

# Finansal Piyasalarda Gösterge Sinyali Tahmini İçin Derin Öğrenme Uygulaması

## An Application of Deep Learning for Trade Signal Prediction in Financial Markets

Ali Caner Türkmen, Ali Taylan Cemgil  
Bilgisayar Mühendisliği Bölümü  
Boğaziçi Üniversitesi  
İstanbul, Türkiye  
{caner.turkmen, taylan.cemgil}@boun.edu.tr

**Özetçe** —Finans piyasalarında algoritmaların karlı sonuçlar vereceği kuramsal düzeyde tartışılır olsa da, işlem yönünü ve zamanını tahmin etmeye yönelik yazılım uygulamalarının kullanıldıklarını biliyoruz. Bu çalışmada, ABD hisse senedi piyasalarında işlem gören senet fiyatlarının hareket yönlerini tahmin etmekte yapay öğrenme yöntemlerinin faydaları incelenmektedir. Bu maksatla, finans piyasalarındaki teknik analizde fayda sağladığı bilinen öznitelikler türetilmekte, denetimli öğrenmedeki çeşitli tekniklerin etkinliği araştırılmaktadır. Son olarak, son yıllarda popüler olan “derin öğrenme” tekniklerine örnek olan Yığılmış Oto-Kodlayıcı’nın problemin çözümünde kayda değer tahmin gücü sağladığı sunulmuştur.

**Anahtar Kelimeler**—Yapay Öğrenme, Derin Öğrenme, Finans

**Abstract**—We know algorithms for predicting price movement direction and time are in practical use, despite being disputed at a theoretical level. In this study, we analyze the benefits of various machine learning algorithms to the price movement direction prediction problem, on selected stocks from the U.S. stock markets. To this end, we generate an array of features known to be beneficial in technical analysis of securities, and show the efficacy of several supervised learning methods. Lastly, we demonstrate that Stacked Denoising Auto-Encoders, an example of “deep learning” that has grown popular in recent years, yields significant prediction power.

**Index Terms**—Machine Learning, Deep Learning, Finance

### I. GİRİŞ

Finansal piyasalarda işlem gören varlıkların fiyatları üstünde tahmin yapmanın, yeterince gelişmiş “etkin pazarlarda” imkansız olduğu Fama [1] tarafından tarihi makalesinde gösterilmiştir. Ancak çoğu finansal piyasanın, Fama’nın Etkin Piyasa Hipotezi’nde (Efficient Market Hypothesis) bildirdiği, tüm paydaşların bilgiye eşit ve anlık ulaşabildiği piyasalar olmadıklarını biliyoruz. Bu sebeple özellikle gelişmiş pazarlarda, hızlı akan anlık bilgiye çok hızlı kararlar cevap verebilen algoritmaların finansal kuruluşlar tarafından kullanılmakta olduklarını açık kaynaklardan teyit edebiliyoruz.

Diğer taraftan, gerek problemin pratik uygulamadaki faydaları; gerekse doğal olarak ortaya çıkan, doğrusal olmayan,

karmaşık bir zaman-serisi verisi olması; problemi yapay öğrenme araştırmacıları açısından da ilgi çekici kılmıştır.

Konuyla ilgili erken araştırmalar, daha çok Destek Vektör Makineleri ve Yapay Sinir Ağlarının genelde regresyon şeklinde ifade edilen probleme uyarlanmasına yoğunlaşmıştır.

Yaptıkları derleme çalışmasında, hisse endeksi tahmini çalışmaları Krollner v.d. [2] tarafından detaylıca incelenmiştir. Bu çalışmada, hisse endeksi fiyatlarını tahminlemede hakim yöntemin yapay sinir ağı olduğu, çalışmaların çoğunun başarı bildirdiğine dikkat çekilmiştir. Ayrıca incelenen çalışmaların çoğunda modele girdi olarak bu çalışmada da kullanılan gecikmeli fiyat göstergelerinin kullanıldığı gösterilmektedir.

Çalışmalarda bağımlı değişken; sonraki günün fiyatının daha yüksek olup olmayacağına bakan bir ikili olduğu gibi, doğrudan fiyat regresyonu olarak da formüle edilmiştir. Literatürde, bu çalışmada kullanılan tanımıyla bir “sinyal” değişkeninin tanımına rastlanmamıştır.

