

Derleme Makalesi-Review Article

Finansal Zaman Serilerini Tahminlemede Kullanılan Yöntemlere Genel Bir Bakış

A General Review of the Methods Used Financial Time Series Forecasting

Nuh Yurduseven^{1*}, Ahmet Anıl Müngen²

Geliş / Received: 18/03/2022

Revize / Revised: 14/06/2022

Kabul / Accepted: 19/06/2022

ÖZ

Geçmişte olduğu gibi günümüzde de yatırımcılar için finansal verilerin trendinin tahmin edilebilmesi ve bu bilgi kullanılarak bir finansal strateji oluşturulması oldukça önemlidir. Fakat günümüzde hızlı internet bağlantıları ile finansal verilerin hızlı ulaşması ve bilişim ve bulut sistemlerindeki gelişmeler, finansal tahminlemek için yapay zekâ algoritmalarının kullanılması bu alanda rekabeti artırmaktadır. Fintech içinde portföy yönetimi gibi alanlarda yapay zekâ uygulamalarının kullanım payı gittikçe artmaktadır. Bu çalışmanın amacı finansal zaman serisi verileri tahminlemek için yapılan daha önceki akademik çalışmaları derlemek, zaman serilerinin tahmin etmek için kullanılan yapay zekâ algoritmalarını açıklamak ve tahmin edilen bazı finansal veri tiplerini ve bağımlılıklarını irdelemektir. Çalışma sonunda incelenen makalelerde kullanılan tekniklerin yeterlilikleri ve hangi veri tipi için hangi metodun daha başarılı sonuçlar verebileceği gibi çıkarımlar yapılmıştır.

Anahtar Kelimeler- *Finansal Zaman Serisi, Öngörü, Yapay Zekâ, Veri Madenciliği*

ABSTRACT

As in the past, it is very important for investors to be able to predict the trend of financial data and to create a financial strategy using this information. However, nowadays, rapid access to financial data with fast Internet connections, developments in informatics, and cloud systems, the use of artificial intelligence algorithms for financial forecasting increase competition in this field. The share of artificial intelligence applications in areas such as portfolio management in Fintech is increasing. The aim of this study is to compile previous academic studies to predict financial time series data, to explain artificial intelligence algorithms used to predict time series, and to examine some predicted financial data types and their dependencies. At the end of the study, inferences were made such as the adequacy of the techniques used in the articles examined and which method could yield more successful results for which data type.

Keywords- *Financial Time Series, Forecasting, Artificial Intelligent, Data Mining*

^{1*}Sorumlu yazar iletişim: 200801001@ostimteknik.edu.tr (<https://orcid.org/0000-0001-7108-4940>)

Yazılım Mühendisliği, Mühendislik Fakültesi, Ostim Teknik Üniversitesi, Yenimahalle, Ankara, Türkiye

²İletişim: ahmet.mungen@ostimteknik.edu.tr (<https://orcid.org/0000-0002-5691-6507>)

Yazılım Mühendisliği, Mühendislik Fakültesi, Ostim Teknik Üniversitesi, Yenimahalle, Ankara, Türkiye

I. GİRİŞ

Finansal verilerin analiz edilip kısa veya uzun vadeli olmak üzere tahminleme çalışmaları uzun zamandır yapılmaktadır. Finans alanında temel ve teknik analizler bir işletmenin hisse senedi, bir emtianın değeri ve bir miktar metallerin ve dövizin karşılığının tahmin edilmesinde sıkça kullanılmaktadır.

Finansal sistemde temel analiz, ekonomik ve finansal faktörleri inceleyerek bir menkul kıymetin değerini ölçme yöntemidir[1]. Temel analistler, şirketin borsadaki finansal durumunu ve performansını anlamaya çalışır, ekonominin durumu ve endüstri koşulları gibi makro ekonomik faktörlerden şirketin yönetiminin etkinliği gibi mikro ekonomik faktörlere kadar güvenliğin değerini etkileyebilecek her şeyi inceler. Temel analistlerin çalışmaları şirketin finansal oranlarına dayandırır. Bulunan değerler ile şirketin finansal durumunu sektördeki rakipleri ile karşılaştırmak için kullanılır. Bu değerler arasında işletme sermayesi oranı, öz kaynak kârlılığı ve hisse başına kazanç gibi metrikler vardır.

Şirketin değerini belirlemek için temel analiz ile dikkate alınması gereken farklı faktörler de vardır. Bu faktörlerden bazıları hükümet politikaları ve haber bültenleridir. Temel analiz ile incelenen tüm faktörler, yatırımcıların şirketin hisse senedi fiyatının değeri ile ilgili yorum yapmasına yardımcı olur.

Teknik analiz, piyasa yapılarını belirlemek ve gelecekteki fiyat hareketlerini tahmin etmek için geçmiş fiyat verilerini kullanan bir finansal analitik uygulamadır [2]. Teknik analiz yöntemleri temelde hisse senetlerinin fiyatı ile bu senetlerin hacmine dayanmaktadır. Teknik analistler, teknik göstergeleri kullanarak geçmiş verilerden motifler çıkartmaktadırlar. Teknik göstergelerden bazıları hacim, momentum, oynaklık ve eğilim grafiklerdir. Bu hesaplamalar ve çizelgeler, yatırımcıların alım satım sinyallerini tanımasını sağlar.

Teknik Analizler yalnızca geçmiş piyasa verilerine (fiyat ve hacim) dayanan nesnel metodolojilerdir. Uzmanların bir değerlendirmeye varmak için bir şirketin operasyonlarını, yönetimini ve gelecekteki beklentilerini dikkate alınması gerekir. Başlangıçta Dow Teorisi¹ yoluyla geliştirilen çoğu teknik analizin temeli, hisse senedi piyasası fiyatlarının yönlü (yukarı, aşağı veya yana) hareket edeceği ve bu eğilimleri belirlemek için geçmiş hareketlerin kullanılabilmesi teorisi [3].


Finansal değer tahmin yaklaşımları, iki ayrı ana başlıkta incelenir. Bunların her biri farklı bilgi türlerine dayanır. Temel analizde yatırımcılar, bir şirkete ait finansal verileri, örneğin şirketin satışlarını, karlarını, borçlarını ve temettülerini inceleyerek hisse senedinin gerçek değerini tahmin eder. Temel göstergeler analiz için kullanılır. Buna karşın temel göstergeleri kullanarak fiyat hareketlerini anlayan modeller oluşturmak daha zor olduğundan, temel analize dayalı modeller literatürde daha az bulunur[5]. Teknik analiz ise hisse senetlerini, piyasa faaliyeti tarafından oluşturulan fiyat eğilimlerini analiz eder ve değerlendirir. Teknik analiz için gereken bilgiler düzenli olarak yayınlanır. Bu sebeple kısa vadeli tahminler için yaygın olarak kullanılır ve modelleme yapılabilir.

Finansal teknoloji (FinTech), finansal hizmetlerin sunumunu ve kullanımını iyileştirmeyi ve otomatikleştirmeyi amaçlayan yeni teknolojiyi tanımlamak için kullanılır[6]. FinTech, bilgisayarlarda ve giderek artan bir şekilde akıllı telefonlarda kullanılan özel finansal yazılım ve algoritmalarıdır. Kullanıcılar bu yazılımlar ile şirketlerin ve tüketicilerin finansal operasyonlarını, süreçlerini yakından takip eder. FinTech, kelime olarak "finansal teknolojinin" bir birleşimidir[6]. Son yıllarda makine öğrenmesi, derin öğrenme gibi konular finansal teknolojiler içerisinde daha sık kullanılmıştır. Mediant'a göre FinTech'teki yapay zekâ (AI) uygulamalarının 2022 yılına kadar 7 milyar dolara kadar çıkacağı tahmin ediliyor [7]. Yine Globennewswire'da yer alan bir habere göre ESOMAR tarafından paylaşılan verilerde 2021 yılında FinTech marketi içinde AI uygulamalarının yaklaşık 10,1 milyar dolara ve 2022 tahmininin 11,76 milyar dolar olacağı tahmin ediliyor. FinTech pazarı içinde yapay zekâ uygulamaları tahmin edilenden çok daha hızlı büyüdüğü söylenebilir. Aynı rapora göre 2022-2032 10 yıllık periyodunda 54 milyar dolara ulaşacağı ve marketin %16.5 'lik bir bölümünü oluşturacağı tahmin ediliyor[8].


