



T.C.

SÜLEYMAN DEMİREL ÜNİVERSİTESİ

SOSYAL BİLİMLER ENSTİTÜSÜ

EKONOMETRİ ANABİLİM DALI

**ZAMAN SERİLERİ TAHMİNİNDE TEKRARLAYAN SİNİR
AĞLARININ ETKİNLİĞİNİN İNCELENMESİ**

HAZIRLAYAN

Kübra KESKİN

1930227004

YÜKSEK LİSANS TEZİ

DANIŞMAN

Dr. Öğr. Üyesi Özge GÜNDOĞDU

ISPARTA-2022

TEZ SAVUNMA SINAV TUTANAĐI





T.C.
SÜLEYMAN DEMİREL ÜNİVERSİTESİ
Sosyal Bilimler Enstitüsü Müdürlüğü



YEMİN METNİ

Yüksek Lisans tezi olarak sunduğum “**Zaman Serileri Tahmininde Tekrarlayan Sınır Ağlarının Etkinliğinin İncelenmesi**” adlı çalışmanın, tezin proje safhasından sonuçlanmasına kadar ki bütün süreçlerde bilimsel ahlak ve geleneklere aykırı düşecek bir yardıma başvurulmaksızın yazıldığını ve yararlandığım eserlerin Bibliyografya’da gösterilenlerden oluştuğunu, bunlara atıf yapılarak yararlanılmış olduğunu belirtir ve onurumla beyan ederim.

Kübra KESKİN

25/07/2022

İmza

(KESKİN, Kübra, *Zaman Serileri Tahmininde Tekrarlayan Sinir Ağlarının Etkinliğinin İncelenmesi*, Yüksek Lisans Tezi, Isparta, 2022)

ÖZET

Borsada, hisse senedi alım satım zamanlarına karar verirken hisse fiyatına bağlı olarak yapılan teknik analizlerin yanında hisse senedinin gelecekteki fiyatının öngörülmesi de yatırımcıya minimum risk ve maksimum kazanç sağlamaktadır. Hisse senedi fiyatlarındaki anlık değişimlerin bile yatırımcı için önemli olduğu bu durumda uzun dönemli öngörülerin elde edilmesi, planlama ve risk analizi açısından kritik öneme sahiptir. Tahmin ve öngörü yapmak amacıyla, literatürde birçok geleneksel zaman serisi analiz yöntemi kullanılmaktadır. Bununla birlikte geleneksel yöntemlere alternatif olarak kullanılan yapay sinir ağları ve derin öğrenme yöntemleri, varsayım gerektirmemesi ve iyi öngörü sonuçları elde edilmesi sebebiyle son yıllarda sıklıkla tercih edilmektedir. Derin öğrenme yöntemlerinden Uzun-Kısa Süreli Bellek Modeli'nde hafıza özelliğinin olması çok adımlı öngörüler için büyük avantaj sağlamaktadır. Bu tezde dört büyük spor kulübünün futbol maçlarından elde ettikleri puanların, bu kulüplerin hisse senedi fiyatlarına etkisini ortaya koyarak puan tahmini ve hisse senedi fiyatı öngörüsü yapmak amaçlanmıştır. Bu amaçla ilk aşamada hisse senedi açılış ve kapanış fiyatları ile futbol kulüplerine ait puanlar arasındaki nedensellik ilişkisi incelenmiştir. Ardından sezonlara bağlı olarak, Tekrarlayan Sinir Ağları'nın özel bir türü olan Uzun-Kısa Süreli Bellek Modeli kullanılarak puan tahmini ve hisse senedi kapanış fiyatı öngörüsü yapılmıştır. Uygulamada 2006/07-2020/21 sezon aralığında dört büyük spor kulübünün futbol maçlarından elde ettikleri haftalık puanlar ve borsada işlem gören şirketlerinin günlük hisse senedi fiyatlarına ait veriler kullanılmıştır. Analiz sonuçları, Uzun-Kısa Süreli Bellek Modeli'nin düşük hata ve yüksek performansa sahip çıktılar ürettiğini göstermektedir. Elde edilen sonuçlar doğrultusunda farklı model yapıları ve yöntem karşılaştırmaları ile öngörü doğruluğu için çalışmalar yapılması literatüre katkı sağlayacaktır.

Anahtar Kelimeler: Çok Adımlı Öngörü, Futbol Puanı, Hisse Senedi Fiyatı, Tekrarlayan Sinir Ağları, Uzun-Kısa Süreli Bellek Modeli, Nedensellik.

(KESKIN, Kübra, *Investigation of the Effectiveness of Recurrent Neural Networks in the Time Series Prediction*, Master Thesis, Isparta, 2022)

ABSTRACT

In addition to the technical analysis based on the share price while deciding on the stock trading times in the stock market, the prediction of the future price of the stock provides the investor with minimum risk and maximum profit. Obtaining long-term forecasts is critical in terms of planning and risk analysis, when even instantaneous changes in stock prices are important. In order to forecasting and predict, many traditional time series analysis methods are used in the literature. In recent years, artificial neural networks and deep learning methods, which are used as an alternative to traditional methods, have been frequently preferred because they do not require assumptions and provide accurate forecast results. The Long-Short Term Memory Model, which is one of the deep learning methods, has a memory feature. This feature also provides a great advantage for multi-step predictions. The aim of this thesis is to make score prediction and stock price forecasting by revealing the effect of the scores obtained from the football matches of the four big sports clubs on the stock prices of these clubs. In the first stage, the causality relationship between the opening and closing prices of stocks and the scores of football clubs was examined. Then, using the Long-Short-Term Memory Model which is a special type of Recurrent Neural Networks, score prediction, and stock closing price forecasting were made based on seasons. Weekly ratings from football matches by four major sports clubs in the 2006/07-2020/21 season range, as well as data on the daily stock prices of their listed companies are used in the application. Long-Short Term Memory Model produces outputs with low error and high performance, according to the analysis results. In line with the obtained results, making studies with different model structures and method comparisons for prediction accuracy will contribute to the literature.

Key Words: Multi-Step Forecast, Football Score, Stock Price, Recurrent Neural Networks, Long-Short Term Memory, Causality.

İÇİNDEKİLER

TEZ SAVUNMA SINAV TUTANAĞI	I
YEMİN METNİ.....	II
ÖZET.....	III
ABSTRACT	İV
İÇİNDEKİLER.....	V
KISALTMALAR LİSTESİ	viii
TABLolar DİZİNİ	İX
ŞEKİLLER DİZİNİ	X
TEŞEKKÜR.....	xii
İTHAF	xiii
GİRİŞ.....	1

1. BÖLÜM

YAPAY SİNİR AĞLARI

1.1. Yapay Sinir Ağlarının Tanımı	5
1.2. Biyolojik Sinir Ağı ve Yapay Sinir Ağı Sistemlerinin İncelenmesi. 6	
1.2.1. Mimari Yapılarına Göre Yapay Sinir Ağları.....	7
1.2.1.1. İleri Beslemeli Sinir Ağları	8
1.2.1.2. Geri Beslemeli Sinir Ağları.....	8
1.2.2. Katmanlarına Göre Yapay Sinir Ağları.....	9
1.2.2.1. Tek Katmanlı Yapay Sinir Ağları	9
1.2.2.2. Çok Katmanlı Yapay Sinir Ağları	10
1.2.3. Öğrenme Yöntemlerine Göre Yapay Sinir Ağları.....	10
1.2.3.1. Denetimli Öğrenme	11
1.2.3.2. Denetimsiz Öğrenme	11
1.2.3.3. Takviyeli Öğrenme Kuralı	11
1.3. Yapay Sinir Ağlarının Avantajları, Dezavantajları ve Kullanım Alanları	11

2. BÖLÜM

YAPAY ZEKA

2.1. Yapay Zekanın Tanımı	14
2.2. Makine Öğrenmesinin Tanımı ve Tarihçesi	15
2.2.1. Makine Öğrenmesi Algoritmaları	17
2.2.2. Makine Öğrenmesinin Avantajları, Dezavantajları ve Kullanım Alanları.....	19
2.3. Derin Öğrenmenin Tanımı ve Tarihçesi	20
2.3.1. Derin Öğrenme Mimarileri.....	22
2.3.1.1. Evrişimli Sinir Ağları	23
2.3.1.2. Pekiştirmeli Öğrenme.....	24
2.3.1.3. Tekrarlayan Sinir Ağları.....	25
2.3.1.3.1. Uzun-Kısa Süreli Bellek Modeli	27
2.3.2. Derin Öğrenmenin Avantajları, Dezavantajları ve Kullanım Alanları.....	30
2.3.3. Makine Öğrenmesi ve Derin Öğrenme Arasındaki Benzerlikler ve Farklılıklar.....	31

3. BÖLÜM

GENEL BİLGİLER

3.1. Futbol.....	32
3.1.1. Futbolun Gelişimi.....	32
3.1.2. Futbol Ekonomisi	34
3.1.3. Türkiye'de Futbol Kulüplerinin Gelir Kaynakları ve Giderleri....	35
3.2. Futbol Kulüplerinin Halka Arz Süreci.....	37
3.2.1. Halka Arz Kavramı	37
3.2.2. Halka Arz Yöntemleri	38
3.2.3. Halka Arzın Avantajları ve Dezavantajları	39
3.2.4. Türk Futbol Kulüplerinin Halka Arzı.....	40
3.3. Literatür İncelemesi.....	43

4. BÖLÜM

UYGULAMA

4.1. Veri Seti.....	49
4.2. İstatistiksel Karşılaştırmalar.....	50
4.2.1. Korelasyon Analizi.....	51
4.2.2. Toda-Yamamoto Nedensellik Analizi.....	60
4.3. Dört Büyük Spor Kulübüne İlişkin Puan Tahmini.....	65
4.4. Dört Büyük spor kulübüne İlişkin Hisse Senedi Öngörüsü	72
SONUÇ VE ÖNERİLER.....	81
KAYNAKÇA	84
EKLER.....	93
ÖZGEÇMİŞ.....	97

KISALTMALAR LİSTESİ

BJKAS	: Beşiktaş Futbol Yatırımları Sanayi ve Ticaret Anonim Şirketi
FENER	: Fenerbahçe Futbol Anonim Şirketi
GSRAY	: Galatasaray Sportif Sınai ve Ticari Yatırımlar Anonim Şirketi
N.	: Numara
OMYH	: Ortalama Mutlak Yüzdelik Hata
TSPOR	: Trabzonspor Sportif Yatırım ve Futbol İşletmeciliği Ticaret Anonim Şirketi



TABLÖLAR DİZİNİ

Tablo 1. Yapay Sinir Ağlarının Kullanım Alanları	13
Tablo 2. Özetlenmiş Yapay Zeka Tarihçesi	14
Tablo 3. Toplam Seyirci Sayıları.....	35
Tablo 4. Literatür Tablosu.....	43
Tablo 5. Değişkenlere İlişkin İsimlendirmeler ve Gözlem Sayıları	50
Tablo 6. İlişki Katsayılarına Ait Olasılık Değerleri	58
Tablo 7. Beşiktaş Jimnastik Kulübü'ne Ait Toda-Yamamoto Nedensellik Analizi Sonuçları	61
Tablo 8. Fenerbahçe Spor Kulübü'ne Ait Toda-Yamamoto Nedensellik Analizi Sonuçları	62
Tablo 9. Galatasaray Spor Kulübü'ne Ait Toda-Yamamoto Nedensellik Analizi Sonuçları	63
Tablo 10. Trabzonspor Spor Kulübü'ne Ait Toda-Yamamoto Nedensellik Analizi Sonuçları	63
Tablo 11. Karmaşıklık Matrisi	68
Tablo 12. Puan Tahmininde Kullanılan Model Parametrelerinin Değer Aralıkları ..	68
Tablo 13. Puan Tahmini İçin Elde Edilen En İyi Modellere Ait Sonuçlar.....	69
Tablo 14. Hisse Senedi Öngörüsünde Kullanılan Model Parametrelerinin Değer Aralıkları	75
Tablo 15. Hisse Senedi Öngörüsü İçin Elde Edilen En İyi Modellere Ait Sonuçlar	76
Tablo 16. Hisse Senedine İlişkin Test Verileri ve Hata Ölçütü Değerleri	80

ŞEKİLLER DİZİNİ

Şekil 1. Biyolojik Sinir Ağı Yapısı	6
Şekil 2. Yapay Sinir Ağı Sistemi	7
Şekil 3. İleri Beslemeli Ağı Modeli	8
Şekil 4. Geri Beslemeli Ağı Modeli.....	9
Şekil 5. Tek Katmanlı Yapay Sinir Ağları.....	10
Şekil 6. Çok Katmanlı Yapay Sinir Ağları	10
Şekil 7. Pekiştirmeli Öğrenme Süreci.....	24
Şekil 8. Tekrarlayan Sinir Ağı Modeli.....	25
Şekil 9. Tekrarlayan Sinir Ağı Modelinin İşleyişi	25
Şekil 10. Uzun-Kısa Süreli Bellek Modeli	27
Şekil 11. Uzun-Kısa Süreli Bellek Modeli İşleyişi	28
Şekil 12. Beşiktaş Jimnastik Kulübü’ne Ait Puan ve Hisse Senedi Verileri Arasındaki İlişki	53
Şekil 13. Fenerbahçe Spor Kulübü’ne Ait Puan ve Hisse Senedi Verileri Arasındaki İlişki	54
Şekil 14. Galatasaray Spor Kulübü’ne Ait Puan ve Hisse Senedi Verileri Arasındaki İlişki	55
Şekil 15. Trabzonspor Spor Kulübü’ne Ait Puan ve Hisse Senedi Verileri Arasındaki İlişki	56
Şekil 16. Puan Tahmini İçin Gerekli Kütüphanelerin Yüklenmesi	65
Şekil 17. Puan Tahmini İçin Model Kurulumu.....	66
Şekil 18. Beşiktaş Jimnastik Kulübü’ne Ait 2020-2021 Sezonu Puan Tahmini Grafiği	70
Şekil 19. Fenerbahçe Spor Kulübüne Ait 2020-2021 Sezonu Puan Tahmini Grafiği	70
Şekil 20. Galatasaray Spor Kulübüne Ait 2020-2021 Sezonu Puan Tahmini Grafiği	71
Şekil 21. Trabzonspor Spor Kulübüne Ait 2020-2021 Sezonu Puan Tahmini Grafiği	72
Şekil 22. Hisse Senedi Öngörüsü İçin Gerekli Kütüphanelerin Yüklenmesi	72
Şekil 23. Hisse Senedi Öngörüsü İçin Tekrarlayan Sinir Ağları Yapısının Oluşturulması.....	74

Şekil 24. BJKAS’a ait Günlük Hisse Senedi Öngörüsü Grafiği.....	77
Şekil 25. FENER’e ait Günlük Hisse Senedi Öngörüsü Grafiği	77
Şekil 26. GSRAY’a ait Günlük Hisse Senedi Öngörüsü Grafiği	78
Şekil 27. TSPOR’a ait Günlük Hisse Senedi Öngörüsü Grafiği.....	78



TEŞEKKÜR

Bu tez çalışmasının hazırlanmasında; yardımlarını, bilgi ve deneyimlerini benden esirgemeyen, sevgisini ve desteğini daima hissettiren, kişiliği ve düşünceleri ile lisans eğitimimden bu yana bana çok şey öğreten sevgili danışman hocam Dr. Öğr. Üyesi Özge GÜNDOĞDU'ya, lisans eğitimimden bu yana bana yol ve yön göstererek kendimi keşfetmemi sağlayan Prof. Dr. Hakan DEMİRGİL ve Doç. Dr. Kenan Oğuzhan ORUÇ'a, uzakta olduğu halde bana olan inancı ile daima güven ve destek veren Ar. Gör. Sinan YILDIRIM'a ve üzerimde emeği olan, dersini aldığım bütün hocalarıma teşekkürü borç bilirim.

Ayrıca, hayatta olsaydı en çok sevineceğine inandığım insanlardan olan sevgili babama ardından saymakla bitmeyecek fedakarlıklarıyla bana güç veren sevgili anneme, her düşüşümde elini ilk uzatan, bütün derdimi ve sevincimi ilk paylaştığım ikinci annem olan canım ablama, yanımda oluşlarını her zaman hissettiren ilk aşklarım olan sevgili abilerime, bana ablalık-abilik yapan sevgili yengem ve sevgili enişteme, benim için yerleri daima ayrı olan, beni dünyanın en şanslı insanıymışımcasına mutlu hissettiren sevgili yeğenlerim Nisa, Taha, Nil ve Bera'ya sonsuz teşekkür ederim. Bana sağladığınız maddi ve manevi bütün destekleriniz için sizlere minnettarım.

Son olarak isimlerini yazmakla bitiremeyeceğim fakat bu yolculukta pozitiflikleri ve inançlarıyla her saniye yanımda olan, yoluma ışık tutan bütün arkadaşlarıma ve hayatımın şekillenmesinde rolü olan bütün yakınlarıma sonsuz teşekkür ederim.

Kübra KESKİN

Isparta, 2022

İTHAF

*Bu tez, her yeni güne umut ışıklarıyla uyanan,
kalbi sevgi ve merhamet dolu olan çocuklara ithaf edilmiştir.*

GİRİŞ

Geçmiş veriler kullanılarak günümüze yönelik çıkarım yapmak “tahmin” ve geçmiş ve günümüz verileri kullanılarak geleceğe yönelik çıkarım yapmak “öngörü” olarak ifade edilmektedir. Bu süreçte, düşük hata oranına sahip başarılı tahmin ve öngörüler elde edebilmek için istatistiksel olarak kullanılan çok sayıda yöntem mevcuttur. Bu yöntemlerden birisi de başarılı sonuçlar verdiği bilinen ve yapay zekanın alt dalı olarak belirtilen derin öğrenme yöntemleridir. Derin öğrenme yöntemlerinden Uzun-Kısa Süreli Bellek Modeli’nde hafıza özelliğinin olması çok adımlı öngörüler için büyük avantaj sağlamaktadır.

Son yıllarda sıklıkla gündeme gelen yapay zeka, insan beyninin öğrenme ve tepki verme süreçlerinden esinlenerek, insan benzeri akıllı olan makineler geliştirmeyi amaçlayan bilim dalı olarak ifade edilebilir. Konu üzerinde yapılan çalışmalar 1940’lı yıllarda bilgisayarların geliştirilmesi ve Alan Turing’in makinelerin düşünmesine yönelik öne sürdüğü tartışma ile başlasa da “yapay zeka” terimi ilk olarak 1956 yılında, Dartmouth isimli yapay zeka konferansında, John McCarthy tarafından kullanılmıştır (Turing, 1950, McCarthy, 1956). Günümüzde sürekli olarak değişim ve gelişim gösteren yapay zeka; yapay sinir ağları, makine öğrenmesi ve derin öğrenme şeklinde üç alt yöntemi ile dünyaya uyum ve katkı sağlamaktadır. Bu üç yöntemin en büyük ortak özellikleri; biyolojik sinir ağı yapısının simülasyonu olarak karşımıza çıkmaları ve eğitim sırasında edindikleri deneyimler ile çalışarak, çıktı üretmeleridir. Bu süreçte sırasıyla geliştirilen ağ türlerinin bir önceki ağ türünün yetersiz kaldığı bir veya birkaç sorunu giderebilmek için geliştirilmesinden ötürü ağ modellerinin benzerlik gösterdiği ve birbirinden tamamen ayrı olarak değerlendirilmelerinin mümkün olmadığı bilinmesi gerekir. Buna göre; ilk yöntem olan yapay sinir ağları, yapay zeka serüveninde öğrenme sürecini pratikleştiren bir yapıya sahiptir. Edindiği bilgiler ile problemlere hızlı bir şekilde çözüm bulmayı amaçlayarak tahmin ve öngörü çalışmalarında başarılı çıktılar sunar. Bu konuda, yapay sinir ağları kullanılarak yapılan ilk çalışma hava durumu tahmini üzerinedir (Hu, 1964). İkinci yöntem olan makine öğrenmesi, 1950 yılında makinelerin düşünüp düşünemeyeceklerini konu alan ve bunun üzerine Turing Testi’ni geliştiren Turing tarafından ortaya atılmıştır (Turing, 1950). Makine öğrenmesi, küçük ve orta ölçekli veri setlerinde daha etkin sonuçlar

veren ve karar sürecinde müdahale gerektiren bir yapıya sahiptir. Son yöntem olan derin öğrenme ise 1960 yılında Kelley'in uçuş optimizasyonunun ele alındığı makalesinde geri yayılım algoritmalarına değinmesiyle kullanılmaya başlamıştır (Kelley, 1960). Derin öğrenme, biyolojik sinir ağı yapısına benzerlik açısından en yakın olan, içeriğinde barındırdığı çok sayıda katman ile karmaşık ve büyük ölçekli veri setlerinde dahi etkin sonuçlar sunan sinir ağı türüdür ve derin öğrenme ile geliştirilen çok sayıda mimari türü mevcuttur. Bu mimari türlerinden birisi de literatürde tahmin ve öngörü çalışmalarında başarılı sonuçlar verdiği bilinen Tekrarlayan Sinir Ağları'dır.

Tekrarlayan Sinir Ağları, ilk olarak geri yayılım algoritmaları ve kendini organize eden bir ağ modelinin ele alındığı makalede ele alınmıştır (Hinton vd., 1986). Temel olarak, ardışık veriler arasında ilişki kurarak çıktı elde etmeyi hedefleyen bir yapıya sahip olduğu için özellikle zaman serisi problemlerinde tercih edilen popüler bir derin öğrenme mimarisidir. Girdi katmanı, gizli katman ve çıktı katmanı şeklinde üç katmandan oluşur ve girdiden aldığı bilgiyi gerekli ağırlıklandırmalar ile çıktıya kadar taşıdıktan sonra çıktı katmanında elde ettiği hatayı geri yayan özel bir ağ modeline sahiptir. En büyük avantajı; ardışık veriler arasındaki ilişkinin kendiliğinden öğrenilmesiyle en büyük dezavantajı ise hatanın geri yayılımı sırasında karşılaşılan gradyan problemidir. Bu problemi giderebilmek amacıyla 1997 yılında, Tekrarlayan Sinir Ağı'nın özel bir türü olan Uzun-Kısa Süreli Bellek Modeli olarak geliştirilmiştir (Hochreither ve Schmidhuber, 1997). Uzun-Kısa Süreli Bellek Modeli, içeriğinde barındırdığı kapılar ile bilgi işleme sürecini çok daha sistemli hale getiren bir yapıya sahiptir. Bu süreçte, ele alınan bilgiler tekrarlar ile ağırlıklandırmaların bulunduğu belirli adımlardan geçerken çıktı için gerekli görülen bilgiler hatırlanacak, gerekli görülmeyen bilgiler ise unutulacak bilgiler olarak değerlendirilir. Hatırlanacak ve unutulacak bilgiler belirlendikten sonra yalnızca gerekli bilgiler ağ hafızasında yer edinir. Hafızada yer edinen bilgiler bir sonraki adıma girdi olarak taşınır ve süreç tamamlanır. Ek olarak, bu süreçte Uzun-Kısa Süreli Bellek Modeli'ni diğer mimarilerden ayıran en önemli özellik; yalnızca gerekli bilgilerin tutulduğu özel bir bellek hücresine sahip olmasıdır. Bununla birlikte, girdiler neticede bir elemeye tabii tutulduğu için eğitim sırasında modelin gösterdiği yüksek performanstan ötürü zamandan tasarruf sağlanır. Bahsedilen özellikleri sebebiyle Uzun-Kısa Süreli Bellek

Modeli, tek adım öngörülerin yanında çok adım öngörülerde de başarılı sonuçlar üretebilmektedir.

Diğer yandan gerek zihinsel açıdan gerekse fiziksel açıdan sağlıklı bir yaşam için spor yapmanın oldukça büyük önem arz ettiği bilinmektedir. Spor, mücadele sonunda barışı hedefleyen bir aktivitedir ve pek çok branşı vardır. Bu branşlardan birisi de dünya çapında oldukça popüler olan futboldur. Türkiye’de futbol sporu incelendiğinde 1901 yılında yapılan ilk futbol karşılaşmasının ardından ülkemizde çok sayıda futbol kulübünün kurulduğu görülmüştür. Bu noktada Beşiktaş Jimnastik Kulübü, Galatasaray Spor Kulübü, Fenerbahçe Spor Kulübü ve Trabzonspor Kulübü “dört büyükler” unvanı ile köklü yapısını koruyarak günümüze kadar ulaşan dört büyük spor kulübü olarak dikkat çekmektedir. Günümüzde taraftarın gösterdiği ilgiyi markalaşma ve şirketleşme ile güçlendiren bu kulüplerin zamanla oluşan borçlarından kurtulmak için halka arz yöntemini kullandıkları bilinmektedir. 2001 yılı itibariyle Borsa İstanbul A.Ş.’de işlem gören dört şirkete ilişkin hisse senedi fiyatlarında büyük farklılıklar gözlemlenmiştir. Bu noktada, gözlemlenen farklılıkların sebebinin takımların maçlardan elde ettikleri puanlardan, şampiyonluk beklentilerinden kaynaklanabileceği ve dolayısıyla puanlar ile hisse senedi fiyatlarının ilişkili olabileceği düşünülmüştür. Bu düşüncenin geçerliliğini ortaya koymak amacı ile puan ve hisse senedi fiyatları arasındaki ilişki Korelasyon Analizi ve Toda-Yamamoto Nedensellik Analizi ile sınanarak Uzun Kısa-Süreli Bellek Modeli ile tahmin ve öngörü çalışmaları yapılmıştır.

Literatür incelendiğinde, yapay zeka alt dallarına yönelik büyük bir ilgi söz konusudur ancak bu konuyu ele alan grupların ağırlıklı olarak mühendislik çalışmaları yaptığı ve sosyal bilimlerin bu konuda geri planda kaldığı gözlemlenmiştir. Öte yandan, literatürde çeşitli yöntemlerle ayrı ayrı puan tahmini, hisse senedi fiyatı öngörüsü ya da nedensellik analizi yapan çalışmalara rastlansa da ilgili yöntemler kullanılarak bir bütün olarak ele alınmış bir çalışmaya rastlanmamıştır. Bu tez çalışmasında ise 2006/07 ile 2020/21 sezon aralığında Türkiye Süper Ligi’nde yer alan dört büyük spor kulübünün maçlardan elde ettikleri puanlar ve şirketlerinin hisse senedi fiyatlarına ilişkin veriler kullanılarak nedensellik analizinin ardından Uzun-Kısa Süreli Bellek Modeli ile tahmin ve öngörü yapılarak bir bütün oluşturmak ve konuyu detaylı bir şekilde ele almak hedeflenmiştir. Bunun yanı sıra literatürde benzer

konuları farklı yöntemlerle ayrı ayrı ele alan çalışmalara kıyasla ele alınan değişkenlerin tüm dünyayı olduğu gibi ülkemizi de etkisi altına alan Covid-19 pandemi sürecinden etkilenip etkilenmediği de incelenmiştir.

Son olarak bu tez şu şekilde tasarlanmıştır: Birinci bölümde, yapay sinir ağlarının genel özellikleri üzerinde tartışılacaktır. İkinci bölümde, yapay zeka, makine öğrenmesi ve derin öğrenme yöntemleri teorik olarak ifade edilecektir. Üçüncü bölümde, ele alınan değişkenler için genel bilgilendirmeler yapılacak ve literatür incelenecektir. Dördüncü bölümde, uygulama içerisinde Korelasyon Analizi ve Toda-Yamamoto Nedensellik Analizi ile istatistiksel karşılaştırmalar yapılarak hipotez testlerine ilişkin sonuçlar ifade edilecek ve elde edilen sonuçlar pandemi dönemi için tekrar karşılaştırmaya tabii tutulacaktır. Karşılaştırma sürecinin ardından, Uzun-Kısa Süreli Bellek Modeli kullanılarak dört büyük spor kulübüne ilişkin puan tahmini ve hisse senedi fiyatı öngörüsü yapılacaktır. Bu sürecin ardından sonuç ve konuya ilişkin öneriler verilerek tez çalışması tamamlanacaktır.

1. BÖLÜM

YAPAY SİNİR AĞLARI

1.1. Yapay Sinir Ağlarının Tanımı

Yapay sinir ağları, anakütleyi en iyi temsil ettiğine inanılan örneklemeler yardımıyla olaylara dair ilişkilerin öğrenilmesinin ardından daha önce karşılaşılmamış örnekler karşısında öğrendiği bilgileri kullanarak karar veren sistemler bütünüdür (Öztemel, 2016, s.29).

