultulmuş lineer birimler (ReLU) katmanı ve (iii) toplu normalleştirme katmanıdır. Durairaj ve Mohan (2022), kaos teorisi, CNN ve polinom regresyon içeren hibrit bir yaklaşımla finansal zaman serisi tahmini yapmışlardır. Altuntaş ve diğerleri (2022) ons altın fiyat verilerini mum grafikleri ve teknik analiz göstergeleri kullanarak grafik görüntülere dönüştürdüler. Alım-satım sinyalleri üretmek için ön-eğitilmiş CNN mimarisini ince-ayarlayarak fiyat yön tahmini için kullandılar. Önerdikleri modelin %53,8 doğruluk ve 3 yıllık test dönemi için %48,42 kâr ile karşılaştırılan diğer yatırım stratejilerinden daha başarılı sonuçlar ürettiğini bildirdiler.

Endeksler borsada işlem hacmi ve değer olarak en büyük şirketlerin performansını gösteren bir ölçektir. Borsa İstanbul'un performansı BIST100 endeksi ile ölçülür. Bu nedenle, borsa yatırımcıları tarafından borsanın genel durumunu anlamak için kullanılır. Borsa yatırımcıları kendi portföylerindeki hisse senetleri için alım-satım kararı verirken BIST100 endeksinden yararlanırlar. Her ne kadar endeksler birer finansal enstrüman olmasalar da portföy

yönetim şirketlerinin çıkarttığı endeksleri replike eden borsa yatırım fonları vardır. Bu yatırım fonları hisse senetleri gibi gerçek zamanlı olarak alınıp satılabilmektedir. Ayrıca, kaldıraçlı işlemlerde endeks kontratları alınıp satılabilmektedir. Bu çalışmada, BIST100 endeks yönünün tahmini için finansal zaman serisi verilerinin teknik analiz göstergeleri yardımıyla grafik görüntülere dönüştürüldüğü ve endeks yön tahmini için ince-ayarlanmış ön-egitimli CNN modellerinin kullanıldığı yeni bir yöntem önerilmiştir.

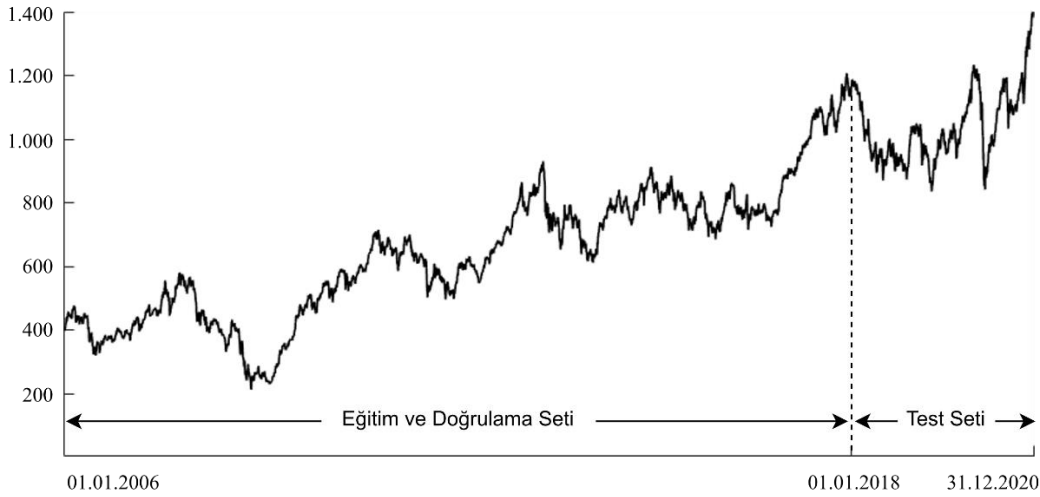
Çalışmanın geri kalanı şu şekilde organize edilmiştir. Veri seti, veri etiketleme prosedürü, verilerin teknik analiz göstergeleri yardımıyla grafik görüntülere dönüştürülme prosedürü, önerilen tahmin modeli Bölüm 2’de verilmiştir. Bulgular Bölüm 3’de ele alınmıştır. Çalışmanın genel değerlendirmesine ve gelecek çalışmalara Bölüm 4’de yer verilmiştir.