Son yıllarda “derin öğrenme” çatı ismi altında popülerleşen derin mimarili yapay sinir ağlarının problem üstündeki etkisi de araştırılacaktır. Derin öğrenme tekniklerinin zaman-serisi verilerde uygulanması son yılların ilgi gören alanlarından biridir. Bu konuda mevcut uygulamaların bir özeti Langkvist v.d. [3] tarafından verilmiştir. Bu uygulama alanında önemli bir örnek olarak Derin İnanç Ağları’nı zaman serisine uygulayan Kuremoto v.d. [4] verilebilir.

Derin öğrenme tekniklerinin finansal zaman-serisi veride uygulamaları hakkında, çok yakın zamanda yayınlanmış araştırmalar vardır. Yoshihara v.d. [5], Özyineli Sinirsel Ağlar ve Kısıtlı Boltzmann Makineleri ile Japon piyasalarında trend tahmini yapabildiklerini göstermişlerdir. Benzer şekilde Zhu, Yin ve Li, [6] Derin İnanç Ağları ile S&P 500 üstünde bir işlem stratejisi geliştirdiklerini bildirmişlerdir.

Bu çalışmanın II. Bölümünde veri seti, kullanılan öznitelikler ve tanımlanan bağımlı değişken tanıtılacaktır. III. Bölüm’de deneysel çalışmalarda kullanılan modellerin detayları ve deneylerin sonuçları paylaşılabilecektir. Son olarak IV. Bölüm’de vargılar ve çalışmanın sonraki adımları verilmiştir.

Tablo I: İncelenen Hisse Senetleri

| Hisse Kodu | Firma İsmi |
|------------|------------|
| AAPL       | Apple      |
| GOOG       | Google     |
| INTC       | Intel      |
| MSFT       | Microsoft  |
| YHOO       | Yahoo      |

Tablo II: Kullanılan Göstergeler

| Gösterge Kodu | Açıklaması                                                                                                                                                                                               |
|---------------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| SMA10-P       | 10 günlük basit hareketli ortalama ile son kapanış farkı fiyatı                                                                                                                                          |
| EMA10-P       | 10 günlük üstel ağırlıklı hareketli ortalama ile son kapanış fiyatı farkı                                                                                                                                |
| SMA20-P       | 20 günlük SMA10-P                                                                                                                                                                                        |
| EMA20-P       | 20 günlük EMA10-P                                                                                                                                                                                        |
| SMA30-P       | 30 günlük SMA10-P                                                                                                                                                                                        |
| EMA30-P       | 30 günlük EMA10-P                                                                                                                                                                                        |
| BBANDS-PCT    | Bollinger bantları, bir hareketli ortalama üstü ve altına hareketli standart sapmanın belli bir katı kadar uzaklıkta çizilmiş çizgilere göre son kapanış fiyatının yüzde olarak durumudur                |
| MACD          | Hareketli Ortalama Yakınsama-Iraksama (Moving Average Convergence Divergence), 26 günlük üstel ağırlıklı hareketli ortalamasının 12 günlük üstel ağırlıklı hareketli ortalamadan çıkarılmasıyla bulunur. |
| MACD-SIGNAL   | MACD göstergesinin, kendisinin 9 günlük hareketli ortalamasından çıkarılmasıyla bulunur                                                                                                                  |

## II. VERİ SETİ

### A. Verinin Toplanması

Çalışmaya konu veriler Yahoo! Finance<sup>1</sup> portalının sunduğu uygulama arayüzünden Matplotlib kütüphanesi [7] aracılığıyla düzeltilmiş olarak alınmıştır. Çalışmaya konu hisse senetleri ABD hisse senedi piyasası NASDAQ'ta işlem gören, teknoloji sektöründe faaliyet gösteren firmalar arasından seçilmiştir ve bu firmalar Tablo I'de gösterilmektedir. Ham veri olarak, bu hisse senetlerinin her birinin günlük açılış, en yüksek, en düşük, ve kapanış (open, high, low, close) fiyatları ile işlem hacmi verisi kullanılmıştır. Süre zarfı olarak 1 Ocak 2010 ile 30 Haziran 2014 tarihleri arası alınmıştır.