1980’li yıllardan günümüze kadar uzanan ve gün geçtikçe popülerliğinde artış gösteren yapay sinir ağları, öğrenim süreci açısından insan beynini taklit eden, dolayısıyla zeka gerektiren işleri sistemler yardımıyla gerçekleştirmesi mümkün olan ağ yapısıdır. Oldukça karmaşık problemler karşısında bile çok sayıda cevap verebilmesi ile dikkat çeken yapay sinir ağları; kümeleme, sınıflandırma, karar, optimizasyon ve yeni bilgi çıkarımı alanlarında oldukça başarılıdır (Öztemel, 2016, s.27). Girdi ve çıktılar arasında ön bilgiye ihtiyaç duymaması ve hem lineer hem de lineer olmayan modellemeler için kullanılabilmesi sebebiyle iyi tahmin performansına sahip tekniklerinden birisidir.

Ayrıca, yapay sinir ağlarında uygulamalara yönelik temel süreç; eğitim ve test kümesi ayrımı ile başlamaktadır. Buna göre; mevcut veri setinin genellikle %80’i eğitim ve %20’si test verisi olarak ayrıldıktan sonra eğitim verileri ile sistem işleyişi makine tarafından öğrenilir ve eğitim tamamlandıktan sonra bir çıktı elde edilir. Elde edilen çıktı, test verileri ile karşılaştırılarak modele yönelik performans, doğruluk, hata oranı gibi bilgiler edinilir. Bu süreçte karmaşık problemlerde verilerin daha iyi eğitilmesi için aktivasyon fonksiyonu kullanılır. Sıklıkla kullanılan aktivasyon fonksiyonlarından bazıları şu şekildedir:


1. Sigmoid Fonksiyonu: 0 ile 1 arasında çıktı üreten, özellikle ikili sınıflandırma problemlerinde yüksek performans sergileyen fonksiyondur.
2. Softmax Fonksiyonu: 0 ile 1 arasında çıktı üreten, özellikle çoklu sınıflandırma problemlerinde yüksek performans sergileyen fonksiyondur.

3. Hiperbolik Tanjant Fonksiyonu: -1 ile 1 aralığında çıktı üreten, verilerin öğrenmesi sırasında hız avantajı sağlayan ve gradyanın yüksek olduğu durumlarda sigmoid fonksiyonuna oranla daha etkin sonuçlar veren fonksiyondur.
4. ReLu Fonksiyonu: 0 ile $+\infty$ aralığında değer alan ve ağırlıklı olarak gizli katmanlarda kullanılan fonksiyondur.

Genel olarak amaç; uygun model ve fonksiyon kalıpları ile yüksek performansa, yüksek doğruluk oranına ve düşük hata oranına sahip çıktıyı elde edebilmektir (URL1).

1.2. Biyolojik Sinir Ağı ve Yapay Sinir Ağı Sistemlerinin İncelenmesi


Yapay sinir ağları kavramı, beynin çalışma unsurlarının bilgisayarlar aracılığıyla uygulanması ile ortaya çıkmıştır. Beyni oluşturan en küçük hücrelerin yani nöronların bilgiyi işlediği süreci ifade eder ve matematiksel modellemeler üzerinde yoğunlaşır (Efe ve Kaynak, 2000). Yapay sinir ağlarına ilişkin detayları öğrenmeden önce Şekil 1’de yer alan biyolojik sinir ağı yapısını incelemekte fayda vardır.



Şekil 1. Biyolojik Sinir Ağı Yapısı (URL2)

Şekil 1’e ait inceleme 3 temel başlık halinde ele alınmıştır. Buna göre: Dendrit, sinyaller ya da bilgilerin alındığı yapıdır ve bir sonucun yani çıkış üretiminin mümkün olup olmadığını inceler. Akson, uzun bir yapıya sahiptir ve çıkış için yapılacak işleri nöron bağlantılarına tek yönlü olarak iletir. Kısaca; uyarı sağlamakta görevlidir. Son olarak sinaps ise akson ve dendritleri birleştiren, genel olarak öğrenme sürecini temsil eden ve beynin düşünmesini sağlayan yapıdır. Burada art arda gelen nöronların tümüne

sinir ağı adı verilirken bunların modellenmesi yapay sinir ağlarını oluşturur (Tan, 1997).



Şekil 2. Yapay Sinir Ağı Sistemi


Sinir sistemleri, birbirleriyle doğrudan ilişkisi bulunan sinir hücrelerinden oluşmaktadır. Bu birleşim gruplara ayrıldığında katmanları oluşturur ve yapay sinir ağları bu katmanların birleşiminden meydana gelir. Bu ön bilginin ardından Şekil 2 incelendiğinde ağ sisteminin 3 katmandan oluştuğu görülmektedir. Bunlar: Bilgilerin iletildiği ve ham verinin kullanıldığı girdi katmanı, bilgilerin yani özelliklerin işlendiği bir diğer anlatımla doğru ağırlığın tespit edilmesi ile ağırlık değerlerinin kullanıldığı, bütün matematiksel işlemlerin yapıldığı, çıktıya dönüşüm sağlayan yani ağı eğiten ara katmanlar ve kararın verilmesiyle elde edilen çıktı katmanı şeklindedir (Öztemel, 2016, s.45). Burada X ile ifade edilen girdi değerleri bağımsız değişkenleri ve Y ile ifade edilen çıktı değeri ise bağımlı değişkeni temsil etmektedir.

1.2.1. Mimari Yapılarına Göre Yapay Sinir Ağları

Yapay sinir ağlarının mimari yapılarına göre ileri beslemeli sinir ağları ve geri beslemeleri sinir ağları olmak üzere iki sınıfta incelendiği bilinmektedir.

1.2.1.1. İleri Beslemeli Sinir Ağları

İleri beslemeli ağları, genellikle zaman serisi problemlerinde tahmin ve öngörü yapmak amacıyla kullanılır. Şekil 3 incelendiğinde ağ sisteminin oldukça anlaşılır ve basit bir yapıya sahip olduğu görülmektedir. Sistemde her bir katman bir önceki katmandan beslenerek ilerler. Dolayısıyla veri düzeni girdiden başlayarak çıktıya doğru tek yönlüdür.




Şekil 3. İleri Beslemeli Ağ Modeli

İncelemesi yapılacak herhangi bir ileri beslemeli ağ yapısında girdi sayısını belirlerken bağımlı değişken olan y 'yi etkileyecek özellikleri ifade eden bağımsız değişkenler olan x 'ler belirlenmelidir. Çünkü burada her bir bağımsız değişken giriş katmanında yer alması gereken bir sinir hücresine karşılık gelir. Benzer şekilde çıktı katmanında çıktı sayısı belirlerken ulaşılması istenilen çıktı sayısına karar verilir ve çıktı içinde barındırılması istenilen her bir değişken için bir sinir hücresi bulundurulması gerekir (Subaşı, 2010).

1.2.1.2. Geri Beslemeli Sinir Ağları

1990'lı yılların sonlarında başarılı sonuçlar vererek kullanımı sıklaşan geri beslemeli ağlar, her bir katman içindeki hücrelerin hem bir önceki katmana hem de bir sonraki katmana ait hücrelerinden beslendiği yapay sinir ağı tipi olarak bilinir. Doğrusal olmayan bir yapıya sahip olan geri beslemeli ağlar, eğitimi güçlendirmek amacıyla ekstra bir hafızaya ihtiyaç duyar. İhtiyaç duyulan bu hafıza dinamiklik özelliğinden üretilir (Aşkın, vd., 2011).



Şekil 4. Geri Beslemeli Ağ Modeli

Şekil 4'e göre; m çıkış ve n giriş nöronuna sahip olan geri beslemeli ağ modellemesinde $(n+m)$ tane giriş olduğu varsayılır. İlk aşamada ileri beslemeli ağ modelinde olduğu gibi, çıktı hesabı yapmak amacıyla, hesaplama ileri doğru yapılır. Ardından çıktılar, giriş elemanı olarak sisteme dahil edilir ve gecikmeler yardımıyla ağ geri beslenir. Geri besleme sürecinde her tekrar adımında elde edilen tahmin değeri gerçek değerden çıkartılır ve bir önceki katmana ait hata değeri elde edilir. Dolayısıyla her tekrarda hata geriye dönük olarak yayılır ve gizli katman içerisinde ağırlık değeri hesaplanır. Burada amaç; hataları geri yayarak uygun ağırlığı belirledikten sonra hata oranı en düşük olan çıktıya ulaşmaktır.


1.2.2. Katmanlarına Göre Yapay Sinir Ağları

Katmanlarına göre iki sınıfta incelenen yapay sinir ağları, tek katmanlı ağlar ile başlamıştır. Ele alınan modellerin doğrusal olmadığı durumlarda tek katmanlı sinir ağları yetersiz kalmış ve çok katmanlı sinir ağları geliştirilmiştir. Burada katman sayıları belirlenirken matematiksel işlemlere ihtiyaç duyulmaması dolayısıyla girdi biriminin göz ardı ediliyor olduğu bilinmelidir (Ocakoğlu, 2006).

1.2.2.1. Tek Katmanlı Yapay Sinir Ağları

Tek katmanlı yapay sinir ağları, doğrusal modellemeler için kullanılır. İçeriğinde yalnızca girdi ve çıktı katmanını bulunduran bu ağ türü için başlangıçta sabit bir eşik değeri (1) belirlenir (Elmas, 2003). Belirleme işleminin ardından modele ait


girdiler, ağırlıklar ile çarpılıp toplanarak ikili değer elde edilir. Elde edilen değer eşik değer ile kıyaslanarak girdinin sınıfı belirlenir. Öğrenme sırasında ağırlıklar ve eşik değer değiştirilir (Öztemel, 2012). Tek katmanlı yapay sinir ağları örneği için Şekil 5 incelenebilir.



Şekil 5. Tek Katmanlı Yapay Sinir Ağları

1.2.2.2. Çok Katmanlı Yapay Sinir Ağları

Çok katmanlı yapay sinir ağları, ikiden fazla sınıfın algılanmasına ihtiyaç duyulan durumlarda karmaşık işlemler ya da doğrusal olmayan modellemeler için kullanılır. Bu sebeple en az bir ara katmana ihtiyaç duyar ve içeriğinde birden fazla girdi ve çıktı yer alır (Yavuz ve Deveci, 2013). Çok katmanlı yapay sinir ağları örneği için Şekil 6 incelenebilir.



Şekil 6. Çok Katmanlı Yapay Sinir Ağları

1.2.3. Öğrenme Yöntemlerine Göre Yapay Sinir Ağları

Öğrenme, günlük yaşam içerisinde canlıların davranışlarında meydana gelen değişimler bütünüdür. Bu sebeple bu süreçte gerçek örnekler ele alınır ve optimum çözüme ulaşabilmek için uygun ağırlıklandırmalar yapılır. Ağırlıklandırma süreci ve

öğrenme yöntemlerine göre çeşitli eğitim stratejileri geliştirilmiştir. Bunlar: Denetimli öğrenme, denetimsiz öğrenme ve takviyeli öğrenme şeklindedir.

1.2.3.1. Denetimli Öğrenme

Denetimli öğrenme, eldeki veri setleri yardımıyla sistem üzerinde bir girdi oluşturularak, istenilen çıktının tanımlandığı öğrenme yöntemidir. Önemli olan elde edilen çıktının doğru sonuçlar vermesidir. Çıktının doğru sonuçlar vermediği durumlarda hesaplamalar ve ağırlıklandırmalar hatanın minimum olduğu noktaya kadar tekrarlanır ve genellikle hava durumu tahmini gibi modellemelerde kullanılır. Batak oyununda kartların tanıtılması, kişinin öğrenmesi, yaptığı hatalar sonucunda oyunu kavrama süreci denetimli öğrenmeye örnek olarak gösterilebilir. Çünkü öğrenme sürecinde ilk yapılan kartların tanıtılmasıdır.

1.2.3.2. Denetimsiz Öğrenme

Denetimsiz öğrenme, istenilen çıktının tanımlanmadığı dolayısıyla çıktının hangi değişkenden etkilenebileceğinin bilinmediği ve bu sebeple eldeki verilerin sistem tarafından kümelenerek sınıflandırıldığı öğrenme yöntemidir. Bu yöntem kullanılarak genellikle veri kümelerinin yoğunluk ve benzerlikleri üzerine analiz yapılır, uç değerler kolaylıkla belirlenir.

1.2.3.3. Takviyeli Öğrenme Kuralı

Takviyeli öğrenme kuralı, ağ performanslarını belirleyen puanlar kullanılan ve bir eğiticiye ihtiyaç duyan sistemdir. İhtiyaç duyulan eğitici beklenen gibi çıktının ne olduğu ya da ne olacağı hakkında bilgi vermez, sadece doğruluğunu kontrol eder. Denetimli ve denetimsiz öğrenme yöntemlerine göre daha az yaygın olan takviyeli öğrenme kuralı genellikle sistem kontrol çalışmalarında kullanılır.

1.3. Yapay Sinir Ağlarının Avantajları, Dezavantajları ve Kullanım Alanları

Ağ sistemi içerisinde tanımlanan durumun tekrarlanması ile birlikte öğrenmenin gerçekleşmesi ve bir sonraki durum karşısında sistemin yaptığı yorumlar ile çıktıya yönelik bir karar verebilmesinden ötürü yapay sinir ağlarının en büyük

avantajının “öğrenme” olduğu bilinmektedir. Dolayısıyla öğrenme süresince sistem genelleme yapabilecek yetkinliğe erişir ve bahsedilen bu durum yapay sinir ağları için önemli bir avantaj niteliğindedir.

Öğrenme ve genellemenin ardından yapay sinir ağlarının diğer avantajları, veriye dayalı bir yapıya sahip olması, modelin kendiliğinden analize uygun hale gelmesi, zaman serisi analizleri için oldukça uygun olması, tahmin, öngörü ve sınıflandırma problemleri için başarılı sonuçlar vermesi, grafikler aracılığıyla yorumlanabilir olması, zamandan ciddi anlamda tasarruf sağlaması, hatalara karşı tolerans gösterebilmesi ve hem doğrusal olan hem de doğrusal olmayan modeller için kullanılabilmesi sıralanabilir. Ayrıca, yapay sinir ağlarını diğer istatistiksel yöntemlerden üstün kılan avantajlar ele alındığında; büyük ve oldukça geniş bir hafızaya sahip olması, eksik veri olsa dahi doğru çıktı üretebilmesi, çok sayıda durum için aynı anda analiz yapabilmesi, normallik gibi temel varsayımlara ihtiyaç duymaması ve kendi içeriğinde karmaşık problemler için bile doğal öngörü kombinasyonları oluşturabilmesi görülür (Yılmaz, 2017, Aktaş vd., 2017).

Ancak buna rağmen yapay sinir ağlarının belli başlı dezavantajları mevcuttur. Bunlar; eğitim verisinden kaynaklı olan bazı eksiklik ve yanlışlıklar dolayısıyla ağın eğitilememesi ve dolayısıyla uygun çözüme ulaşamaması, ağırlıkların tam olarak değerlendirilememesinden ötürü kesin yargılardan söz etmenin mümkün olmaması, ağ yapısının doğruluğunu görebilmek için deneme yanılma yöntemi kullanılması ve bunun için uygun çözüme ulaşmanın kimi problemler için zaman alması, tahmin ve öngörü dağılımlarının belli olmaması, hipotez testlerinin anlamlılıklarının sınıanamaması şeklindedir (Aktaş, vd., 2017).

Yukarıda avantajlarına ve dezavantajlarına değinilen yapay sinir ağları, oldukça geniş bir kullanım alanına sahiptir. Tablo 1’de bu konuya ilişkin örnekler verilmiştir.

Tablo 1.Yapay Sinir Ağlarının Kullanım Alanları

Kullanım Alanı	Örnekleri
Bankacılık ve Finans	Müşteri analizi, bütçe ve kredi öngörülleri
Otomotiv	Otomobil satış tahmini, talep tahmin analizi
Savunma	Hedef seçmek için optimizasyon çalışmaları, savunma bütçe öngörüsü
Eğlence	Efektler ve animasyonlar
Teknoloji	Uygulama indirme sayısı, ürün satış oranı ve abonelik öngörüsü
Elektronik	Çip analizleri, elektronik sistem tahmini
Sağlık	Korona virüs sürecinde test sayısı, vefat sayısı, iyileşen hasta sayısı vb. için öngörü çalışmaları
Uzay, Dil, Güvenlik, Üretim, Telekomünikasyon vb.	

Kaynak: Kaya vd., 2018, Karahan, 2011

2. BÖLÜM

YAPAY ZEKA

2.1. Yapay Zekanın Tanımı

“Yapay” kelimesi temel olarak, doğal olmayan, yapmacıklık içeren anlamında kullanılmaktadır. Diğer yandan, algılar yardımıyla nesneler arasındaki ilişkiyi anlayabilme, mantık yürüterek çözüm bulabilme, kavrama, karar verebilme ve sonuç sunabilme durumlarına “zeka” adı verilir. Yani bireylerin daha önce karşılaşmadıkları durumlar karşısında anlık olarak verdikleri tepkiler, uyumlar, öğrenme ve analizler zeka sayesinde gerçekleşir (Yılmaz, 2017).

Yapay zeka ise insanlar tarafından başarılı bir şekilde gerçekleştirilen işlerin bilgisayar tarafından daha iyi yapıldığı çalışmaları ifade etmek için kullanılan bir terimdir (Aydın, 2000). Temel amacı; cansız olan nesnelere verilen eğitim ile akıllı nesneler üretebilmektir (Yılmaz, 2017). Bu noktada, yapay zekanın insanlara kendini göstermesinin oyun oynamakla başladığı bilinmektedir. Satranç oyunu gibi düşünce yetisine bağlı olan oyunlarda bilgisayarların oldukça hızlı hamleler yapmasının yanı sıra bu hamleleri yaparken rakibinin yapabileceği bir sonraki hamleyi tahmin ederek çok sayıda çözüm üretmeleri, kendilerini gösterme süreci üzerinde pozitif yönlü etki sağlamıştır. Makine öğrenmesi ve derin öğrenmeyi kapsayan, psikoloji, biyoloji, felsefe, matematik ve bilgisayar gibi pek çok teorik alanla ilişkisi olan yapay zekanın tarihçesi Tablo 2’de özetlenmiştir.

Tablo 2. Özetlenmiş Yapay Zeka Tarihçesi

1940	Gerçek yapay zeka olan "bilgisayar"ların ortaya çıkması
1950	Alan Turing'in düşünen robotlar üzerine makale paylaşması
1951	Mark adlı aygıt için ilk yapay zeka programının yazılması
1956	"Yapay zeka" teriminin ilk kez kullanılması
1962	Endüstriyel alan için robot üreten ilk firmanın kurulması

Tablo 2. Özetlenmiş Yapay Zeka Tarihçesi (Devamı)

1969	XOR Probleminin tartışılması
1978	"Savaş Yıldızı Galactica" isimli bilim kurgu dizisinin savaşçı robotları tanıtması
1980	Amerikan Yapay Zeka Derneği tarafından ilk Ulusal Konferans'ın düzenlenmesi
1997	Dünya Satranç Şampiyonu Garry Kasparov'un satranç oyununda Deep Blue adlı bilgisayara karşı yenilmesi
(...)	(...)
2006	Derin öğrenmenin tanıtılması
2011	Apple tarafından Siri'nin tanıtılması
2012	İşlemci odaklı bir sistemin, İmagennet'te en iyi hata oranını yarılayarak birinci olması
2016	Google DeepMind'in AlphaGO'su ile Dünya Eski 1 numaralı Go oyuncusu Lee Sedol'un karşılaştığı go maçını AlphaGO'nun 4-1 ile kazanması
2018	Kurumların yapay zekaya yaklaşımlarını temel alan rehberlerin yayınlanması
2019	Yapay zeka önderliğinde 5G Mobil Telekomünikasyon planlamasının yapılması

Kaynak: Hamzaçebi, 2011, URL3.

Tablo 2 incelendiğinde yalnızca bir kısmı verilmiş olan tarihte bile yapay zekanın gelişim hızını görmek mümkündür. Günümüzde hemen hemen her alanda kendini geliştiren ve gelişimine devam eden yapay zeka, dünyaca ünlü şirketlerin yatırım kaynağı haline gelmiştir. Güncel veriler ele alındığında 2030 yılında yapay zekanın, küresel ekonomiye yaklaşık olarak 15,7 trilyon dolar gibi ciddi oranda büyük bir katkısının olacağı öngörülmektedir (URL4). Örneği verilen bu durum rekabetin artacağına işaretçisi niteliğindedir ve bütün süreçlerde gizlilik esası olduğu için kişi ve kurumlara güven vermektedir. Ayrıca, alanında günden güne profesyonelleşen yapay zeka, çok sayıda alt başlığa sahiptir. Bunlardan en sık kullanılanları; makine öğrenmesi, derin öğrenme ve yapay sinir ağlarıdır.

2.2. Makine Öğrenmesinin Tanımı ve Tarihçesi

Düşünce ve davranış olarak insana benzeyen fakat yapay olan uygulamaların genel adı; makine öğrenmesidir. Makine öğrenmesi, çeşitli öğrenme türleri ile analiz sırasında uzman kişiler tarafından özellikleri sunulan veriler arasındaki ilişkiyi

deneyimleyerek öğrenmeye çalışan ve bu ilişkiye bağlı olarak bir kural oluşturduktan sonra yüksek performans oranına sahip çıktılar sunan, çok katmanlı bir yapıya sahiptir. Çeşitli algoritmalar ile tahmin, sınıflandırma ve kümeleme problemlerine çözüm üretir.

Genel olarak makine öğrenmesi tarihinin 1950 yılında İngiliz matematikçi Alan Turing tarafından, Turing Testi ile keşfedildiği bilinmektedir. Keşif sürecinde, ilk aşamada yetişkin bir insan ve bir çocuk beyninin öğrenme ve cevap verme süreci incelenmiştir. Elde edilen sonuçlara göre; yetişkinler için süreç doğum, eğitim ve deneyim adımlarından oluşuyorken, çocuklar için aynı sürecin doğum ve eğitim olmak üzere iki adımdan oluştuğu görülmüştür. Bu incelemenin ardından, çocuk beynini not defterine benzeten Turing, makineye yönelik benzetim çalışmalarını çocuk beynine uygun yapmıştır. Ayrıca, geliştirmiş olduğu Turing Testi için makinelerin düşünme yetisine sahip olup olmadıkları konusunda belirli kriterler dahilinde makineye eğitim vermiştir. Ardından, önceden talimatları verilmiş olan makineye sorular sormuş ve aldığı cevaplar ile karşı tarafın insan mı makine mi olduğunu anlamaya çalışmıştır. Bu ayrımın yapılamadığı durumda oluşturulan makinenin testi geçtiği kabul edilerek eğitimin başarılı olduğu sonucuna ulaşmıştır (Turing, 1950).

Bu keşfin ardından ünlü bilgisayar uzmanı Arthur Samuel tarafından 1959 yılında “Dama Oynama” programı geliştirilmiştir. Bu program, öğrenimini kendiliğinden sağlayan ilk program olması niteliğiyle ilgi çekmiş ve makine öğrenmesi için büyük bir devrin başlangıcı olarak değerlendirilmiştir (Schaeffer, 2006).

1980’li yıllara gelene dek çok sayıda çalışma yapılmış ancak beklentilerin uzağında sonuçlar elde edilmiştir. Bu süreçten yaklaşık iki sene sonra ise nöronlar ve yapay sinir ağları ilişkisi tekraren gündeme gelmiş ve en güçlü adımlarını 1990’lı yıllarda atan makine öğrenmesi ile istatistiksel yöntemler kullanılarak tahmin ve öngörü alanına yönelim sağlanmıştır.

1997 yılında satranç oynayan bir bilgisayar olan Deep Blue, dönemin satranç dünya şampiyonunu yenmiştir (URL5). Satrancın beyin sporu olması dolayısıyla bu başarı sayesinde makine öğrenmesi büyük bir yol kat etmiştir. 2000’li yılların başlarında makine-insan ilişkisi doğal bir hale bürünmüş ve çıktılar belirgin oranda

güç kazanmıştır. Dünya genelinde 2006 yılında Spotify uygulaması kullanıma sunulmuş ve uygulama kullanıcıların dinlediği müzikleri öğrendikten sonra dinleyebileceği müzikler için tahminde bulunarak benzer müzik önerileri sunmuştur. 2007 yılında sesli navigasyon cihazları gündeme gelmiş ve hedefe kaç kilometre kaldığı, ulaşım süresi, yön bilgisi gibi çok sayıda bilgiyi hesap ederek seslendirmiştir. 2011 yılında Siri uygulaması geliştirilmiş ve Apple kullanıcılarına arama, mesaj atma gibi belirgin kısa yollar sunulmuştur. 2014 yılı itibariyle Google, Youtube, Amazon gibi dünyaca ünlü firmalar yapay zeka alanına ciddi yatırımlar yapmış ve olumlu etkileşimlerin ardından 2018 yılında yatırımlarında artışa gitmişlerdir. Bu aşamada en büyük yatırımcı Google şirketi olmuştur. Satış ve pazarlama sistemlerinin yanı sıra insansız araç planlamaları tekrar ele alınmış ve veri toplama amacıyla internet kullanımı sırasında güvenlik kontrolü başlığıyla kullanıcılara trafik lambaları, otomobiller ya da yaya geçitleri işaretlettirilmiştir. Sağlık sektöründe erken teşhisler için yapılan öngörüler büyük önem taşımış, 21.yüzyılın tıp alanında yeni bir çağ olduğu düşüncesi gündeme gelmiştir. Tüm dünyada günden güne gelişim gösteren ve değer kazanan makine öğrenmesi için Türkiye’de de çok sayıda yazılımcı, mühendis ve istatistikçi konu üzerine araştırmalar yapmış ve 2000’li yıllardan sonra ASELSAN gibi gelişmiş savunma sanayi firmaları meslek liselerinden başlayarak, yapay zeka ve makine öğrenmesi konuları üzerine seminerler vermiştir. Öte yandan özellikle 2021 yılında hukukla ilişkilendirmeler gerçekleşmiş ve konu üzerinde çok sayıda yayın yapılmıştır. Bilgilendirme amacıyla sosyal medya üzerinden çok sayıda topluluk çalışmalara halen devam etmektedir.

2.2.1. Makine Öğrenmesi Algoritmaları

Makine öğrenmesi algoritmaları, tahmin, sınıflandırma ve kümeleme problemlerini ele alır ve bu problemler için veri seti üzerinde analiz yapabilmek amacıyla yazılan kodlar bütünü olarak ifade edilir. Öğrenme türleri; denetimli öğrenme, yarı denetimli öğrenme ve denetimsiz öğrenme şeklinde 3 alt bölüme ayrılır. Bir önceki bölümde açıklanan denetimli öğrenme ve denetimsiz öğrenmenin haricinde yarı denetimli öğrenme; hem denetimli hem denetimsiz öğrenme yönteminin birlikte kullanıldığı, dolayısıyla verilerin bir kısmının tanımlı olmasına karşın bir kısmının tanımlanmadığı öğrenme türü olarak ifade edilmektedir (Lee, 2013). Tamamen tanımlanmamış verilerden yapılan analizlere kıyasla daha iyi sonuç verdiği

bilinmektedir. Diğer yandan, uygulamasının kolay olması ve etkili çıktılar sunmasıyla makine öğrenmesinde en sık kullanılan algoritmalar denetimli olarak öğrenme sağlayan tahmin problemleri için en önemlileri şu şekildedir:

- Doğrusal Regresyon Algoritması: Sayısal verilerden oluşan, iki veya daha fazla değişken arasındaki doğrusal ilişkiyi ele alan algoritmadır.
- Lojistik Regresyon Algoritması: Bağımlı değişkeni iki veya daha fazla kategorik veri yapısından oluşan, değişkenler arasındaki doğrusal olmayan ilişkiyi ele alan algoritmadır.
- Yapay Sinir Ağları Algoritması: Herhangi bir varsayım bulundurmeyen ve geleneksel regresyon yöntemlerine göre daha başarılı çıktılar sunduğu bilinen, her adımda hatayı geri yayarak hata oranı düşük çıktılar elde etmeyi amaçlayan algoritmadır.
- Karar Ağacı Algoritması: Veri setinin belirli kurallara göre gruplara ayrıldığı, hem sayısal hem de kategorik yapıdaki değişkenlerin ele alındığı algoritmadır.
- Rastgele Orman Algoritması: İçeriğinde çok sayıda karar ağacının bulunduğu ve her bir ağacın detaylandırılarak, ayrı ayrı eğitilip, modellendiği algoritmadır.
- Destek Vektör Algoritması: Her bir problemi adım adım ikili sınıflara ayırıp, dallandırmalara ve tahminlere göre karara ulaşmanın hedeflendiği algoritmadır.