2. Materyal ve Metot

2.1. Veri Seti

Çalışma kapsamında 01/01/2006 – 31/12/2020 tarihlerini kapsayan 15 yıllık günlük BIST100 endeks verileri kullanılmıştır. Veriler <https://finance.yahoo.com> kaynağından elde edilmiştir. Veri seti borsanın işlem gördüğü 3.761 kayıttan oluşmaktadır. Borsa İstanbul 2020 yılında pay endekslerinin ulaştıkları seviyeleri dikkate alarak fiyat ve getiri endekslerinden iki sıfır atılmasına karar verdi (Borsa İstanbul, 2020). Bu nedenle, veri setinin anlamsal bütünlüğünü korumak için 27/07/2020 tarihinden önceki endeks değerleri 100 ile bölünmüştür.

01/01/2018 – 31/12/2020 tarihlerini kapsayan 3 yıllık veri model performanslarının ölçülmesi amacıyla test seti olarak ayrılmıştır. 01/01/2006 – 31/12/2017 tarihlerini kapsayan 12 yıllık veri 4:1 oranında iki parçaya bölünerek eğitim ve doğrulama için kullanılmıştır. Çalışmada kullanılan BIST100 endeks verilerine ait değişim grafiği Şekil 1’de gösterilmiştir.



Şekil 1. 2006 – 2020 yıllarına ait BIST100 endeksi değişim grafiği.

2.2. Verilerin Etiketlenmesi

Çalışma kapsamında BIST100 endeks yön tahmini yapabilmek için veriler Yukarı ve Aşağı olarak etiketlenmiştir. Etiketleme işlemi her bir güne ait endeks değerinin kendinden sonraki günün endeks değeri ile karşılaştırılması ile yapılmıştır. Veriler endeks değerinin bir gün sonra yükselmesi durumunda Yukarı, bir gün sonra düşmesi durumunda ise Aşağı olarak etiketlenmiştir. Etiketli hesaplanan güne ait endeks değerinin bir sonraki günün endeks değeri ile eşit olduğu durumlarda, devam eden günün etiketi kullanılmıştır. Veri etiketleme aşaması Denklem (1)’e göre gerçekleştirilmiştir.

$$etiket_t = \begin{cases} \text{"YUKARI"}, & deęer_t < deęer_{t+1} \\ \text{"AŐAĐI"}, & deęer_t > deęer_{t+1} \\ etiket_{t+1}, & deęer_t == deęer_{t+1} \end{cases} \quad (1)$$

Burada etiket_t ve etiket_{t+1} sırasıyla t’nci ve t+1’nci günün etiketini; deęer_t ve deęer_{t+1} sırasıyla t’nci ve t+1’nci günlerin BIST100 endeks değerini temsil etmektedir.

2.3. Finansal Zaman Serisi Verilerinin Görüntü Dönüşümleri

Zaman serisi verilerinin grafik görüntülere dönüştürülmesi için endeks değeri ile teknik analiz göstergelerinden basit hareketli ortalama (SMA) ve Bollinger bantları kullanılmıştır. SMA 10, 20, 30, 40 ve 50 günlük periyotlar için hesaplanmıştır.

SMA, en çok kullanılan hareketli ortalama (MA) türlerinden biridir. En sade ifadeyle, bir finansal varlığın belirlenen dönem içerisindeki kapanış fiyatlarının ortalamasıdır (Achelis, 2001). SMA Denklem (2)'ye göre hesaplanmaktadır.

$$SMA(t, m) = \sum_n^t \frac{değer_n}{m}, \quad n = t - m + 1 \quad (2)$$

Burada, t SMA hesaplanan t'nci günü, m ise SMA'nın kaç gün için hesaplanacağını göstermektedir. $değer_n$ n'nci güne ait endeks değerini temsil etmektedir.