Trend terimi finansal veriler için sıklıkla kullanılır ve serinin uzun vadedeki yönünü belirtir[9]. Zaman serileri zamana bağlı olarak yukarı veya aşağı yönlü olabilen değişime uğrayan veri tipleridir. Bu veriler trend etkisi, konjonktürel hareketler, mevsimsel hareketler, rassal etki ve durağanlık bileşenlerinden oluşurlar. Seri uzun vadede artma veya azalma eğilimine sahip olabilir. Konjonktürel (düzensiz) hareketler zaman serisinin trend çizgisi etrafındaki dalgalanmalarını ifade eder. Mevsim etkisi veya mevsimsel hareketler belirli zaman aralıklarında seri trendinin değişmesi, birbirini izleyen dönemlerde serinin benzer şekilde davranması olarak ifade

¹Dow Teorisi, Charles Dow tarafından açıklanan en eski ve en bilinen teknik analiz teorilerinden biridir. Teoriye göre ortalamalar her şeyi hesaba katar ve piyasa hareketi ana(majör) trend, ikincil trend ve minör trend olmak üzere üç şekildedir [3], [4].

edilebilir. Rassal veya düzensiz etkiler belli olmayan bazı durumların seri üzerindeki önceden tahmin edilemeyen değişimler yaratmasına denir. Durağanlık ise zaman serilerinde zaman içinde varyans değerinin sabit olması gerektiğini ifade eder. Buna göre zaman içinde durağan olan zaman serilerinin analizi edilmesi ve tahminlenmesi mümkündür. Belirli bir zaman içerisinde durağan olmayan seriler için matematiksel bir formül yazılması mümkün değildir.



Şekil 1. Zaman serisi bileşenleri [10]



Şekil 2. Zaman serisi bileşenleri [11]

Bu çalışma;

- Finansal zaman serisi verileri ve özellikleri,
- Finansal zaman serisi tahminlemede kullanılan yapay zekâ metotlarının tipleri ve özellikleri,
- Finansal zaman serisi tahminlemek için önceden hazırlanmış çalışmalarda hangi tip veriler üzerinde hangi teknikler kullanıldığı ve başarı oranları,
- Konu ile ilgili yapılacak çalışmalarda bu tekniklerin uygulanması ile ilgili tavsiyeler içerir.

Bu çalışmada bu konuda yapılan çalışmalarda kullanılan zaman serisi verileri üzerinde, uygulanan tekniklerin başarımı ve performans kriterlerine bakılmıştır. Bu çalışmanın amacı bu konuyla ilgili gelecek çalışmalarda kullanılmak üzere geçmiş çalışmalarda kullanılan tekniklerin başarım ve kullanılan verinin hangi finansal zaman serisi veri tipinden olduğu gibi parametrelere göre değerlendirilip eşleştirilerek bir sınıflandırma yapmaktır. Bu bağlamda makalenin ikinci bölümünde bazı finansal zaman serisi verilerine değinip bu veriler hakkında temel ve teknik anlamda genel bilgi verilmesi amaçlandı. Üçüncü bölümde finansal zaman serisi tahminlemek için kullanılan yapay zekâ metotları teknik açıdan ele alındı ve bu yöntemlerin hangi problem tipinde sıklıkla tercih edildiği gibi konular üzerinde duruldu. Dördüncü bölümde literatürde yapılan çalışmalar üzerine geniş bir perspektifle bakılarak bu konuda yapılan çalışmalar incelendi. Özellikle dikkat çekici sonuçları olan başarılı çalışmalar okuyucu için detaylı biçimde incelenip ve detayları verilmiştir. Son bölümde bu çalışmadan çıkarımlar ve bunlar üzerinde değerlendirme yapıldı. Bu çalışma gelecek çalışmalar için önemli bir başucu kaynağı olması için hazırlanmıştır.

II. FİNANSAL ZAMAN SERİLERİ VE BAĞIMLIKLARI

Finansal zaman serileri gün, saat ve yıllara göre bir finansal değerini gösteren verilerdir. Bunlar bir hisse senedinin, devlet tahvilinin veya bir emtianın zamana bağlı yukarı veya aşağı yönlü trend çizgilerini takip eden verileri olabileceği gibi itibari paralar dışında Web 3.0 ile gelen kripto değerlerin zaman içindeki değişimlerini de ifade edebilir. Ayrıca ülkelerin ekonomik göstergeleri de global pazarı etkiler. Bu tip verilerin önceden tahmin edilebilmesi hem bireysel hem kurumsal olarak finansal strateji belirlemek için oldukça önemli bir yetenektir ve bu anlamda yetenekli kurum veya bireyler finansal açıdan daha başarılı olabilir. Temel ve teknik analiz gibi finansal analizlerin yanında makine ve derin öğrenme gibi girdi ve çıktı değerleri üzerinde çalışarak

uygun matematiksel modeli hazırlayan algoritmalar bu problemin çözümü için kullanılabilir. Bu bölümde kullanılacak algoritmalara verilen girdiler üzerinde durulması amaçlanmaktadır. Kullanılacak girdi verileri ve aralarındaki ilişkiler modelin öğrenme ve test metriklerine göre performansını doğrudan etkilediği için bu bölümde bu veriler ve bağımlılıkları incelenmiştir [12].

A. Hisse Senedi Verileri

Hisse senedi verileri bir şirketin piyasadaki değerini ifade eden verilerdir ve bu veriler zaman içinde değişik trendlere göre harekete edebilir [13]. Dünyanın birçok borsasında insanlar hisse senedi alıp satarak kâr payı kazanmak için çeşitli yöntemlere başvurmaktadır. Hisse senetleri şirketin büyüklüğüne veya küçüklüğüne bağlı olmaksızın farklı sayıda veya farklı değerlere sahip olabilir. Borsalarda hisse senetleri satın almak şirkete finansal ortak olmak anlamına gelir. Eğer hisse temettü dağıtan bir hisse ise yıl sonunda şirket elde ettiği karı ortaklar arasında hisse büyüklüklerine yani şirketteki pay oranlarına göre dağıtılır [14]. Temettü hissesi değil ise kâr payı dağıtılmaz. Eğer şirket faaliyetleri iyiye gidiyorsa şirket hisselerine olan talep artar ve hisseler değerlendirilir. Veya tam tersi olabilir. Bu veriler aslında şirketin kamuoyundaki itibarı, finansal istikrar, ekonomik yapı, muhasebe yapısı, hükümet politikaları veya tüm dünyada şirketin faaliyet gösterdiği sektördeki durağanlık veya volatilité gibi bağımlılıklara göre artar veya azalır. Bu veriler doğrusal olmayan verilere örnektir ve bu tip veriler önceden oluşan koşullara duyarlılık gösterirler, yani sınırsız hafızaya sahiptirler. Eğer bir hisse senedi serisinde uzun hafızadan kaynaklanan bir süreklilik varsa eski ve yeni veriler arasında bir korelasyon ilişkisi vardır [15]. Yapılan bir çalışmada Avrupa borsalarının bağımlılıkları çok yüksek oranda değiştiğindeki davranışları incelenmiş ve bazı borsa hareketleri arasında korelasyon olduğu keşfedilmiştir [16]. Çalışmada Almanya, Birleşik Krallık, Fransa, Hollanda, İtalya borsalarına ait 1973-2001 arası veriler kullanılmıştır ve bir borsada ortaya çıkan aşırı büyük bir hareketin (aşağı veya yukarı) diğer borsalar ile ne kadar güçlü bir bağlantıya sahip olduğu ortaya çıkarılmıştır. Aynı şekilde bu makalenin konusu olan yapay zekâ yöntemleri ile zaman serisi tahmin eden bir diğer çalışmada aynı borsada işlem gören 3 hisse için bir CNN modeli oluşturulup ilk hisse ile değeri verisiyle eğitilen modelin diğer iki hisse verisi üzerinde test edildiğinde oldukça iyi bir performans ile gelecek verileri tahmin ettiği görülmüştür. Literatüre yapılan çalışmalar çoğunlukla hisse senedi verilerinin tahmin edilmesi üzerine yoğunlaşmıştır. Sezer ve arkadaşlarının yaptığı sistematik inceleme çalışmasında 2005-2019 yılları arasında derin öğrenme metotları ile tahmin etme çalışmaları incelenmiş ve arxiv.org'dan alınan istatistiklerde hisse senedi verilerinin tahmin edilmesi isimli konunun bilimsel araştırma konusu olarak oldukça popüler olduğu görülmüştür [17]. Bu tip çalışmalar günümüzde de popülerliğini sürdürmektedir. Sonuç olarak hisse senetleri fiyatlarının birçok enstrümana bağımlı olduğu görülebilmektedir ve bunları doğru ve etkili kullanmak tahmin eden modelin başarımını doğrudan olumlu yönde etkileyecektir.

B. Forex Verileri

Forex borsaları, yabancı ülke paralarının veya çeşitli değerli metal ve emtiaların işlem gördüğü borsalardır. Forex piyasaları dünyanın işlem hacmi en yüksek ve en likit piyasasıdır ve menkul kıymetler haftada 5 gün 24 saat işlem görür [18]. Günlük işlem hacmi trilyonlarca dolardır. Bu kadar yüksek hacimde verilerin tek bir piyasada olması birçok yatırımcılara birçok fırsat sunmaktadır ve sonuç olarak yatırımcılar açısından iyi stratejiler belirlemek yüksek kar elde etmek için son derece önemlidir [17]. Yatırımcılar için birçok online platform bulunmaktadır. Bu servisler içinde portföy yönetiminde yapay zekâ algoritmaları sıklıkla kullanılır. Forex itibarı paralar, emtialar, değerli metallerin fiyatlandığı bir piyasa olduğu için bağımlılıklara sahiptir. Forex piyasasında işlem gören itibarı paralar, değerli metaller veya emtialar hükümet politikaları, ekonomik yapı, muhasebe yapısı, ekonomik veriler gibi hisse senedi ile benzer bağımlılıklara sahip olmakla birlikte yine hisse senetleri gibi borsa içi dinamiklere de bağımlılık gösterirler. Bu sebeple bu tipte finansal verilerin tahmin edilebilmesi için geniş yelpazede finansal değerlendirme yapılmalı, iç ve dış dinamikler bu tip verilerin tahmin edilebilmesi için kullanılmalıdır.