Bahsedilen algoritmalar; Karar Ağacı ve Destek Vektör Algoritmaları hem tahmin hem de sınıflandırma problemlerinde, Yapay Sinir Ağları ise hem tahmin hem sınıflandırma hem de kümeleme problemlerinde kullanılmaktadır. Ek olarak, tahmin problemlerinde olduğu gibi denetimli olarak öğrenme sağlayan sınıflandırma problemleri için kullanılan diğer popüler algoritmalar şunlardır:

- Naive Bayes Algoritması: Edinilen eğitim ile sisteme eklenen verilere kısa sürede uyum sağlayıp, her adımda olayın gerçekleşme olasılığını hesaplayarak elde edilen olasılık değerlerine göre sınıflandırma yapan algoritmadır.
- k-En Yakın Komşu Algoritması: İlk sınıflandırma sonrasında veri setine yeni bir gözlem değeri eklendiğinde, eklenen bu gözlem değerinin hangi sınıfa ait olacağını ve komşularına olan uzaklık değerlerini hesaplayarak belirleyen algoritmadır.

Son olarak denetimsiz şekilde öğrenme sağlayan ve benzer özelliklere sahip verilerin gruplara ayrıldığı kümeleme problemleri için kullanılan en popüler algoritma ise k-Ortalama Kümeleme Algoritması'dır. Buna göre;

- k-Ortalama Kümeleme Algoritması: Bu algoritma içerisinde k küme sayısını ifade etmektedir. Ele alınan verinin, k tane belirlenen küme dahilinde, küme merkezlerine olan uzaklıkların hesaplanmasının ardından en yakın kümeye dahil edildiği, tekrara dayalı bir algoritmadır.

2.2.2. Makine Öğrenmesinin Avantajları, Dezavantajları ve Kullanım Alanları

Makine öğrenmesi, yapay sinir ağlarının bazı problemleri çözme konusunda yetersiz kaldığı noktalar için geliştirilmiş bir yöntemdir. Bu konuda özellikle tahmin, öngörü ve sınıflandırma için geliştirilen mimariler dolayısıyla yapay sinir ağlarına kıyasla etkin sonuçlar verir. Dolayısıyla makine öğrenmesinin avantajlarına değinirken tahmin, öngörü ve sınıflandırma çalışmalarında başarılı çıktılar elde edilmesi ilk sırada yer almaktadır.

Diğer avantajları ise küçük ve orta ölçekli veriler ile çalışma olanağı sağlaması, sürekli kendisini güncellemesi ve güncellemelerin ardından performans başarısını kümülatif olarak ele alması, eğitim için sunulan veri seti içerisindeki mantığı kısa sürede çözmesi ve test adımında probleme en uygun çıktıları sunması, otomatik öğrenim sağlaması, özellikleri doğru kullanması ve diğer istatistiksel yöntemlere göre çok daha hızlı sonuca ulaştırması şeklindedir.

Dezavantajları incelendiğinde ise uzun vadeli çalışmak için ortalamanın üzerinde bir bilgisayar temini gerektirmesi ve bu durumun ekstra maliyeti ifade etmesi, veri toplama sürecinin uzun sürebilmesi, uygun algoritma seçiminin otomatik olarak sağlanamamasından ötürü iyi bir araştırma yapılmadığı takdirde verilebilecek yanlış kararın çıktıyı olumsuz yönde etkilemesi şeklinde olduğu görülmektedir (Global AI Hub Eğitimleri, 2021).

Son olarak ürün satış öngörüsü, ürün öneri çalışmaları, müşteri yaşam boyu değeri tahmini, hisse senedi tahmini, ziyaretçi sayısı tahmini ve doluluk oranı öngörüsü gibi tahmin ve öngörü içerikli çalışmalar başta olmak üzere sesli asistanlar,

yol ve yön tarifi saęlayan cihazlar, çeviri programları, görüntü tanıma sistemleri vb. pek çok alanda makine öğrenmesi algoritmalarının kullanıldığını görmek mümkündür.

2.3. Derin Öğrenmenin Tanımı ve Tarihçesi

Derin öğrenme temel olarak öğrenimini kendi kendine gerçekleştirerek, ezberlemeden, başarılı kararlar alabilen yapay sinir aęları elde edebilmek üzere geliştirilmiş algoritmalar olarak ifade edilebilir. İçeriğinde çok katmanlı yapay sinir aęı yapısını barındırır ve her bir katmanı geri yayılım algoritması kullanılarak ayrı ayrı eğitilir. Bununla birlikte makine öğrenmesinin bir alt dalı olarak bilinen derin öğrenme, makine öğrenmesi içerisinde çözülemeyen belirli problemleri giderebilmek amacıyla geliştirilmiştir. Dolayısıyla, çok büyük ve karmaşık işlemler için diğer yöntemlere kıyasla çok daha kısa sürede hesap yapabilmesi, sistem girdilerini kendi belirledięi kurallara göre atayabilmesi ve hatta değerlendirebilmesi, gelişime açık olması, veriler üzerinde ayırım yapabilmesi gibi sebepler dolayısıyla sıklıkla kullanılmaktadır. Temel amacı; makine öğrenmesinde olduęu gibi kendisini sürekli olarak iyileştirmek ve en iyi çıktıyı elde etmektir. Bu amaç için önceki bölümlerde tanımlanmış olan denetimli ya da denetimsiz öğrenme tekniklerini kullanır.

Derin öğrenme tarihi, Henry J. Kelley (1960) tarafından yayınlanan “Gradient Theory of Optimal Flight Paths” isimli makaleye dayanmaktadır. Bu makalede uçuş performanslarının optimizasyonları konu alınırken, ilk defa geri yayılım sürecini de ele alan bir model kullanılmıştır. Makale üzerinde yapılan incelemelerin ardından bu modelin daha da fazla geliştirilerek, olabildiğince açık hale getirilmesi için çalışmalar yapılmış fakat 1965 yılına kadar başarılı bir sonuca ulaşamamıştır.

Ivakhnenko ve Lapa (1965) tarafından yazılan Cybernetic Predicting Devices isimli kitapta, o zamana kadar çok sayıda yazar tarafından ele alınan tahmin ve öngörü konularında geliştirilmiş formüller ve algoritmalara değinilmiştir. Ayrıca, bu kitabın en önemli özellięi; yazılı olarak ifade edilen formüller ve algoritmaların ilk defa bilgisayara uyarlanması ve farklı tahmin algoritmalarına ilişkin öneriler verilmesinin ardından ilk defa derin öğrenme mimarileri kullanılarak uygulama yapılmasıdır. Kitap içeriğinde yer alan uygulamalardan bazıları; hava durumu tahmini, deprem tahmini, süreç tahmini, su seviyesi tahmini, bitki hastalıkları öngörüsü ve benzeri şeklindedir.

Ayrıca, bu kitapta özellikle hata ölçütlerine ve kendiliğinden öğrenen tahmin filtrelerine de değinilmiştir.

Fukushima (1980) tarafından yayınlanan makalede, insan beyninin sıralı şekiller olan örüntüleri tanımasından etkilenilerek bu durumun sinir ağlarına uyarlanmasına değinilmiş ve derin öğrenme mimarisi olan evrişimli sinir ağları geliştirilmiştir. Geliştirilen bu mimarinin en önemli özelliğinin denetimsiz olarak öğrenme sağlaması ve kısa bir zaman içerisinde düşük hata oranları ile şekilleri tanıyarak uyarılar doğrultusunda çıktı sunması olduğu ifade edilmiştir. Bu çalışmanın ardından 5 yılı aşkın bir süre sonra ilk defa hesaplanan hatayı geri yayan ve ağırlıkların tekrar hesaplanması sayesinde hata oranı düşük çıktı elde etmek için olanak sağlayan geri yayılım algoritması ile evrişimli sinir ağları birlikte kullanılmıştır.

Hinton, Rumelhart ve Williams (1986) tarafından yayınlanan makalede, geri yayılım algoritmaları ve kendiliğinden organize olabilen bir ağ modeli girişiminden bahsedilmiştir. Ayrıca çalışmanın temel amacı; sistemin belirlenen sayıda kendiliğinden tekrar yapması ve tekrar sonunda elde edeceği çıktıya ait hata değerinin sıfır ya da sıfıra yakın olması şeklinde ifade edilmiştir. Bu amaç için yalnızca girdi ve çıktı katmanlarından oluşan basit modeller ile elde edilen çıktıların yetersizliğine ve gizli katmanın önemine değinilmiştir. Önemi açıklayabilmek adına Tekrarlayan Sinir Ağı modeli ele alınarak, 1500 tekrarlama ile çalıştırılan bir örnek verilmiştir. Başlangıçta iyi bir performans sergileyen örnekte belirli bir tekrar sayısından sonra takılmalar dolayısıyla yavaşlamalar ve bozulmalar meydana gelmiş, hata değerleri yükselmiştir. Bu örnek ile çok katmanlı modellerin basit modellere kıyasla daha başarılı olduğu görülürken bahsedilen amaca ulaşmak için gradyan probleminin engel olduğu tespit edilmiştir.

Hochreiter ve Schmidhuber (1997) tarafından yayınlanan makalede, tekrarlayarak öğrenme sırasında meydana gelen gradyan problemi konu alınmıştır. Bu problemi çözebilmek için; geri yayılım algoritmalarından yararlanılan, giriş-çıkış kapıları ve bellek özellikleriyle birlikte Tekrarlayan Sinir Ağı mimarisinin özel bir türü olan Uzun-Kısa Süreli Bellek Modeli tanıtılmıştır. Tanıtımın ardından Schmidhuber ve Cummins danışmanlığında yürütülen bir çalışmada Uzun-Kısa Süreli Bellek Modeli içerisinde bir eksiklik görülmüştür. Buna göre; modelde sıfırlama(unutma)

sistemi olmadığı takdirde ağ içerisinde bozulmalar meydana gelebileceği ve performansın düşebileceği düşüncesi üzerinde durularak ağ modeline unutmaya kapısı eklenmiştir. Bu sayede, Uzun-Kısa Süreli Bellek Modeli güncellenmiştir. Sonuç olarak; ağın bozulmalara karşı direnç gösterdiği ve eğitimin belirgin oranda hızlandığı görülmüştür (Gers vd., 1999). Aynı zamanda geliştirilen bu mimari, farklı mimari türleri ile çözüme kavuşturulamayan çok sayıda problemi düşük hata oranı ile çözüme kavuşturmuştur.

Hinton, Osindero ve Teh (2006) tarafından yayınlanan makalede, derin inanç ağları tanıtılmıştır. Bu ağ modeli çok sayıda gizli katmandan oluşan, oldukça hızlı öğrenim sağlayan, hem etiketli hem etiketsiz veriler için kullanılabilen, şekiller arasında güçlü ayırım yetisine sahip olan, grafiksel bir model olarak ifade edilmiştir. Ayrıca, optimizasyon, kümeleme, sınıflandırma gibi problemler karşısında oldukça başarılı çıktılar sunduğu görülmüştür. Bu çalışma çok sayıda farklı algoritma ve sinir ağı gelişimine olanak sağlamıştır. Bununla birlikte, 2006 yılından günümüze kadar uzanan süreç içerisinde çok sayıda problem için çözüm üretilmiştir.

Özetle, üzerinde inceleme yapılan ilk yıllarda eksik veri setleri, yanlış fonksiyon kalıbı seçimleri ve yetersiz bilgisayar özellikleri gibi birçok sebep dolayısıyla sağlıklı sonuçlar veremeyen derin öğrenme, teknolojinin de gelişmesiyle birlikte 21.yüzyılın başlarından itibaren modern derin öğrenme sürecine geçmiştir. Günümüzde Google, Facebook ve Microsoft başta olmak üzere çok sayıda büyük firma tarafından kullanılan oldukça popüler bir yöntem olarak bilinmektedir.

2.3.1. Derin Öğrenme Mimarileri

Derin öğrenme; tahmin ve öngöründe bulunma, sınıflandırma, optimize etme, görüntü tanıma, dil işleme gibi çok sayıda alanda oldukça başarılı sonuçlar vermesiyle bilinmektedir. Bu başarının oluşumu için kullanılan çeşitli mimari ağ türleri mevcuttur ve en sık kullanılan türleri aşağıda verilmiştir:

- Evrişimli Sinir Ağları
- Pekiştirmeli Öğrenme
- Tekrarlayan Sinir Ağları

2.3.1.1. Evrişimli Sinir Ağları

Evrişimli sinir ağları, nesne tanıma, takip etme, yüz doğrulama ve finans uygulamaları gibi birçok alanda sıklıkla kullanılan ileri beslemeli bir derin öğrenme mimarisidir. En büyük avantajı nesne tanımlamak olan evrişimli sinir ağlarının en büyük dezavantajı ise elde edilecek çıktı kalitesinin veri boyutu ve veri kalitesine bağlı olmasıdır. Burada evrişim kelimesi; girdiler ve fonksiyonlar arasında yapılan matematiksel işlemler bütünü olarak ifade edilir. Evrişimli sinir ağları ile ele alınan model ya da görüntüyü katmanlara işlenir ve ağın katmanları genel olarak şu şekildedir:

Giriş Görüntüsü → Evrişim Katmanı → Ortaklama Katmanı → Tam Bağlantı


Buna göre giriş görüntüsünde, görsel tanımlanarak giriş alınır. Evrişim katmanında, girişi yapılan görselin özellikleri tanımlanır (Giriş katmanında bir kedi görseli tanımlandığı varsayıldığında evrişim katmanında pati tanımlanması yapılması gibi). Bu katman görseli tarayan filtreleri içerir ve filtreler nöronları temsil eder. Örneğin; 10x10 boyutlu bir görsel ve 5x5 boyutlu bir filtre olduğu varsayılın. Filtrede yapılan 1x1'lik kaydırmalarla yeni ulaşılabilecek görsel 5x5 boyutunda olacaktır. Burada üst üste gelen görsel ve filtre çarpılarak elde edilen ağırlık değerleri çıktıyı temsil eder. Filtreleme işleminin temel amacı; özellikleri adım adım işlemektir. Dolayısıyla bu süreç sonunda elde edilen çıktı, işlenen özellikleri yansıtacaktır. Bu sebeple başarılı çıktılar elde edebilmek için özellikleri mümkün olduğunca arttırmakta fayda vardır. Yapılan bütün işlemlerin sonunda bu katmandan elde edilen içeriğinde özelliklerin tamamını barındıran çıktı “öznitelik haritası” olarak adlandırılır.

Evrişim katmanının ardından ortaklama ya da diğer adıyla havuzlama katmanına geçilir. Bu katmanda özellikleri tanımlanmış görsel, parçalara ayrılır. Bu parçalama işleminde minimum, maksimum, ortalama gibi değerler kullanılır. Örneğin; evrişim katmanı örneğinin tekrar ele alındığı varsayıldığında; 5x5 boyutlu filtre, 10x10 görsel üzerine geldiğinde ağırlıklar hesaplanır ve filtre üzerindeki en büyük değer alınır. Benzer şekilde filtre ilerledikçe yeni oluşan en büyük değerler not edilir. Bu şekilde yapılan boyut indirgemesi ile fazlalık olarak değerlendirilen hesaplamalardan arındırılmış ve temel özellikleri esas alınmış bir görsel meydana gelmiş olur. Dolayısıyla hesaplama kolaylığına zemin hazırlanır.

Son katman olan tam bağlantıda ise bütün işlemler birleştirilir ve elde edilen sonuçlar en iyiye ulaşmak amacıyla kullanılır. Dolayısıyla ileri beslemeli olarak öğrenme işlemi gerçekleşir (Fukushima, 1980).

2.3.1.2. Pekiştirmeli Öğrenme

Pekiştirmeli öğrenme, ele alınan veriler için istatistiksel yöntemler yardımıyla az veri kullanarak kendiliğinden öğrenebilen bir yapıya sahip olan derin öğrenme mimarisidir. Sadece kural ve ödül sistemine ihtiyaç duyar. Genellikle sosyal alanlarda, optimizasyon sağlamak için kullanılır. Pekiştirmeli öğrenme için amaç karşılaşılan durumlar karşısında neler yapılabileceğinin öğrenilmesidir. Günlük hayat için pekiştirmeli öğrenme temelli çok sayıda örneğe rastlamak mümkündür. Bunlardan birkaç tanesi şu şekilde örneklendirilebilir: Bir basketbol oyuncusu oyuna başladığı ilk zamanlarda topu potaya denk getiremezken düzenli bir antrenmanın ardından kolaylıkla denk getirebilir. Çünkü belirli konum ve teknik, deneme yanılma yoluyla tespit edilmiştir ve en iyisini öğrenmiştir. Benzer şekilde satranç veya SOS oyunları ele alındığında yapılan hamlenin ardından rakip muhtemel hamleyi planlar ve sezgisel çıkarımlar yardımıyla oynamaya devam eder. Psikolojik açıdan ise kişinin durum ve koşulları göz önünde bulundurarak karar vermesi pekiştirmeli öğrenme için ideal örnek niteliğindedir (Global AI Hub Eğitimleri, 2021).




Şekil 7. Pekiştirmeli Öğrenme Süreci

Şekil 7 incelendiğinde, ajan olarak ifade edilen makine için bir hedef belirlenir ve bu hedef doğrultusunda ajanın hareket etmesi beklenir. Bu süreçte ajan, öğrenim ve karar için çevreyi kullanarak karşılaştığı olaylara yönelik tepkiler vermeye başlar. Verdiği tepkiler eylem olarak adlandırılır ve eylemler karşılığında bir puan alır. Burada alınan puanlar sistem içerisinde ödül olarak tanımlanır, ajanın ödül almasıyla birlikte öğrenim süreci başlamış olur. Ayrıca, bu noktada sistem kendisine bir politika belirler. Politika, ajanın karşılaştığı durumlarda başarılı tepkiler verdiği zamanları bilir ve

tekrar karşılaştırılması durumunda karar sürecini hızlandırır. Bu süreç çok kez tekrarlanır ve elde edilen puanlar bir sonraki adımda karşılaştırılır (Global AI Hub Eğitimleri, 2021).


2.3.1.3. Tekrarlayan Sinir Ağları

Tekrarlayan Sinir Ağları, Hinton ve arkadaşları tarafından geliştirilmiş olan, özellikle zaman serisi analizlerinde sıralı veriler arasındaki ilişkiyi anladıktan sonra bir sonraki adım için tahminde bulunmak amacıyla kullanılan derin öğrenme mimarisidir ve ağ modeli Şekil 8’de verildiği gibidir:



Şekil 8. Tekrarlayan Sinir Ağı Modeli

Şekil 8’de görülen Tekrarlayan Sinir Ağı modeli, girdi katmanından aldığı bilgiyi çıktı katmanına kadar işlemek için ileri beslemeli ağlardan faydalanırken, tekrarlama sırasında kullandığı geri yayılım algoritması ve zaman kavramı dolayısıyla özelleştirilmiş bir yapıya sahiptir. Buna ilişkin model işleyişini daha net görebilmek adına Şekil 9 incelenebilir.



Şekil 9. Tekrarlayan Sinir Ağı Modelinin İşleyişi

Şekil 9'a göre;

- X_t : t zamanında sağlanan girdi,
- h_t : t zamanında gerçekleşen durum,
- W : ağırlık,
- W_{xh} : gizli katman ağırlığı,
- W_{hy} : çıktı katmanı ağırlığı,
- f : sonraki adıma aktarılan ağırlık ve ağ hafızası,
- y_t : t zamanında elde edilen çıktı

olmak üzere model işleyiş adımları sırasıyla şu şekildedir:


1. Ağ modeline en az bir adım geri gidilecek şekilde t gibi bir zaman belirtilerek girdi verilir.
2. Girdi ve t-1 zamanında gerçekleşen durum kullanılarak, yineleme formülü olan; $h_t = f(h_{t-1} + X_t)$ ile güncel durum hesaplanır.
3. Her adım sonunda güncel durumlardan elde edilen bilgiler birleştirilerek $y_t = \tanh(W_{hy} * h_{t-1} + W_{xh} * X_t)$ formülü ile bir çıktı hesaplanır.
4. Çıktı olarak elde edilen değerler, gerçek değerlerden çıkartılarak hata değerleri elde edilir.
5. Ağırlıkların güncellenmesini sağlamak için elde edilen hata geri yayılır ve yeni çıktı üretilir. Bu döngünün belirlenen tekrar sayısı kadar devam etmesiyle birlikte ağ eğitimi sağlanır (Karakoyun, 2018).

Tekrarlayan Sinir Ağları, içeriğinde barındırdığı zaman kavramı ve yüksek performans oranları ile yaptığı başarılı tahmin ve öngörülerden ötürü zaman serisi analizlerinde, çeviri, dil işleme, müzik gibi devamlılık arz eden alanlarda sıklıkla kullanılmaktadır. Öte yandan, değişkenler arasında var olan bağımsızlık etkisiyle tekrarlama sırasında ezberlemeyi önleyen başarılı bir yapıya sahiptir ancak öğrenme hızını yavaşlatan bazı problemler vardır. Bu problemlerden ilki ve en büyüğü gradyan problemidir. Gradyan problemi, modele katman eklendikçe geri yayılım sırasında çarpılan ağırlıkların zamanla 0'a yaklaşmasıyla oluşan problemidir (Hermans ve Schrauwen, 2013). İkinci problem; Tekrarlayan Sinir Ağları'nın yapısı gereği bir sonraki adımda yapılacak işlemin bir önceki adıma bağlı olmasından kaynaklanan

bağımlılık problemidir. Son olarak üçüncü problem ise modelin içeriğinde gerekli ve gereksiz olan bütün bilgileri ayrıştırmadan barındırması şeklindedir. Bu üç problem, uzun süreli analizlerde öğrenme hızını belirgin oranda yavaşlatırken, problemin olduğundan daha fazla karmaşıklaşmasına sebep olur. Dolayısıyla çıktı elde edebilmek için daha fazla zamana ihtiyaç duyulur ve elde edilen çıktılar yüksek hata oranına sahip olur (Hinton vd., 1986).


2.3.1.3.1. Uzun-Kısa Süreli Bellek Modeli

Uzun-Kısa Süreli Bellek Modeli, Tekrarlayan Sinir Ağları'nda uzun süreli analizlerde karşılaşılan önceki adıma bağlılık, bilgilerin ayrıştırılmaması ve gradyan problemlerini giderebilmek amacıyla geliştirilmiş olan bir tür Tekrarlayan Sinir Ağı mimarisidir (Hochreither ve Schmidhuber, 1997).



Şekil 10. Uzun-Kısa Süreli Bellek Modeli

Şekil 10'da görüldüğü gibi Uzun-Kısa Süreli Bellek Modeli sürekli etkileşim ve tekrarlama içeren, kapılardan oluşan ve dört katmanlı, özel bir yapıya sahiptir. Buna göre; modelde yer alan oklar vektörden elde edilen çıktının bir sonraki adıma girdi olarak taşınmasını, dikdörtgen formundaki tanh ve σ ; ağ yapısında kullanılan aktivasyon fonksiyonlarını ve öğrenmeyi, son olarak $\otimes$ ve $\oplus$ ise o noktada yapılan çarpma ya da toplama işlemleri sonucunda oluşan hareketi ifade etmektedir. Uzun-Kısa Süreli Bellek Modeli'nde temel amaç; yararlı olan bilgilerin bir sonraki adıma taşınmasıdır ve bu karar eğitim sürecinde verilir. Bu noktada Uzun-Kısa Süreli Bellek Modeli'nin işleyişine ilişkin adımlar Şekil 11'de detaylı olarak verilmiştir (URL6).



Şekil 11. Uzun-Kısa Süreli Bellek Modeli İşleyişi

Katman 1: Gerekli ve gereksiz bilgilerin ayrıştırıldığı unutma katmanıdır. Bu katmanda, sigmoid (σ) aktivasyon fonksiyonu kullanılarak önceki katmandan gelen bilgi (y_{t-1}) ile güncel giriş bilgisi (X_t) işlenir ve bir hesaplama yapılır. Hesaplama için gerekli hesaplamalar; f : fonksiyon, f_t : unutma kapısı değeri, W ve U : ilgili değişkenler kullanılarak elde edilen kapı ağırlık değerleri ve b_f : ön bilgi değeri olmak üzere, Eşitlik 1’de verilen denklem kullanılır:

$$f_t = \sigma (W_{f,x} X_t + U_{f,y} y_{t-1} + b_f) \quad (1)$$

Eşitlik 1 kullanılarak sonucu 0 ya da 1 olacak şekilde çıktılar elde edilir. Elde edilen çıktılar sonucunda 0’a karşılık gelen bilgiler unutulurken 1’e karşılık gelen bilgiler yararlı görülür ve hücre içerisinde hafızada yer edinmek üzere bir sonraki katmana taşınır.

Katman 2: Giriş kapısı katmanıdır. Önceki katmandan elde edilen çıktılar ve mevcut katmandan gelen güncel bilgiler kullanılarak yeni çıktılar elde edilir. Elde edilen bu çıktılar unutma kapısı katmanında olduğu gibi sigmoid aktivasyon fonksiyonundan geçirilerek yeniden hesaplama yapılır. Hesaplama için; i_t : giriş kapısı değeri, b_i : girişe ilişkin ön bilgi değeri olmak üzere, Eşitlik 2’de verilen denklem kullanılır:

$$i_t = \sigma (W_{i,x} X_t + U_{i,y} y_{t-1} + b_i) \quad (2)$$

Buradan elde edilen sonuçlara göre unutulacak ve hatırlanacak bilgiler güncellenir. Son olarak, tanh aktivasyon fonksiyonu kullanılarak eklenebilecek yeni bilgiler için hesaplama yapılır ve iki fonksiyondan elde edilen sonuçlar birleştirilerek yeni sonuçlara ulaşılır. Bu sayede, sonraki adıma taşınacak bilgiler kesinleşir. Bu süreç için; $\hat{C}_t$: güncel aday değeri(çıktıya iletilebilecek yeni değer), b_c : hücreye ilişkin ön bilgi değeri olmak üzere, Eşitlik 3’de verilen denklem kullanılır:

$$\hat{C}_t = \tanh(W_{c,x} X_t + U_{i,y} y_{t-1} + b_c) \quad (3)$$

Katman 3: Hafıza katmanıdır. Bu katman, son güncellemelerin yapıldığı ve yararlı bilginin hafıza özelliği ile çıktıya iletildiği katmandır. İlk olarak, bir önceki katmanda unutulacak bilgilerin hafızadan silinebilmesi için t-1 zamanındaki eski aday değeri ve unutma kapısı değeri çarpılır. Ardından, giriş kapısı değeri ve güncel aday değeri çarpılır ve bu iki değer toplanarak yeni aday değeri (C_t) elde edilir. Bu süreç için; $\otimes$: çarpma işlemi ve $\oplus$: toplama, birleştirme işlemi olmak üzere, Eşitlik 4’de verilen denklem kullanılır ve son güncelleme yapılır:

$$C_t = (f_t \otimes C_{t-1}) \oplus (i_t \otimes \hat{C}_t) \quad (4)$$

Burada C_t ile elde edilen değer hafızada yer alarak son katmana iletilir.

Katman 4: Çıkış kapısı katmanıdır. Bu katman, modelin hafıza özelliği kullanılarak taşınan bilgiler ile sonraki adıma ilişkin yeni bir girdi değeri sunar. Yapılacak tahmin ve öngörülere ilişkin çıktılar bu katmanda elde edilir. Bu süreç için; o_t : çıkış kapısı değeri ve b_o : hücre çıktısına ilişkin ön bilgi değeri olmak üzere; Eşitlik 5’de verilen denklem kullanılır ve çıkış kapısı değeri elde edilir:

$$o_t = \sigma(W_{o,x} X_t + U_{o,h} y_{t-1} + b_o) \quad (5)$$

Son olarak elde edilen çıkış kapısı değeri ve tanh aktivasyon fonksiyonuna tabi tutulan hafıza katmanından iletilen aday değeri çarpılır. Bu süreç için kullanılan denklem Eşitlik 6’da verildiği gibidir:

$$y_t = o_t \otimes \tanh(C_t) \quad (6)$$

Eşitlik 6 sonunda kapılar ile eğitim süreci tamamlanarak nihai kararı ifade eden çıkış değeri (y_t) elde edilir (URL18, Le vd., 2019).

Katmanlarına göre detaylı bir şekilde anlatılan Uzun-Kısa Süreli Bellek Modeli bir bütün olarak incelendiğinde avantajlarını kısaca şu şekilde özetleyebiliriz: Uzun-Kısa Süreli Bellek Modeli, hafızada yer alan bilgileri uzun süre tutabilen özel bir bellek hücresi içermektedir. Bu hücre, Uzun-Kısa Süreli Bellek Modeli'ni diğer mimarilerden ayırır ve üstün kılmaktadır. Özellikle tahmin ve çok adımlı öngörü problemleri için kullanılan diğer mimarilere oranla çok daha başarılı çıktılar sunmaktadır. Bunun sebebi; diğer mimarilerde bütün girdilere ait bilgiler ele alınırken, Uzun-Kısa Süreli Bellek Modeli'nde yalnızca gerekli bilgilerin ele alınması, bellekte depolanması ve depolanan bilgiler ile çıktı hesaplanmasından kaynaklanmaktadır. Ayrıca, yalnızca tahmin ve öngörü değil aynı zamanda sınıflandırma problemlerinde de oldukça başarılı çıktılar üretmektedir. Son olarak veri artışı diğer mimarilerde karmaşıklığa sebep olurken Uzun-Kısa Süreli Bellek Modeli'nde ekstra bilgi demektir ve eklenen her bir bilgi çıktının daha başarılı olmasına olanak sağlamaktadır.