Bollinger bantları, hareketli ortalamanın üstüne ve altına yerleştirilen volatilité bantlarıdır. Orta bant, n periyotluk hareketli ortalamadır. Üst ve alt bantlar, n periyotluk hareketli ortalamaya, n periyotluk endeks değerinin standart sapmasının m katının sırasıyla eklenip çıkarılması ile hesaplanır (Achelis, 2001). Bollinger bantları Denklem (3-5)'e göre hesaplanmaktadır.

$$Bollinger_{orta} = MA(n) \quad (3)$$

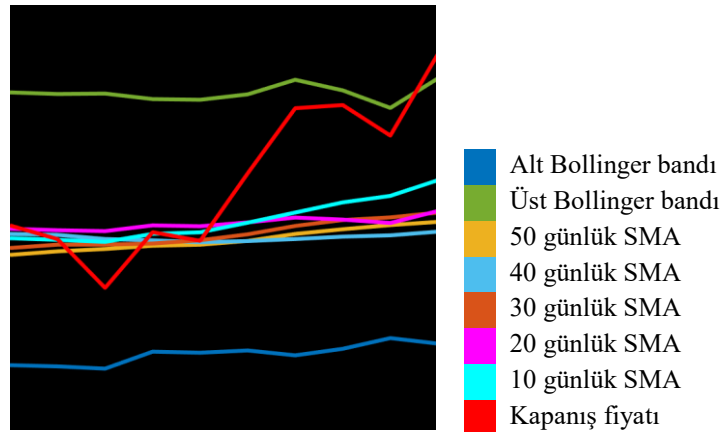
$$Bollinger_{üst} = Bollinger_{orta} + m \cdot \sigma(n) \quad (4)$$

$$Bollinger_{alt} = Bollinger_{orta} - m \cdot \sigma(n) \quad (5)$$

Burada, n Bollinger bantlarının hesaplanacağı periyot sayısını ve m eklenip çıkarılacak standart sapma sayısını temsil etmektedir. MA(n) n periyotluk hareketli ortalamayı ve $\sigma(n)$ n periyotluk endeks değerinin standart sapmasını ifade etmektedir. Farklı periyotlar için farklı m ve n değerleri kullanılarak Bollinger bantları hesaplanabilir. Bu çalışmada Bollinger bantları 20 günlük periyotta SMA için hesaplanmış ve m değeri 2 olarak kullanılmıştır.

Veri setindeki ilk 49 kayıt için 50 günlük basit hareketli ortalama değeri hesaplanamadığından ve veri setindeki son işlem gününe ait kayıt etiketlenemediğinden bu veriler için görüntü dönüşümleri yapılmamıştır. Görüntü veri seti 1.957'si Yukarı etiketli ve 1.754'ü Aşağı etiketli olmak üzere toplam 3.711 görüntüden oluşmaktadır. Yukarı etiketli görüntü verilerinin 1.551'i eğitim ve doğrulama işlemleri, 406'sı test işlemi için kullanılmıştır. Aşağı etiketli görüntü verilerinin 1.413'ü eğitim ve doğrulama işlemleri, 341'i test işlemi için kullanılmıştır.

Teknik analiz göstergeleri kullanılarak elde edilen 675x675 piksel çözünürlüklü grafik görüntüler PNG formatında kaydedilmiştir. Her bir görüntü 10 günlük çerçevede oluşturulmuştur. Görüntüler, en-boy oranları muhafaza edilerek, çalışma kapsamında kullanılan ön-eğimli CNN modellerinin giriş görüntü boyutları olan 224x224 ve 227x227 piksel çözünürlüğe yeniden boyutlandırılmışlardır. Oluşturulan görüntü veri setinden örnek bir görüntü ve teknik analiz göstergeleri için kullanılan renk bilgisi Şekil 2'de gösterilmiştir.



Şekil 2. Veri setinden örnek bir görüntü

2.4. Önerilen Model

CNN verideki uzamsal bağımlılıkları ağ katmanları boyunca kendiliğinden öğrenen bir derin öğrenme mimarisidir. 1D (zaman serisi), 2D (görüntü) veya 3D (video) verilere uygulanabilmektedir (Lecun ve diğerleri, 2015). Öncü CNN mimarilerinden AlexNet'in ImageNet yarışmasında elde ettiği başarı bilgisayarlı görü topluluğunun tamamen bu alana yönelmesi ile sonuçlanmıştır (Lecun ve diğerleri, 2015). CNN mimarilerine olan ilgi sadece bilgisayarlı görü topluluğu ile sınırlı kalmamıştır. Doğal dil işleme ve zaman serisi analizi gibi farklı alanlardan araştırmacılar da CNN mimarisini kendi problemlerine adapte etmişlerdir (Fawaz ve diğerleri, 2019).