C. Endeks Verileri

Endeksler bir hisse, bir tahvil, emtia veya bir pazarın gibi finansal varlıkların iniş ve çıkışlarını izler ve bu piyasanın sağlığını belirlemek için hızlı ve etkili bir yoldur [19]. Örneğin borsa endeksleri içinde hisse senedi bulunduran ve bunların farklı ağırlıklar ile hesaplanması sonucunda bulunan değerlerdir. Bu ağırlıklar her hisse senedi için farklılık gösterebilir. En bilinen borsa endeksleri S&P 500, Dow Jones, Nasdaq 100, Russel 200 veya Türkiye'de Borsa İstanbul içinde BIST100, BIST30 gibi borsa endeksleri mevcuttur. Endeks ağırlıklandırma için farklı modeller mevcuttur fakat en yaygın kullanılan üç model şunlardır [20]:

- Piyasa Değeri Ağırlıklı
- Eşit ağırlıklı
- Fiyat ağırlıklı

Piyasa değeri ağırlıklı bir endeks yüksek değerli şirketler endeksin performansına diğerlerinden daha fazla etki eder. Eşit ağırlıklı modelde tüm hisseler aynı şekilde incelenir ve endeks performansına etkileri aynıdır. Fiyat ağırlıklı ise şirket hisselerinin fiyatlarına göre şirketler ağırlıklandırılır ve hisse fiyatı fazla olan şirketler endeks üzerinde daha etkilidir.

Bu bağlamda endeksler yatırımcılar için borsa endeksleri ve küresel korku endeksi olarak tanımlanan VIX endeksi piyasayı analiz edebilmek, yatırım için uygun zemin olup olmadığını anlayabilmek için son derece önemli göstergelerdir[21].

Endeks değerleri için zaman serisi gösterimi oldukça fikir vericidir ve bu çalışmanın ana konusu olan zaman serisi öngörme açısından bu verilerde incelenebilir. Her endeksin farklı ağırlıklandırma metotları olması bu endekslerin her birinin kendine has bağımlılıklara sahip olduğunu gösterebilir. Ayrıca endeks türüne göre değişmekle birlikte endekte izlenen finansal değerlerin bağımlılıkları endekslerin de bağımlılıkları olduğu sonucuna varılabilir.

III. ZAMAN SERİSİ TAHMİNLEMEDE KULLANILAN YAPAY ZEKA METOTLARI

A. ARIMA(AR-I-MA)

Doğrusal durağan stokastik tahmin modelleri otoregresif (AR) modeller, hareketli ortalama(MA) ve ikisinin birleşmesi ile oluşan bütünleşik otoregresif hareketli ortalama(ARIMA) modelleridir[22]. ARIMA modeli durağan olmayan zaman serilerinin tahmininde kullanılan bir modeldir. Finansal veriler durağan olmayan zaman serilerine örnektir. Bu serilerin durağanlığı trend, mevsimsel ve konjonktürel dalgalanmalar ve tesadüfi sebepler gibi etkenler tarafından bozulur. Zaman serilerini modellemek için hareketli ortalama, üstel yumuşatma ve ARIMA dahil olmak geleneksel istatistiksel modeller kullanılabilir. Gelecekteki değerler geçmiş verilerin doğrusal fonksiyonları olarak ifade edildiğinden bu modeller doğrusaldır.

Zaman serisi tahmin modelleri literatürde sıklıkla gelecekteki talebi tahmin edebilmek amacıyla kullanılır. Bu modellerin geçmişine ve doğuşuna baktığımızda Miller ve Williams [23], tahmin doğruluğunu artırmak için modellerinde mevsimsel faktörleri karıştırmış, mevsimsel faktörler çarpımsal modelden hesaplanmıştır ve Hyndman, [24] mevsimsel ARIMA hipotezi altında trend ve mevsimsellik arasında farklı ilişkiler uygulayarak Miller ve Williams'ın çalışmalarını genişletmiştir.

Bir ARIMA modeli, ARIMA(p,d,q) olarak ifade edilir. Bu gösterimdeki:

- p, otoregresif terimlerin sayısıdır;
- d farkların sayısıdır; ve
- q hareketli ortalamaların sayısıdır.

1) Otoregresif Süreç(AR): Otoregresif modeller, Y_t 'nin önceki değerlerin doğrusal bir fonksiyonu olduğunu varsayar[25]. Bu, eşitlik (1)'de şu şekilde ifade edilmiştir. ARIMA (1,0,0) olarak da ifade edilebilir.

$$Y_t = a_1 Y_{t-1} + \varepsilon_t \quad (1)$$

Her gözlem rastgele bir değişkenden oluşmaktadır (ε_t bunun ifade eder. Her gözlem bir önceki gözlemin doğrusal bir kombinasyonundan oluşmaktadır. Ayrıca a_1 ile ifade edilen değer öz regresyon katsayısıdır.

2) Entegrasyon Süreci(I): Zaman serilerinin davranışı, bazı süreçlerin ortaklaşa etkisinden etkilenebilir. Örneğin hisse senetlerinin ortalama seviyesi, hisse senetleri arasındaki süre boyunca anlık değişikliklerin ortak etkisine bağlıdır. Kısa vadeli hisse senedi değerleri, bu ortalama değer etrafında büyük beklenmedik durumlarla dalgalanabilse de uzun vadede serinin seviyesi değişmeyecektir. Faaliyetin kümülatif etkisi tarafından belirlenen bir zaman serisi, bütünleşmiş süreçler sınıfına aittir. Bir serinin davranışı düzensiz olsa bile, bir gözlemden diğerine farklar nispeten düşük olabilir. Farklı zaman aralıklarında gözlemlenen bir süreç için sabit bir değer etrafında salınım hareketi yapılabilir. Bütünleşmiş bir süreç için farklılıklar serisinin durağanlığı, zaman serisinin istatistiksel analiz yönünden bakıldığında çok önemli bir özelliktir[25].

Bütünleşmiş süreçler, durağan olmayan serilerin ilk örneğidir. 1. dereceden bir türev, Y 'nin iki ardışık değeri arasındaki farkın sabit olduğunu varsayar. Bütünleşmiş bir süreç eşitlik (2) ile şu şekilde tanımlanabilir. ε_t rastgele pertürbasyonu simgeler. ARIMA (0,1,0) olarak da ifade edilebilir[25].

$$Y_t = Y_{t-1} + \varepsilon_t \quad (2)$$

3) Hareketli Ortalamalar (MA): Hareketli bir ortalama alma işleminin mevcut değeri, bir veya daha fazla önceki bozulma ile mevcut bozulmanın doğrusal bir birleşimidir[25]. Hareketli ortalama sayısı, mevcut değere gömülü olan önceki dönemlerin sayısını göstermektedir. Böylece, hareketli bir ortalama eşitlik (3) ile tanımlanır. ARIMA (0,0,1) olarak da ifade edilebilir.

$$Y_t = \varepsilon_t - \Phi_1 \varepsilon_{t-1} \quad (3)$$

Bu durumda p. mertebeden otoregresif süre. ARIMA(p,0,0) formülü eşitlik (4)'teki gibi ifade edilebilir.

$$Y_t = \beta_1 Y_{t-1} + \beta_2 Y_{t-2} + \dots + \beta_p Y_{t-p} + \varepsilon_t \quad (4)$$

ARIMA(p,d,q) formülü ise eşitlik (5)'de görülebilir. Alfa(α) terimi modelin tahmin ettiği kesme terimini ifade eder.

$$Y_t = \alpha + \beta_1 Y_{t-1} + \beta_2 Y_{t-2} + \beta_3 Y_{t-3} + \dots + \beta_p Y_{t-p} \varepsilon_t + \Phi_1 \varepsilon_{t-1} + \Phi_2 \varepsilon_{t-2} + \dots + \Phi_q \varepsilon_{t-q} \quad (5)$$