2.3.2. Derin Öğrenmenin Avantajları, Dezavantajları ve Kullanım Alanları

Derin öğrenmenin en büyük avantajı; eğitim sırasında yaptığı genelleme ile öğrenimi hızlandırmasıdır. Ardından, zaman serilerinde tahmin ve çok adımlı öngörü için etkin sonuçlar vermesi, klasik yöntemlere kıyasla çok daha hızlı çıktı üretmesi, ekonomik olması, basit bir eğitim ara yüzüne sahip olması, çok sayıda model ve geleneksel yöntemin bir arada kullanımına olanak tanınması, hataları göz ardı etmesi, verileri çok yönlü olarak incelenmesi, veri özelliklerini tanınması ve sınıflandırma yapabilmesi ve eksik veri durumunda önceki birikimlerinden yola çıkarak çıktı üretebilmesi gibi çok sayıda avantaja sahip olduğu görülmektedir (Şeker vd., 2017). Ayrıca, derin öğrenmeyi diğer yöntemlerden ayıran en önemli özellik ise manuel işlemlere gerek duymadan keşif yetisi ile görüntü uygulamalarına ait parametreleri otomatik olarak belirleyerek uygulama için hazır hale getirmesidir.

Öte yandan derin öğrenmenin dezavantajları incelendiğinde, özellikle tekrar ve katman sayısının fazla olduğu durumlarda problem çözümünün zaman alıcı olması, genelleme sırasında yalnızca sisteme sunulan değişkenlerin ele alınmasından ötürü elde edilen çıktının etkinlik içermemesi ve eğitim sırasında çok fazla işlem kapasitesine ihtiyaç duyulması görülür.

Son olarak derin öğrenmenin kullanım alanları incelendiğinde; özellikle finans, sağlık, mühendislik, teknoloji gibi alanlarda tahmin ve öngörü çalışmalarında kullanıldığı görülmüştür. Bunlardan bazıları; erken tanı tespiti, proje süresi hesabı, hisse senedi tahmini, takım performans tahmini ve uygulama içi satın alma öngörüsü şeklindedir. Ayrıca, çeviri yapma, görüntü tanıma, asistan uygulamaları ve daha birçok alanda da kullanılmaktadır.

2.3.3. Makine Öğrenmesi ve Derin Öğrenme Arasındaki Benzerlikler ve Farklılıklar

Derin öğrenme ve makine öğrenmesi yapay zekanın alt kümeleridir. Bu iki alt kümeye ait benzerlikler ve farklılıklar şu şekildedir:

- Her iki öğrenme türü de insan beynini taklit eder.
- Her ikisi de denetimli ve denetimsiz olarak öğrenme sağlayabilir.
- Her ikisi için de yorumlama yapmak güçtür.
- Her ikisi için de yüksek teknoloji şarttır.
- Derin öğrenme büyük veri setlerinde, makine öğrenmesi ise daha küçük veya orta büyüklükteki eğitim veri setlerinde daha iyi öğrenim sağlar.
- Derin öğrenme yaptığı ağırlıklandırmalar ve tekrarlardan dolayı daha detaylı çalışarak daha uzun sürede sonuç verirken, makine öğrenmesi çok daha kısa sürede sonuç verir.
- Derin öğrenme zorlayıcı ve karmaşık yapıli problemlerde etkin sonuçlar verirken, makine öğrenmesi daha basit yapıli problemlerde etkin sonuç verir.
- Derin öğrenme problemlerde özellikleri otomatik olarak algılarken, makine öğrenmesinde özelliklerin uzman kişi yardımıyla tanıtılması gerekir.
- Derin öğrenme sorunu bir bütün olarak değerlendirirken, makine öğrenmesi parçadan bütüne gitme tekniğini uygular.
- Derin öğrenme çıktısı metin, ses ve benzeri dahil olmak üzere herhangi bir biçimde sunulabilirken, makine öğrenmesi sadece sayısal çıktı sunar.
- Derin öğrenme yapılandırılmamış verilerin öğrenmesinde kullanılırken, makine öğrenmesi yapılandırılmış verilerin öğrenilmesi için kullanılır (Gürsakaı, 2017).

3. BÖLÜM

GENEL BİLGİLER

3.1. Futbol

İnsan yaşamının sağlıklı bir şekilde sürdürülebilmesi için büyük önem taşıyan spor; fiziksel ve zihinsel gelişim, eğlence, yarışma gibi pek çok amaçla yapılabilir ve kendisi ya da karşısındakine karşı daimi bir mücadeleyi barındırırken barışı hedefler. Farklı mekanlarda, farklı koşul ve kurallara bağlı birçok spor dalı mevcuttur. Bunlardan birisi de dünyanın en popüler spor dalı olan futboldur.

Futbol, yediden yetmişe bireylerin önem ve sevgiyle yakından takip ettiği bir spor dalıdır ve rakibe karşı üstün puan kazanmak amacıyla ayak ya da kafa kullanarak gol atmanın hedeflendiği bir tür top oyunu olarak düşünülebilir. İçeriğinde iki takım ve her bir takım için aktif 11 oyuncu mevcuttur. Arka planında ise oyuncularını maça hazır hale getiren teknik direktör, maç yönetimini sağlayan hakem, takımı destekleyen seyirciler ve daha nice görevli bulunmaktadır.

3.1.1. Futbolun Gelişimi

Dünyada ortaya çıkış tarihi üzerine çok sayıda yorum yapılan fakat net bir bilgiye ulaşılamayan futbol tarihinin oldukça eski dönemlere dayandığına dair araştırmalar mevcuttur. Örneğin; yaklaşık 2000 yıl önce Çin’de el kullanılmadan, topun tekmelenerek hedefe ulaştırıldığı, on ikiden fazla oyuncunun bulunduğu bir takım oyunu keşfedilmiştir. Bu oyun “Cuju” şeklinde isimlendirilmiş ve Japonya’da “Kemari” isimli farklı bir oyunun gelişimi için kullanılmıştır. Kemari, belirli bir alana bağlı olmaksızın, topla yalnızca ayak aracılığıyla temas kurulabilen, sekiz kişilik bir takım oyunudur ve ilk çıktığı dönemde yalnızca soyluların oynamasına izin verilmesinin ardından zamanla halka taşınmasıyla bilinmektedir (URL7). Öte yandan Kemari’nin de geliştirilmesiyle birlikte farklı oyunlar için zemin hazırlanmıştır.

Dünyanın dört köşesinde benzer içeriklerde oynanmış oyunlar mevcuttur. Bunlar belirli izler, resimler ve yazılarla gündeme gelmiştir ve günümüz futbolunun ortaya çıkmasında fikir bazında etkileri olduğu düşünülmektedir. Bu düşünce süreci

ilkel futbol dönemi olarak isimlendirilirken bu düşünceye karşıt olarak Uluslararası Futbol Federasyonları Birliği'nce futbola dair ata formun yalnızca cuju olarak kabul edilmesinin ardından modern futbol dönemine geçilmiştir.

Bu bağlamda modern futbol dönemi incelendiğinde; 19. yüzyılda, İngiltere'de, Cambridge Kuralları ile doğduğu görülür. Cambridge Kuralları, günümüz futbolunun temelini oluşturmaktadır ve başlangıç, kale değişimi, gol sonrası süreç, topun dışarı çıkması ve puana kadarki bütün süreç için belirli kuralları içeren yazılı belgeler olarak bilinmektedir ancak günümüz futboluna ulaşana kadar çok sayıda itiraz alması dolayısıyla bağımsız kulüpler tarafından temel kurallarında değişiklikler gözlemlenmiştir (URL7).

Öte yandan Türkiye'de futbolun gelişimi incelendiğinde ise ilk adımlarının 19. yüzyıl sonlarında İngilizler tarafından Selanik'te ve hemen ardından İzmir'de atıldığı görülmüştür (URL8). Dönem içerisindeki yoğun baskıdan ötürü Müslümanların futbol etkinliklerine katılması yasaklanmıştır. Dolayısıyla maçlar uzunca bir süre farklı dinlere mensup bireyler tarafından yapılmış ve kulüpler kurulmaya devam edilmiştir (Akşar ve Merih, 2006).

Türkiye'nin ilk futbol karşılaşması, İzmir-İstanbul karmasıyla yapılmış ve ardından 1901 yılında Fuat Hüsnü Bey ve Reşat Danyal Bey tarafından Türkiye'nin ilk futbol kulübü olan "Black Stocking" yani "Siyah Çoraplar" kurulmuştur. Siyah Çoraplar'ın ilk karşılaşması Rumlarla yapılmıştır (URL8). Yapılan karşılaşmanın ardından İstanbul Futbol Ligi oluşturulurken aynı dönem içerisinde çok sayıda farklı kulüp kurulmuştur fakat kulüplerin ileri adım atma konusunda yetersiz kalması dolayısıyla devamlılık sağlanamamıştır. Bu noktada futbola yönelimini 7 sene sonra gerçekleştirmek üzere 1903 yılında Beşiktaş Jimnastik Kulübü, 1905 yılında Galatasaray Spor Kulübü ve 1907 yılında Fenerbahçe Spor Kulübü kurulmuştur. Kulüpler kuruldukları günden bu yana uzun soluklu yolculuklarını sürdürerek adım adım yükselmişlerdir. Bu yükseliş başarılı üç kulübe "üç büyükler" unvanını getirmiştir.

Zamanla kurulan kulüp sayıları artmış ve kulüpler yeni kurulan liglere dahil edilirken, 1923 yılında yönetim idaresiyle birlikte Türkiye Futbol Federasyonu kurulmuştur (URL9).

Son olarak 1967 yılında kurulan Trabzonspor Kulübü'nün ardı ardına kazandığı şampiyonluklar ile üç büyükler, aralarına Trabzonspor Kulübünü de alarak yolculuklarına “dört büyükler” unvanı ile devam etmişlerdir. Günümüzde Türkiye'nin en köklü ve en başarılı kulüpleri olarak bilinen dört büyük spor kulübü, başarı basamaklarını hızla tırmanmışlardır. Aldıkları puanlar ve elde ettikleri ödüller ile başarılarını ispatlamışlardır.

Ek olarak, yapılan uluslararası maçlar ile futbola ilgi devrim niteliği yaratmış ve 1992 yılında Türkiye Futbol Federasyonu 3813 sayılı kanun ile özerk hale gelmiştir. O günden bugüne uzanan futbol gelişim süreci daha büyük bir heyecan ve daha büyük bir seyirci kitlesiyle birlikte devam etmektedir.

3.1.2. Futbol Ekonomisi

20. yüzyıl sonlarında teknolojinin gelişmesi ve futbolun televizyon ile buluşmasıyla birlikte kitle bazında bambaşka bir boyuta ulaşılmış, maçların izleyiciye yönelik sağladığı heyecan, kişiler arası iddialaşma durumlarıyla artmış, sohbet konularında yerini almış ve futbol daha da popüler bir spor dalı haline gelmiştir. Oluşan gelişmeler dolayısıyla futbol ve televizyon buluşması büyük bir sıçramaya olanak sağlamıştır (Arık, 2008). Bu sıçrama küreselleşmeyle birlikte endüstrileşmeyi de beraberinde getirmiştir.

Bu süreçte taraftarların takıma yönelik bağlılıklarının arttığı gözlemlenirken, yapılabilir değişiklikler ve yeniliklerle birlikte kısa bir zaman içerisinde tek düzen olan bilet geliri yerine daha büyük gelirler elde edilebileceği fark edilmiştir (Çakmak, 2019). Bunun için markalaşma sürecine gidilmiş ve takımlara yönelik atkı, bere, forma gibi tasarım içerikli giyim ürünleri piyasaya sürülmüştür. Alınan olumlu dönüşler sonrasında taraftarın kendisini özel hissetmesine yönelik çalışmalar hızla devam etmiştir. Örneğin; tasarım ürünleri arttırılmış, statlar yenilenmiş, transfer sürecinde başarısı ve kişiliğiyle dikkat çeken sevilen futbolcular tercih edilmiştir. Bunların tamamı kulüplerin şirketleşmesiyle meydana gelmiş ve ciddi oranda gelir artışı gözlemlenmiştir. Bu gelir artışının ana kaynağı taraftarlar ile başlasa da arka planda teknoloji dolayısıyla farklı içeriklerde de gelir sağlanmıştır. Dolayısıyla artık futbol,

üzerinde konuşulabilir büyüklükte ekonomiye sahip bir alan haline gelmiş ve borsada işlem görmeye başlamıştır.

Bu durum sağladığı gelir artışı kadar gider artışını da beraberinde getirmiştir. Çünkü rekabet, büyümeyi daha da hızlandırmıştır. Bu hızlanma; piyasa araştırmalarını kısıtlamış, fiyatların yanlış belirlenmesine zemin hazırlamış ve ödemelere yönelik kontrol kaybı sebebiyle borçlanmayı arttırmıştır (Merih, 2006). Sonuç olarak; borçlanma sürecini doğru yöneten kulüpler yolculuklarına devam etmişlerdir.

3.1.3. Türkiye'de Futbol Kulüplerinin Gelir Kaynakları ve Giderleri

Teknolojinin gelişmesi ve kulüplerin şirketleşmesiyle birlikte şirket gelirleri ciddi anlamda artış sağlamıştır. Bu noktada gelir kaynakları Türkiye kulüpleri için şu şekilde sıralanabilir:

1) Bilet Geliri: Futbolda gelir kaynakları denildiğinde akla ilk gelen maç günü bileti getirisi. Dünya çapında futbol, sezonda yaklaşık 3.5 milyar seyircisiyle, diğer spor dallarından ayrılarak en fazla seyirci kitlesine sahip spor dalı olma niteliğindedir. Buna göre; Süper Lig içinde dört büyük spor kulübü örneği incelendiğinde, 2006/07-2020/21 sezon aralığını kapsayan, 15 sezonluk toplam seyirci sayılarının şu şekilde olduğu görülmüştür:

Tablo 3. Toplam Seyirci Sayıları

Takım	Toplam Seyirci Sayısı
Süper Lig	30.291.385
Beşiktaş	3.390.999
Fenerbahçe	5.073.600
Galatasaray	5.017.183
Trabzonspor	3.652.226

Kaynak: URL10.

Tablo 3'e göre, 15 sezon içerisinde Süper Lig takımlarının tamamı için toplam seyirci sayısı 30.291.385'tir ve bu değer %56.3'ü dört büyük spor kulübüne aittir. Yani, 2006/07-2020/21 sezon aralığında, Süper Lig içerisinde minimum 18, maksimum 20 takımın yer aldığı bilindiğine göre, kalan %43.7'lik oran kalan 14 ila 16 takımın tamamına aittir. Bu durum Süper Lig için dört büyük spor kulübünün

katkısının ne denli önemli olduğunu vurgulamaktadır ancak durum genelleme yapılarak detaylandırıldığında Süper Lig takımlarının oynadığı maçlarda, statların doluluk oranlarının diğer ülkelerin gerisinde kaldığına dair araştırmalar mevcuttur. Bu araştırmalar, genel olarak spora yönelik verilmesi gereken değerin verilmediği ya da verilemediği yorumunu beraberinde getirmektedir. Öte yandan, güncel veriler dahilinde dört büyük spor kulübü için maç bilet fiyatları incelendiğinde, bilet fiyatlarının yüksek olmasının taraftarlar tarafından tepki toplaması da doluluk oranlarını etkilemektedir. Bunlara rağmen takım ruhu dolayısıyla bilet getirisi futbol için önemli bir gelir kaynağıdır ve bahsi geçen konuya çözüm niteliğinde, alternatif olarak, çok sayıda taraftar kombine bilet tercih etmektedir. (Kombine biletler, genellikle sezonu kapsayan süre içerisinde tüm iç saha maçlarını tek seferlik ödeme yaparak, aynı alanda izlemeye olanak tanıyan ve normal bilete nispeten toplu ödeme dolayısıyla bir miktar daha uygun fiyatlı olan bilet türüdür.)

2) Mağaza Geliri: Günümüzde takımların orijinal logolu ürünlerinin satışının yapıldığı sezonluk olarak giyimden aksesuara çok sayıda ürünün bulunduğu, fiziki mağazalar (Kartal Yuvası, GS Store, Fenerium ve TS Club gibi) ve bunların yanı sıra çok sayıda kullanıcıya hizmet veren çevrimiçi internet mağazaları mevcuttur. Pandemi dönemiyle birlikte internet mağazacılığı kullanımı artmış ve bu durum fiziki mağazaların azaltılması kararını beraberinde getirmiştir. Bu kararın maliyeti azaltması dolayısıyla net gelir açısından oldukça olumlu sonuçlar doğurması beklenmektedir.

3) Bahis Geliri: Son yıllarda oldukça yaygınlaşmış bir gelir türüdür. Bayii ya da uygulamalar aracılığıyla, belirlenen miktarda ödeme yapılarak, maç sonucuna yönelik yapılan tahminler için kupon hazırlanarak elde edilir. Bu gelir türünde Türkiye Futbol Federasyonu tarafından bahisten pay alınır ve alınan pay ilgili takımlara gelir olarak dağıtılır.

4) Yayın Geliri: Kullanımı pandemi dönemi içerisinde seyircisiz oynanan maçlar dolayısıyla fazlaca artmış gelir türüdür. Kupa maçlarının yayınlanması ya da direkt spor kanallarının kullanıcıya satılması ile elde edilir. Bahis gelirine benzer şekilde gelir Türkiye Futbol Federasyonu'na aktarılır. Federasyon takımlara pay dağıtır.

5) Sponsorluk Geliri: Çok sayıda firma tarafından reklam aracılığıyla sağlanan gelir türüdür. Başta forma sponsorluğu ardından ise stat ve isim sponsorluğu bu gelir türüne örnektir (URL11). İçeriğinde kulübün isminin, logosunun ya da sporculara ait fotoğrafların kullanım izni yer alır. Sponsorluk geliri de diğer gelir türleri gibi oldukça önemlidir ve kulüplere önemli paralar kazandırdığı bilinmektedir (URL12).

Maddelerle ifade edilen gelir kaynaklarının yanı sıra transfer gelirleri, sosyal medya gelirleri, tesis gelirleri, spor okulu gelirleri ve daha niceleri eklenebilir.

Öte yandan, büyük gelir artışları beraberinde gider artışlarını da getirmiştir. Yapılan araştırmalara göre futbol kulüplerinin giderleri şu şekildedir:

Gider başlığında en büyük pay futbolcular başta olmak üzere personele yapılan maaş ödemesine aittir. Ödemeler; transfer görüşmesi sırasında ödenen bonservis ödemeleri, futbolcuların oynadığı ya da oynamadığı her maç için ödenmesi gereken garanti ödemeler ve ilk 11’de yer aldığı her maç için yapılan maç başı ödemeler şeklindedir (Güven, 2010). Ayrıca, personele yönelik prim ve ikramiye ödemeleri de yapılmaktadır.

Bunun haricindeki giderler, sporcuların gelişimine yönelik verilen eğitimler, faizleri içeren finansman giderleri, satışı yapılan ürünler için üretim giderleri, mağaza kira gideri, antrenman alanı için kira gideri, kamp giderleri, seyahat-konaklama ve sağlık giderleri, genel bakım onarım giderleri şeklinde sıralanabilir (Aktaş ve Mutlu, 2016).

3.2. Futbol Kulüplerinin Halka Arz Süreci

3.2.1. Halka Arz Kavramı

Şirketlerin borçlarını giderme, büyüme, daha fazla kesime hitap edebilme ya da yenilikçiliği sürdürebilme gibi amaçlarla sermayelerine katkı sağlamak için paydaş edinmeleri halka arz olarak adlandırılır (Sermaye Piyasası Kurulu Eğitim Semineri Kitapçığı, 2019). Halka arz, şirketler için önemli bir finansman kaynağı niteliğindedir. Bu süreçte hisselerle ilişkin satış duyuru yoluyla yapılmaktadır ve duyuruya dönüş yaparak hisse alan yatırımcılar bireysel yatırımcılar ve kurumsal yatırımcılar olarak

ikiye ayrılır. Bu noktada paydaşlığın belgelenmesi, kıymetli evrak niteliği taşıyan hisse senedi ile sağlanır.

Bunun yanı sıra Sermaye Piyasası Kurulu'na göre halka arz, “serbest piyasa araçlarının satın alınması amacıyla yapılan genel çağrı ve gerçekleştirilen satış” olarak tanımlanmıştır (Sermaye Piyasası Kurulu Eğitim Semineri Kitapçığı, 2019). Sermaye piyasalarının temelde üç amacı vardır. Bunlar: Tasarruf yapan bireylerin sermaye piyasası araçlarına yönlendirilmesi, araçların çeşitlendirilerek artırılması ve yatırımın devamlılığının sağlanmasıdır (Sermaye Piyasası Kurulu Eğitim Semineri Kitapçığı, 2019). Bu noktada amaçların gerçekleştirilebilmesi için tebliğe uygun şekilde satış yapılması esastır.

3.2.2. Halka Arz Yöntemleri

Temelde üç farklı halka arz yöntemi vardır. Bunlar:

1.Mevcut Sermaye Paylarının Satışı Yoluyla Halka Arz: Paylarının bir kısmını halka arz eden ortaklar elde edilen kaynaklarla kendilerine finansman sağlarlar. Bu süreç için gerekli amaç ve ilkelerin sağlandığı, esas belgede yapılacak değişikliklerin belirtildiği gerekli tasarıyı hazırlayarak Serbest Piyasalar Kurulu'na başvuruda bulunurlar. Başvurunun ardından onay alınması ile birlikte yapılacak değişiklikler için ilk genel kurul toplantısında karar çıkması gerekir (URL13).

2.Sermaye Artırımı Yoluyla Halka Arz: şirketlerin yatırımlarını finanse etmek amacıyla başvurdukları yöntemdir. Yeni yatırımlar yapabilmek için karar genel kurula sunulur ve olumlu sonuçlandığı takdirde Serbest Piyasalar Kurulu'na başvuruda bulunulur. Alınan Serbest Piyasalar Kurulu onayı ile artırım gerçekleştirilir. Sermaye artırımını için kullanılan iki yol vardır. Bunlar:

- Bedelli Sermaye Artırımı: Şirketlerin, yatırımlarına tekabül eden hisse senetlerinin bedellerinin ödenmelerinin ardından genel kurul kararı ile yeni hisse senedi çıkarması durumudur. Elde edilen yeni hisse senetleri için şirket içerisinde önceden hisse senedi alan kişilere ön alım hakkı verilir. Bu kişiler belirlenen tarihler arasında haklarını satabilir ya da belirlenen fiyat ile ödeme

yaparak hisse senedi sahibi olabilir (Sermaye Piyasası Kurulu Eğitim Semineri Kitapçığı, 2019).

- Bedelsiz Sermaye Artırımı: Şirketlerin piyasa değerlerini arttırmadan, iç kaynaklarını kullanarak bedelsiz olarak hisse senedi vermesi durumudur. Bu sayede dolaşımdaki hisse senedi miktarı artırılır.

3.Mevcut Payların Satışı Yoluyla Halka Arz: Bu yöntemde mevcut sermaye paylarının satışı ve sermaye artırımı yöntemleri bir arada kullanılır. Diğer iki halka arz yöntemine oranla yaygınlığı azdır ve belirli bir düzenleme mevcut değildir (Özboyacı, 2010).

3.2.3. Halka Arzın Avantajları ve Dezavantajları

Halka arzın sağladığı en büyük avantaj; finansmandır. Finansman sayesinde elde edilen nakit para varsa şirketin borçları için yoksa şirketin büyümesi için kullanılır. Bu durum hissedarlık etkisiyle ek gelir sağlamasından dolayı yatırımcı için de büyük bir avantajdır.

Ayrıca, hisse değerinin takip edilebilir olması yeni yatırımcılara kapı açar ve her bir yatırımcı şirket için ekstra fonu ifade eder. Bu süreçte kurumsallaşma gerçekleşir, şirketin güven ve itibarı yükselir, hisse karı ile farklı şirketlere yatırım yapılarak kar katlanabilir. Öte yandan mecburi olarak şirket hakkında genel bilgilerin verildiği platformlarda şirketin isminin geçiyor olması dahi ücretsiz bir reklamdır ve geri dönüşler olması halinde şirkete mutlaka artısı olacağı düşünülmektedir (URL14). Dolayısıyla bu süreç markalaşmayı ve profesyonelleşmeyi de beraberinde getirir.

Dezavantajları ise; hissenin ilk halka arz edildiği dönem içerisinde beklenen talebin görülmemesi ile saygınlık düşüşü ya da olası durum için şirketin düşük değer belirlenmesi ve elde edebileceği karın altında kar elde etmesi, bilgi verilmesi ve onay alınması gereken kişi sayısının artması, süreçlerin daha yavaş ilerlemesi, toplu hisse satışı yapıldığı durumda şirketin zor duruma düşmesi, ekstra raporlama ihtiyacı dolayısıyla zaman kaybı ve bunu karşılamak için alınacak personel dolayısıyla ekstra maliyet şeklindedir (URL15).

3.2.4. Türk Futbol Kulüplerinin Halka Arzı

Rekabet ve hızlı büyüme dolayısıyla yapılan eksik araştırmalar, yanlış gelir-gider hesapları, plansız harcamalar ve benzeri sebeplerin yanı sıra finansal açıdan süreklilik sağlama isteği, ulusal ve uluslararası alanda ses getirmek amaçlı ekstra ihtiyaçlar, gelir artışı sağlamak için uygulanması gereken projeler gibi nice sebeplerden ötürü şirketlerin büyük borçlar altına girmesi kaçınılmaz hale gelmiştir (Durmaz, 2019).

Bu noktada gelirlerin giderleri sağlayamaması dolayısıyla batma eşiğine gelen şirketler bu durumdan kurtulabilmek için diğer ülkelerde uygulanan ve çoğunlukla başarılı sonuçlar doğuran halka arz yöntemini kullanmışlardır. Bu yöntem şirketlerin borçlarının önemli bir kısmının kapatılmasına olanak sağlarken profesyonelleşmeyi de beraberinde getirmiştir.

Ülkemizde 2001 yılından bu yana çok sayıda kulüp şirketleşme sürecine dahil olsa da yalnızca dört büyük spor kulübü hisselerinin belirli kısımlarını halka arz etmişlerdir. Bu noktada; Borsa İstanbul verilerine göre ilk halka arz edilen kulüp; Beşiktaş Jimnastik Kulübü'dür. Ardından ise Galatasaray Spor Kulübü, Fenerbahçe Spor Kulübü ve Trabzonspor Spor Kulübü gelmektedir. Şirketlerin halka arz süreçleri sırasıyla incelendiğinde süreç hakkındaki bilgiler şu şekilde özetlenebilir:

Beşiktaş Jimnastik Kulübü (BJK), 1995 yılında logosunu barından ürünlerinin satışını derneğe bağlı şirket üzerinden sağlama kararı almıştır. Karar sonrasında, %99.9'u derneğe ait olmak üzere Beşiktaş Jimnastik Kulübü Spor Malzemeleri A.Ş.'nin açılışını gerçekleştirmiştir. Ardından 14-15 Şubat 2002 tarihlerinde hisselerinin %15'inin halka arz edilmesiyle birlikte şirket adı "Beşiktaş Futbol Yatırımları Sanayi ve Ticaret A.Ş." olarak güncellenmiştir. Halka arz sürecinde sermaye artırım yöntemi ile 326.500.000 adet hisse sunulurken, hisseye 57 TL'lik değer biçilmiştir. Halka arz süreci sonunda ana sermayesi 1.85 trilyon dolar olan BJK yaklaşık 14 milyon dolarlık bir gelir elde ederken şirket ve dernek arasında bir sözleşme imzalanmıştır. Sözleşme içeriği, Beşiktaş'a ait bütün gelir ve giderler şirkete devredilirken, her yıl elde edilen gelirin %5'inin derneğe ödenmesine yöneliktir. Bunun için ek husus olarak bu ödemenin, belirlenen tutarın dışına çıkılmamak koşuluyla, 1-2 milyon dolar aralığında

yapılması gerektiği belirtilmiştir. Ayrıca gelir-giderlerinin tamamını şirkete devreden tek kulüp BJK'dir (URL16, Sevim ve Güven, 2015).