Kaynaktan çekilen fiyat ve hacim verileri üzerinden finansal varlıkların “teknik (nicel) analizinde” sıklıkla yararlanılan gecikmeli fiyat göstergeleri (indicator) türetilmiştir. Öğrenme için yalnızca bu göstergeler ve standardize edilmiş hacim verisi kullanılmıştır. Kullanılan ölçütler ve anlamları, Tablo II'de sunulmuştur.

Finansal zaman serilerinin doğası gereği, belli bir zamana dek eğitilen modelin o zamanın sonrasında yüksek performans vermesi gerektiği açıktır. Bu sebeple test seti ayrılırken, 1 Ocak 2010 ile 30 Haziran 2013 tarihleri arası günler eğitim, kalan bir yıllık süre zarfı ise test seti olarak ayrılmıştır.

### B. Bağımlı Değişken

Tahmin edilen “sinyal” değişkeni tanımlanmadan önce, birkaç basit tanımın verilmesine ihtiyaç vardır. Finansal

piyasalarda işlem gören varlıklar üzerinde, insan girdisi olmadan işlem yapacak algoritmaların da birkaç “ayar parametresi” bulunmaktadır. Bunlardan başlıcaları, **kar al** (take-profit) ve **zarar durdur** (stop-loss) seviyeleridir. Birer fiyat noktası olan bu parametrelerle, bir varlıkta alım işlemi yapıldıktan sonra fiyat yükseliyorsa hangi noktada satılarak karın alınacağına, ya da zarar ediliyorsa hangi noktada satılarak zararın durdurulacağına karar verilmektedir.

Belli bir fiyat seviyesinde işlem yapıldıktan sonra, kar al ve zarar durdur seviyelerine **risk-ödül oranı** ile karar verilir.  $k$  işlemi için satın alma fiyatının  $P_k$ , zarar-durdur seviyesinin  $SL_k$ , kar-al seviyesinin  $TP_k$  olarak belirlendiğini düşünelim. Risk-ödül oranı  $RR$ 'nin hesaplanması (1)'de gösterilmiştir.

$$RR_k = \frac{P_k - SL_k}{TP_k - P_k} \quad (1)$$

Son olarak, hisse senetlerinin fiyatları birbirlerinden ayrı ölçeklerde gerçekleşmektedir. Bu sebeple zarar-durdur seviyesinin hesaplanmasında mutlak değerler yerine  $u_k = (P_k - SL_k)/P_k$  olarak tanımlı bir oran kullanıyoruz. Bu durumda, tahmin edilecek olan “sinyal”  $S_t(r, u)$  aşağıdaki şekilde hesaplanmaktadır.

$$S_t(r, u) = \begin{cases} 1 & t \text{ zamanında açılan, } r \text{ risk-ödül oranlı ve} \\ & u \text{ zarar-durdur seviyeli pozisyon kar edecektir} \\ 0 & \text{diğer halde} \end{cases} \quad (2)$$

Böylelikle, kurulan yapay öğrenme modeli sinyalin 1 olduğunu tahmin ettiği durumlarda ‘al’, 0 durumlarda ‘alma’ tavsiyesi veriyor da denebilir.

Böyle bir bağımlı değişken kullanmanın başlıca iki avantajı vardır. Öncelikle problem ikili sınıflandırma problemine indirgenerek çözümü kolaylaştırılmaktadır. Diğer taraftan, deneylerle elde edilecek algoritmanın başarısına dair içgüdüsel bir ölçüt sunulmaktadır. Örneğin, tahmin modelinin test verisi üzerinde verdiği kesinlik (precision), model kullanılırsa yapılacak işlemlerden ne kadarının kar edeceğini vermektedir.

Çalışmada, risk-ödül oranları olarak 1:3 ve 1:4,  $u$  oranı için ise 0.05 kullanılmıştır.