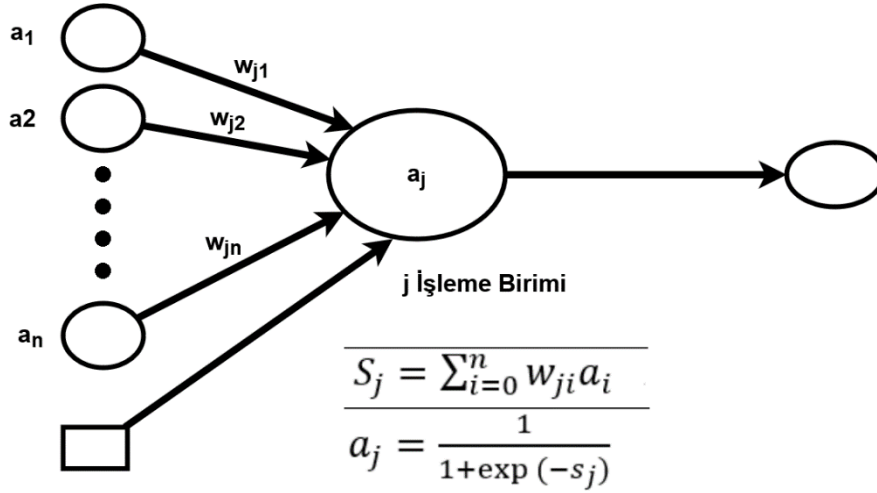
B. Üstel Yumuşatma

Üstel yumuşatma tekniği oldukça sık kullanılan ve iyi sonuçlar veren zaman serisi tahminleme metotlarından biridir. Metot verideki son değişimleri ve trendleri ele alarak öngörülerin sürekli olarak güncelleştirildiği dinamik çalışan bir modeldir[26]. Bu modele göre ileri yönlü olarak oluşan yeni hareketlere uyum sağlayabilmek amacıyla modele üstel olarak azalan ağırlıklar verilir ve bir çeşit ağırlıklı ortalama alınır [27]. Çünkü bu yöntemin çalışma prensibine göre daha yeni veriler eski verilere oranla veriyle ve tahmin ile daha alakalıdır. Bu sebeple daha yüksek ağırlıklar verilir. Üstel yumuşatma yöntemi bir regresyon doğrusu ile açıklanamayan, zaman içinde değişen deterministik ve stokastik trende sahip zaman serileri ile kullanılır. Bu yöntem doğası itibarı ile yakın dönemli değişimlere daha çok öncelik verdiği için çok uzun dönemli tahminler için uygun olmayabilir.

C. Yapay Sinir Ağları


Yapay Sinir Ağları (YSA) insan beyni esas alınarak geliştirilmiş, birbirleri ile ağırlık bağlantı ilişkisi bulunan elemanların bir araya gelmesiyle oluşturulmuş paralel ve karmaşık bilgi işleme yapıları olarak adlandırılmaktadır[28]. Ağ yapısının en ayırıcı özelliği, tecrübe odaklı öğrenilme yeteneğine sahip olmasıdır. Yıldırım ve arkadaşları önceki verilerden hareketle bunu başarabilen ağırlık öğrenme yolu ile yeni bilgiler elde etme ve oluşturabilme gibi fonksiyonel özellikleri sayesinde tahmin modellemelerinde sıklıkla kullanılan bir yapı haline geldiğini yaptıkları çalışmada ortaya koymuşlardır[29].

Bir sinir ağı, orijinal olarak beyindeki nöronların biyolojik mekanizmalarından esinlenen bir öğrenme modelidir. Yapı, esasen bağlantılı düğümler ve kenarlar veya "nöronlar" ve "ağırlıklar" ile bir ağ sisteminin yapısıdır. Nöronlar, girdi birikiminin çıktının "ateşlenmesi" ile sonuçlandığı beyinde görülen sinapslarla aynı fikre dayanır. Buradaki girdi, modelin girdisi (tipik olarak gerçek sayılar) tarafından belirlenir ve nöronun ağırlıkları ve aktivasyon fonksiyonları aracılığıyla işlenir. Aktivasyon fonksiyonu daha sonra ya orta seviyede ya da modelin nihai çıktısı olarak bir çıktı değeri ile sonuçlanır. Sistem, girdi örneklerini sırayla dikkate alarak ve daha doğru çıktılar elde etmek için kenarlar arasındaki ağırlıkları ayarlayarak öğrenir. Çıktı türleri, sınıflandırma veya regresyon değerleri olabilir.



Şekil 3. Algılayıcı modeli [30]

1) Çok katmanlı algılayıcı: Çok katmanlı algılayıcı ağlar veya Multilayer Perceptron (MLP), girdi katmanı, gizli katmanlar ve çıktı katmanı olmak üzere çok sayıda katmandan oluşan bir yapay sinir ağı tipidir [31]. Bu tip ağlarda en uygun gizli katman sayısı ve bulundurduğu nöron sayılarının belirlenmesi için bir metodoloji yoktur. Araştırmacı kendi metodu ile bu parametreleri belirleyebilir. Şekil 3'te girdi ve çıktı nöronları arasındaki gizli katmanlar ve aralarında bağlantılar görülebilmektedir. Her bağlantı bir ağırlığa sahiptir. Şekil 4'te bir ileri beslemeli birçok katmanlı algılayıcı ağı görülebilmektedir. Ağırlıklar ve değerler çarpılarak toplam fonksiyonu ile toplanır, sonrasında seçilen aktivasyon fonksiyonu uygulanarak bir sonraki katmandaki nöronlara girdi olarak tekrar verilir.



Şekil 4. Çok katmanlı Algılayıcı modellemesi [32]

İleri beslemeli algoritmada ağırlıkların her iterasyonda güncellenmesi için geri yayılım algoritması kullanılır. Ağın her bir işlem elemanı, transfer fonksiyonu türevinin tüm gizli katmanlardan ilk katmana geriye doğru yayılması yoluyla uygulanan uyumsuzluklar için bir cezalandırma uygulanır. Bu ancak geri yayılım algoritması ile mümkün olabilir. Geri yayılım algoritması hatayı geriye doğru dağıtarak modelin ağırlıklarını güncellemeye ve daha hızlı ve etkin bir eğitim için kullanılan bir algoritmadır [33]. Maliyet fonksiyonu ise gerçek ve ağın tahmin ettiği değerleri ölçmek için kullanılır. Bu şekilde maliyet fonksiyonunu değerini azaltmak için tüm

ağırlıklar güncellenir. Ağın tahmin edilen ve gerçek çıktıları arasındaki ortalama kare hatası (MSE) genellikle bir maliyet fonksiyonu olarak seçilir. Fakat birçok maliyet fonksiyonu bu iş için kullanılabilir.

Geri yayılımda, maliyet fonksiyonu genellikle türevsel iniş (gradientdescent) tekniği kullanılarak minimize edilir. Mevcut noktada maliyet fonksiyonunun negatif türevi boyunca yönü takip etmeye dayanır. Ancak, bazı dezavantajlar vardır[34]:


1. Maliyet fonksiyonunun yerel minimumu, yanlışlıkla istenen global minimum için alınabilir ve bu nedenle MLP'nin yanlış performansına neden olabilir.
2. İlgili hesaplamalar önemli zaman harcamaları gerektirir ve MLP'nin yakınsama hızını olumsuz etkileyebilir MLP'nin performans kalitesi de iç mimarisine bağlıdır.

Belirli miktarda düğüm ve katman, aktivasyon fonksiyonlarının tipi ve parametreleri, MLP'nin verilen problemi ne kadar iyi çözdüğünü önemli ölçüde etkileyebilir.

Bu tip ağ yapısında işlemler ileri yönlü olarak gerçekleşir ve son katmandaki nöronun çıktısı modelin tahmin ettiği değeri verir. Ağ yapısında W_n ile gösterilen değerler ağırlıklara karşılık gelir. Bu değerler ile girdi değerleri eşitlik (6)'da gösterilen toplam fonksiyonunda işleme tabi tutulur.

$$\text{Net} = \sum_{i=1}^n x_i * w_i \quad (6)$$

Eşitlik (6) 'da ki x değerleri girdi değerlerini, "w" ile gösterilen değerler ise ağırlıkları simgeler. Toplam işlemin sonucu "Net" toplam aktivasyon fonksiyonuna girdi olarak verilen değerdir. Her düğüm için ayrı ayrı hesaplanır. Bu işlemden sonra aktivasyon fonksiyonu uygulanır. Örnek bir aktivasyon fonksiyonu olarak sık kullanılan Sigmoid aktivasyon fonksiyonu Şekil 4'te verilmiştir. Görüldüğü gibi -2 ve 2 arasında değişken değerler alması -2 ve 2 veya 0-1 arasında değer alan girdiler üzerinde iyi bir öğrenme sağlayabileceğini göstermektedir. Ayrıca aktivasyon fonksiyonunun türevlenebilir ve türevinin sabit olmaması da gerekmektedir.




Şekil 5. Sigmoid aktivasyon fonksiyonu ve türevi [35]

$$f(x) = \sigma(x) = \frac{1}{1+e^{-x}} \quad (7)$$

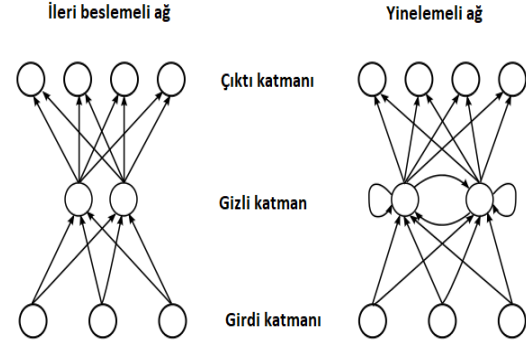
Eşitlik (7) sigmoid aktivasyon fonksiyonunun matematiksel gösterimidir. "e" ile ifade edilen değer Euler sabitidir.