CNN mimarileri finansal zaman serisi tahmini konusunda tek başlarına ya da hibrit modellerde çözümün bir parçası olarak kullanılmışlar ve CNN'lerin bu alandaki kullanımı artan bir ilgi ile devam etmektedir (Sezer ve Özbayoğlu, 2018). Literatürde finansal zaman serisi tahmininde CNN kullanan çalışmalar incelendiğinde, kullanılan modellerin düşük karmaşıklığa sahip modeller olduğu görülmektedir. Bu çalışmada problemin karmaşık doğası gereği yüksek karmaşıklığa sahip modellerin daha üstün performans gösterebileceği motivasyonu ile ön-eğitimli modellere ve ince-ayarlamaya dayalı bir endeks yön tahmin modeli öneriyoruz. Ön-eğitimli CNN modelleri kullanmamızın birkaç sebebi vardır: (i) Ön-eğitimli CNN modelleri ImageNet yarışmasında 1000 sınıflı bir problemi üstün performans ile çözmüş olmalarından dolayı görüntü sınıflandırma problemlerinde başarımları kanıtlanmıştır. (ii) Ön-eğitimli CNN modelleri yüksek karmaşıklığa sahiptirler. (iii) Ön-eğitimli CNN modelleri düşük miktarda veri ile benzer ancak farklı bir probleme adapte edilebilirler. (iv) Rastgele ağırlık değerleri ile başlanacak sıfırdan eğitim ile karşılaştırıldığında, ön-eğitimli CNN modelleri problemin çözümüne daha hızlı yakınsarlar.

Çalışmada kullanılan ön-eğitimli CNN modelleri aşağıda kısaca tanıtılmıştır. AlexNet (Krizhevsky ve diğerleri, 2012) öncü CNN mimarilerinden biridir. AlexNet, 5 evrişim katmanı ve 3 tam bağlantılı katmandan oluşan basit bir mimariye sahiptir. GoogLeNet (Szegedy ve diğerleri, 2015), başlangıç ağırlığının bir çeşidi olan 22 katmanlı bir CNN mimarisidir. GoogLeNet mimarisinin en önemli özelliği başlangıç modülünün kullanılmasıdır. Modül, birden fazla farklı katman arasında doğrudan bağlantı sağlar. Bu, bilgi işlem maliyetini aynı seviyede tutarken ağ karmaşıklığını artırır. ResNet-50 (He ve diğerleri, 2016) mimarisi 50 katmandan oluşmaktadır. ResNet-50, mikro mimari modül yapısıyla diğer mimarilerden farklıdır. Mimaride bazı katmanlar arasındaki değişim göz ardı edilerek alt katmana geçilmesi tercih edilebilir. ResNet mimarisinde bu yapı ile bloklar arası geçiş işlemlerine olanak sağlanarak performans oranı artırılmıştır.

Önerilen tahmin modelinin işlem adımlarına ait sözde kod Algoritma 1'de, önerilen tahmin modelinin genel akış şeması Şekil 3'te sunulmuştur.

Algoritma 1. Önerilen Tahmin Modelinin İşlem Adımları

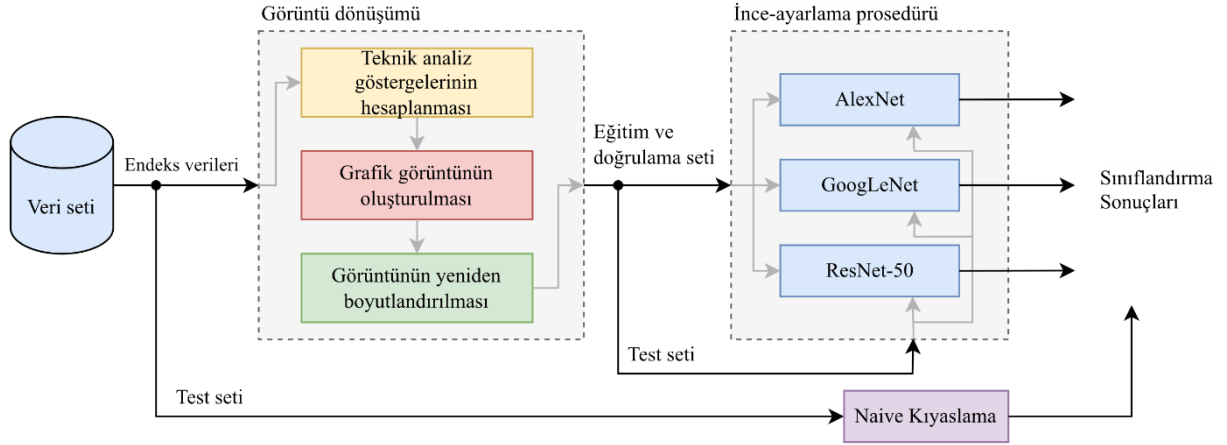
- 1: **procedure Tümİşlemler()**
- 2: **Veri Seti Önİşleme Aşaması:**
- 3: 27/27/2020 tarihinden önceki verileri 100 ile böl
- 4: Veriyi eğitim, doğrulama ve test setlerine ayır