## III. DENEYSEL ÇALIŞMALAR

### A. Sınıflandırma Yaklaşımı

Çalışmada sınıflandırma modeli olarak üç klasik modelden faydalanılmıştır: Destek Vektör Makineleri, Rassal Ormanlar ve Çok Katmanlı Algılayıcı.

**Destek Vektör Makineleri**, [8] iki sınıfa ait örnekleri ayıran maksimum marjlı düzlemi bir optimizasyon problemi olarak formüle eden bir yapay öğrenme modelidir. Örnekler, model vasıtasıyla çok boyutlu bir uzaya yansıtılırlar. Bu işlem doğrusal bir çekirdek yapılabileceği gibi, radyal baz fonksiyonu (RBF) vasıtasıyla da yapılabilir.

Daha önce de belirtildiği gibi, gerek regresyon gerek sınıflandırma türü finansal tahmin problemlerinde DVM sıklıkla başvurulan bir yöntem olmuştur.

<sup>1</sup><http://finance.yahoo.com>

Bu çalışmada, DVM modeli RBF türeviyle kullanılacaktır. Algoritmanın kararlı uygulamaları için Scikit-Learn [9] kütüphanesinden faydalanılmıştır. Çekirdek fonksiyonu hariç diğer parametreler sabit bırakılmıştır.

**Rassal Ormanlar**, Breiman [10] tarafından tanıtılmış ve kendisini oluşturan karar ağaçlarının her bir dallanmasında özniteliklerin ve eğitim verilerinin rassal bir altkümelerini kullanan topluluk (ensemble) modelleridir. Gerek sınıflandırıcı (karar ağacı) sayısının büyüklüğü, gerekse rassal altkümelerle yapılan eğitim, öğrenilen modelin kolayca genelleşmesini sağlamaktadır.

Çalışmada Rassal Ormanlar 100 sınıflandırıcı ile kullanılmıştır. Deneyler için Scikit-Learn kütüphanesinin Rassal Orman Sınıflayıcısı kullanılmış olup, sınıflandırıcı sayısı hariç parametreler sabit bırakılmıştır.

**Çok Katmanlı Algılayıcı** (ÇKA, Multi-layer Perceptron), en temel ve sıklıkla kullanılan yapay sinir ağı modellerinden biridir. Bir ya da daha fazla saklı katmanı olan bu sinir ağı modelinde orta katmanlar doğrusal olmayan bir aktivasyon fonksiyonu (örn. sigmoid) ile kurulur. Model, geriye doğru yayma (backpropagation) algoritması ile öğrenilir.

Bu çalışmada kullanılan ÇKA'da tek saklı katmanda 100 birim kullanılmış ve model Stokastik Eğitim İniş ile öğrenilmiştir.

**Derin Öğrenme**, özellikle Hinton v.d.'nin [11] 2006'da yayınlanan bildirisiyle hızla ivme kazanan; imge ve doğal dil işleme gibi alanlarda faydaları gösterilmiş bir yapay öğrenme araştırma alanıdır. Kökleri LeCun v.d.'nin [12] Evrimsel Yapay Sinir Ağlarına (Convolutional Neural Network), dayanan araştırmalar, Hinton v.d.'nin yapay sinir ağının ilk katmanlarının denetimsiz olarak eğitilmesi fikriyle yüksek başarımla vermeye başlamıştır.

Hinton v.d.'nin algoritması, yaygın bilinen ismiyle Derin İnanç Ağları (Deep Belief Networks), veriyi ilk katmanlarda bir Kısıtlı Boltzmann Makinesi ile kodlayarak sonraki katmana aktarmaktadır. Modelden denetimli öğrenme çıktısı alınmak istendiğinde ise, son katmanda geleneksel yapay sinir ağlarında olduğu gibi Lojistik Regresyon gibi bir doğrusal sınıflayıcı ile çıktı verilmektedir.

Model öğrenilirken ise, ilk olarak denetimsiz katmanlar ilk katmandan başlayarak ileriye doğru eğitilmektedir. Her katman, kendisinden bir önceki katmanın aktivasyon çıktıları olarak öğrenilmektedir. Son safhada ise, denetimli katman üstünden geriye doğru bir "ince ayar"la model parametrelerine son halleri verilmektedir. Araştırmacılar, bu ön-öğrenme safhası ile insan öğrenmesi arasında paralellik kurmaktadır. Aynı zamanda bu ön-öğrenme sayesinde öğrenmenin daha hızlı yakınsadığı ve daha yüksek başarımla elde edildiği gösterilmiştir.