D. Yinelemeli Sinir Ağları (RNN)

Yinelemeli sinir ağları veya RNN (Recurrent Neural Network) bir derin öğrenme modelidir. Derin öğrenme yöntemleri, zaman serisi tahmininde doğrusal olmama ve karmaşıklık gibi verilerin yapısını ve modelini belirleme yeteneğine sahiptir[36].

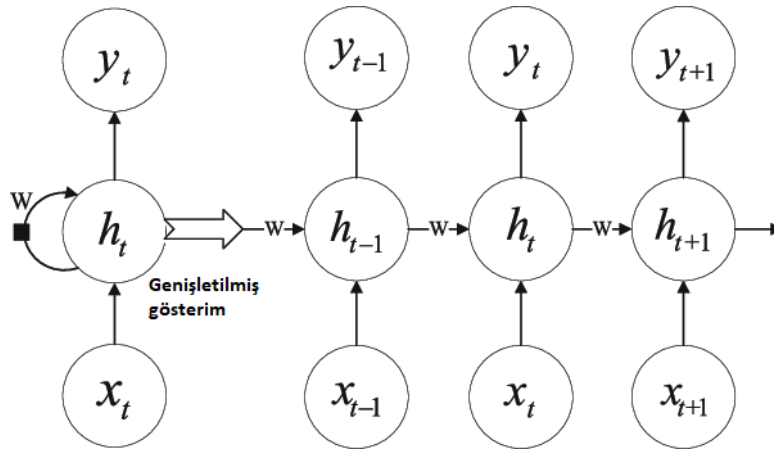


Şekil 6. RNN ve ileri beslemeli yapay sinir ağlarının nöronları arasında bağlantıların karşılaştırılması[37]



Şekil 7. RNN ve ileri beslemeli yapay sinir ağlarının nöronları arasında bağlantıların karşılaştırılması[38]

Şekil 6 ve Şekil 7’de görüldüğü gibi tekrarlayan sinir ağı modeli her iterasyonda bir önceki iterasyona ait gizli katman veya çıktı değerlerini yeniden gizli katman nöronlarına besler ve bu şekilde iteratif olarak devam eden süreçte önceki iterasyonlarda kullanılan ve çıktı alınan veriler ile sonraki iterasyon verileri arasındaki ilişkinin öğrenilmesi sağlanır. Bu özellikle doğal dil işleme ve zaman serisi verileri gibi bir önceki verinin bir sonraki veri hakkında bilgi sağladığı veri tiplerinde kullanılabilir bir yöntemdir. Şekil 8’de bu ilişki matematiksel ve şematik olarak gösterilmiştir.



Şekil 8. RNN hiyerarşisi [39]

Matematiksel olarak ifade edilmiş şekli aşağıdaki eşitlik (8)’de [38] görüldüğü gibidir. “P” fonksiyonu burada herhangi bir aktivasyon fonksiyonu olarak düşünülebilir. t zamanında h değeri bir t-1 zamanında h değeri ve t zamanında x değerinin aktivasyon fonksiyon çıkışına eşittir. “h”, hücre çıktı değeridir.

$$h_t = f(h_{t-1}, x_t) \quad (8)$$


Eşitlik (9)’daki [40] t zamanında h değeri elde edilebilmesi için eski gizli katman ağırlık değeri ile bir önceki iterasyondaki h değeri tanjant aktivasyon fonksiyonuna yeni iterasyonda eklenir.

$$h_t = \tan(w_{hh}h_{t-1} + w_{hx}x_t) \quad (9)$$

Eşitlik (10)’da [40] görüldüğü gibi t zamanında iterasyon çıktı değeri y ise t zamanındaki h değeri ile çıktı katmanı ağırlık değeri çarpımı ile bulunur.

$$y_t = w_{hy}h_t \quad (10)$$

1) Uzun-Kısa Süreli Bellek(LSTM):LSTM (Long-ShortTerm Memory)metodu tıpkı GRU (Gated Recurrent Unit) gibi yinelemeli sinir ağı yönteminin geliştirilmiş bir versiyonudur [41]. Uzun kısa vadeli bellek modeli, 1997’de Hochreiter ve Schmidhuber tarafından ortaya atılan bir tekrarlayan RNN sinir ağı modelidir[42]. Finansal zaman serilerinin ileri adım tahmini, yalnızca en son verileri değil, aynı zamanda önceki verilerinde bilinmesini gerektirir. Gizli katmanın kendi kendine geri bildirim mekanizmasından yararlanan RNN modeli, uzun vadeli bağımlılık problemleriyle başa çıkmada bir avantaja sahiptir, ancak pratik uygulamada zorluklar vardır. RNN'ningradyan kaybolması problemini çözmek için Sepp Hochreiter ve Jurgen Schmidhuber 1997’de LSTM modelini önerdi [42].



Şekil 9. LSTM blok mimarisi[43]

Şekil 9’da bir LSTM hücre modeli görülebilmektedir. Bu hücre modelinde kullanılan girdi, çıktı ve unutmaya kapıları hücreyi klasik bir RNN modelinden ayıran en önemli farklılıklardan biridir. Bu kapılar sayesinde hücre bir önceki verinin önemli olup olmadığını ayırt edebilir. Burada unutmaya kapısında yapılan işlem eşitlik (11)’de [43] verilmiştir.

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (11)$$

Bu fonksiyon girdilerinden biri t-1 zamanında h değeri t zamanındaki x değeridir. Sigmoid fonksiyonu 0 veya 1 sonucu üretecektir. Eğer 1 sonucu üretilirse sonucu depolayacaktır.

Denkmlerde (12) (13) [43] girdi kapısında yapılan işlemleri gösterilmektedir.

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (12)$$

$$C_{tg} = \tanh(W_c[h_{t-1}, x_t] + b_c) \quad (13)$$

Hücrenin t zamanında giriş kapısından çıkan sonuç C vektörüdür. Daha sonra hücre durumunu belirlemek için elde edilen değerlerin çarpımları mantıksal olarak toplanır. Bu, aşağıdaki eşitlik (14)’te [43] ifade edilmiştir.

$$C_t = f_t * C_{t-1} + i_t * C_{tg} \quad (14)$$

Çıktı katmanında yapılan işlemler eşitliklerde (15) (16) [43] ifade edilmiştir.

$$o_t = \sigma(W_o[h_{t-1}, h_t] + b_o) \quad (15)$$

$$h_t = o_t * \tanh(C_t) \quad (16)$$

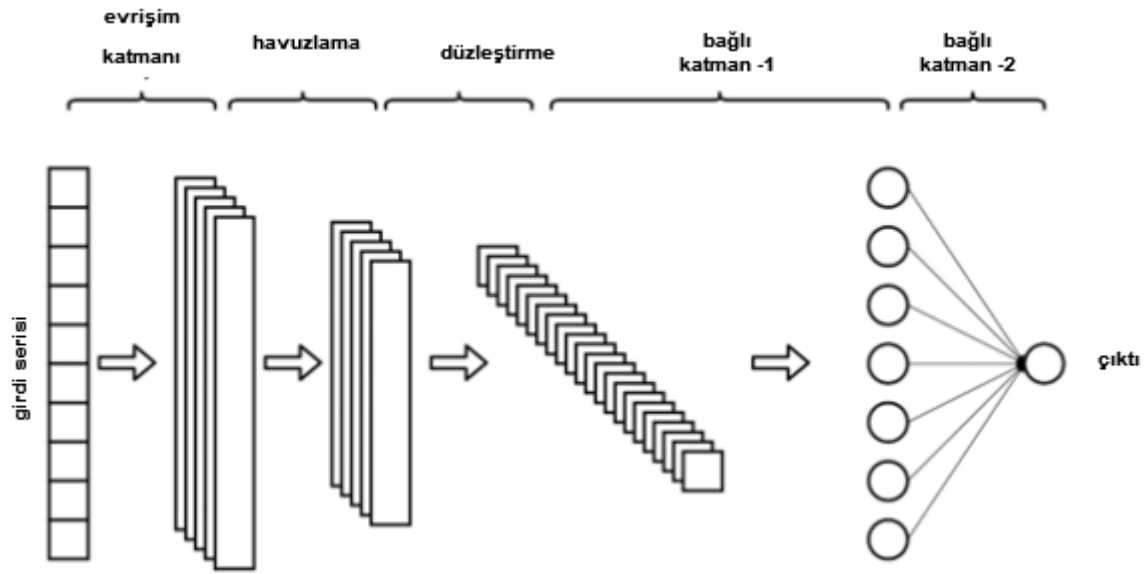
Çıktı katmanında tanjant fonksiyonu, -1 ile 1 arasında değer alır ve bu işlem ile saklanan bilginin ne kadarının kullanılacağı hesaplanmaktadır. Sigmoid fonksiyonun çıktısı ise 0 ile 1 arasında değer alır ve yeni gelen bilginin, kullanılıp kullanılmayacağına karar verir.