Galatasaray Spor Kulübü (GS), 1997 yılında pazarlama ve yönetim haklarına sahip olan Galatasaray Sportif Sınai ve Ticari Yatırımlar A.Ş.'yi kurmuştur. Şirket, 14-15 Şubat 2002 tarihlerinde, %78.93'ü derneğine ait olan hisselerinin %16'sını halka arz etmiştir. Halka arz sürecinde, sabit fiyatla talep toplama yöntemi ile 325.600 adet hisse sunulurken, hisseye 87 TL'lik değer biçilmiştir. Halka arz süreci sonunda 20.799 milyon dolarlık gelir elde edilmiştir. Öte yandan alınan kararla birlikte elde edilen gelirlerin şirket hesabında, giderlerin ise dernek hesabında tutulması istenmiştir (Sevim ve Güven, 2015).

Fenerbahçe Spor Kulübü (FB), 1998 yılında bütün ticari faaliyetler ve yatırımlarını sürdürmek üzere Fenerbahçe Sportif Hizmetler Sanayi ve Ticaret A.Ş.'yi kurmuştur. Şirket, 6 yıl boyunca spora yönelik araç gereçlerin alım, satım, bakım ve onarımıyla ilgilenirken 2002 yılı sonrasında profesyonel takıma yönelik ticari, ekonomik ve hukuki süreçlerin tamamı ya da büyük bir kısmının yönetimini üstlenmiştir. Ardından şirket, 12-13-16 Şubat 2004 tarihlerinde, hisselerinin %15'ini halka arz etmiştir. Halka arz sürecinde, sabit fiyatla talep toplama yöntemi ile başlangıçta 375.000 ve ardından 596.147 adet hisse sunulurken, hisseye 10.5 TL'lik değer biçilmiştir. Halka arz süreci sonunda 30.030 milyon dolarlık gelir elde edilmiştir. Yakın dönemde belirlenen hisse adedine 4 katı talep görmesiyle dikkat çeken şirket beklentinin üzerinde gelir sağlamıştır. Ayrıca, FB ve şirket arasında oluşturulan, Lisans Kiralama Sözleşmesi dahilinde FB haklarını 30 yıllık süreçte şirkete devretmiştir. Bu devir, Galatasaray sisteminde olduğu gibi elde edilen gelirlerin şirket hesabında, giderlerin ise dernek hesabında tutulmasına yöneliktir (Akşar, 2005, Aydın vd., 2007, Fenerbahçe Sportif A.Ş. Halka Arz İzahnamesi, 2004, URL17).

Son olarak Trabzonspor Kulübü (TS), 1994 yılında ticari faaliyetlerini sürdürmek üzere, Trabzonspor Futbol İşletmeciliği Ticaret A.Ş.'yi ve ardından kulüp hisselerinin halka arz edilmesi isteğiyle birlikte bu şirkete bağlı olarak Trabzonspor Sportif A.Ş.'yi kurmuştur. Şirket, 6-8 Nisan 2005 tarihlerinde, mevcut hisselerinin %25'ini halka arz etmiştir. Halka arz sürecinde, sabit fiyatla talep toplama ve bakiyeyi yüklenim yöntemi ile hisseye 5.25 TL'lik değer biçilmiştir. "Halka arz süresince

satılamayan kısmın tamamının, satış sonrasında ödeme yapılarak satın alınmasının taahhüt edilmesi “bakiyeyi yüklenim” olarak adlandırılır.” (URL18). Halka arz süreci sonunda 24.300 milyon dolarlık gelir elde edilmiştir. Öte yandan imzalanan kira ve lisans sözleşmeleri ile kulübe ait marka, sponsorluk ve takım haklarından kaynaklı elde edilecek gelirlerin tamamı 30 yıllık süreç boyunca şirket tarafından kiralanmıştır (Aydın vd., 2007).



3.3. Literatür İncelemesi

Tablo 4. Literatür Tablosu

n	Yazar, Tarih	Özet	Sonuç
1	Devecioğlu (2004)	Makalede, Galatasaray ve Beşiktaş takımlarının 2002/2003 sezonunda spora yönelik başarıları ile hisse senedi fiyatları arasındaki ilişki karşılaştırmalı analizler ile incelenmiştir.	Spora yönelik başarılar ile hisse fiyatları arasında pozitif yönlü ve anlamlı bir ilişki görülmüştür.
2	Loeffelholz vd. (2009)	Makalede, yapay sinir ağları ile Ulusal Basketbol Birliği'nde takımların başarılarını öngörebilmek amacıyla 620 maç verisi kullanılarak, çeşitli sinir ağları eğitilmiştir. Eğitim sırasında sinir ağlarının en belirgin özellikleri alt bilgi olarak sunulmuş, sunulan alt bilgiler için sinyal oranları ve uzman görüşlerinden yararlanılmıştır.	Yapay sinir ağları ile elde edilen öngörülerin gerçeğe oldukça yakın olduğu sonucuna ulaşılmıştır.
3	Samagaio vd. (2009)	Makalede, faktör analizi ve regresyon analizi ile 1995-2007 yılları arasındaki İngiliz Futbol Kulüpleri maç ve hisse fiyatı verileri kullanılarak değişkenler arasındaki ilişki incelenmiştir.	Sportif başarı ve hisse fiyatları arasında istatistiksel olarak güçlü ve anlamlı bir ilişkinin varlığı tespit edilmiştir.
4	Ivankoviç vd. (2010)	Makalede, 2005-2010 sezon aralığında Sırbistan B Basketbol Ligi verileri kullanılarak 890 maçtan oluşan, doğrusal olmayan spor verileri için ileri beslemeli ağlar yardımıyla analiz yapılmıştır.	Yapay sinir ağları ile elde edilen öngörülerin gerçeğe oldukça yakın olduğu gözlemlenmiştir.

Tablo 5. Literatür Tablosu (Devamı)

n	Yazar, Tarih	Özet	Sonuç
5	Erdoğan ve Özyürek (2012)	Makalede, yapay sinir ağları ile borsada işlem gören beyaz eşya firmalarına yönelik günlük fiyat tahmini yapılmıştır	Elde edilen tahminlerin gerçeğe oldukça yakın olduğu ve bu yöntemin yatırımcıların önemli kazançlar sağlayabilmesi için kullanabilecekleri etkili bir yöntem olduğuna kanaat getirilmiştir.
6	Demirhan (2013)	Makalede, GARCH modeli ile Türk Milli takımının sportif başarısı ve BİST-100 endeksi arasındaki ilişki incelenmiştir.	Galibiyetler ile endeksler arasında etki görülmezken, mağlubiyetler ile endeksler arasında olumsuz etki gözlenmiştir.
7	Bankers (2014)	Tezde, binom testi ile 1993-2014 yılları Brezilya Milli maç verileri ve hisse fiyatları kullanılarak değişkenler arasındaki ilişki analiz edilmiştir.	Maç sonuçları ile hisse fiyatları arasında istatistiksel olarak anlamlı bir ilişki bulunamamıştır. Dolayısıyla maç sonuçlarının hisse fiyatlarını etkilemediği sonucuna ulaşılmıştır.
8	Arabzad vd. (2014)	Makalede, makine öğrenmesi algoritmaları aracılığı ile İran Pro Ligi'ne ait son 7 sezonluk maç verileri kullanılarak 2013-2014 sezonu için 1 haftalık öngörü yapılmıştır.	Yapay sinir ağlarının öngörü konusunda oldukça yetenekli olduğu gözlemlenmiştir.
9	Çalışkan ve Deniz (2015)	Makalede, yapay sinir ağları ile BİST-30 endeksi içerisinde yer alan 30 hisse senedinin günlük fiyatları ve yönleri tahmin edilmiştir.	Fiyatlara ilişkin yönün %58 oranında doğru tahmin edildiği ve ortalama mutlak yüzdelik hatanın %1.8 olduğu görülmüştür.

Tablo 6. Literatür Tablosu (Devamı)

n	Yazar, Tarih	Özet	Sonuç
10	Elsaid (2016)	Tezde, Tekrarlayan Sinir Ağı mimarisi olan Uzun-Kısa Süreli Bellek Modeli kullanılarak uçak motorlarında oluşan 1, 5, 10 ve 20 saniyelik titreşim sayısını tahmin etmek amaçlanmıştır.	Elde edilen hata oranlarının sırasıyla %2.84- %10.19 aralığında olduğu görülürken öngörü yapılması halinde uçuş esnasında yaşanacak olumsuzlukların önceden raporlanacağına dair umut olduğu sonucuna ulaşılmıştır.
11	Özçalıcı (2016)	Makalede, yapay sinir ağları ile 5 yılı kapsayan BIST-30 endeksi verileri kullanılarak 1,2 ve 20 günlük öngörü yapılmıştır.	%72.88 oranında doğru öngörülerin elde edildiği görülmüştür. Ayrıca, yapay sinir ağları ile 20 gün önceden doğru tahmine ulaşmanın mümkün olduğu yorumu yapılmıştır.
12	Ektik (2017)	Makalede, dört büyük takımın derbi maçlarında elde ettikleri puanlar ile hisse senedi getirileri arasındaki ilişki GARCH analizi ile incelenmiştir.	Yalnızca Fenerbahçe için hem mağlubiyet hem de galibiyette pozitif yönlü bir ilişki görülürken diğer üç takımda sadece mağlubiyette pozitif yönlü bir ilişki görülmüş ya da iki durum için de ilişki görülememiştir.
13	Petterson ve Nyquist (2017)	Tezde, Tekrarlayan Sinir Ağları'nın özel bir türü olan Uzun-Kısa Süreli Bellek Modeli kullanılarak turnuva maç verileri ile galibiyete yönelik sınıflandırma ve tahmin yapılmıştır.	Kullanılan yöntem ile %98.63 doğruluk oranına sahip oldukça başarılı tahminler elde edilmiştir.

Tablo 7. Literatür Tablosu (Devamı)

n.	Yazar, Tarih	Özet	Sonuç
14	Ayyıldız (2018)	Makalede, yapay sinir ağları ile 2015-2016 sezonu NBA maç verileri kullanılarak takımların galibiyetleri için öngörü yapılmıştır.	Yapay sinir ağları %90 başarı performansında öngöründe bulunmuştur.
15	Karakoyun (2018)	Tezde, Tekrarlayan Sinir Ağı mimarisi olan Uzun-Kısa Süreli Bellek Modeli ve ARIMA yaklaşımları ile hisse senetleri ve Bitcoin'e ilişkin fiyat öngörüsü yapılmıştır.	Yapılan karşılaştırmada Uzun-Kısa Süreli Bellek Modeli ile elde edilen öngörülerin belirgin oranda daha başarılı sonuçlar verdiği görülmüştür.
16	Song (2018)	Tezde, dört farklı makine öğrenmesi algoritması ile yirmi popüler hisse senedine ilişkin teknik endeks verileri girdi olarak kullanılarak fiyat tahmini yapılmıştır.	Diğer yöntemlerin doğruluk oranlarından en az %5 oranında daha fazla doğruluk oranına sahip olduğu için en iyi tahmin Tekrarlayan Sinir Ağları ile gerçekleştirilmiştir.
17	Botoc vd. (2019)	Makalede, GARCH modeli ile 2017-2018 yıllarında İtalyan Borsası'nda yer alan futbol şirketleri ele alınarak spor başarısı ve hisse fiyatlarına yönelik duyarlılık analiz edilmiştir.	Maç sonuçlarının hisse fiyatlarına karşı duyarlılığı olduğu sonucuna ulaşılmıştır.

Tablo 8. Literatür Tablosu (Devamı)

n.	Yazar, Tarih	Özet	Sonuç
18	Tuna (2019)	Tezde, yapay sinir ağları ve ARIMA yaklaşımları ile 2009-2019 yılları aralığında yer alan altın fiyatları verileri kullanılarak tahmin yapılmıştır.	Her iki yaklaşımda da tahmin edilen değerler gerçek değerlere oldukça yakındır.
19	Turan (2019)	Tezde, Tekrarlayan Sinir Ağı mimarisi olan Uzun-Kısa Süreli Bellek Modeli ve geçitli tekrarlayan birim aracılığı ile 2001-2018 yılları arasında BIST-100 endeksine ait günlük kapanış değerleri kullanılarak finansal piyasalarda karşılaştırmalı fiyat öngörüsü yapılmıştır.	Yapılan karşılaştırılmada geçitli tekrarlayan birim yönteminin daha başarılı sonuçlar verdiği görülmüştür.
20	Aliaksandr (2020)	Tezde, Tekrarlayan Sinir Ağı mimarisi olan Uzun-Kısa Süreli Bellek Modeli ve yalnızca ileri beslemeli sinir ağı modeli kullanılarak gerçek zamanlı futbol maç puanı tahmini yapılmıştır.	Tahminler karşılaştırıldığında %54 ile başlayan performans başarısının Tekrarlayan Sinir Ağı ile %90'a yalnızca ileri beslemeli sinir ağı modeli ile ise %93.54'e yükseldiği görülmüştür.
21	Busalini (2020)	Tezde, regresyon analizi ile 2000-2012 yılları arasında farklı dönemler ele alınmak üzere Manchester United, Juventus, Borussia Dortmund ve AS Roma takımları için futbol maçı sonuçları ve hisse fiyatları arasındaki ilişki incelenmiştir.	Manchester United için maç sonuçları, hisse fiyatlarını istatistiksel olarak etkilemezken diğer takımlar için maç sonuçlarının hisse fiyatlarını önemli ölçüde etkilediği görülmüştür

Tablo 9. Literatür Tablosu (Devamı)

n.	Yazar, Tarih	Özet	Sonuç
22	Galloppo ve Boido (2020)	Makalede, borsada yer alan 25 farklı futbol şirketi ele alınarak 2003-2015 yılları arasında oynanan kupa maçları için atılan gol sayısı, lig sıralaması ve hisse fiyatları arasındaki ilişki analiz edilmiştir.	Gol sayısı-hisse fiyatları ve lig sıralaması-hisse fiyatları arasında istatistiksel olarak anlamlı bir ilişki olduğu görülmüştür.
23	Moghar ve Hamiche (2020)	Makalede, Tekrarlayan Sinir Ağı mimarisi olan Uzun-Kısa Süreli Bellek Modeli ile anormal piyasa getirilerini esas alan veriler için öngörü yapılmıştır.	Burada önemli olan temel etkenlerden birisinin de "uzunluk ve tekrar sayısı" belirleme olduğu gözlemlenerek başarılı öngörüler yapılmıştır.
24	Tiwari vd. (2020)	Bildiride, Tekrarlayan Sinir Ağı mimarisi olan Uzun-Kısa Süreli Bellek Modeli ile 2011-2018 sezon aralığında oynanan İngiltere Premier Ligi'ne ait maç verileri kullanılarak tahmin yapılmıştır. Yapılan tahminler klasik yapay sinir ağları ile karşılaştırılmıştır.	Tahminlere yönelik klasik yapay sinir ağları ile elde edilen en yüksek doğruluk oranı %68.8 iken Tekrarlayan Sinir Ağları ile bu oranın %80.75 olduğu görülmüştür.
25	Tsiaras (2020)	Tezde, Tekrarlayan Sinir Ağı mimarisi olan Uzun-Kısa Süreli Bellek Modeli ile 2013-2019 yılları arasında Atina Menkul Kıymetler Borsası'nda yer alan hisse senedi verileri kullanılarak öngörü yapılmıştır.	0.0010 gibi düşük hata oranlarıyla başarılı sonuçlar elde edilmiştir. Ayrıca, Uzun-Kısa Süreli Bellek Modeli'nin tahmin çalışmaları için elverişli olduğu ve hatta birkaç dönemlik öngörülerde kullanılabileceği yorumu yapılmıştır.

4. BÖLÜM

UYGULAMA

Tekrarlayan Sinir Ağları, tanımlanan verilerin ardışık özelliklerini benimseyerek olası durumların tahmini ve öngörüsü için kullanılan sinir ağı türüdür. Bilginin iki yönlü işlenmesine olanak sağlar ve ileri beslemeli sinir ağlarında olduğu gibi ilk girişin ardından bilgileri işleme süreci başlamış olur. Bilgiyi ağı tekraren döndürebilmek için geri besleme döngülerini kullanır. Bu durum ise ardışık ve zamansal içerikli verilerin işlenmesi, tahmin edilmesi ve yorumlanabilmesi için imkan sağlar. Standart Tekrarlayan Sinir Ağları'nın en belirgin dezavantajı; gradyan problemi sebebiyle oluşan performans düşüklüğüdür. Bu sorunun önüne geçebilmek için Tekrarlayan Sinir Ağları'nın özel bir türü olarak Uzun-Kısa Süreli Bellek Modeli geliştirilmiştir. Bu modelin sağladığı en büyük avantaj unutulacak ve hatırlanacak bilgiyi tespit etmesi ve önemli bilgileri ağı geri yayarak tahmini güçlendirmesidir.

Tez kapsamında ilk olarak değişkenler arasındaki ilişki Toda-Yamamoto Nedensellik Analizi ile araştırılmış, tahmin ve öngörüler ise Uzun-Kısa Süreli Bellek Modeli ile elde edilmiştir. dört büyük spor kulübüne ilişkin 2006/07-2020/21 sezon aralığını kapsayan, toplamda 518 haftalık maç verisi ve 3859 günlük hisse senedi fiyatı verisinden oluşan, 15 sezonluk veri seti ele alınmıştır. Uygulama sırasında ilk aşamada 4 sezonu kapsayan puan, hisse senedi açılış ve hisse senedi kapanış fiyatı verileri kullanılarak nedensellik analizi yapılmıştır. Ardından, 15 sezonu kapsayan maç verileri ile puan tahmini ve bu sezonlardaki hisse senedi kapanış fiyatı verileri ile hisse senedi öngörüsü yapılarak yönteme yönelik performans incelenmiştir. Tahmin ve öngörülerin elde edilmesinde ve grafiklerin oluşturulmasında Python programı kullanılmıştır. Uygulamada kullanılan veri setinin detayları aşağıda açıklanmıştır.

4.1. Veri Seti

2006-2021 yılları arasında Futbol Süper Ligi'nde yer alan dört büyük spor kulübü; Beşiktaş, Fenerbahçe, Galatasaray ve Trabzonspor tarafından haftalık olarak oynanan ve toplam 15 sezonu kapsayan maç verileri ele alınmıştır. Veri setinin %80'i eğitim ve

%20'si test verisi olarak belirlenmekle birlikte her bir takım için “sıralama, galibiyet, beraberlik, mağlubiyet, atılan gol sayısı, yenilen gol sayısı, averaj sayısı, puan ve dummy (puana göre galibiyet=1, puana göre beraberlik ve mağlubiyet=0)” başlıklı, 518'er gözlemlili, 9 değişkenden oluşmaktadır. Ele alınan veriler Türkiye Futbol Federasyonu resmi sitesinden temin edilmiştir.

Daha sonra, 2006-2021 yılları arasında günlük olarak gözlemlenen Borsa İstanbul A.Ş.'de işlem gören; Beşiktaş Futbol Yatırımları Sanayi ve Ticaret A.Ş.(BJKAS), Fenerbahçe Futbol A.Ş.(FENER), Galatasaray Sportif Sınai ve Ticari Yatırımlar A.Ş.(GSRAY) ve Trabzonspor Sportif Yatırım ve Futbol İşletmeciliği Ticaret A.Ş.(TSPOR)'ye ait hisse senedi verileri ele alınmıştır. Veri setinin %80'i eğitim ve %20'si test verisi olarak belirlenmekle birlikte “hisse senedi açılış fiyatı” ve “hisse senedi kapanış fiyatı” başlıklı, 3859'ar gözlemden oluşmaktadır. Ele alınan veriler investing.com internet sitesinden temin edilmiştir. Değişkenlere ilişkin isimlendirmeler ve gözlem sayıları şu şekildedir:

Tablo 10. Değişkenlere İlişkin İsimlendirmeler ve Gözlem Sayıları

Değişkenler	Gözlem Sayıları
<i>S</i> (Sıralama)	518
<i>G</i> (Galibiyet)	518
<i>B</i> (Beraberlik)	518
<i>M</i> (Mağlubiyet)	518
<i>A</i> (Atılan Gol Sayısı)	518
<i>Y</i> (Yenilen Gol Sayısı)	518
<i>AV</i> (Averaj)	518
<i>P</i> (Puan)	518
<i>d</i> (Dummy)	518
<i>acilis</i> (Hisse Senedi Açılış Değeri)	3859
<i>kapanis</i> (Hisse Senedi Kapanış Değeri)	3859

4.2. İstatistiksel Karşılaştırmalar

İstatistiksel karşılaştırmalar ile puanlar ve hisse senedi fiyatlarının ilişkili olabileceği düşüncesinin geçerliliğini ortaya koymak amaçlanmıştır. Korelasyon Analizi ve Toda-Yamamoto Nedensellik Analizi yapılarak ilgili hipotezler sınanmıştır.

4.2.1. Korelasyon Analizi

Bu bölümde; spor kulüplerinin puan, hisse senedi açılış ve hisse senedi kapanış fiyatlarına ilişkin veriler ele alınmıştır. Bu süreçte, hisse senedi verileri; kapanış için maç günlerine karşılık gelen değerler ve açılış için maç günlerinden bir gün sonraya karşılık gelen değerlerinden oluşmak üzere düzenlenmiştir. Bu noktada hafta sonu ve resmi tatillerde oynanan maç günlerinde hisse değerlerinin olmayışı göz önünde bulundurulmuş ve bir sonraki günün değeri esas alınmıştır. Ayrıca, ele alınan değişkenlere ait veriler ilk aşamada, pandemi dönemi öncesi ve pandemi dönemi olmak üzere iki gruba ayrılmıştır. Bu ayrımın sebebi şu şekilde açıklanmıştır: Pandemi dönemiyle birlikte gelen sokağa çıkma yasakları bireyleri aktivite arayışına itmiştir. Pek çok kişi için ilk tercih; internet ve televizyon aracılığıyla eski yayınları verilen diziler, filmler ya da maçlardan yana olmuştur. Aynı zamanda bu süreç içerisinde özellikle kısa ya da uzun vadeli yatırım yapmak amacıyla borsada işlem yapan bireylerin sayısının da azımsanamayacak düzeyde arttığı düşünülmüştür. Bu düşünce doğrultusunda Borsa İstanbul A.Ş.'de işlem gören sektörlere ilişkin genel bir inceleme yapılmış ve pandemi döneminde bireylerin borsaya yöneliminde artış olsa dahi çok sayıda sektörün bu süreçten olumsuz yönde etkilendiği görülmüştür. Ayrıca, benzer içeriği konu alan bir araştırmada pandemi sürecinde salgının çıkış noktası olan Çin Borsası'nda genel olarak sektörler üzerinde olumsuz bir etki görülmezken Türkiye borsalarında görülen olumsuz etki ilgi çekmiştir (Peker ve Demirhan, 2020). Dolayısıyla konu detaylandırılmış ve literatürde; Türkiye'de pandemi döneminde olumlu yönde en fazla etkilenen sektörlerin sağlık ve gıda sektörü olduğu aşikar olmak üzere bu dönemden olumsuz yönde en fazla etkilenen sektörlerin turizm ve ulaşım sektörleri olduğu görülmüştür. Bu sektörler beraberinde ertelenen ya da iptal edilen maçlardan kaynaklı olarak spor sektörünü de getirmiştir (Gümüş ve Hacıevliyagil, 2020). Süreç detaylı olarak incelendiğinde, önlemler dahilinde ertelenen maçların yeniden oynanmasıyla birlikte oluşan olumsuz etkinin normal seyrine döndüğü hatta belirgin düzeyde artış gösterdiği kanısına varılmıştır.

Bu bölümde değişkenler arasındaki ilişkinin daha net bir şekilde ifade edilmesi amaçlanarak oluşan normalleşmenin ya da artışın, verilen aranın ardından dinlenmiş bir şekilde tekrar sahalara dönen takımların performansından kaynaklandığı düşünülmektedir. Dolayısıyla ilerleyen bölümlerde tahmin ve öngörü çalışmaları


yapmadan önce bu düşünce üzerinde durularak puan, hisse senedi açılış fiyatı ve hisse senedi kapanış fiyatı değişkenleri arasındaki ilişkinin yönü ve büyüklüğü incelenmiştir. Bu süreçte, her bir sezonda elde edilen puanlar ve şampiyonluk beklentileri farklı olduğu için sezonlar ayrı ayrı analiz edilmiştir. Aynı zamanda süreç içerisinde pandeminin payını görebilmek adına pandemi öncesi dönem ve pandemi dönemine ait veriler ile karşılaştırma yapılmıştır.

Son olarak, veriler için gruplar arası ayrım sırasında, Türkiye’de ilk korona virüs vakasının 11.03.2020 tarihinde görüldüğü ve korona virüsün Türkiye geneline yayılımının 01.04.2020 tarihinde gerçekleştiği bilgisi göz önünde bulundurulmuştur. Bu nedenle, pandemi dönemi öncesi grubunun “2017-2018 ve 2018-2019” sezonlarından ve pandemi dönemi grubunun “2019-2020 ve 2020-2021” sezonlarından oluşmasına karar verilerek, Korelasyon Analizi yapılmıştır. Analiz süresince;

$$H_0 : \rho = 0 \text{ (Değişkenler arasında doğrusal ilişki yoktur.)}$$


$$H_1 : \rho \neq 0 \text{ (Değişkenler arasında doğrusal ilişki vardır.)}$$

hipotezleri esas alınmıştır. Puan değişkeni ile açılış ve kapanış değişkenleri arasındaki ilişkinin incelendiği Korelasyon Analizi sonuçları şu şekildedir:




Şekil 12. Beşiktaş Jimnastik Kulübü'ne Ait Puan ve Hisse Senedi Verileri Arasındaki İlişki

Beşiktaş için; pandemi dönemi öncesinde, değişkenler arasında var olan pozitif yönlü ilişki, pandemi dönemi süresince de pozitif yönünü korumuş ve güçlü bir ilişkiye dönüşmüştür.




Şekil 13. Fenerbahçe Spor Kulübü’ne Ait Puan ve Hisse Senedi Verileri Arasındaki İlişki

Fenerbahçe için; pandemi dönemi öncesinde, ilk sezonda değişkenler arasında var olan negatif yönlü ve orta düzeyde ilişki, bir sonraki sezonda ilişkisiz hale gelmiş ardından ise pandemi dönemiyle birlikte tekrar negatif yönünü koruyarak zayıf bir ilişkiye dönüşmüştür.



Şekil 14. Galatasaray Spor Kulübü'ne Ait Puan ve Hisse Senedi Verileri Arasındaki İlişki

Galatasaray için; pandemi dönemi öncesinde, değişkenler arasında var olan pozitif yönlü ve orta düzeyde ilişki, pandemi döneminin ilk sezonuna kadar pozitif yönünü korumuş ve artarak güçlü hale gelmiştir. Ardından ise son sezonda negatif yönlü ve orta düzeyde ilişkiye dönüşmüştür.



Şekil 15. Trabzonspor Spor Kulübü'ne Ait Puan ve Hisse Senedi Verileri Arasındaki İlişki

Trabzonspor için; pandemi dönemi öncesinde, değişkenler arasında var olan pozitif yönlü ve zayıf ilişki, pandemi döneminin ilk sezonuna kadar pozitif yönünü korumuş ve artarak güçlü hale gelmiştir. Ardından ise son sezonda negatif yönlü ve güçlü ilişkiye dönüşmüştür.

Ayrıca, yukarıdaki şekiller ilişki bazında bir bütün olarak incelendiğinde diğer takımlara nazaran pandemi dönemi süresince yalnızca Beşiktaş için pozitif yönlü ve güçlü ilişki görülmüştür. Bu noktada, 4 sezonluk süreçte Beşiktaş'ın lig sonu sıralamalarının; 4., 3., 3., 1. şeklinde olduğu göz önünde bulundurulduğunda, takım performansında görülen artış, takımın ligde üst sıralara ilerlemesi ve olası şampiyonluk beklentisinin Beşiktaş için puan ve hisse senedi fiyatları arasındaki ilişkiyi güçlendirdiği açıkça görülmüştür.

Beşiktaş'tan sonra puan ve hisse senedi fiyatları arasındaki artarak güçlenen ilişkin en net görüldüğü bir diğer takım olan Trabzonspor'un, 4 sezonluk süreçte lig sonu sıralamalarının 5., 4., 2., 4. olduğu göz önünde bulundurulduğunda, Beşiktaş'ta olduğu gibi, takımın ligde üst sıralara ilerlemesi ve benzeri sebeplerin Trabzonspor için puan ve hisse senedi fiyatları arasındaki ilişkiyi güçlendirdiği açıkça görülmüştür. Buna nazaran, son sezonda değişkenler arasındaki ilişkinin güç düzeyi artarken, negatif yönlü bir ilişkiye dönüşmesinin sebebinin, takımın 2. sıradan 4. sıraya gerilemesinden kaynaklı olarak taraftarın verdiği psikolojik bir tepki olduğu düşünülmektedir.