Son olarak, Bengio v.d. [13] Hinton'un yaklaşımındaki Kısıtlı Boltzmann Makinelerini (KBM), Gürültü Gidermeli Oto-Kodlayıcı (Denoising Auto-Encoder) ile değiştirerek Yığılmış Oto-Kodlayıcı (YOK, Stacked Auto-Encoder) modelini önermişlerdir. Çalışmada YOK modelinin MNIST veri seti üzerinde Derin İnanç Ağlarına çok benzer sonuçlar verdiği gösterilmiş, ve KBM yerine oto-kodlayıcı kullanarak model girdileri reel-değerli ve kısıtsız değerlere genellenmiştir.

Bu çalışmada, Derin Öğrenme yöntemlerinin finansal veri setleri üzerinde fayda sağladığı gösterilirken, girdi olarak kullanılan gecikmeli fiyat göstergeleri kısıtsız reel değerler olduğundan YOK modeli kullanılmıştır. Modelin öğrenilmesi için dört oto-kodlayıcı katmanlı bir mimari tercih edilmiş, aktivasyon fonksiyonları için sigmoid seçilmiştir. Her bir oto-kodlayıcı katmanında (saklı katman), 100 birim (nöron) kullanılmıştır. Mimarinin yazılım uygulaması için Palm'dan [14] faydalanılmıştır.

## B. Deney ve Sonuçlar

Çalışmada yukarıda listelenen dört algoritma standardize edilmiş öznitelikler üzerinde çalıştırılmış ve her veri seti için 1:3 ve 1:4 risk-ödül oranları kullanılmıştır.

Çalışma sonuçları "kesinlik" (precision) değeri ve F1 değeri ile ölçülmektedir. Kesinlik, eğitilmiş modelin tahmin ettiği pozitif değerler arasından ne kadarının gerçek pozitif ( $S_t(u, r) = 1$ ) olduğunu niceleyen bir ölçüdür.

Problem bağlamında ise kesinliğin özel bir yorumu vardır. Kesinlik yoluyla, modelin pozitif tahminde bulunduğu her örnek için alım yapıldığı takdirde, bu alımların ne kadarının karla sonuçlanacağı anlaşılmaktadır. Kesinlik değerinin yorumlanmasında, risk-ödül oranının da önemi vardır. Örneğin 1:3 risk-ödül oranlı bir "sinyal" ile işlem yapılıyorsa, yapılan dört alımın bir tanesinin dahi karlı kapanması yeterli olduğundan 0.25 kesinliğin üstündeki modellerin karlı sonuç vereceği tahmin edilebilir. Bu çalışmada 1:3 ve 1:4 oranları kullanıldığından sırasıyla 0.25 ve 0.20'den yüksek kesinliğin başarılı sonuçlar olduğu söylenebilir.

Diğer taraftan, işlem algoritmasından beklenen tek başarı kriteri yapılan işlemlerin karlı olması kadar, kar fırsatlarının önemli kısmının değerlendirilmesidir. Problem bağlamında bu, gerçek pozitiflerin ne kadarının tahmin edilebildiğini niceleyen "çağrı" (recall) ölçüsüyle verilebilir. Çalışmada, bir modelin başarısını açıklamak için çağrı ve kesinlik ölçütlerinin harmonik ortalaması F1-değeri (F değeri de denir) de tüm deneyler için sunulmuştur.

Kesinlik değerinin karşılaştırmaları Tablo III'de, F1 değerlerinin karşılaştırmaları Tablo IV'de görülebilir.

Deney sonuçlarında birkaç nokta göze çarpmaktadır. Öncelikle, kesinlik değerleri, tüm algoritma-veri seti ikilileri için kayda değer başarıya işaret etmektedir. Bir ikili hariç tüm örneklerde, model başarısı beklenen kesinlik seviyesinden (sırasıyla 0.25 ve 0.2) yüksektir. Ayrıca, Rassal Orman sınıflayıcısının diğerlerinden daha düşük kesinlik verdiği görülmektedir.