E. Evrişimli Sinir Ağları (CNN)

Bir CNN (Convolutional Neural Network), evrişim katmanları, havuzlama katmanları ve tamamen bağlı katmanlardan oluşan çoklu katmanlardan oluşur[44]. Evrişimli bir katmanda, her nöron bir önceki katmanın alt alanından girdi alır ve bir önceki katmanın alt alanına “alıcı alan” adı verilir. Her nöron bir önceki katmanın alıcı alanından gelen girdi değerlerine belirli bir fonksiyon uygular ve bir sonraki nörona iletmek için bir çıktı değeri

hesaplar. Uygulanan fonksiyon, ağırlıklar ve sapma ile belirlenir. Ağırlıkların vektörü ve yanlılık filtreler olarak adlandırılır. Ağırlıklar ve biaslar, sinir ağının eğitilebilir parametreleridir ve öğrenme süreci bu ağırlıkları ve biasları yinelenmeli olarak ayarlar. Evrişim katmanının filtre boyutu, beklenen çıktının boyutu ile aynı olmalıdır. Evrişim katmanının çekirdek boyutu, evrişim penceresinin genişlik ve yükseklik parametrelerini gösterir. Havuzlama katmanı, alt örnekleme yoluyla parametre sayısını ve hesaplamayı azaltmak için bir işlev kullanır.

Bir evrişimli sinir ağı özellik çıkarma ve problem çözücü olmak üzere bir sinir ağı olan iki parçadan oluşur. Sinir ağının özellik çıkarma ile bölümü evrişim (konvolüsyon), aktivasyon ve havuzlama katmanlarından oluşur [45]. Bu katmanların görevi aslında makine öğrenmesinde bulunmayan öznitelik çıkarma aşamasının da model tarafından yapılabilmesidir. Model verinin ayırt edilebilir özniteliklerini anlamlandırmaya çalışır ve sonraki aşamada bir tam bağlı bir sinir ağı ile tahminleme, sınıflandırma gibi denetimli öğrenme problemlerinin çözümü yapılır.



Şekil 10. Zaman serisi tahmin analizi çalışmasında kullanılan CNN modelinde konvolüsyon, havuzlama ve düzeltme katmanlarına sahip özellik çıkarımı bölümü ve ardından tam bağımlı sinir ağı modellemesi [46]

Şekil 10'daki gibi bir modelde konvolüsyon işleminde bir maske ile verinin filtrelenmesi sağlanır ve verinin türevleri elde edilir. Formülasyon gösterimi aşağıdaki gibi olabilir[17]. Burada (17) iki boyutlu görseller için konvolüsyon işlemi yapılıyor. I input görselleri, K çekirdeği, m ve n boyutları, i ve j değişkenleri ifade eder[17].

$$S(i, j) = (I * K)(i, j) = \sum_m \sum_n I(m, n)K(i - m, j - n) \quad (17)$$

Konvolüsyondan sonra aktivasyon işlemi gelir ve aktivasyon işlemi için genelde 0'dan küçük değerler için 0 değeri üreten ReLU aktivasyon fonksiyonu (18) tercih edilir[45].

$$y = \max(0, x) \quad (18)$$

Havuzlama işleminde katman ve boyut azaltılır. Düzeltme aşamasında matrisler dizilere sıkıştırılır ve tam bağlı sinir ağı ile denetimli öğrenme işlemi yapılır. Bu yöntemler özellikle öznitelik çıkarmanın zor olduğu görsel veriler üzerinde çok daha anlamlıdır.

Derin öğrenme alanında en çok kullanılan yöntemlerden biri olan evrişimli sinir ağları, birçok alanda, özellikle öznitelik çıkarımının oldukça zor olduğu problemlerde son derece faydalıdır[44]. Bir çok problem çeşidinde, özellikle görüntü işleme problemlerinde[44], [47]–[49] öznitelik çıkarma aşamasının zor olması sebebi ile tercih edilen bu yöntem, zaman serisi analizinde de oldukça sık kullanılmaktadır. Tıp alanında tümör sınıflandırma gibi problemlerde de faydalı olan bir sınıflandırıcıdır[50].

F. Facebook Prophet Algoritması

Prophet algoritması Facebook tarafından geliştirilen zaman serisi tahmin etmek için kullanılan başarılı algoritmalarından biridir. Prophet algoritması R ve python paketi olarak kullanıma sunulmuştur. Prophet algoritması özellikle şu veri kümeleri için yararlıdır:

- Ayrıntılı tarihsel gözlemlerin (saatlik, günlük veya haftalık) uzun bir süresini (ay veya yıl) içeren
- Birden fazla güçlü mevsimselliğe sahip
- Önceden bilinen önemli, ancak düzensiz olaylar
- Eksik veri noktalarına veya büyük aykırılıklara sahip
- Bir sınıra yaklaşan doğrusal olmayan büyüme eğilimlerine sahip Zaman serisi verileri için kullanımı uygundur.

Model python, R gibi açık kaynak yazılım dağıtımlarında kolaylıkla entegre edilip kullanılabilir [51].

Prophet, parçasal doğrusal veya lojistik büyüme eğrisi eğilimine sahip bir katkı regresyon modelidir ve Fourier serisi kullanılarak modellenen yıllık mevsimsel bir bileşen ve sahte değişkenler kullanılarak modellenen haftalık bir mevsimsel bileşen içerir [52].

IV. LİTERATÜRDEKİ ÇALIŞMALARA GENEL BİR BAKIŞ

Bu bölümde literatürde son yıllarda yapılan finansal zaman serisi tahminleme çalışmalarından modelleme, kullanılan veri, uygulama yöntemi, başarısı, değerlendirme kriterleri ve benzer diğer faktörler açısından dikkat çekici olan bazı çalışmalar detaylı bir şekilde kullanılan yöntem başlığı altında açıklanmıştır.

A. ARIMA veya ARIMA Tabanlı Modeller

ARMA veya ARIMA, diğer adıyla Box-Jenkins metodu kullanılan bu çalışma kapsamında incelenen çalışmalardan ilk olarak Mondal ve arkadaşları tarafından hazırlanan çalışmada, ARIMA modelinin hisse senedi verileri üzerinde performansının etkisi ölçülmüştür [53]. Çalışmada 56 adet farklı sektörlerde bulunan (9 farklı sektör) firmaların hisse senetleri üzerinde farklı ARIMA modelleri uygulanmış ve performans kriteri olarak AIC ve AICc kullanılmıştır. AIC, "Akaike Information Criterion"nın kısaltma kullanımınıdır. Bu zaman serileri ile modelin ürettiği zaman serisinin uyumunu ölçen bir performans ölçme yöntemidir. AICc "Akaike Information Criterion corrected"ın kısaltma kullanımınıdır. "c" harfi değerinin küçük örnek boyutları için düzeltilmiş AIC testinden hesaplandığını gösterir. AIC veya AICc için düşük değerler gelmesi modelin iyi uyum sağladığını gösterir. En iyi uyum sağlayan model seçilip MAE ile modelin başarımı 6,12,18 ve 23 aylık periyotlarda ölçülmüştür. 9 farklı sektör ve 56 farklı hisse senedi üzerinde model başarımlarının performansı sektörel bazda incelenmiş ve otomobil, çelik ve bankacılık sektörlerinde standart sapmanın yüksek olduğu görülerek bu sektörlerde verinin yayıldığı ve bazı hisse verilerinde iyi sonuç vermediği görülmüştür. IT sektöründe standart sapmanın çok yüksek veya çok düşük olmadığı ve bu sebeple %90 üzeri başarıma ulaştığı gözlemlenmiştir.

ARIMA, LSTM ve GRU ile geliştirilen modellerin karşılaştırıldığı çalışmada Bitcoin fiyatları zaman serisi verisi kullanılmıştır [54]. 1647 satırdan oluşan veri seti 70:30 olarak bölünerek eğitim ve test veri seti oluşturulmuş, özellikler arasında korelasyon çözülmeye çalışılmış ancak sadece kapanış fiyatları kullanılarak model oluşturulmuştur. %2,76 ve 302,53 MAPE (Mean absolute percentage error) ve RMSE (root means square error) değerleri ile en iyi modelin ARIMA olduğu görülmüştür.

B. Üstel Yumuşatma Tabanlı Modeller

Üstel Yumuşatma yöntemi ve türevleri kullanılan modeller yine sık kullanılan modellerdir ve literatürde sık karşılaşılır.

Lai ve arkadaşlarına [55] ait çalışmada üstel yumuşatma ve yapay sinir ağları modelleri kullanılarak bir hibrit model oluşturulmuş ve finansal zaman serisi tahmini için önerilmiştir. Çalışmada geri yayımlı yapay sinir ağı ve üstel yumuşatma tekniği kullanan iki ayrı model daha aynı veri üzerinde kullanılmıştır. İki ayrı modelin ürettiği tahminler sinerji yakalayarak hibrit bir model oluşturmuştur. Burada üstel yumuşatma modelinin zaman

serilerindeki doğrusal karakteristiği, yapay sinir ağının ise doğrusal olmayan karakteristiğini yakalayabilme yeteneğinden faydalanılmış ve iki model birleştirilerek iki farklı karakteristik için tek model çözümü getirmeye çalışılmıştır. Veri olarak 1 Ocak 2000- 31 Aralık 2002 periyodundaki USD/EUR ve JPY/USD kur verileri kullanılmıştır. 1 Ocak 2000- 31 Eylül 2002'ye kadar eğitim verisi olarak kullanılmış ve sonraki üç ay bu modellerle tahmin edilmiştir. RMSE ve S_{stat} istatistiksel olarak doğrulanma yöntemleri kullanılmış ve hibrit model iki veri üzerinde de RMSE ölçütünde 0,0035 ve ile diğer modellerden daha başarılı sonuç vermiştir. Ayrıca D_s göre de en yüksek yüzde değerine yine hibrit model ulaşmıştır. Çünkü iki ayrı modelin başarılı bir sinerjisini yakalayabilmiştir.