- 5: **Veri Etiketleme Aşaması:**
- 6: Kapanış endeks değerlerini kullanarak etiketleri (Yukarı|Aşağı) hesapla

- 7: **Verinin Görüntü Temsillerinin Oluşturulması Aşaması:**
- 8: Teknik analiz (SMA ve Bollinger bantları) değerlerini hesapla
- 9: Grafik görüntüleri oluştur
- 10: Görüntüleri 227x227 ve 224x224 piksel çözünürlüğe boyutlandır
- 11: Görüntüleri etiket bilgisi ile birlikte ait olduğu sete (eğitim, doğrulama, test) kaydet

- 12: **CNN Modellerinin İnce-Ayarlanması Aşaması:**
- 13: CNN modellerini ince-ayarla

- 14: **Kıyaslama Aşaması:**
- 15: İnce-ayarılanmış CNN modellerinin sınıflandırma sonuçlarını al
- 16: Naive kıyaslama yönteminin sınıflandırma sonucunu al
- 17: Model sınıflandırma sonuçlarını karşılaştır



Şekil 3. Önerilen tahmin modelinin genel akış şeması

3. Bulgular

3.1. Deneysel Kurulum

BIST100 endeks verilerinin etiketlenmesi, teknik analiz göstergelerinin hesaplanması, verilerin görüntü temsillerinin üretilmesi ve ön-eğitilmiş CNN modellerinin ince-ayarlar prosedürü MATLAB © (R2020b) ortamında gerçekleştirilmiştir. Çalışmada kullanılan bilgisayar 2.6 GHz i5 işlemci, 512 GB SSD sabit disk, 8 GB DDR4 sistem belleği ve 4GB ekran kartına sahiptir.

Ön-eğitilmiş CNN modellerinin ince-ayarlanması için kullanılan hiper-parametre değerleri şu şekilde ayarlanmıştır: Modellerin son tam bağlı katmanları 2 çıkışlı tam bağlı katman ile değiştirildi. Maksimum epoch sayısı 100, mini batch sayısı 32, öğrenme katsayısı 10^{-3} olarak ayarlandı. Bir epoch 69 eğitim adımı sürdü. Doğrulama prosedürü her epochda bir kez çalıştırıldı. Art arda 5 doğrulama prosedürü sonucunda öğrenme başarımının artmaması durumunda eğitim sonlandırıldı.

AlexNet modelinin ince-ayarlar işlemi 17 dakika 38 saniye sürdü. İşlem 13. epoch sonunda, 897 eğitim adımında, %51,82 doğruluk oranı ile tamamlandı. GoogLeNet modelinin ince-ayarlar işlemi 41 dakika 59 saniye sürdü. İşlem 11. epoch sonunda, 759 eğitim adımında, %52,09 doğruluk oranı ile tamamlandı. ResNet-50 modelinin ince-ayarlar işlemi 56 dakika 59 saniye sürdü. İşlem 6. epoch sonunda, 414 eğitim adımında, %50,20 doğruluk oranı ile tamamlandı.