Yüksek kesinliğin yanı sıra, en yüksek kesinliğin DVM ve YOK modellerinde ortaya çıktığı gözlenmektedir. Beklendiği gibi, YOK modeli daha "sığ" bir yapay sinir ağı olan ÇKA'dan daha yüksek kesinlik sağlamaktadır. Ancak bu çalışmada, bir derin öğrenme algoritması olan YOK'un, finansal varlıkların fiyat tahmininde halihazırda kullanılmış DVM'den daha yüksek başarı sağladığına dair kanıt bulunamamıştır.

F1 değerleri incelendiğinde, yine DVM'nin en yüksek başarıyı sağladığı gözlemlenebilir. MSFT veri setinde sinir ağı temelli algoritmaların yüksek kesinlik ancak düşük F1 değeri vermelerinin sebebi ise, algoritmaların çok az sayıda örneği pozitif olarak tahmin etmesi olarak düşünülebilir.

Tablo III: DENEY SONUÇLARI: KESİNLİK

|                 | Sınıflandırma Algoritması |             |       |      |      |             |             |             |
|-----------------|---------------------------|-------------|-------|------|------|-------------|-------------|-------------|
|                 | DVM                       |             | RO100 |      | ÇKA  |             | YOK         |             |
| Risk/Ödül Oranı | 1:3                       | 1:4         | 1:3   | 1:4  | 1:3  | 1:4         | 1:3         | 1:4         |
| AAPL            | <b>0.41</b>               | <b>0.40</b> | 0.31  | 0.33 | 0.35 | 0.39        | 0.40        | 0.35        |
| INTC            | <b>0.51</b>               | <b>0.47</b> | 0.45  | 0.30 | 0.40 | 0.40        | 0.43        | 0.42        |
| MSFT            | 0.42                      | <b>0.30</b> | 0.32  | 0.23 | 0.80 | 0.66        | <b>0.57</b> | <b>0.30</b> |
| YHOO            | <b>0.37</b>               | 0.21        | 0.29  | 0.20 | 0.34 | <b>0.33</b> | 0.33        | 0.17        |

Tablo IV: DENEY SONUÇLARI: F1 DEĞERİ

|                 | Sınıflandırma Algoritması |             |       |      |             |             |      |      |
|-----------------|---------------------------|-------------|-------|------|-------------|-------------|------|------|
|                 | DVM                       |             | RO100 |      | ÇKA         |             | YOK  |      |
| Risk/Ödül Oranı | 1:3                       | 1:4         | 1:3   | 1:4  | 1:3         | 1:4         | 1:3  | 1:4  |
| AAPL            | <b>0.44</b>               | 0.42        | 0.14  | 0.13 | 0.41        | <b>0.48</b> | 0.41 | 0.32 |
| INTC            | 0.20                      | <b>0.55</b> | 0.20  | 0.10 | <b>0.38</b> | 0.31        | 0.34 | 0.26 |
| MSFT            | <b>0.45</b>               | <b>0.35</b> | 0.29  | 0.20 | 0.07        | 0.04        | 0.21 | 0.11 |
| YHOO            | <b>0.37</b>               | 0.21        | 0.22  | 0.15 | 0.34        | <b>0.36</b> | 0.34 | 0.24 |

Tablolarda, kesinlik ve F1 değerleri her bir hisse senedi, algoritma ve risk-ödül oranı üçlüsü için sunulmuştur. Her hisse - risk/ödül oranı için en yüksek başarımlı algoritma koyu renkle işaretlenmiştir.

#### IV. VARGILAR

Çalışmada, finansal piyasalarda işlem gören varlıkların fiyat hareketlerini tahmin etmede klasik denetimli öğrenme yöntemlerinin yanında bir “derin öğrenme” yönteminin başarısı incelenmiştir. Problem bağlamında tüm yöntemlerle başarı elde edilmiştir.