C. Yapay Sinir Ağı Tabanlı Modeller

Yapay sinir ağları birçok amaçla kullanılan geleneksel-köklü yapay zekâ ve makine öğrenmesi metodlarından biridir ve metodun başarısı hala sıklıkla tercih edilmesinin en büyük sebeplerindedir. Bu kapsamda Yapay sinir ağları kullanılan modeller veya yapay sinir ağı ile hibrit kullanılan diğer modellere literatürde oldukça sık karşılaştığımızı söyleyebiliriz. Hibrit kullanım model başarısına çoğu zaman olumlu yönde etmektedir ve özellikle farklı verilere uyum sağlama konusunda oldukça başarılı istatistikler vermektedir. Örneğin Khashei ve arkadaşlarının çalışmasında farklı tipte zaman serisi verileri üzerinde aynı model uygulanmış ve model uyumu konusunda hibrit olmayan modellere daha iyi olduğu görülmüştür[56]. Çalışmada güneş ışığı verisi, Kanada vaşakları sayısının yıllar içinde değişimi ve sterlin-dolar fiyat değişimi zaman serisi verileri arasındaki ilişki ARIMA, ANN (Artificial Neural Network) ve ARIMA-ANN hibrit modeli kullanılarak tahmin edilmiştir. Her veri için çalışmada önerilen model diğer modeller ve Zhang'ın hibrit modelinden[57] daha iyi performans gösterdiği sonucuna varılmıştır. Hibrit bir model olan Zhang'ın modeli de sadece ARIMA ve ANN modellerinden daha düşük hata oranına ve daha iyi uyuma sahiptir.

Başka bir çalışmada Babu ve arkadaşları zaman serisi tahmini için yine ARIMA-ANN hibrit bir model kullanmıştır[58]. Bu çalışmada önceki çalışmada kullanılan "sunspotdataset", elektrik fiyatı zaman serisi verileri ve L&T ye ait hisse senedi fiyat verileri ile 4 farklı model denenmiştir. Bu denemeler sonucunda ARIMA ve ANN modellerinin tek başlarına zaman serisi tahminleme konusunda yetersiz olduğu, fakat hibrit modeller geliştirildiğinde her iki yöntemin yetersiz kaldığı veri tiplerinde başarılı oldukları tespit edilmiştir. Babu ve Reddy çalışma sonunda çeşitli uygulamalardan kaynaklanan zaman serisi verileri genel olarak hem doğrusal hem de doğrusal olmayan varyasyonları içerdiği, doğrusal ARIMA modelleri ve doğrusal olmayan YSA modelleri, bu tür verileri tek tek doğru şekilde modelleyemeyeceği. ARIMA ve ANN modellerinin güçlü yanlarını birleştiren hibrit modeller, her iki model türünün avantajlarından aynı anda yararlanabildikleri için, bireysel model türlerinden daha iyi olduğu çıkarımını yapmıştır. Bu çalışmada, ARIMA dizilerinin istatistiksel özelliklerine dayalı olarak yeni bir hibrit ARIMA-ANN tabanlı tahmin modeli önerilmektedir. Önerilen model, verilen zaman serisini iki veri kümesine ayırtmak için bir MA filtresi kullanır. Daha sonra yazarlar bu ayırtmalarına uygun olarak ARIMA ve ANN modellerini uygulamıştır. Hibrit modelden alınan tahminler, iki ayrı modelden tahminlerin birleştirilmesi ile elde edilir. Bu hibrit model hem bir adım ileri hem de çok adım ileri tahmin yeteneğine sahiptir. Önerilen model, zaman serisi verilerine ve güneş lekeleri verileri, elektrik fiyat verileri ve finansal veriler olmak üzere farklı türden üç mevcut veri kümesi üzerinde test edilmiştir. Hem tek adımlı hem de çok adımlı tahmin için, önerilen hibrit model, MAE ve MSE açısından ARIMA ve ANN modelleri ve bazı mevcut hibrit ARIMA-ANN modelleri gibi diğer birkaç modelden daha yüksek tahmin doğruluğuna sahiptir. Bu durumda ANN-ARIMA hibrit modelinin basit ve kolay uygulanabilen başarılı bir model olduğu görülmüştür. Bu iki çalışma hibrit modellerin ARIMA ve ANN modellerinin avantajlı özelliklerini birleştirdiğini göstermektedir.

Adhikari ve arkadaşlarına ait çalışmada RandomWalk (RW), ileri beslemeli yapay sinir ağı, elman ağı ve RW-ANN hibrit modelleri kullanılarak Büyük Britanya Pound ve Hindistan Rupisi (GBP-INR) parite değişim oranı, S&P endeksinin verisi ve IBM 'e ait hisse senedi verileri üzerinde tahmin çalışması yapılmıştır [59]. Çalışmada Randomwalk ve ANN algoritmalarının dezavantajlarını ortadan kaldırarak lineer ve lineer olmayan zaman serileri için etkili bir şekilde modelleme yapabilecek hibrit bir model oluşturulmuştur. Uygulama sonunda MAE, MSE ve simetrik MAPE ile değerlendirilen modellerden hibrit modelin diğer modellerden daha etkili olduğu görülmüştür.

D. RNN-LSTM Tabanlı Modeller

Önceki bölümde bahsedilen yinelemeli sinir ağları ve LSTM bir hafızaya sahip olması sayesinde zaman serisi tahminleme metodları arasında en iyilerinden biridir. Literatürde yapılan çalışmalardan Sima ve Akbar'a ait çalışmada LSTM metodu kullanılmış ve yüksek başarımlı oranları sağlanmıştır[60]. LSTM' deki hata oranındaki

azalma miktarlarının %84-87 arasında olduğudur. Ayrıca, çalışmadan elde edilen diğer bir sonuç göre derin öğrenmede “epoch” olarak bilinen eğitim zamanlarının sayısının, eğitilen tahmin modelinin performansı üzerinde hiçbir etkisi olmadığı ve gerçekten rastgele bir davranış sergilediğidir[60].

Bir finansal zaman serisi çalışması olmasa bile Sagher ve Kotb’a ait petrol üretim verilerinin incelendiği “Time series forecasting of petroleum production using deep LSTM recurrent networks” isimli çalışma kullandığı yöntemler ve veri kullanım yöntemi açısından oldukça dikkat çekiciydi ve bu çalışma içinde incelenmesi gereken bir çalışma olduğunu düşündük [61]. Çalışmada iki senaryo, iki veri seti ve çok sayıda yapay zekâ metodu kullanılmıştır. Çalışmada Çin Huabei Petrol sahası Blok-1 ‘den toplanan 227 birim veriden oluşuyor. Bu verilerin %80’i eğitim veri seti ve %20’si test veri seti olarak kullanılmıştır. Bu senaryoda Derin LSTM modelinin statik ve dinamik olarak iki senaryo ile, single-RNN, multi-RNN ve Derin GRU modelleri kullanılmıştır.

Fang ve arkadaşlarına ait [62] bir diğer çalışmada Morgan Tayvan endeks verileri kullanılmıştır. Çalışmada Facebook prophet algoritması ve LSTM modelleri birleştirilip bir yapay sinir ağı modeli önerilmiştir. Kullanılan veriler 2014 ve 2018 arasında paylaşılan MSF verileri olup “Taiwan Economics News Database TEJ” ‘den toplanmıştır. İlk 5 yıl eğitim verisi olarak kullanıp 60 günlük trend tahmini yapılmış ve RMSE’ye göre model performansı değerlendirilmiştir. Sonuç olarak birleştirilmiş yapay sinir ağı modelinde 0,04464 RMSE değerine ulaşılabilmektedir.

E. CNN Tabanlı Modeller

Evrışimli sinir ağı kullanılan modellerden biri olan Livieris ve arkadaşlarına ait çalışmada LSTM-CNN hibrit modeli altın fiyatları zaman serisi üzerinde kullanılmıştır [63]. Yazarlar bu çalışmada CNN’in yararlı bilgiyi çıkarma yeteneğinden ve LSTM ağının uzun ve kısa dönem etkinlikleri LSTM katmanlarıyla tanımlayabilme yeteneğinden yararlanmışlardır. Son durumda hibrit modelin sadece LSTM kullanılan modellerden daha iyi bir performans sergilediği sonucu elde edilmiştir. Çalışmada yazarlar kısa ve uzun vadeli bağımlılıkların belirlenmesinin zaman serisi doğru tahmin sağlayacağı çıkarımında bulunmuşlardır.