3.2. Sınıflandırma Sonuçları

Çalışma kapsamında önerilen BIST100 endeks yön tahmin modelinin sınıflandırma başarımını ölçmek için sınıflandırma performans metriklerinden Doğruluk (Acc), Duyarlılık (Sen), Hassasiyet (Pre) ve F-ölçütü kullanılmıştır. Bu metrikler karmaşıklık matrisinden türetilen Doğru Pozitif (TP), Yanlış Pozitif (FP), Yanlış Negatif (FN) ve Doğru Negatif (TN) değerleri kullanılarak hesaplanmaktadır. Bu değerler hesaplanırken sınıflardan biri pozitif sınıf diğeri negatif sınıf olarak kabul edilir. Bu çalışmada Aşağı sınıfı pozitif sınıf ve Yukarı sınıfı negatif sınıf olarak ele alınmıştır. Model tarafından doğru tahmin edilen pozitif örneklerin sayısı TP, doğru tahmin edilen negatif örneklerin sayısı TN, yanlış tahmin edilen pozitif örneklerin sayısı FN ve yanlış tahmin edilen negatif örneklerin sayısı FP değerini verir. Çalışmada kullanılan sınıflandırma performans metriklerine ait matematiksel ifadeler aşağıda verilmiştir.

$$\text{Doğruluk} = \frac{TP + TN}{TP + FP + FN + TN} \quad (6)$$

$$\text{Duyarlılık} = \frac{TP}{TP + FN} \quad (7)$$

$$\text{Hassasiyet} = \frac{TN}{TN + FP} \quad (8)$$

$$F - \text{ölçütü} = \frac{2 * TP}{2 * TP + FP + FN} \quad (9)$$

Model performanslarının karşılaştırılması için Naive kıyaslama yöntemi kullanılmıştır. Naive kıyaslama yönteminde t-1. günün sınıf etiketi t. günün tahmini olarak atanır (Gündüz ve diğerleri, 2018). Deney sonuçlarında ele edilen karmaşıklık matrisleri Şekil 4'te gösterilmiştir. Çalışma kapsamında kullanılan AlexNet, GoogLeNet ve ResNet-50 CNN modellerinin ve Naive kıyaslama yönteminin sınıflandırma sonuçları Tablo 1'de sunulmuştur.

		GERÇEK SINIF DEĞERİ		
		AŞAĞI	YUKARI	
TAHMİN EDİLEN SINIF DEĞERİ	AŞAĞI	63 8.4%	64 8.6%	49.6% 50.4%
	YUKARI	278 37.2%	342 45.8%	55.2% 44.8%
		18.5% 81.5%	84.2% 15.8%	54.2% 45.8%

(a)

		GERÇEK SINIF DEĞERİ		
		AŞAĞI	YUKARI	
TAHMİN EDİLEN SINIF DEĞERİ	AŞAĞI	58 7.8%	68 9.1%	46.0% 54.0%
	YUKARI	283 37.9%	338 45.2%	54.4% 45.6%
		17.0% 83.0%	83.3% 16.7%	53.0% 47.0%

(b)

		GERÇEK SINIF DEĞERİ		
		AŞAĞI	YUKARI	
TAHMİN EDİLEN SINIF DEĞERİ	AŞAĞI	160 21.4%	158 21.2%	50.3% 49.7%
	YUKARI	181 24.2%	248 33.2%	57.8% 42.2%
		46.9% 53.1%	61.1% 38.9%	54.6% 45.4%

(c)

Şekil 4. AlexNet (a), GoogLeNet (b) ve ResNet-50 (c) modellerine ait karmaşıklık matrisleri

Tablo 1. Modellerin sınıflandırma performans değerleri

	TP	FN	FP	TN	Acc. (%)	Sen.	Pre.	F-ölçütü
Naive	162	180	179	227	52.01	0.4737	0.5591	0.4744
AlexNet	63	278	64	342	54.22	0.1848	0.8424	0.2692
GoogLeNet	58	283	68	338	53.01	0.1701	0.8325	0.2484
ResNet-50	160	181	158	248	54.62	0.4692	0.6108	0.4856

4. Sonuç

Bu çalışmada, günlük BIST100 endeks yönünü tahmin etmek için 01/01/2006 – 31/12/2020 tarihlerini kapsayan 15 yıllık veri kullanılmıştır. Günlük BIST100 endeks değerleri bir sonraki günün endeks değeri ile karşılaştırılarak Aşağı ve Yukarı şeklinde etiketlenmiştir. Her bir güne ait endeks verileri teknik analiz göstergeleri kullanılarak grafik görüntülere dönüştürülmüştür. Böylece, borsa endeks yön tahmini 2-sınıflı görüntü sınıflandırma problemine indirgenmiştir. Ön-egitimli CNN mimarilerinden AlexNet, GoogLeNet ve ResNet-50 modelleri ince-ayrılarak probleme adapte edilmiştir.