Ek olarak, Fenerbahçe ve Galatasaray için 4 sezonluk süreçte lig sonu sıralamalarının sırasıyla 2., 6., 7., 3. ve 1., 1., 6., 2. olduğu göz önünde bulundurulduğunda pandemi dönemi öncesi süresince Beşiktaş ve Trabzonspor'da olduğu gibi, takımların ligde üst sıralara ilerlemesi ve benzeri sebeplerin puan ve hisse senedi fiyatları arasındaki ilişkiyi güçlendirdiği görülürken, pandemi dönemi süresince bahsedilen ilişkinin takım performansından bağımsız olarak değiştiği gözlemlenmiştir. Bu durumda, takımın lig sonu sıralamasının önceki sezona nazaran düştüğü halde değişkenler arasındaki ilişkinin artması; taraftar desteğinin güçlü olmasından ya da takımın lig sonu sıralamasının önceki sezona nazaran yükseldiği halde değişkenler arasındaki ilişkinin azalması; taraftarın, takımdan beklediği başarıyı elde edememesinden kaynaklandığı düşünülmektedir.

Sonuç olarak, özellikle Beşiktaş ve Trabzonspor başta olmak üzere puan durumunun hisse senedi fiyatları ile ilişkili olduğu ve elde edilen bu sonucun çalışma öncesinde ifade edilen düşüncüyü desteklediği görülmüştür. Ek olarak, ilişki katsayılarına ait olasılık değerleri incelenmiştir ve elde edilen sonuçlar aşağıdaki tabloda verilmiştir.

Tablo 11. İlişki Katsayılarına Ait Olasılık Değerleri

		Pandemi Dönemi Öncesi						Pandemi Dönemi					
		2017-2018			2018-2019			2019-2020			2020-2021		
	Olasılık Değerleri	Puan	Açılış	Kapanış	Puan	Açılış	Kapanış	Puan	Açılış	Kapanış	Puan	Açılış	Kapanış
Beşiktaş	Puan	-			-			-			-		
	Açılış	*0.0000	-		*0.0000	-		*0.0000	-		*0.0000	-	
	Kapanış	*0.0000	*0.0000	-	*0.0000	*0.0000	-	*0.0000	*0.0000	-	*0.0000	*0.0000	-
Fenerbahçe	Olasılık Değerleri	Puan	Açılış	Kapanış	Puan	Açılış	Kapanış	Puan	Açılış	Kapanış	Puan	Açılış	Kapanış
	Puan	-			-			-			-		
	Açılış	*0.0001	-		*0.0003	-		0.2562	-		*0.0164	-	
	Kapanış	*0.0001	*0.0000	-	*0.0001	*0.0000	-	0.3557	*0.0000	-	*0.0067	*0.0000	-
Galatasaray	Olasılık Değerleri	Puan	Açılış	Kapanış	Puan	Açılış	Kapanış	Puan	Açılış	Kapanış	Puan	Açılış	Kapanış
	Puan	-			-			-			-		
	Açılış	*0.0010	-		0.0610	-		*0.0000	-		*0.0004	-	
	Kapanış	*0.0005	*0.0000	-	0.1858	*0.0000	-	*0.0000	*0.0000	-	*0.0001	*0.0000	-
Trabzonspor	Olasılık Değerleri	Puan	Açılış	Kapanış	Puan	Açılış	Kapanış	Puan	Açılış	Kapanış	Puan	Açılış	Kapanış
	Puan	-			-			-			-		
	Açılış	0.0930	-		*0.0012	-		*0.0000	-		*0.0000	-	
	Kapanış	0.0858	*0.0000	-	*0.0004	*0.0000	-	*0.0000	*0.0000	-	*0.0000	*0.0000	-
$\alpha = 0.05$ kabul edilmiştir.													

Tablo 6’da, $p=0.05$ değerinden küçük olan olasılık değerleri * ile işaretlenmiştir.

Beşiktaş için her iki dönemde de elde edilen bütün olasılık değerleri, $\alpha=0.05$ değerinden küçük olduğu için H_0 hipotezi %5 anlamlılık düzeyinde reddedilir. Dolayısıyla, 2017/18-2020/21 sezon aralığında değişkenler arasında istatistiksel olarak anlamlı bir ilişki vardır diyebiliriz.

Fenerbahçe için pandemi dönemi öncesine ve pandemi döneminin ikinci sezonuna ait elde edilen bütün olasılık değerleri $\alpha=0.05$ değerinden küçük olduğu için H_0 hipotezi %5 anlamlılık düzeyinde reddedilir. Dolayısıyla 2017/18, 2018/19 ve 2020/21 sezonlarında değişkenler arasında istatistiksel olarak anlamlı bir ilişki vardır diyebiliriz. Buna karşılık pandemi döneminin ilk sezonunda “puan ve açılış” ve “puan ve kapanış”a ait elde edilen olasılık değerleri, $\alpha=0.05$ değerinden büyük olduğu için H_0 hipotezi %5 anlamlılık düzeyinde reddedilemez. Dolayısıyla 2019/20 sezonunda değişkenler arasında istatistiksel olarak anlamlı bir ilişki olmadığı görülmektedir.

Galatasaray için pandemi dönemi öncesinde, ikinci sezonda “puan ve açılış” ve “puan ve kapanış” değişkenlerine ait elde edilen olasılık değeri $\alpha=0.05$ değerinden büyük olduğu için H_0 hipotezi %5 anlamlılık düzeyinde reddedilemez. Dolayısıyla 2018/19 sezonunda bu değişkenler arasında istatistiksel olarak anlamlı bir ilişki yoktur. Buna nazaran, bu değişkenler haricinde, her iki dönemde de elde edilen bütün olasılık değerleri, $\alpha=0.05$ değerinden küçük olduğu için H_0 hipotezi %5 anlamlılık düzeyinde reddedilir. Dolayısıyla, 2017/18-2020/21 sezon aralığında değişkenler arasında istatistiksel olarak anlamlı bir ilişki varlığı belirlenmiştir.

Trabzonspor için pandemi dönemi öncesinde, ilk sezonda “puan ve açılış” ve “puan ve kapanış” değişkenlerine ait elde edilen olasılık değeri $\alpha=0.05$ değerinden büyük olduğu için H_0 hipotezi %5 anlamlılık düzeyinde reddedilemez. Dolayısıyla 2017/18 sezonunda bu değişkenler arasında istatistiksel olarak anlamlı bir ilişki yoktur diyebiliriz. Bu değişkenler haricinde, her iki dönemde de elde edilen bütün olasılık değerleri, $\alpha=0.05$ değerinden küçük olduğu için H_0 hipotezi %5 anlamlılık düzeyinde reddedilir. Dolayısıyla, 2018/19-2020/21 sezon aralığında değişkenler arasında istatistiksel olarak anlamlı bir ilişki vardır denir.

4.2.2. Toda-Yamamoto Nedensellik Analizi

Bu bölümde; spor kulüplerinin puan, hisse senedi açılış ve hisse senedi kapanış fiyatları kullanılarak nedensellik analizi yapılmıştır. İlk aşamada bütün olarak nedensellik ilişkisini görebilmek adına 2006/07-2020/21 sezon aralığını kapsayan toplamda 15 sezondan oluşan veriler için tüm sezonlar ele alınarak nedensellik analizi yapılmış ve anlamlı bir nedensellik ilişkisi görülmemiştir. Ardından, pandemi döneminin bu nedensellik ilişkileri üzerindeki etkisinin gözlemlenmesi amacıyla; takımların lig sıralamaları da göz önünde bulundurularak 2017/18-2020/21 sezon aralığını kapsayan toplamda dört sezonluk veri kullanılmıştır. Veriler pandemi dönemi ve pandemi dönemi öncesi olmak üzere ikiye sezonluk gruplara ayrılmıştır ve her bir sezon için analiz yapılmıştır. Bu sayede değişkenler arasındaki sezonluk nedensellik ilişkisi ile birlikte pandemi döneminin etkisi de incelenmiştir. Burada pandemi dönemi etkisi olarak belirtilen durum, bu süreçte borsaya giren yatırımcı sayısının artması ile birlikte sezon maçlarındaki beklentilerin takımın hisse senedi fiyatına yansımalarıdır. Analiz süresince,

$$H_0 : \rho = 0 \text{ (Değişkenler arasında nedensellik ilişkisi yoktur.)}$$

$$H_1 : \rho \neq 0 \text{ (Değişkenler arasında nedensellik ilişkisi vardır.)}$$

hipotezleri esas alınmış ve aşağıdaki sonuçlar elde edilmiştir. (Tablolarda $p=0.05$ değerinden küçük olan olasılık değerleri * ile işaretlenmiştir.)

Tablo 7’de Beşiktaş Kulübü verileri için araştırılan dönemlere ait nedensellik test sonuçları verilmiştir.

Tablo 12. Beşiktaş Jimnastik Kulübü'ne Ait Toda-Yamamoto Nedensellik Analizi Sonuçları

BEŞİKTAŞ							
Pandemi Dönemi Öncesi							
2017-2018				2018-2019			
Lig Sırası		4		Lig Sırası		3	
Değişkenler	Ki-kare	Gecikme Uzunluğu	Olasılık Değeri	Değişkenler	Ki-kare	Gecikme Uzunluğu	Olasılık Değeri
Puan→Açılış	8.268	2	*0.0160	Puan→Açılış	9.458	1	*0.0021
Puan→Kapanış	6.138	2	*0.0464	Puan→Kapanış	8.925	1	*0.0028
Pandemi Dönemi							
2019-2020				2020-2021			
Lig Sırası		3		Lig Sırası		1	
Değişkenler	Ki-kare	Gecikme Uzunluğu	Olasılık Değeri	Değişkenler	Ki-kare	Gecikme Uzunluğu	Olasılık Değeri
Puan→Açılış	2.931	1	0.0860	Puan→Açılış	2.045	3	0.5630
Puan→Kapanış	1.813	1	0.1780	Puan→Kapanış	4.935	3	0.1760

Tablo 7 incelendiğinde; pandemi dönemi öncesinde, olasılık değerlerinin tamamı $\alpha=0.05$ değerinden küçük olduğu için H_0 hipotezi %5 anlamlılık düzeyinde reddedilir. Dolayısıyla 2017-2018 ve 2018-2019 sezonlarında, puandan açılış fiyatına ve puandan kapanış fiyatına doğru nedensellik ilişkisi olduğu görülmektedir.

Diğer yandan, pandemi dönemi itibarıyla olasılık değerlerinin tamamı $\alpha=0.05$ değerinden büyük olduğu için H_0 hipotezi %5 anlamlılık düzeyinde reddedilemez. Dolayısıyla, 2019-2020 ve 2020-2021 sezonlarında puandan açılış fiyatına ve puandan kapanış fiyatına doğru nedensellik ilişkisi yoktur diyebiliriz.

Tablo 8'de Fenerbahçe Kulübü verileri için araştırılan dönemlere ait nedensellik test sonuçları verilmiştir.

Tablo 13. Fenerbahçe Spor Kulübü'ne Ait Toda-Yamamoto Nedensellik Analizi Sonuçları

FENERBAHÇE							
Pandemi Dönemi Öncesi							
2017-2018				2018-2019			
Lig Sırası		2		Lig Sırası		6	
Değişkenler	Ki-kare	Gecikme Uzunluğu	Olasılık Değeri	Değişkenler	Ki-kare	Gecikme Uzunluğu	Olasılık Değeri
Puan→Açılış	2.775	1	0.0950	Puan→Açılış	2.578	2	0.2750
Puan→Kapanış	2.829	1	0.0920	Puan→Kapanış	1.385	2	0.5010
Pandemi Dönemi							
2019-2020				2020-2021			
Lig Sırası		7		Lig Sırası		3	
Değişkenler	Ki-kare	Gecikme Uzunluğu	Olasılık Değeri	Değişkenler	Ki-kare	Gecikme Uzunluğu	Olasılık Değeri
Puan→Açılış	0.678	1	0.4100	Puan→Açılış	7.080	2	*0.0290
Puan→Kapanış	0.481	1	0.4880	Puan→Kapanış	6.957	2	*0.0308

Tablo 8 incelendiğinde; pandemi dönemi öncesinde ve pandemi döneminin ilk sezonunda olasılık değerlerinin tamamı $\alpha=0.05$ değerinden büyük olduğu için H_0 hipotezi %5 anlamlılık düzeyinde reddedilemez. Dolayısıyla, 2017-2018, 2018-2019 ve 2019-2020 sezonlarında puandan açılış fiyatına ve puandan kapanış fiyatına doğru nedensellik ilişkisi yoktur diyebiliriz.

Diğer yandan, pandemi döneminin ikinci sezonunda olasılık değerlerinin tamamı $\alpha=0.05$ değerinden küçük olduğu için H_0 hipotezi %5 anlamlılık düzeyinde reddedilir. Dolayısıyla, 2020-2021 sezonunda puandan açılış fiyatına ve puandan kapanış fiyatına doğru nedensellik ilişkisi olduğu görülmektedir.

Tablo 9'de Galatasaray Spor Kulübü verileri için araştırılan dönemlere ait nedensellik test sonuçları verilmiştir.

Tablo 14. Galatasaray Spor Kulübü'ne Ait Toda-Yamamoto Nedensellik Analizi Sonuçları

GALATASARAY							
Pandemi Dönemi Öncesi							
2017-2018				2018-2019			
Lig Sırası		1		Lig Sırası		1	
Değişkenler	Ki-kare	Gecikme Uzunluğu	Olasılık Değeri	Değişkenler	Ki-kare	Gecikme Uzunluğu	Olasılık Değeri
Puan→Açılış	3.274	1	0.0700	Puan→Açılış	1.153	1	0.2820
Puan→Kapanış	2.598	1	0.1070	Puan→Kapanış	2.447	1	0.1170
Pandemi Dönemi							
2019-2020				2020-2021			
Lig Sırası		6		Lig Sırası		2	
Değişkenler	Ki-kare	Gecikme Uzunluğu	Olasılık Değeri	Değişkenler	Ki-kare	Gecikme Uzunluğu	Olasılık Değeri
Puan→Açılış	0.233	1	0.6290	Puan→Açılış	0.659	1	0.4160
Puan→Kapanış	0.097	1	0.7550	Puan→Kapanış	3.650	1	0.0560

Tablo 9 incelendiğinde; her iki dönemde de olasılık değerlerinin tamamı $\alpha=0.05$ değerinden büyük olduğu için H_0 hipotezi %5 anlamlılık düzeyinde reddedilemez. Dolayısıyla, 2017-2018 ve 2020-2021 sezon aralığında puandan açılış fiyatına ve puandan kapanış fiyatına doğru nedensellik ilişkisi yoktur diyebiliriz.

Tablo 10'da Trabzonspor Kulübü verileri için araştırılan dönemlere ait nedensellik sonuçları verilmiştir.

Tablo 15. Trabzonspor Spor Kulübü'ne Ait Toda-Yamamoto Nedensellik Analizi Sonuçları

TRABZONSPOR							
Pandemi Dönemi Öncesi							
2017-2018				2018-2019			
Lig Sırası		5		Lig Sırası		4	
Değişkenler	Ki-kare	Gecikme Uzunluğu	Olasılık Değeri	Değişkenler	Ki-kare	Gecikme Uzunluğu	Olasılık Değeri
Puan→Açılış	0.834	1	0.3610	Puan→Açılış	2.872	1	0.0900
Puan→Kapanış	3.598	1	0.0570	Puan→Kapanış	3.557	1	0.0590
Pandemi Dönemi							
2019-2020				2020-2021			
Lig Sırası		2		Lig Sırası		4	
Değişkenler	Ki-kare	Gecikme Uzunluğu	Olasılık Değeri	Değişkenler	Ki-kare	Gecikme Uzunluğu	Olasılık Değeri
Puan→Açılış	6.379	2	*0.0411	Puan→Açılış	2.722	2	0.2560
Puan→Kapanış	8.815	2	*0.0121	Puan→Kapanış	4.140	2	0.1260

Tablo 10 incelendiğinde; pandemi dönemi öncesinde ve pandemi döneminin ikinci sezonunda olasılık değerlerinin tamamı $\alpha=0.05$ değerinden büyük olduğu için H_0

hipotezi %5 anlamlılık düzeyinde reddedilemez. Dolayısıyla 2017-2018, 2018-2019 ve 2020-2021 sezonlarında puandan açılış fiyatına ve puandan kapanış fiyatına doğru nedensellik ilişkisi olmadığı görülmektedir.

Diğer yandan, pandemi döneminin ikinci sezonunda olasılık değerlerinin tamamı $\alpha=0.05$ değerinden küçük olduğu için H_0 hipotezi %5 anlamlılık düzeyinde reddedilir. Dolayısıyla, 2020-2021 sezonunda puandan açılış fiyatına ve puandan kapanış fiyatına doğru nedensellik ilişkisi vardır. Ayrıca, takımların tamamı için lig sıralamasının nedensellik üzerinde etkisi olmadığı gözlemlenmektedir.

Konuya ilişkin literatür incelendiğinde; Dobson ve Goddard (2010) makalelerinde, 1946/47-1993/94 sezon aralığında her sezonda liglerde var olan 77 farklı futbol kulübü için performans ve gelir verilerini kullanarak eşbütünleşme ve nedensellik analizleri yapmışlardır. Analizler sonucunda, yalnızca 10 futbol kulübü için değişkenler arasında eşbütünleşme ilişkisi görülürken, 67 futbol kulübü için değişkenler arasında eşbütünleşme ilişkisi görülmemiştir. Öte yandan, performansın gelirin nedeni olup olmadığına dair yapılan nedensellik analizinde, küçük kulüplerde büyük kulüplere oranla daha sık nedensellik ilişkisi tespit etmişlerdir. Çalışkan ve Deniz (2016) makalelerinde, 5 Ağustos 2005-8 Aralık 2014 tarih aralığında Süper Lig’de yer alan dört büyük futbol kulübü tarafından kupa maçları dahil olmak üzere oynanan maçlardan elde edilen puanlar ve hisse senedi fiyatları verilerini kullanarak tek yönlü varyans analizi yapmışlardır. Analiz sonucunda, maç puanına göre hisse senedi fiyatı en fazla etkilenen takımın Beşiktaş ve en az etkilenen takımın ise Galatasaray olduğunu tespit etmişlerdir. Bütün (2019) çalışmasında, 2011/12-2016/17 sezonları arasında Süper Lig’de yer alan 8 farklı futbol takımına ilişkin puan durumları ve piyasa değerlerine ait verileri kullanarak nedensellik analizi yapmıştır. Analiz sonucunda, çift yönlü nedensellik ilişkisi tespit etmiştir.

Klein, Zwergel ve Heiden (2009) makalelerinde, 1990/91-2005/06 sezonları arasında Avrupa’daki belirli futbol kulüplerine ilişkin puan durumları ve hisse senedi endeks fiyatlarına ait verileri kullanarak regresyon analizi başta olmak üzere çeşitli yaklaşımlar ile analizler yapmışlardır. Analizler sonucunda, takımların maç sonucunda

galip ya da mağlup olmalarının hisse senedi endeks fiyatlarını etkilemediği ve bu değişkenler arasında bir ilişki olmadığı tespit edilmiştir.

Son olarak, literatürde yapılan çalışmaların yanı sıra bu çalışmada pandemi döneminin etkisi de göz önünde bulundurularak dönemlere göre yapılan karşılaştırmada sezonlara göre nedensellik ilişkilerinde değişiklikler olduğu gözlemlenmiştir. Galatasaray hariç diğer takımlar için ele alınan sezonların bazılarında anlamlı bir nedensellik ilişkisi tespit edilmiştir. Dolayısıyla burada, GSRAY şirketi için yatırım yapan yatırımcıların takımın puan durumundan etkilenmediği ve buna karşıt olarak diğer üç şirkete yatırım yapan yatırımcıların belirli sezonlarda puan durumundan etkilendiği gözlemlenmiştir. Diğer yandan, Beşiktaş için pandemi dönemi öncesinde değişkenler arasında nedensellik ilişkisi varken pandemi dönemi ile birlikte nedensellik ilişkisinin yok olduğu görülmüştür. Fenerbahçe için ise pandemi dönemi öncesinden pandemi döneminin ilk sezonuna kadar değişkenler arasında nedensellik ilişkisi yokken pandemi döneminin son sezonunda nedensellik ilişkisi tespit edilmiştir. Elde edilen sonuçlar genel olarak literatürle benzerlik göstermiştir.

4.3. Dört Büyük Spor Kulübüne İlişkin Puan Tahmini

Bu bölümde, Uzun-Kısa Süreli Bellek Modeli kullanarak dört büyük spor kulübüne ilişkin puan tahmini yapılmıştır. Analizin ilk aşamasında puan tahmininde kullanılacak olan değişkenlere ilişkin özet değerler EK-1’de sunulmuştur. Bu işlemin ardından galibiyetler için “1”, beraberlik ve mağlubiyetler için “0” değerleri atanarak bir dummy değişken tanımlanmıştır. Ardından Şekil 16’da görüldüğü gibi gerekli kütüphaneler yüklenmiştir.

```
import pandas as pd
import numpy as np
from sklearn.preprocessing import LabelEncoder, OneHotEncoder, StandardScaler
from sklearn.model_selection import train_test_split
from sklearn.metrics import confusion_matrix
import keras
from keras.models import Sequential
from keras.layers import Dense
from keras.layers import Dropout
from keras import regularizers
from keras.optimizers import Adam
```

Şekil 16. Puan Tahmini İçin Gerekli Kütüphanelerin Yüklenmesi

Şekilde görülen kütüphanelerin kullanım amaçları şu şekildedir:

Pandas: Zaman serisi analizlerinde işlem kolaylığı sağlamak için kullanılır.

Numpy: Verilerin yorumlanabilmesi ve anlaşılır hale gelebilmesi için kullanılan temel kütüphanedir. Dizi oluşturma, matris, lineer cebir gibi çok sayıda istatistiksel ifade, matematiksel fonksiyon ve çok boyutlu matris kullanımına olanak sağlar.

Sklearn: Veri normalizasyonu için kullanılır.

Keras: Ağ mimarisi tasarımı için kullanılır.

Gerekli kütüphanelerin yüklenmesinin ardından pandas kütüphanesi ile veri aktarımı sağlanarak X(girdi) ve y(çıktı) değişkenleri tanımlanmıştır. Bu noktada X değişkeni, bahsi geçen 4 takıma ilişkin sıralama, galibiyet, beraberlik, mağlubiyet, atılan gol sayısı, yenilen gol sayısı, averaj sayısı ve puan değerlerini, y değişkeni ise dummy değişkeni temsil etmiştir. Girdi-çıktı ayrımının ardından toplam veri setinin %80'i eğitim verisi, %20'si ise test verisi olarak tanımlanmıştır. Hesaplama kolaylığı adına bir sonraki adımda ele alınan veriler Eşitlik 7 kullanılarak StandardScaler() ile normalize edilmiş ve 0-1 aralığında dönüştürülmüştür.

$$Z = \frac{x-\mu}{\sigma} \quad (7)$$

```
#Model Kurulumu
classifier = Sequential()
classifier.add(Dense(units = 32, kernel_initializer = "uniform", kernel_regularizer=regularizers.l2(0.001),
activation = "relu",input_dim = 8))
classifier.add(Dropout(0.10))
classifier.add(Dense(units = 16, kernel_initializer = "uniform",kernel_regularizer=regularizers.l2(0.001),
activation = "relu"))
classifier.add(Dropout(0.10))
classifier.add(Dense(units = 8, kernel_initializer = "uniform", kernel_regularizer=regularizers.l2(0.001),
activation = "relu"))
classifier.add(Dropout(0.10))
classifier.add(Dense(units = 4, kernel_initializer = "uniform", kernel_regularizer=regularizers.l2(0.001),
activation = "relu"))
classifier.add(Dense(units = 1, kernel_initializer = "uniform", activation = "sigmoid"))

adam = Adam(lr=0.001)
classifier.compile(optimizer = adam, loss="binary_crossentropy", metrics=["accuracy"])

classifier.fit(X_train, y_train, batch_size=4096, epochs=8192)
```

Şekil 17. Puan Tahmini İçin Model Kurulumu

Ardından Şekil 17'de görüldüğü gibi model kurulumuna başlanarak Sequential sınıfı ile katman dizilimi sağlanmıştır. Bu dizilim sırasında her bir takım için farklı sayıda

birim değerlerine sahip gizli katmanlar kullanılmıştır. Sonuç olarak oluşturulan modelde gizli katmanlara ait içerikler şu şekildedir:

İlk adımda, her bir tekrarda bulunması istenilen ve nöron sayısını temsil eden units'e değer verilmiştir. Bu noktada f1 skor değeri yüksek olan, iyi bir tahmin elde edebilmek hedeflenmiştir. Bu hedef doğrultusunda tekrarlanacak nöron sayılarına değer verirken ani düşüşlerin ya da sabit kalışın modelin doğruluğunu olumsuz yönde etkileyebileceği göz önünde bulundurulmuş ve ideal düşüş “*başlangıç/2*” şeklinde kabul edilerek değer verme süreci 32 ile başlatılmıştır. Ardından kernel_initializer ile ağırlıklandırmanın sürekli dağılıma uygun olması belirtilmiş, kernel_regularizer ile çok değişkenli zaman serisi analizleri için aşırı öğrenmeyi önleyen, hata kareler toplamını minimum yapan katsayılarla ulaşmak amaçlanmış ve relu fonksiyonu kullanılarak 8 girdinin bulunduğu bir gizli katman oluşturulmuştur. Bu işlemlerin ardından bir sonraki gizli katmanlar için units değerleri *başlangıç/2* formülü kullanılarak sırasıyla 16, 8 ve 4 olarak belirlenmiştir.

Son değer verme adımında ise units=1 olarak tanımlanmış ve 1 çıktı istenmiştir. Ayrıca bu adımda 0-1 sınıflandırma yapıldığı için aktivasyon fonksiyonu sigmoid olarak tanımlanmıştır.

Düzenleme adımında sınıflandırma dolayısıyla loss=binary_crossentropy olarak tanımlanırken, modelin doğruluk oranını görebilmek için metrics=accuracy olarak tanımlanmıştır. Bu işlemin ardından X ve Y değişkenlerine ait eğitim verilerinin her bir eğitim dönüşünde geri yayılıma bağlı olarak yapılacak ağırlıklandırmayı da temsil ettiği belirlenmiş ve kaçarlı gruplar halinde ele alınacağı ve kaç deneme yapılacağı ya da kaç alt örneklem olacağı belirlenerek model eğitilmiştir. Model eğitimi sonunda ulaşılan “accuracy” değeri ile eğitimin doğruluk oranı elde edilmiş ve bu değer birinci model seçim ölçütü olarak kullanılmıştır.

Yapılan analizin ardından “confusion matrix” ile karmaşıklık matrisi elde edilmiştir. Son olarak dummy değişken kullanılmasından dolayı ikinci model seçim ölçütü olarak kullanılmak üzere elde edilen karmaşıklık matrisi verileri ile “f1 skor” değeri hesaplanmıştır. f1 skor değerinin hesaplanma adımları şu şekildedir:

Tablo 16. Karmaşıklık Matrisi

Gerçek	Tahmin	
	Pozitif	Negatif
	Pozitif	Negatif
Pozitif	Gerçek Pozitif	Yanlış Negatif
Negatif	Yanlış Pozitif	Gerçek Negatif

1. Kesinlik: Kesinlik, gerçek pozitif değerlerin, gerçek pozitif ve yanlış olarak tahmin edilen pozitif değerlere bölümünden elde edilir ve tutarlılığı temsil eder.

$$Kesinlik = \frac{Gerçek\ Pozitif}{Gerçek\ Pozitif + Yanlış\ Pozitif} \quad (8)$$

2. Duyarlılık: Duyarlılık, gerçek pozitif değerlerin, gerçek pozitif ve yanlış olarak tahmin edilen negatif değerlere bölümünden elde edilir.

$$Duyarlılık = \frac{Gerçek\ Pozitif}{Gerçek\ Pozitif + Yanlış\ Negatif} \quad (9)$$

3. f1 skor: f1 skor, sınıflandırma modellerinde testin doğruluğunun ölçümünde kullanılan, doğru ve yanlış olarak tahmin edilen bütün değerleri ele alan, kesinlik ve duyarlılık değerlerinden elde edilen orandır.

$$f1\ Skor = 2 * \frac{Kesinlik * Duyarlılık}{Kesinlik + Duyarlılık} \quad (10)$$

Elde edilen çıktılarına göre accuracy ve f1 skor değeri en yüksek olan model en iyi model olarak kullanılmıştır. Bu modele ulaşabilmek üzere her bir takım için 5 farklı durum ve her bir durum için 12 farklı model oluşturularak, 60 farklı alt modelden oluşan toplamda 240 farklı deneme yapılmıştır. Yapılan denemelerde kullanılan değer aralıkları Tablo 12’de verildiği gibidir:

Tablo 17. Puan Tahmininde Kullanılan Model Parametrelerinin Değer Aralıkları

	En Küçük Değer	En Büyük Değer
Gizli Katman	0	4
Dropout	0	3
Batch	32	131072
Epoch	64	262144
Adam(lr)	0.001	0.100

Bu deęer aralıklarında yapılan denemeler sonucunda elde edilen en iyi modeller ve doęruluk oranları Tablo 13'te verilmiřtir.