Finansal piyasalarda otomatik olarak işlem yapacak algoritmaların geliştirilmesi için yeni bir bağımlı değişken (“sinyal”) önerilmiş, ve bu değişken üstünde yapılan deneylerde başarı elde edilmiştir. Bu ölçütle beraber, kesinlik ve F1 değerleri, kullanılan yöntemin başarısını anlamakta hem bilimsel hem finansal anlamları ile yorumlanmıştır.

Bir derin öğrenme algoritması olan Yığılmış Oto-Kodlayıcının, daha sık mimarideki bir yapay sinir ağına göre daha yüksek başarı verdiği ve problemin çözümünde doğru sonuç veren bir alternatif olduğu önerilmektedir. Literatürde, benzer problemlerin genelde sık sinir ağları (örn. Çok Katmanlı Algılayıcı) ile çözüldüğü düşünülürse, derin sinir ağlarının problemin çözümünde yeni bir araştırma sahası olması gerektiği açıktır.

Sonraki adımlar arasında, derin öğrenme modellerinin daha farklı konfigürasyonlarda probleme uygulanarak başarılarının incelenmesi sayılabilir. Başka uygulama alanlarında zaman serilerine uygulanmış özyineli derin sinirsel mimarilerin probleme uygulanması fayda sağlayacaktır.

Diğer taraftan, yöntemlerin diğer finansal varlık sınıflarına ve örneklerine uygulanarak yukarıda sunulan vargıların genelleştirilmesi gerekmektedir. Öznitelik uzayı genişletilerek daha yüksek kesinlikli modeller elde edilebileceği açıktır. Diğer çalışmalarda göze çarpan ve finansal piyasalara dair haberleri doğal dil işleme ile öznitelige dönüştüren yöntemler bir alternatif olarak incelenmelidir.

#### KAYNAKÇA

- [1] E. F. Fama, “Efficient capital markets: A review of theory and empirical work\*,” vol. 25, no. 2, pp. 383–417.
- [2] B. Krollner, B. Vanstone, and G. Finnie, “Financial time series forecasting with machine learning techniques: A survey.”
- [3] M. Längkvist, L. Karlsson, and A. Loutfi, “A review of unsupervised feature learning and deep learning for time-series modeling,” vol. 42, pp. 11–24.
- [4] T. Kuremoto, S. Kimura, K. Kobayashi, and M. Obayashi, “Time series forecasting using a deep belief network with restricted boltzmann machines,” vol. 137, pp. 47–56.
- [5] A. Yoshihara, K. Fujikawa, K. Seki, and K. Uehara, “Predicting stock market trends by recurrent deep neural networks,” in *PRICAI 2014: Trends in Artificial Intelligence*, ser. Lecture Notes in Computer Science, D.-N. Pham and S.-B. Park, Eds. Springer International Publishing, no. 8862, pp. 759–769.
- [6] C. ZHU, J. YIN, and Q. LI, “A stock decision support system based on DBNs,” vol. 10, no. 2, pp. 883–893.
- [7] J. D. Hunter, “Matplotlib: A 2d graphics environment,” vol. 9, no. 3, pp. 90–95.
- [8] C. Cortes and V. Vapnik, “Support-vector networks,” vol. 20, no. 3, pp. 273–297.
- [9] F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, P. Prettenhofer, R. Weiss, V. Dubourg, J. Vanderplas, A. Passos, D. Cournapeau, M. Brucher, M. Perrot, and E. Duchesnay, “Scikit-learn: Machine learning in python,” vol. 12, pp. 2825–2830.
- [10] L. Breiman, “Random forests,” vol. 45, no. 1, pp. 5–32.
- [11] G. Hinton, S. Osindero, and Y.-W. Teh, “A fast learning algorithm for deep belief nets,” vol. 18, no. 7, pp. 1527–1554.
- [12] Y. LeCun, L. Bottou, Y. Bengio, and P. Haffner, “Gradient-based learning applied to document recognition,” vol. 86, no. 11, pp. 2278–2324.
- [13] Y. Bengio, P. Lamblin, D. Popovici, H. Larochelle, and others, “Greedy layer-wise training of deep networks,” vol. 19, p. 153.
- [14] R. B. Palm, “Prediction as a candidate for learning deep hierarchical models of data,” 2012.