Deneyel sonuçlar ince-ayrılmış AlexNet, GoogLeNet, ResNet-50 modellerinin ve Naive kıyaslama yönteminin sırasıyla %54,22, %53,01, %54,62 ve %52,01 doğruluk değeri ile BIST100 günlük endeks yönünü tahmin edebildiğini göstermektedir. Doğruluk değeri dikkate alındığında ince-ayrılmış her üç CNN modeli Naive kıyaslama yönteminden daha iyi sonuç vermiştir. Bununla birlikte ince-ayrılmış AlexNet ve GoogLeNet mimarilerinin hassasiyet ve duyarlılık değerleri arasında bir dengesizlik söz konusudur. Bu durum, veri setinin sınıfsal dağılımının nispeten dengesiz olmasından kaynaklanmış olabilir. Modeller f-ölçütü performans metriği açısından incelendiğinde en kötü sonuçlar ince-ayrılmış AlexNet ve GoogLeNet modellerinden elde edilmiştir. Buna karşın en iyi f-ölçütü değeri ince-ayrılmış ResNet-50 modelinden elde edilmiştir. Deneyel çalışmalar finansal zaman serisi verileri ile gelecekteki fiyat hareketi arasında küçük de olsa anlamlı bir ilişki olduğunu ve önerilen modelin bu ilişkiyi yakalayabildiğini göstermektedir.

Gelecek çalışmalarda tahmin performansını arttırmak için topluluk öğrenme yöntemleri ve hibrit modeller probleme adapte edilecektir. Ayrıca gelecekte önerilecek tahmin modellerinin farklı finansal enstrümanlar üzerindeki başarımları ölçülecektir.

Kaynaklar

- Achelis, S. B. (2001). *Technical Analysis from A to Z*. McGraw Hill New York.
- Albuquerque, P. H. M., Peng, Y., Silva, J. P. F. da. (2022). Making the whole greater than the sum of its parts: A literature review of ensemble methods for financial time series forecasting. *Journal of Forecasting*, 41(8), 1701–1724. <https://doi.org/10.1002/FOR.2894>
- Altuntaş, Y., Okumuş, F., Kocamaz, A. F. (2022). Evrimsel Sinir Ağları ve Transfer Öğrenme Yaklaşımı Kullanılarak Altın Fiyat Yönünün Tahmini. *Journal of Computer Science*, 7(2), 124–131. <https://doi.org/10.53070/bbd.1205299>
- Bhandari, H. N., Rimal, B., Pokhrel, N. R., Rimal, R., Dahal, K. R., Khatri, R. K. C. (2022). Predicting stock market index using LSTM. *Machine Learning with Applications*, 9, 100320. <https://doi.org/10.1016/J.MLWA.2022.100320>
- Borsa İstanbul. (2020). *BIST Pay Endekslerinden İki Sıfır Atılıyor*. <https://www.borsaistanbul.com/tr/duyuru/2860/bist-pay-endekslerinden-iki-sifir-atiliyor>. Erişim Tarihi: 15 Kasım 2023.
- Bukhari, A. H., Raja, M. A. Z., Sulaiman, M., Islam, S., Shoaib, M., Kumam, P. (2020). Fractional neuro-sequential ARFIMA-LSTM for financial market forecasting. *IEEE Access*, 8, 71326–71338. <https://doi.org/10.1109/ACCESS.2020.2985763>
- Cavalcante, R. C., Brasileiro, R. C., Souza, V. L. F., Nobrega, J. P., Oliveira, A. L. I. (2016). Computational Intelligence and Financial Markets: A Survey and Future Directions. *Expert Systems with Applications*, 55, 194–211. <https://doi.org/10.1016/j.eswa.2016.02.006>
- Dixon, M. F., Halperin, I., Bilokon, P. (2020). Machine learning in finance: From theory to practice. *Machine Learning in Finance: From Theory to Practice*, 1–548. <https://doi.org/10.1007/978-3-030-41068-1/COVER>