Tablo 18. Puan Tahmini İin Elde Edilen En İyi Modellere Ait Sonular

	Beřiktař	Fenerbahe	Galatasaray	Trabzonspor
Gizli Katman	3	3	3	3
Dropout	2	2	2	2
Batch	4096	131072	16384	8192
Epoch	8192	131072	16384	16384
Adam(lr)	0.001	0.010	0.001	0.010
Accuracy	0.800	0.880	0.881	0.821
F1 Skor	0.710	0.720	0.724	0.713

Tablo 12 ve Tablo 13 incelendięinde řu yorumları yapmak mmkndr:


Analiz sresince,

- 0-4 deęer aralıęında gizli katman denenmiř ve tercih edilen en iyi modelde btn takımlar iin 3 gizli katman kullanılmıřtır.
- 0-3 deęer aralıęında dropout denenmiř ve tercih edilen en iyi modelde btn takımlar iin 2 dropout kullanılmıřtır.
- 32-131072 deęer aralıęında batch denenmiř ve tercih edilen en iyi modelde Beřiktař iin 4096, Fenerbahe iin 131072, Galatasaray iin 16384 ve Trabzonspor iin ise 8192 batch kullanılmıřtır.
- 64-262144 deęer aralıęında epoch denenmiř ve tercih edilen en iyi modelde Beřiktař iin 8192, Fenerbahe iin 131072, Galatasaray iin 16384 ve Trabzonspor iin ise 16384 batch kullanılmıřtır.
- 0.001-0.100 deęer aralıęında adam(lr) deęeri denenmiř ve en iyi model ierięinde Beřiktař ve Galatasaray iin 0.001, Fenerbahe ve Trabzonspor iin ise 0.010 deęeri kullanılmıřtır.


Son olarak yapılan denemeler sonucunda elde edilen accuracy deęerlerinin 0.800-0.881 ve f1 skor deęerlerinin 0.710-0.724 aralıęında olduęu grlmřtr. Buna gre elde edilen en dřk tahmin performansına ait deęerin 0.800 accuracy ve 0.710 f1 skor deęeri

ile Beşiktaş'a ve en yüksek performansına ait değerin 0.881 accuracy ve 0.724 f1 skor değeri ile Galatasaray'a ait olduğu sonucuna ulaşılmıştır.


Öte yandan her bir takıma ait tercih edilen en iyi model için doğru tahminler yeşil ve yanlış tahminler kırmızı renkle gösterilerek bir sezonluk örnek puan tahmini grafiği çizilmiştir. Buna göre 4 spor kulübü için elde edilen sonuçlar Şekil 18, 19, 20 ve 21'de gösterilmiştir.




Şekil 18. Beşiktaş Jimnastik Kulübü'ne Ait 2020-2021 Sezonu Puan Tahmini Grafiği



Şekil 19. Fenerbahçe Spor Kulübüne Ait 2020-2021 Sezonu Puan Tahmini Grafiği



Şekil 20. Galatasaray Spor Kulübüne Ait 2020-2021 Sezonu Puan Tahmini Grafiği



Şekil 21. Trabzonspor Spor Kulübüne Ait 2020-2021 Sezonu Puan Tahmini Grafiği

Grafiklere bakıldığında 2020-2021 sezonu için dört büyük spor kulübüne ait yapılan puan tahminlerinin başarısının yüksek olduğu görülmektedir. Ek olarak, 36. hafta sonrasında yapılan yanlış tahminlerin eğitim veri setinde ele alınan sezonların 36 haftadan oluşmasına karşılık test veri setinde yer alan 2020-2021 sezonun 42 haftadan oluşmasından kaynaklandığı düşünülmektedir.

4.4. Dört Büyük spor kulübüne İlişkin Hisse Senedi Öngörüsü

Bu bölümde, Uzun-Kısa Süreli Bellek Modeli kullanarak spor kulüplerinin hisse senedi kapanış fiyatları için öngörü yapılmıştır. Analizin ilk aşamasında özet değerlere ilişkin çıktılar EK-2’de verilmiş ve ardından Şekil 22’de görülen kütüphaneler yüklenmiştir.

```
import numpy as np
import matplotlib.pyplot as plt
import pandas as pd
from sklearn.preprocessing import MinMaxScaler
from keras.models import Sequential
from keras.layers import Dense
from keras.layers import LSTM
from keras.layers import Dropout
```

Şekil 22. Hisse Senedi Öngörüsü İçin Gerekli Kütüphanelerin Yüklenmesi

Şekil 22’de görülen kütüphanelerin bir kısmının kullanım amaçları 5.3’te açıklanmıştır. Yapılan açıklama haricinde,

Matplotlib: Verilerin görselleştirilmesi için kullanılan çizim kütüphanesidir.

Analiz öncesinde veri seti %80 eğitim ve %20 test olmak üzere ayrılmıştır. Gerekli kütüphanelerin yüklenmesinin ardından pandas kütüphanesi ile ilk veri grubu olan eğitim verilerinin aktarımı sağlanarak ilgili sütun (kapanış değerleri) tanımlanmıştır. Hesaplama kolaylığı adına bir sonraki adımda ele alınan veriler Eşitlik 11 ile MinMaxScaler() kullanılarak normalize edilmiş ve 0-1 aralığına dönüştürülmüştür.

$$x = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (11)$$

Bu işlemin ardından X_train ve y_train ayrımı yapılmış ve açılan for döngüsü ile adım sayısı belirlenmiş, 1 çıktılı veri yapısı modellenmiştir. Uzun-Kısa Süreli Bellek Modeli için yeniden şekillendirme adımında reshape kullanılmış ve verilerin sıralanma, istenilen adım ve boyut sayıları düzenlenmiştir. Düzenlemenin ardından Tekrarlayan Sinir Ağı yapısı oluşturulmuştur:

Oluşum öncesinde her bir katman içeriğinde 1 girdi ve 1 çıktı olduğu için keras kütüphanesinin, Sequential sınıfı,

Sunulan aktivasyonların çıktıya dönüştürülmesi için keras kütüphanesinin, Dense sınıfı,

Zaman serilerinde davranış modellemesi yapan Tekrarlayan Sinir Ağları türü olan Uzun-Kısa Süreli Bellek Modeli’ni kullanabilmek için keras kütüphanesinin, Uzun-Kısa Süreli Bellek sınıfı ve son olarak,

Aşırı öğrenmeyi önlemek için keras kütüphanesinin, Dropout sınıfını temsil eden paketleri içe aktarılmıştır. Aktarım sonrasında Tekrarlayan Sinir Ağları yapısı Şekil 23’te görüldüğü gibi modellenmiştir.

```

regressor = Sequential()

regressor.add(LSTM(units = 16, return_sequences = True, input_shape = (X_train.shape[1], 1)))
regressor.add(Dropout(0.2))

regressor.add(LSTM(units = 8, return_sequences = True))
regressor.add(Dropout(0.2))

regressor.add(LSTM(units = 4, return_sequences = True))
regressor.add(Dropout(0.2))

regressor.add(LSTM(units = 2))
regressor.add(Dropout(0.2))

regressor.add(Dense(units = 1))

regressor.compile(optimizer = 'adam', loss = 'mean_squared_error')
regressor.fit(X_train, y_train, epochs = 100, batch_size = 32)

```

Şekil 23. Hisse Senedi Öngörüsü İçin Tekrarlayan Sinir Ağları Yapısının Oluşturulması

Burada Sequential sınıfı ile katman dizilimi sağlanmıştır. Toplamda 4 gizli katman kullanılan bu modelde gizli katmanlara ait içerikler şu şekildedir:

İlk olarak units ile 32 nöron kullanımı için izin verilmiş ve bu kullanımın 1 gizli katmana aktarılması istenmiş, return_sequences ile çıktının sadece şu anı değil, geçmiş verileri de kapsadığı belirtilmiştir. Bunun için True olarak eşitleme yapılmıştır. Gösterge boyutu verilmiş ve son olarak aşırı öğrenmeyi önleyebilmek amacıyla dropout katmanı eklenmiştir. X_train.shape, 1'e eşitlenerek şekil bilgisinde sütun sayısının esas alması istenmiştir. Bu bilginin model kurulumunun yalnızca ilk adımında tanımlanması yeterlidir. Ardından units sayısı azaltılarak modele 3 gizli katman daha eklenmiştir. Son katmanda ise tek çıktı istendiği için nöron sayısı 1'e eşitlenmiş ve model daha dayanıklı hale getirilmiştir. Ardından, Tekrarlayan Sinir Ağı yapısı düzenlenmiş ve Eşitlik 12 ve 13'de verilen model seçim kriterleri kullanılmıştır.

$$\text{Hata Kareler Ortalaması} = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n} \quad (12)$$

$$\text{Hata Kareler Ortalamasının Karekökü} = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (13)$$

Eşitlik 12 ile loss=mean_squared_error eşitliği sağlanmak üzere kayıp metriği olarak belirlenmiş ve Eşitlik 13 ile elde edilen hata değerinin karekökü alınarak model seçim ölçütü olarak kullanılmıştır. Ayrıca kaybı azaltmak için optimizer=adam olarak tanımlanmıştır. Ardından, ele alınacak grup sayısı ve kaç deneme yapılacağı ya da kaç alt örneklem olacağı yukarıda belirtildiği şekilde belirlenmiş ve model eğitilmiştir.

Eğitim tamamlandıktan sonra pandas kütüphanesi kullanılarak ayrılmış diğer veri grubu olan test verileri aktarılmış, ilgili sütun seçilmiş ve eğitim-test karşılaştırması yapılmıştır. Eğitim verisinde olduğu gibi test verisinde de uzunluk ve şekil bilgileri tanımlanmış, normalizasyon yapılmıştır. Karşılaştırma sırasında eğitim ve test verileri normalleştirme öncesi değerlerine dönüştürülmüştür. Son olarak, elde edilen öngörü değerleri için hata ölçütü olarak “Ortalama Mutlak Yüzdelik Hata” tercih edilmiş ve Eşitlik 14 ile model performansına yönelik değerlendirme yapılarak analiz tamamlanmıştır.

$$\text{Ortalama Mutlak Yüzdelik Hata} = \frac{\sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{y_i}}{n} * 100 \quad (14)$$

Bu noktada, eğitim süresince hata kareler ortalaması ve test süresince ortalama mutlak yüzde hatası en düşük olan en iyi modeli bulabilmek için farklı dropout, batch_size ve epoch değerleri kullanılmıştır. Bu süreçte her bir şirket için 3 farklı durum ve her bir durum için 10 farklı model oluşturularak, 30 farklı alt model için inceleme yapılmıştır. Toplamda 4 takım için yapılan 120 farklı model incelemesi göz önünde bulundurulmuştur. Yapılan denemelerde kullanılan değer aralıkları Tablo 14’te verildiği gibidir:

Tablo 19. Hisse Senedi Öngörüsünde Kullanılan Model Parametrelerinin Değer Aralıkları

	En Küçük Değer	En Büyük Değer
Gizli Katman	0	4
Dropout	0	4
Batch	32	512
Epoch	100	1024
Adam(lr)	0.1	0.5

Yapılan denemeler sonucunda hisse senedi kapanış fiyatlarına ilişkin elde edilen en iyi modeller ve kayıp fonksiyonunu ifade eden loss değerleri Tablo 15’te verilmiştir.

Tablo 20. Hisse Senedi Öngörüsü İçin Elde Edilen En İyi Modellere Ait Sonuçlar


	BJKAS	FENER	GSRAY	TSPOR
Gizli Katman	4	4	4	4
Dropout	4	4	4	4
Batch	128	64	128	64
Epoch	256	128	256	200
Adam(lr)	0.1	0.1	0.1	0.1
Loss	0.044	0.033	0.037	0.030

Tablo 14 ve Tablo 15 incelendiğinde şu yorumları yapmak mümkündür:


Analiz süresince,

- 0-4 değer aralığında gizli katman denenmiş ve tercih edilen en iyi modelde bütün spor kulüpleri için 4 gizli katman kullanılmıştır.
- 0-4 değer aralığında dropout denenmiş ve tercih edilen en iyi modelde bütün spor kulüpleri için 4 dropout kullanılmıştır.
- 32-512 değer aralığında batch denenmiş ve tercih edilen en iyi modelde BJKAS için 128, FENER için 64, GSRAY için 128 ve TSPOR için ise 64 batch kullanılmıştır.
- 100-1024 değer aralığında epoch denenmiş ve tercih edilen en iyi modelde BJKAS için 256, FENER için 128, GSRAY için 256 ve TSPOR için ise 200 batch kullanılmıştır.
- 0.01-0.05 değer aralığında adam(lr) değeri denenmiş ve en iyi model içeriğinde bütün spor kulüpleri için 0.01 değeri kullanılmıştır.


Son olarak, en iyi modellere ait loss olarak ifade edilen hata kareler ortalamasının karekökü değerlerinin 0.030-0.044 aralığında olduğu ve en yüksek hataya sahip şirket BJKAS iken en düşük hataya sahip şirketin TSPOR olduğu sonucuna ulaşılmıştır. Elde edilen öngörülerini örneklemek adına 01.06.2020-01.06.2021 aralığı için 4 spor kulübüne ait günlük hisse senedi öngörü grafikleri Şekil 24, 25, 26 ve 27’de verilmiştir:




Şekil 24. BJKAS’a ait Günlük Hisse Senedi Öngörüsü Grafiği



Şekil 25. FENER’e ait Günlük Hisse Senedi Öngörüsü Grafiği



Şekil 26. GSRAY'a ait Günlük Hisse Senedi Öngörüsü Grafiği



Şekil 27. TSPOR'a ait Günlük Hisse Senedi Öngörüsü Grafiği

Yukarıdaki grafikler incelendiğinde, yapılan öngörülerde dönemlere göre farklılıklar mevcut olsa da genel olarak hisse senedi kapanış fiyatları artış-azalışlarının gidişatları hakkında yorum yapılabilecek kadar iyi sonuçlar elde edildiği sonucuna varılmıştır.

Bu noktada Şekil 24 detaylı bir şekilde incelendiğinde, özellikle son 2 aylık dönemde önceki aylar gibi gidişat için yorum yapmak mümkün olsa da gerçek değer ve

öngörü değerleri arasında gözle görülür düzeyde bir farklılık gözlemlenmiştir. Bu farklılığın sebebinin aykırı değerlerden kaynaklandığı düşünülmüştür. Çünkü Uzun-Kısa Süreli Bellek Modeli geçmiş değerleri ele almaktadır ve ele alınan dönemde fiyatlar yakın seyrinde hareket etmektedir. Buna karşıt olarak tahmini yapılan son dönemde ise fiyatlarda görülen ani artış veri ortalamasının üzerindedir. Eğitim sırasında karşılaşılan bu durumun tahmini zorlaştırması olasıdır. Buna rağmen gerçek ve öngörü değerlerinin birlikte grafiğine bakıldığında Uzun-Kısa Süreli Bellek Modeli'nin öngörü elde etmede oldukça başarılı olduğu söylenebilir. Diğer yandan ani artışın sebepleri incelendiğinde ise; takımın ele alınan tarih aralığında UEFA Şampiyonlar Ligi ve UEFA Avrupa Ligi için Türkiye'yi temsil etmek üzere ön eleme maçlarına katılması, özellikle oynadığı son 20 maçta 13 galibiyet ve 4 beraberlik ile Süper Lig içerisinde şampiyonluk beklentisini arttırması, görüşmeler sonunda transferi yapılacak oyuncuların kulübün mali borçlarını olumlu yönde etkileyeceği düşüncesi ve kulübün ekstra vaatleri, sponsorluk artışı, pandemi dolayısıyla seyircisiz oynanan maçlardaki açığın kapatılması üzere düzenlenen yardım kampanyaları gibi pek çok sebep sayılabilmektedir.

Son olarak, toplam veri setinin %20'sini oluşturan, 2 yılı aşkın zamana ait olan öngörü değerlerinin bir kısmı ve modele ilişkin performans değerlendirmesinin yapıldığı ortalama mutlak yüzdelik hata değerleri Tablo 16'da verilmiştir. Burada OMYH, test verilerinden elde edilen ortalama mutlak yüzdelik hata değerini ifade etmektedir.

Tablo 21. Hisse Senedine İlişkin Test Verileri ve Hata Ölçütü Değerleri

<i>Test Verileri</i>							
BJKAS		FENER		GSRAY		TSPOR	
Gerçek	Öngörü	Gerçek	Öngörü	Gerçek	Öngörü	Gerçek	Öngörü
2.460	2.315	12.500	11.064	3.370	3.280	3.290	3.438
2.520	2.467	13.100	11.617	3.360	3.286	3.340	3.338
2.520	2.498	13.240	12.248	3.520	3.271	3.300	3.381
2.540	2.511	12.980	12.707	3.490	3.355	2.980	3.352
2.510	2.511	12.930	12.824	3.740	3.398	2.680	3.076
2.600	2.501	13.200	12.762	3.820	3.547	2.950	2.784
2.600	2.502	13.070	12.786	3.760	3.679	3.240	2.957
2.600	2.561	12.940	12.832	3.650	3.682	3.340	3.263
2.570	2.570	12.660	12.834	3.650	3.594	3.240	3.370
2.620	2.555	12.840	12.742	3.290	3.545	3.290	3.280
2.470	2.553	12.340	12.724	3.290	3.342	3.620	3.327
2.490	2.537	12.840	12.609	3.300	3.208	3.980	3.651
2.490	2.445	12.380	12.654	3.280	3.187	4.370	3.995
2.480	2.446	12.200	12.624	3.250	3.191	4.810	4.349
2.430	2.455	11.910	12.500	3.010	3.174	4.660	4.738
2.440	2.437	11.380	12.304	2.880	3.033	5.020	4.540
2.400	2.411	11.300	12.003	2.960	2.866	4.540	4.984
2.510	2.405	12.430	11.745	2.860	2.825	4.790	4.488
2.450	2.419	12.350	11.935	2.820	2.800	4.820	4.842
2.500	2.473	12.340	12.247	2.880	2.758	4.870	4.792
(...)	(...)	(...)	(...)	(...)	(...)	(...)	(...)
8.420	6.317	28.600	28.122	3.060	3.083	1.880	1.906
9.260	6.383	27.940	27.738	3.100	3.009	1.900	1.895
10.180	6.461	28.260	27.243	3.090	2.994	2.090	1.900
9.560	6.541	27.300	27.496	3.100	3.003	2.290	2.047
8.810	6.561	27.000	26.785	3.070	3.014	2.220	2.264
9.200	6.466	26.640	26.289	3.180	3.003	2.170	2.261
10.120	6.372	27.020	25.981	3.220	3.051	2.190	2.196
10.120	6.418	26.120	26.336	3.540	3.114	2.170	2.187
9.110	6.478	23.520	25.736	3.360	3.325	2.140	2.177
8.900	6.372	25.860	23.412	3.270	3.341	2.350	2.152
8.010	6.190	28.440	24.464	3.440	3.242	2.360	2.312
7.210	6.147	31.280	27.819	3.490	3.275	2.450	2.377
7.280	5.938	31.420	31.317	3.420	3.363	2.440	2.454
6.940	5.708	33.460	31.710	3.290	3.362	2.580	2.461
6.250	5.733	33.960	33.371	3.350	3.265	2.550	2.575
6.510	5.580	32.840	34.092	3.270	3.236	2.680	2.577
6.000	5.419	31.460	32.858	3.300	3.206	2.600	2.681
5.860	5.489	33.340	31.292	3.250	3.204	2.550	2.637
5.620	5.323	33.900	33.078	3.270	3.184	2.500	2.578
5.570	5.293	32.780	34.047	3.280	3.179	2.600	2.526
OMYH	4.743		4.902		3.743		7.534

Tablo 16'ya göre hesaplanan ortalama mutlak yüzdelik hata değerleri incelendiğinde, Uzun-Kısa Süreli Bellek Modeli'nin uzun dönem öngörülerde başarılı olduğu görülmüştür. Ayrıca, en düşük hata değerinin sırasıyla GSRAY, BJKAS, FENER ve TSPOR şirketlerine ait olduğu tespit edilmiştir.

SONUÇ ve ÖNERİLER

Bu tez kapsamında Uzun-Kısa Süreli Bellek Modeli'nin zaman serisi analizlerinde sağladığı üstünlükler kullanılarak tahmin ve öngörü çalışmaları yapılmıştır. Uygulama, toplamda dört alt başlık halinde ele alınmıştır. Buna göre:

Puanlar ile hisse senedi açılış fiyatı ve hisse senedi kapanış fiyatı arasında ilişki olduğu düşünülerek yapılan Korelasyon Analizi ile ilişkinin yönü ve büyüklüğü incelenmiştir. İnceleme sırasında ele alınan tarih aralığındaki sezonlar ayrı ayrı değerlendirilmiş ve pandemi döneminin etkisini de görebilmek adına iki gruba ayrılarak karşılaştırma yapılmıştır. Yapılan analiz sonucunda genel olarak, pandemi dönemi öncesine göre pandemi döneminde değişkenler arasındaki ilişkinin artışı yönünde değişiklik olduğunu söylemek mümkündür. Örneğin; pandemi dönemi öncesinde değişkenler arasında ağırlıklı olarak pozitif yönlü ve zayıf-orta düzeyde ilişki görülürken, pandemi döneminin ilk sezonunda ağırlıklı olarak pozitif yönlü ve güçlü ilişki görülmüş ve son döneminde ise negatif yönlü ve orta-güçlü düzeyde bir ilişki görülmüştür.

Değişkenler arasında ilişki bulunması sebebiyle bu ilişkinin nedensellik ilişkisinden kaynaklı olup olmadığı nedensellik analizi ile araştırılmıştır. Pandemi dönemi de göz önünde bulundurularak yapılan analiz sonucunda, değişkenler arasındaki nedensellik ilişkisinin varlığının sezonlara göre değişiklik gösterdiği gözlemlenmiş ve Galatasaray hariç diğer takımlarda en az bir sezonda nedensellik ilişkisi tespit edilmiştir. Dolayısıyla, GSRAY şirketi hariç diğer üç şirkete yatırım yapan yatırımcıların belirli sezonlarda puan durumundan etkilendiği sonucuna ulaşılmıştır. Elde edilen sonuç doğrultusunda takımların bu süreçteki piyasa değerleri, transfer sayıları ve lig sıralamaları da ele alınarak tekrar bir inceleme yapılmıştır. Buna göre; pandemi dönemiyle birlikte dört büyük spor kulübünün tamamının transfer sayıları ve piyasa değerlerinde artış yaşandığı gözlemlenmiştir. Farklı olarak, incelenen süreçte Fenerbahçe ve Trabzonspor takımlarına dair nedensellik ilişkisinin bulunduğu sezonların, transfer sayılarının en yüksek olduğu sezonlarla aynı olduğu görülmüştür. Ayrıca bu sezonlarda, Fenerbahçe'nin 7. sıradan 3. sıraya ve Trabzonspor'un 4. sıradan 2. sıraya yükselmiş olması da dikkat çekmiştir. Ek olarak, literatür incelemesi ile bu çalışma kıyaslandığında

elde edilen nedensellik analizi sonuçlarının genel olarak benzerlik gösterdiği sonucuna ulaşılmıştır.

Nedenselliğin ardından futbol maçlarından haftalık olarak elde edilen puanlar için; model seçiminde %85 ortalamaoya sahip, en yüksek öğrenme başarısına karşılık gelen model parametreleri kullanılarak tahmin yapılmıştır. Ardından tahmin başarısını incelemek adına f1 skor değeri hesaplanmıştır. Hesaplanan bu değerin ortalamasının %72 oranında olduğu tespit edilmiştir. Buna göre; takımlara ilişkin tahmin performansları kıyaslandığında, en yüksek performansın sırasıyla Galatasaray, Fenerbahçe, Trabzonspor ve Beşiktaş takımlarına ait olduğu görülürken, yapılan yanlış tahminlerin dağılımını görebilmek adına çizilen grafikler kıyaslandığında, yanlış sonuç sayılarının birbirine yakın olduğu gözlemlenmiştir.

Diğer yandan Borsa İstanbul A.Ş.'de günlük olarak işlem gören spor kulübü hisse senedi kapanış fiyatları için; model seçiminde 0.036 ortalamaoya sahip, en düşük hata değerine karşılık gelen model parametreleri kullanılarak öngörü yapılmıştır. Yapılan öngörü sonucunda tahmin hatasını incelemek adına ortalama mutlak yüzdelik hata değeri hesaplanmıştır. Hesaplanan bu değerin ortalamasının 5.23 olduğu tespit edilmiştir. Burada en az tahmin hatasının sırasıyla GSRAY, BJKAS, FENER ve TSPOR şirketlerine ait olduğu gözlemlenmiştir. Ayrıca, yapılan yanlış öngörülerini daha net görebilmek adına çizdirilen grafikler incelendiğinde; hatalara rağmen hisse senedi fiyatlarının artış ve azalışlarına yönelik yorum yapılmasının mümkün olduğu görülmüştür. Dolayısıyla, Uzun-Kısa Süreli Bellek Modeli'nin üstünlükleri kullanılarak elde edilen öngörünün literatürle benzerlik göstererek iyi bir performansa sahip olduğu sonucuna ulaşılmıştır.

Uygulama bir bütün olarak değerlendirildiğinde, Uzun-Kısa Süreli Bellek Modeli'nin üstünlükleri kullanılarak elde edilen öngörünün literatürle benzerlik göstererek iyi bir performansa sahip olduğu sonucuna ulaşılmıştır.

Son olarak hisse senedi ile yatırım yaparken şirketlerin net piyasa değerleri, kar ve zarar durumları, belirli süreçler içerisindeki büyüme oranları, yatırımcıya kar payı verip vermedikleri, sektörlerinde gösterdikleri rekabet güçleri gibi dikkat edilecek çok sayıda önemli kriter mevcuttur. Bununla birlikte, sermaye artırımını yolu kullanılmışsa elde edilen gelir, borçları karşılamak ya da yeni projelerle çeşitli yatırımlar yapmak için

kullanılabilir. Bu durumda şirketin amacının bilinmesi de özellikle uzun vadeli yatırımlar için esasen bir kriter niteliğindedir. Öte yandan yatırım yapılacak şirket bir spor kulübü şirketi ise bu kriterlere ek olarak, farklı stratejik planlamaların da yapılması gerektiği düşünülmektedir. Çünkü; spor kulübü hisseleri genellikle diğer hisselerle oranla daha kısa vadede belirgin oranda tepki gösterir. Örneğin; 2020/2021 sezonu öncesinde BJKAS hisseleri belirli bir fiyat seyrinde ilerlerken, 2020/2021 sezonunda Beşiktaş takımının futbolda şampiyonluk beklentisi oluşturmasıyla birlikte fiyatlarda belirgin bir artış gözlemlenmiştir. Diğer bir örnekle; 2017/2018 ve 2018/2019 sezonlarında futbolda ligi 1. sırada tamamlayan Galatasaray takımı, 2019/2020 sezonunda 6. sıraya gerilemiştir. Bu gerilemeyle birlikte hisse senedi fiyatlarında gözle görülebilir bir düşüş gözlemlenmiştir. Dolayısıyla, önemli kriterler göz önünde bulundurularak alımı yapılan spor kulübü hisselerinden kar elde edebilmek için düzenli takip tavsiye edilir.

Ayrıca, BJKAS şirketinin hisse senedi fiyatlarına dair yapılan öngörülerin son döneminde hatalarda gözlemlenen artışın aykırı değer kaynaklı olduğu düşünülerek bu durum için yöntem geliştirilmesi, değişken ve veri sayılarının arttırılması ve performans bazlı başarının kıyaslanabilmesi adına çalışmanın diğer istatistiksel yöntemlerle de karşılaştırılması önerilmektedir.