- Durairaj, D. M., Mohan, B. H. K. (2022). A convolutional neural network based approach to financial time series prediction. *Neural Computing and Applications*, 34(16), 13319–13337. <https://doi.org/10.1007/S00521-022-07143-2/TABLES/16>
- Durairaj, M., Krishna Mohan, B. H. (2019). A review of two decades of deep learning hybrids for financial time series prediction. *International Journal on Emerging Technologies*, 10(3), 324–331.
- Gong, Y., Ming-Tai Wu, J., Li, Z., Liu, S., Sun, L., Chen, C. M. (2022). A CNN-Based Method for AAPL Stock Price Trend Prediction Using Historical Data and Technical Indicators. *Smart Innovation, Systems and Technologies*, 268, 25–33. https://doi.org/10.1007/978-981-16-8048-9_3/COVER
- Gündüz, H., Yaslan, Y., Çataltepe, Z. (2018). Finansal haberler kullanılarak derin öğrenme ile borsa tahmini. *26th IEEE Signal Processing and Communications Applications Conference, SIU 2018*, 1–4. <https://doi.org/10.1109/SIU.2018.8404616>
- He, K., Zhang, X., Ren, S., Sun, J. (2016). Deep residual learning for image recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 770–778.
- Fawaz, H.I., Forestier, G., Weber, J., Idoumghar, L., Muller, P. A. (2019). Deep learning for time series classification: a review. *Data Mining and Knowledge Discovery 2019 33:4*, 33(4), 917–963. <https://doi.org/10.1007/S10618-019-00619-1>
- Khodae, P., Esfahanipour, A., Mehtari Taheri, H. (2022). Forecasting turning points in stock price by applying a novel hybrid CNN-LSTM-ResNet model fed by 2D segmented images. *Engineering Applications of Artificial Intelligence*, 116, 105464. <https://doi.org/10.1016/J.ENGAPPAL.2022.105464>
- Kirisci, M., Cagcag Yolcu, O. (2022). A New CNN-Based Model for Financial Time Series: TAIEX and FTSE Stocks Forecasting. *Neural Processing Letters*, 54(4), 3357–3374. <https://doi.org/10.1007/S11063-022-10767-Z/FIGURES/8>
- Krizhevsky, A., Sutskever, I., Hinton, G. E. (2012). *ImageNet Classification with Deep Convolutional Neural Networks*. Advances in neural information processing systems, 25.
- Lecun, Y., Bengio, Y., Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>
- Li, A. W., Bastos, G. S. (2020). Stock market forecasting using deep learning and technical analysis: A systematic review. *IEEE Access*, 8, 185232–185242. <https://doi.org/10.1109/ACCESS.2020.3030226>
- Mehtab, S., Sen, J. (2022). Analysis and Forecasting of Financial Time Series Using CNN and LSTM-Based Deep Learning Models. *Lecture Notes in Networks and Systems*, 302, 405–423. https://doi.org/10.1007/978-981-16-4807-6_39/COVER
- Moghar, A., Hamiche, M. (2020). Stock Market Prediction Using LSTM Recurrent Neural Network. *Procedia Computer Science*, 170, 1168–1173. <https://doi.org/10.1016/J.PROCS.2020.03.049>
- Ozbayoglu, A. M., Gudelek, M. U., Sezer, O. B. (2020). Deep learning for financial applications : A survey. *Applied Soft Computing*, 93, 106384. <https://doi.org/10.1016/J.ASOC.2020.106384>
- Sezer, Ö. B., Güdelek, M. U., Özbayoğlu, A. M. (2020). Financial time series forecasting with deep learning: A systematic literature review: 2005–2019. *Applied Soft Computing Journal*, 90, 106181. <https://doi.org/10.1016/j.asoc.2020.106181>
- Sezer, Ö. B., Özbayoğlu, A. M. (2018). Algorithmic financial trading with deep convolutional neural networks: Time series to image conversion approach. *Applied Soft Computing Journal*, 70, 525–538. <https://doi.org/10.1016/j.asoc.2018.04.024>
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., Rabinovich, A. (2015). Going deeper with convolutions. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 1–9.
- Yoo, S., Jeon, S., Jeong, S., Lee, H., Ryou, H., Park, T., Choi, Y., Oh, K. (2021). Prediction of the Change Points in Stock Markets Using DAE-LSTM. *Sustainability 2021, Vol. 13, Page 11822*, 13(21), 11822. <https://doi.org/10.3390/SU132111822>