KAYNAKÇA

- Arık, B. (2008). Futbol ve televizyon bağı: Simbiyoz beslenme. *İletişim Kuram ve Araştırma Dergisi*, (26), 201.
- Akşar, T. (2005). *Endüstriyel futbol* (1. Baskı). Literatür Yayıncılık, 226.
- Akşar T. & Merih, K. (2006). *Futbol ekonomisi*. Literatür Yayınları, 70.
- Aktaş, H. & Mutlu, S. (2016). Futbolda finansal sürdürülebilirlik kapsamında “finansal fair play başa baş kuralı” ve beşiktaş futbol kulübü üzerinde bir uygulama. *CBÜ Sosyal Bilimler Dergisi*, 14(2), 241,242.
- Aktaş, R. vd. (2017). Milli başarısızlığın öngörülmesi: İstatistiksel yöntemler ve yapay sinir ağı karşılaştırılması. *Ankara Üniversitesi SBF Dergisi*, 58(4), 11.
- Aliaksandr, D. (2020). *Real-time prediction of football matches results*. [Lisans, Brno University].
- Arabzad, S., Araghi, M. E. T., Nezhad, S. S. & Ghofrani, N. (2014). Football match results prediction using artificial neural networks; the case of iran pro league. *Journal of Applied Research on Industrial Engineering*, 1(3), 159-179.
- Aşkın, D., İskender, İ. & Mamızadeh, A. (2011). Farklı yapay sinir ağları yöntemlerini kullanarak kutu tip transformatör sargısının termal analizi. *Gazi Üniversitesi Mimarlık Fakültesi Dergisi*, 26(4), 907.
- Aydın, D. A., Turgut, M. & Bayırlı, R. (2007). Spor kulüplerinin halka açılmasının türkiye’de uygulanan modeller açısından incelenmesi. *Gazi Üniversitesi Ticaret ve Turizm Eğitim Fakültesi Dergisi*, (1), 65-66.
- Aydın, Y. S., (2000). *Visual prolog ile programlama*. Sistem Yayıncılık, 253.
- Ayyıldız, E. (2018). Amerika basketbol ligi (nba) maç sonuçlarının yapay sinir ağları ile tahmini. *Gaziantep Üniversitesi Spor Bilimleri Dergisi*, 3(1).

- Bankers, P. (2014). *The impact of national football results on stock prices: A case study for brazil* (Yayın No. 199197). [Yüksek lisans tezi, Tilburg School of Economics and Management].
- Botoc, C., Mihancea, E. & Molcut, A. (2019). Football and stock market performance correlation: Evidence from Italy. *Journal of Scientific Annals of Economics and Business*, 66(4). <https://doi.org/10.47743/saeb-2019-0044>
- Busalini, G., (2020). *The impact of soccer results on publicly traded soccer clubs*. [Yüksek lisans tezi, Universidade Catolica Portuguesa].
- Bütün, F. (2019). *Futbol takımlarının süper lig puan başarısı ile piyasa değeri arasındaki ilişkinin analizi*. [Yüksek lisans tezi, Nuh Naci Yazgan Üniversitesi]. YÖK Tez Merkezi. <https://tez.yok.gov.tr/UlusalTezMerkezi/>
- Çakmak, U. (2019). *Futbol ekonomisi: avrupa ve türkiye üzerine karşılaştırmalı bir inceleme* [Yüksek lisans tezi, İstanbul Üniversitesi]. YÖK Tez Merkezi. <https://tez.yok.gov.tr/UlusalTezMerkezi/>
- Çalışkan, M. M. T. & Deniz, D. (2015). Yapay sinir ağlarıyla hisse senedi fiyatları ve yönlerinin tahmini. *Eskişehir Osmangazi Üniversitesi İİBF Dergisi*, 10(3).
- Çalışkan, M. M. T. & Deniz, D. (2016). BİST'te işlem gören spor kulüplerinin futbol maçlarının hisse senedi getirisi üzerine etkisi. *Anadolu Üniversitesi Sosyal Bilimler Dergisi*, 16.
- Demirhan, D. (2013). Stock market reaction to national sporting success: Case of bursa istanbul. *Pamukkale Spor Bilimleri Dergisi*, 4(3).
- Devecioğlu, S. (2004). Halka arz edilen spor kulüplerinin sportif başarıları ile piyasa değerleri arasındaki ilişki. *Spormetre Beden Eğitimi ve Spor Bilimleri Dergisi*, 2(1).
- Dobson, S.M., Goddard, J.A. (2010). Performance and revenue in professional league football: Evidence from granger causality tests. *Applied Economics*, 30(12). <https://doi.org/10.1080/000368498324715>

- Durmaz, M. (2019). *Futbol kulüplerinin borsa performanslarını etkileyen değişkenler üzerinde bir inceleme*. [Yüksek lisans tezi, Sivas Cumhuriyet Üniversitesi]. YÖK Tez Merkezi. <https://tez.yok.gov.tr/UlusalTezMerkezi/>
- Efe, M. & Kaynak, O. (2000). *Yapay sinir ağları ve uygulamaları*. Boğaziçi Üniversitesi Yayınları, 2.
- Ektik, D. (2017). Futbol takımlarının saha içerisindeki başarılarının hisse senedi getirilerine etkisi. *Marmara Üniversitesi Öneri Dergisi*, 13(49), 91-108.
- Elmas, Ç. (2003). *Yapay sinir ağları*. Seçkin Yayıncılık, 43.
- Elsaid, A. (2016). *Using long-short-term-memory recurrent neural networks to predict aviation engine vibrations*. [Yüksek lisans tezi, University of North Dakota UND Scholarly].
- Erdoğan, E. & Özyürek, H. (2012). Yapay sinir ağları ile fiyat tahminlemesi. *Sosyal ve Beşeri Bilim Dergisi*, 4(1), 85-92.
- Fenerbahçe Sportif Hizmetler Sanayi ve Ticaret A.Ş. (2004). *Halka arz izahnamesi*.
- Fukushima, K. (1980). Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. *Biological Cybernetics - SCI Journal*, 36, 193,194.
- Galloppo, G. & Boido, C. (2020). How much Is a goal in the football championship worth? Match results and stock price reaction. *International Journal of Sport Finance*, (15). <https://doi.org/10.2139/ssrn.3208369>
- Gers, F.A., Schmidhuber, J. & Cummins, F. (1999). *Learning to forget: Continual prediction with lstm*. London: 9th International Artificial Neural Networks Conference: ICAAN'99, 850-855.
- Gümüş, A. & Hacıevliyagil, N. (2020). Covid-19 salgın hastalığının borsaya etkisi: Turizm ve ulaştırma endeksleri üzerine bir uygulama. *Akademik Yaklaşımlar Dergisi*, 11(1), 87.

- Gürsaka1, N. (2017). *Makine öğrenmesi & derin öğrenme*. Dora Basım-Yayın ve Dağıtım, 71.
- Güven, S. (2010). *Türkiye’de futbol kulüplerindeki mevcut muhasebe sisteminin incelenmesi: Örnek bir uygulama* (Tez No.264020). [Yüksek lisans tezi, Dokuz Eylül Üniversitesi]. YÖK Tez Merkezi, <https://tez.yok.gov.tr/UlusalTezMerkezi/>
- Hamzaçebi, C. (2011). *Yapay sinir ağlarının tahmin amaçlı kullanımı matlab ve neurosolutions uygulamalı*. Ekin Yayınevi, 27.
- Hermans, M. & Schrauwen, B. (2013). *Training and analysing deep recurrent neural networks*. Advances in Neural Information Processing Systems, (26), 190-198.
- Hinton, G., Rumelhart, D. & Williams, R. (1986). Learning representations by back-propagating errors. *Nature*, 533-536. <https://doi.org/10.1038/323533a0>
- Hinton, G., Osindero, S. & Teh, Y. (2006). A fast learning algorithm for deep belief nets. *Neural Computation*, 1527-1554. <https://doi.org/10.1162/neco.2006.18.7.1527>
- Hochreiter, S. & Schmidhuber, J. (1997). Long short – term memory, *Neural Computation*, 9(8), 1735-1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Hu, M. J. C. (1964). *Application of the adaline system to weather forecasting*. Neural Computation.
- Ivankovic, Z., Rackovic, M., Branko, M. & Dragica, R. (2010). Appliandce of neural networks in basketball scouting. *Acta Polytechnica Hungarica*, 7(4).
- Ivakhnenko, A. & Lapa, V. (1965). Cybernetic predicting devices. *CCM Information Corp*, 1-26,172,178.
- Karahan, M. (2011). *İstatistiksel tahmin yöntemleri: Yapay sinir ağları ile ürün talep tahmini uygulaması* (Tez No.280985). [Doktora tezi: Selçuk Üniversitesi]. YÖK Tez Merkezi, <https://tez.yok.gov.tr/UlusalTezMerkezi/>
- Karakoyun, E. Ş. (2018). *Derin öğrenme ile zaman serilerinin gerçek zamanlı tahmini* (Tez No.513085). [Yüksek lisans tezi, Necmettin Erbakan Üniversitesi]. YÖK Tez Merkezi, <https://tez.yok.gov.tr/UlusalTezMerkezi/>

- Kaya, Ü., Oğuz, Y., & Şenol, Ü. (2018). An assessment of energy production capacity of amasra town using artificial neural networks. *Turkish Journal of Electromechanics and Energy*, 3(1).
- Kelley, H. J. (1960). Gradient theory of optimal flight paths, *ARS Journal*, 30(10), 947. <https://doi.org/10.2514/8.5282>
- Klein, C., Zwergel, B. & Heiden S. (2009). On the existence of sports sentiment: The relation between football match results and stock index returns in europe. *Rev Manag Sci* 3(3).
- Le, X.H., Ho, H.V., Lee, G. & Jung, S. (2019). Application of long short-term memory (LSTM) neural network for flood forecasting. *Article in Water*, 11(7), 8. <https://doi.org/10.3390/w11071387>
- Lee, D. H. (2013). Pseudo-label: The simple and efficient semi-supervised learning method for deep neural networks. *Workshop on Challenges in Representation Learning*, (3), 2-4.
- Loeffelholz, B., Bednar, K. & Bauer, K. (2009). Predicting nba games using neural networks. *Journal of Quantitative Analysis in Sports*, 5(1). <https://doi.org/10.2202/1559-0410.1156>
- McCarthy, J. (1956). *A proposal for the dartmouth summer research project on artificial intelligence*. Dartmouth College.
- Merih, K. (2006). Futbol sektörünün ekonomik yorumu. *İşveren Dergisi*, 44(11), 20.
- Moghar, A. & Hamiche, M. (2020). Stock market prediction using lstm recurrent neural network. *Procedia Computer Science*, 170.
- Ocakoğlu, G. (2006). *Lojistik regresyon analizi ve yapay sinir ağı tekniklerinin sınıflama özelliklerinin karşılaştırılması ve bir uygulama* (Tez No. 192743). [Yüksek lisans tezi, Uludağ Üniversitesi]. YÖK Tez Merkezi, <https://tez.yok.gov.tr/UlusalTezMerkezi/>
- Özboyacı, M. (2010). *Halka arzın şirketlerin performansı üzerine etkisi ve imkb'de bir uygulama* (Tez No. 263775). [Yüksek lisans tezi, Süleyman Demirel Üniversitesi]. YÖK Tez Merkezi. <https://tez.yok.gov.tr/UlusalTezMerkezi/>

- Özçalıcı, M. (2016). Yapay sinir ağları ile çok aşamalı fiyat tahmini: BIST30 senetleri üzerine bir araştırma. *Dokuz Eylül Üniversitesi İktisadi İdari Bilimler Fakültesi Dergisi*, 31(2). <https://doi.org/10.24988/deuiibf.2016312517>
- Öztemel, E. (2012). *Yapay sinir ağları*. Papatya Yayıncılık, 59.
- Öztemel, E. (2016). *Yapay sinir ağları*. Papatya Bilim, 27,29,45.
- Petterson, D. & Nyquist, R. (2017). *Football match prediction using deep learning recurrent neural network applications*. [Yüksek lisans tezi, Chalmers University of Technology].
- Peker, Y. & Demirhan, E. (2020). Covid-19 küresel salgınının borsa istanbul'daki sektörel etkileri. *Türkiye Ekonomi Politikaları Araştırma Vakfı, Değerlendirme Notu*, 5.
- Samagaio, A., Counto, E. & Caiado, J. (2009). *Sporting, financial and stock market performance in english football: An empirical analysis of structural relationships*. Technical University of Lisbon, Centre for Applied Mathematics and Economics Working Papers.
- Schaeffer, J. (2006). *Samuel's checkers player*. Encyclopedia of Cognitive Science, 881.
- Sermaye Piyasalar Kurulu (2019). *Sermaye piyasası kurulu eğitim semineri kitapçığı*. SPK Yayınları, 43,47.
- Sevim, Ş. & Güven, Ö. (2015). Spor kulüplerinin halka açılması ve hisse senetlerinin değerinin etkileyen faktörlerin analizi: Beşiktaş ve galatasaray örneği. *Dumlupınar Üniversitesi Sosyal Bilimler Dergisi*, 7(7), 4,5.
- Song, Y. (2018). *Stock Trend Prediction: Based on Machine Learning Methods*. [Yüksek lisans tezi, University of California].
- Subaşı, H. (2010). *Yapay sinir ağı ile atıksu arıtma performansının modellenmesi* (Tez No. 270589). [Yüksek lisans tezi, Çukurova Üniversitesi]. YÖK Tez Merkezi. <https://tez.yok.gov.tr/UlusalTezMerkezi/>

- Şeker, A., Diri, B. & Balık, H. H. (2017). Derin öğrenme yöntemleri ve uygulamaları hakkında bir inceleme. *Gazi Mühendislik Bilimleri Dergisi*, 3(3), 47-55.
- Tan, C. (1997). *Artificial neural networks: A financial tool as applied in the australian market*. [Doktora Tezi, Bond University].
- Tsiaras, K. (2020). *Stock market predictions using lstm neural networks*. [Lisans tezi, National and Kapodistrian University of Athens School of Science].
- Turan, S. (2019). *Uzun kısa süreli hafıza ve geçitli yinelenen birim ile borsa istanbul 100 endeks değeri tahmini üzerine bir uygulama* (Tez No. 598946). [Yüksek lisans tezi, Yıldız Teknik Üniversitesi]. YÖK Tez Merkezi. <https://tez.yok.gov.tr/UlusalTezMerkezi/>
- Tiwari, E., Sardar, P. & Jain, S. (2020). *Football match result prediction using neural networks and deep learning*. India, 8th International Conference on Reliability.
- Tuna, M. (2019). *Altın fiyatlarının yapay sinir ağları ve arma modelleri ile tahminlenmesi* (Tez No. 589740). [Yüksek lisans tezi, Adnan Menderes Üniversitesi]. YÖK Tez Merkezi. <https://tez.yok.gov.tr/UlusalTezMerkezi/>
- Turing, A. M. (1950). *Computing machinery and intelligence*. Oxford University Press on behalf of the Mind Association, 455-457.
- Yavuz, S. & Deveci, M. (2013). İstatistiksel normalizasyon tekniklerinin yapay sinir ağı performansına etkisi. *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, (4), 171,172.
- Yılmaz, A. (2017). *Yapay zeka*. KODLAB Yayınları, 33,35,47.

İnternet Kaynakları

- URL1. Nilgün Şengöz. *Yapay sinir ağları*. <https://www.derinogrenme.com/2017/03/04/yapay-sinir-aglari/>. (Erişim Tarihi: 24.07.2020).

- URL2. Anonim. *Sinir hücresi(nöron) ve yapısı*. https://www.fenokulu.net/yeni/Fen-Konulari/Konu/Sinir-Hucresi-Noron-ve-Yapisi_0_1617.html. (Erişim Tarihi: 15.03.2020).
- URL3. Türkiye Yapay Zekâ İnisiyatifi. *Yapay zeka zaman çizelgesi*. <https://turkiye.ai/kaynaklar/yapay-zeka-zaman-cizelgesi/>. (Erişim Tarihi: 27.04.2020).
- URL4. Anadolu Ajansı. *Yapay zeka ekonomisi 2030'da 15.7 trilyon dolar olacak*. <https://www.aa.com.tr/tr/bilim-teknoloji/yapay-zeka-ekonomisi-2030da-15-7-trilyon-dolar-olacak/1958379>. (Erişim Tarihi: 15.04.2021).
- URL5. Anonim. *Deep blue(satranç bilgisayarı)*. https://stringfixer.com/tr/IBM_Deep_Blue. (Erişim Tarihi: 30.03.2020).
- URL6. Colah's Blog. *Understanding lstm networks*. <http://colah.github.io/posts/2015-08-Understanding-LSTMs/>. (Erişim Tarihi: 10.05.2021).
- URL7. Anonim. *Futbolun tarihçesi*. <https://www.sporforma.net/blog/futbolun-tarihcesi>. (Erişim Tarihi: 01.10.2021).
- URL8. Türkiye Futbol Federasyonu. *Ülkemizde futbolun doğuşu*. <https://www.tff.org/default.aspx?pageID=293>. (Erişim Tarihi: 04.10.2021).
- URL9. TRT 2. *Türkiye'de futbol tarihi | tarih söyleşileri*. <https://www.youtube.com/watch?v=hd0tU1tmf2I>. (Erişim Tarihi: 04.10.2021).
- URL10. Transfermarkt. *Süper lig – kulüp piyasa değerler | transfermarkt*. <https://www.transfermarkt.com.tr/superlig/marktwerteverein/wettbewerb/TR1>. (Erişim Tarihi: 07.10.2021).
- URL11. Milliyet. *Futbola sponsor dopingi – son haberler*. <https://www.milliyet.com.tr/ekonomi/futbola-sponsor-dopingi-6584229>. (Erişim Tarihi: 12.10.2021).
- URL12. Futbol Akademisi. *Futbol kulüplerinin yaşam kaynakları*. <https://www.futbolakademi.net/futbol-kuluplerinin-yasam-kaynaklari>. (Erişim Tarihi: 12.10.2021).

- URL13. Borsa İstanbul A.Ş.. *Halka arz ve satış yöntemleri – borsa istanbul a.ş.*
<https://www.borsaistanbul.com/tr/sayfa/243/halka-arz-yontemleri>. (Erişim Tarihi: 24.05.2021).
- URL14. Borsa İstanbul A.Ş.. *Halka arzın faydaları ve halka arza karar verme*.
<https://www.borsaistanbul.com/tr/sayfa/151/halka-arzin-faydalari-ve-halka-arza-karar-verme>. (Erişim Tarihi: 26.09.2021).
- URL15. Anonim. *Avantajları ve dezavantajları ile halka açılma*.
<https://lexist.com.tr/blog/2021/05/22/avantajlari-ve-dezavantajlari-ile-halka-acilma/>. (Erişim Tarihi: 26.09.2021).
- URL16. Beşiktaş jimnastik kulübü. *halka açılıyoruz – beşiktaş jk*.
https://bjk.com.tr/tr/haber/29494/halka_aciliyoruz.html. (Erişim Tarihi: 08.10.2021).
- URL17. Mete İkiz. *Türkiye’de spor kulüplerinin şirketleşmesi ve halka arzları*.
<https://docplayer.biz.tr/35889110-Turkiye-de-spor-kuluplerinin-sirketlesmesi-ve-halka-arzlari-mete-ikiz.html>. (Erişim Tarihi: 10.10.2021).
- URL18. Vakıf Yatırım. *Halka arza aracılık faaliyeti-vakıf yatırım*.
<https://www.vakifyatirim.com.tr/halka-arza-aracilik-faaliyeti>. (Erişim Tarihi: 11.10.2021).
- <https://www.investing.com/> (Erişim Tarihi: 30.09.2020)
- <https://www.tff.org/> (Erişim Tarihi: 30.09.2020)
- Global AI Hub x Turkish AI Hub Eğitimleri. <https://globalaihub.com/activity/>. (Erişim Tarihi: 09.09.2021).

EKLER

EK-1: Puan Tahmini Verilerine İlişkin Özet Bilgiler

EK-2: Hisse Senedi Öngörüsü Verilerine İlişkin Özet Bilgiler



EK-1: Puan Tahmini Verilerine İlişkin Özet Bilgiler

Beşiktaş

	S	G	B	M	A	Y	AV	P	D
count	518.000000	518.000000	518.000000	518.000000	518.000000	518.000000	518.000000	518.000000	518.000000
mean	3.635135	10.067568	4.142857	3.507722	30.980695	18.212355	12.768340	34.345560	0.573359
std	2.626321	6.161061	2.692287	2.405454	19.210521	11.072702	10.058071	20.343432	0.495067
min	1.000000	0.000000	0.000000	0.000000	0.000000	0.000000	-4.000000	0.000000	0.000000
25%	2.000000	5.000000	2.000000	2.000000	14.000000	9.000000	5.000000	17.000000	0.000000
50%	3.000000	9.000000	4.000000	3.000000	30.000000	18.000000	11.000000	33.000000	1.000000
75%	4.000000	15.000000	6.000000	5.000000	45.750000	26.000000	18.000000	50.750000	1.000000
max	18.000000	26.000000	11.000000	10.000000	89.000000	49.000000	47.000000	84.000000	1.000000

Fenerbahçe

	S	G	B	M	A	Y	AV	P	d
count	518.000000	518.000000	518.000000	518.000000	518.000000	518.000000	518.000000	518.000000	518.000000
mean	3.841699	10.241313	4.102317	3.413127	32.747104	18.415058	14.332046	34.826255	0.588803
std	3.504355	6.382828	2.790415	2.423926	19.527587	10.768512	11.204870	20.838254	0.492526
min	1.000000	0.000000	0.000000	0.000000	0.000000	0.000000	-8.000000	0.000000	0.000000
25%	2.000000	5.000000	2.000000	2.000000	16.000000	9.000000	5.000000	17.000000	0.000000
50%	3.000000	10.000000	4.000000	3.000000	32.000000	19.000000	13.000000	34.000000	1.000000
75%	4.000000	15.000000	6.000000	4.750000	48.000000	27.000000	21.000000	51.000000	1.000000
max	17.000000	26.000000	13.000000	11.000000	84.000000	46.000000	50.000000	82.000000	1.000000

Galatasaray

	S	G	B	M	A	Y	AV	P	d
count	518.000000	518.000000	518.000000	518.000000	518.000000	518.000000	518.000000	518.000000	518.000000
mean	3.418919	10.003861	4.164093	3.577220	32.837838	18.432432	14.405405	34.175676	0.565637
std	2.800281	6.002255	2.867497	2.956294	19.306866	11.180352	11.027736	19.814762	0.496152
min	1.000000	0.000000	0.000000	0.000000	0.000000	0.000000	-10.000000	0.000000	0.000000
25%	1.000000	5.000000	2.000000	1.000000	15.250000	9.000000	6.000000	18.000000	0.000000
50%	3.000000	10.000000	4.000000	3.000000	32.000000	18.000000	14.000000	33.000000	1.000000
75%	4.000000	14.000000	6.000000	5.000000	49.000000	27.000000	21.000000	50.000000	1.000000
max	17.000000	26.000000	12.000000	16.000000	80.000000	49.000000	45.000000	84.000000	1.000000

Trabzonspor

	S	G	B	M	A	Y	AV	P	d
count	518.000000	518.000000	518.000000	518.000000	518.000000	518.000000	518.000000	518.000000	518.000000
mean	6.550193	8.036680	4.851351	4.880309	27.200772	20.841699	6.359073	28.961390	0.469112
std	3.777720	5.216827	2.972978	3.519654	17.295426	12.444307	9.645477	18.036672	0.499527
min	1.000000	0.000000	0.000000	0.000000	0.000000	0.000000	-19.000000	0.000000	0.000000
25%	4.000000	4.000000	3.000000	2.000000	13.000000	10.000000	0.000000	13.250000	0.000000
50%	6.000000	8.000000	5.000000	4.000000	26.000000	21.000000	4.000000	27.000000	0.000000
75%	9.000000	12.000000	7.000000	7.000000	39.000000	30.000000	10.000000	43.000000	1.000000
max	19.000000	25.000000	14.000000	18.000000	76.000000	59.000000	46.000000	82.000000	1.000000



EK-2: Hisse Senedi Öngörüsü Verilerine İlişkin Özet Bilgiler

Beşiktaş	Fenerbahçe																																				
<table><tr><th></th><th>kapanis</th></tr><tr><td>count</td><td>3869.000000</td></tr><tr><td>mean</td><td>2.387240</td></tr><tr><td>std</td><td>1.416221</td></tr><tr><td>min</td><td>0.430000</td></tr><tr><td>25%</td><td>1.500000</td></tr><tr><td>50%</td><td>2.040000</td></tr><tr><td>75%</td><td>3.190000</td></tr><tr><td>max</td><td>13.510000</td></tr></table>		kapanis	count	3869.000000	mean	2.387240	std	1.416221	min	0.430000	25%	1.500000	50%	2.040000	75%	3.190000	max	13.510000	<table><tr><th></th><th>kapanis</th></tr><tr><td>count</td><td>3869.000000</td></tr><tr><td>mean</td><td>18.321884</td></tr><tr><td>std</td><td>7.717258</td></tr><tr><td>min</td><td>6.060000</td></tr><tr><td>25%</td><td>13.550000</td></tr><tr><td>50%</td><td>17.670000</td></tr><tr><td>75%</td><td>21.760000</td></tr><tr><td>max</td><td>49.240000</td></tr></table>		kapanis	count	3869.000000	mean	18.321884	std	7.717258	min	6.060000	25%	13.550000	50%	17.670000	75%	21.760000	max	49.240000
	kapanis																																				
count	3869.000000																																				
mean	2.387240																																				
std	1.416221																																				
min	0.430000																																				
25%	1.500000																																				
50%	2.040000																																				
75%	3.190000																																				
max	13.510000																																				
	kapanis																																				
count	3869.000000																																				
mean	18.321884																																				
std	7.717258																																				
min	6.060000																																				
25%	13.550000																																				
50%	17.670000																																				
75%	21.760000																																				
max	49.240000																																				
Galatasaray	Trabzonspor																																				
<table><tr><th></th><th>kapanis</th></tr><tr><td>count</td><td>3869.000000</td></tr><tr><td>mean</td><td>2.25734</td></tr><tr><td>std</td><td>1.19909</td></tr><tr><td>min</td><td>0.88000</td></tr><tr><td>25%</td><td>1.47000</td></tr><tr><td>50%</td><td>1.86000</td></tr><tr><td>75%</td><td>2.55000</td></tr><tr><td>max</td><td>6.88000</td></tr></table>		kapanis	count	3869.000000	mean	2.25734	std	1.19909	min	0.88000	25%	1.47000	50%	1.86000	75%	2.55000	max	6.88000	<table><tr><th></th><th>kapanis</th></tr><tr><td>count</td><td>3869.000000</td></tr><tr><td>mean</td><td>1.645849</td></tr><tr><td>std</td><td>0.992944</td></tr><tr><td>min</td><td>0.500000</td></tr><tr><td>25%</td><td>0.830000</td></tr><tr><td>50%</td><td>1.450000</td></tr><tr><td>75%</td><td>2.160000</td></tr><tr><td>max</td><td>6.080000</td></tr></table>		kapanis	count	3869.000000	mean	1.645849	std	0.992944	min	0.500000	25%	0.830000	50%	1.450000	75%	2.160000	max	6.080000
	kapanis																																				
count	3869.000000																																				
mean	2.25734																																				
std	1.19909																																				
min	0.88000																																				
25%	1.47000																																				
50%	1.86000																																				
75%	2.55000																																				
max	6.88000																																				
	kapanis																																				
count	3869.000000																																				
mean	1.645849																																				
std	0.992944																																				
min	0.500000																																				
25%	0.830000																																				
50%	1.450000																																				
75%	2.160000																																				
max	6.080000																																				

ÖZGEÇMİŞ

Kişisel Bilgiler

Adı ve Soyadı : Kübra KESKİN

Eğitim Durumu

Lisans Öğrenimi : Süleyman Demirel Üniversitesi - Ekonometri Bölümü (Genel Not Ortalaması: 3.25)

Yüksek Lisans Öğrenimi: Süleyman Demirel Üniversitesi - Ekonometri Anabilim Dalı (Genel Not Ortalaması: 3.93)

Yabancı Dil ve Düzeyi

1.İngilizce - Orta

Bilimsel Yayınlar ve Çalışmalar

1. Keskin, K. ve Gündoğdu, Ö. (2022). *Share price forecast and evaluation of four big football clubs with long short term memory model*. ECONANADOLU 2022: Anadolu Uluslararası İktisat Kongresi. Anadolu Üniversitesi, Eskişehir, 13-15 Mayıs, Eskişehir, 206.

2. Keskin, K. ve Gündoğdu, Ö. (2022). *Dört büyük futbol kulübüne ait puan ve hisse senedi fiyatlarının nedensellik ilişkisi ele alınarak uzun kısa süreli bellek modeli ile çok adımlı öngörüsü*. 21. Yüzyılda İktisadı Anlamak: Güncel Ekonometrik Zaman Serileri Çalışmaları. 8. Bölüm, 1. Baskı, Gazi Kitabevi.



ORCID: 0000-0002-4465-4554