Li[64]’ye ait çalışmada kullanılan “Shanghai Stock Exchange Index (Shanghai Stock Exchange Index)” ve “Shenzhen Stock Exchange Index (Shenzhen Component Index)” üzerinde yatırımcılar için CNN ile kısa vadeli bir model oluşturulmuştur. Kullanılan veri seti bölünerek 3 farklı boyutta veri seti oluşturulmuştur. Önceki çalışmalarda “radial bases function tabanlı yapay sinir ağı” ve “Kalman filtered neural network” ile CNN arasındaki hata oranı bir grafik ile ortaya konmuş ve CNN’in üstünlüğü görülmektedir. Makalede zaman serisi temel alan modellerin yatırımcı duyarlılığını dikkate almadığı için bir evrışimli sinir ağları ve ağ güvenlik modeli oluşturulmuştur. Çeşitli gün aralıklarına ve ardışık günlere göre model performansı değerlendirilmiştir. Çalışma sonucunda alınan sonuçlara göre zaman serisi modeline bağlı olarak oluşturulan derin duygusal bilgileri temel duygusal özelliklerle değiştirmek için CNN kullanılması önerilmektedir.

Selvin ve arkadaşlarına ait çalışmada LSTM,RNN,CNN-sliding window (kayan pencere yaklaşımı)ile ilaç sektöründe faaliyet gösteren üç firmaya ait hisse senedi verilerini tahminlemek üzere sadece bir tanesi eğitim veri seti olarak kullanılarak bir tahmin modeli geliştirilmiştir[12]. Eğitim veri seti 1 Haziran 2014’ten 14 Ekim 2014’e kadar olan sadece INFOSYS hisse senedi verilerini içerirken test veri seti ise 16 Ekim 2014’ten 28 Kasım 2014 ‘e kadar olan INFOSYS, TSC ve CIPLA hisse senedi fiyatlarını içermektedir. Veri setleri üzerinde normalizasyon işlemi yapılmış ve ARIMA ve diğer modellerin hata yüzdeleri arasında karşılaştırma yapılmıştır. CNN ile kurulan modelin sırasıyla 2,36, 8,96 ve 3,63’lük hata yüzdeleri verdiği görülmüştür. Burada en düşük hata oranı eğitim veri seti olarak kullanılan şirketin hisse senedi verilerine aittir fakat diğer veriler ile de oldukça iyi performans gösterdiği söylenebilir. Çalışmada derin sinir ağı mimarilerinin gizli dinamikleri yakalayabildiği ve tahminlerde bulunabildiği görülmektedir. Bu, önerilen sistemin verilerdeki bazı karşılıklı ilişkileri tanımlayabildiğini göstermektedir. Ayrıca, CNN mimarisinin trendlerdeki değişiklikleri belirleyebildiği çıkarımı yapılmıştır. Önerilen metodoloji için CNN en iyi model olarak belirlenmiştir. Tahmin için belirli bir anda verilen bilgileri kullanır. Yazarlar borsada meydana gelen değişimler her zaman düzenli bir seyir izlemeyebileceğini veya her zaman aynı döngüyü takip etmeyebileceğini bu sebeple CNN gibi ağların ilişki tespit yeteneğinin kullanımının daha fazla kazanç sağlayabileceği çıkarımını yapmışlardır.

F. Facebook Prophet Algoritması Tabanlı Modeller

İbrahim ve arkadaşlarına [51] ait çalışmada bitcoin fiyatları üzerinde bir trend tahmini çalışması yapılmıştır. Çalışmada oldukça 5 dakikalık zaman dilimlerinde veri çekilerek “day-trading” olarak bilinen gün

çinde yapılan alım satım işlemleri için trend yönü tespit etmek için prophet algoritması ile BTC-USD fiyat tahmini yapılmıştır. Prophet, Rastgele Orman, gecikmeli otoregresif rastgele orman, çok katmanlı algılayıcı modelleri çalışmada kullanılmıştır. 2014'e ve 2017 ye uzanan iki ayrı borsadan 5 dakikalık tick-data formatında bitcoin/usd verileri kullanılmıştır. Ayrıca Apple, Facebook, Google, Microsoft gibi hisse verileri de yine aynı format ile toplanmıştır. "Naive Guessing" ve "Momentum strategy" iki ayrı değerlendirme stratejisidir. Çok kullanılan bazı indikatörler veri üzerinde özellik mühendisliği aşamasında kullanılmış ve veri trend yönü ve momentum tahmin edilebilecek şekilde model girdisi olmak için hazırlanmıştır. Son durumda çok katmanlı algılayıcı en yüksek başarımlarını yakalamış ve ikinci sırada prophet algoritması başarılı sonuçlar vermiştir.

Yusof ve arkadaşlarına ait[65] çalışmada Standard & Poor's 500 endeksi (SP500), Dow Jones Endüstriyel Ortalama endeksi (DJIA), Çin Güvenlik endeksi (CSI300), Kuala Lumpur Kompositendesi (KLCI), Hong Kong HangSeng 300 endeksi (HS300) ve Nihon Keizai Shinbun endeksi (Nikkei) verileri facebook prophet algoritması ile tahmin edilmiştir. Sonuçta ortalama mutlak yüzde hatası en fazla %6'ya ulaşabilmiş ve verilere iyi uyum sağlayan bir model geliştirilmiştir.

İncelenen çalışmalarda özet bilgi niteliğindeki veriler Tablo 1'de özetlenmiştir. Özet bilgi olarak kullanılan yöntemlerin hangi yöntemlerle beraber veya karşılaştırmalı olarak kullanıldığına, çalışma periyoduna ve başarımlarına yer verildi.

Tablo 1. Facebook Prophet algoritması ile oluşturulan modelleri kullanan çalışmaların özeti

Yazarlar	Kullanılan veriler	Periyot	Kullanılan yöntemler	Performans Ölçütleri	Başarımlar oranı
[53]	Hisse senedi	Nisan 2012-Şubat 2014	ARIMA	AICc, ve MAE,std of acc,paired t-test	>%90
[54]	Kripto varlık	Kasım 2014- Haziran 2019	ARIMA, LSTM, GRU	MAPE, RMSE	%2,76, 302,53
[55]	Forex verileri	Ocak 2000 -Aralık 2002	ES, BPNN,hibrit model	RMSE, D _{stat}	RMSE-0,0035 USD/EUR RMSE-0,6571 JPY/USD
[56]	Forex ve diğerleri	1980-1993(forex)	ANN, ARIMA, ANN-ARIMA hibrit model	MAE, MSE	-
[58]	Hisse senedi	2013-2013(200günlük)	ANN, ARIMA, ANN-ARIMA hibrit model	MAE, MSE	-
[59]	Forex, endeks, hisse senedi	2009-11 ve 1980-93,2004-07, 1965-2011	RandomWalk, ANN,Elman ANN, Hibrit	MAE, MSE, SMAPE	-
[60]	Endeks ve ekonomik veriler	1985-2018	ARIMA, LSTM	RMSE	%85>ARIMA
[61]	Petrol üretim verileri		ARIMA, Derin LSTM	RMSE, RMSPE, MAPE	-
[63]	Altın fiyatı	2014-2018	LSTM-CNN hibrit	MAE, RMSE ACC, AUC, SEN SPE AAPE,	-
[64]	Endeks	2015-2019	CNN	RMSE,Accuracy ErrorPersantage	-
[12]	Hisse senedi	Haziran 2014-Kasım 2014	CNN-slidingwindow, RNN, LSTM, ARIMA		2,36, 8,96, 3,63(CNN)
[62]	Endeks verileri	2014-2018	Prophet, LSTM-BPNN	RMSE	0.04464(LSTM-BPNN)
[65]	Endeks verileri	-	Prophet	MAPE	%6

V. SONUÇLAR VE TARTIŞMA

Bu çalışmada birçok zaman serisi tahmin metodu incelenmiş ve her birinin kullanıldığı veri üzerinde göreceli olarak başarılı performans sergilediği görülmüştür. Bazı çalışmalarda klasik tahmin metotları ve diğer yapay zekâ algoritmaları ile veri üzerinde performans karşılaştırması yapılmıştır. Bazı çalışmalarda ise veriyi tahminlemedeki hata payı üzerinden model değerlendirilmiştir. Bazı çalışmalarda uzun vadeli veri tahmini için

modeller oluşturulmuş, bazı çalışmalarda kısa vadeli veya her iki durumu aynı anda sağlayan hibrit modeller kullanılmıştır.

Çalışmada veri tiplerinin bağımlılıkları ve kendilerine has özellikleri gereği tahminlemeye uygunluğu araştırıldı. Bunlardan hisse senedi verileri aynı veya farklı borsalar içindeki farklı hisse senetleriyle bağımlı olduğu, bir hisse senedi verisi ile eğitilen bir modelin farklı hisse senedi verilerinin fiyatlarını oldukça iyi tahmin edebildiği görüldü. Veri seti olarak endeksler birden fazla hisse senedini içerdiği için hisse senetlerinde olduğu gibi ani iniş ve çıkışlara hisse senedi verileri kadar tepki vermezler bu açıdan volatilitesi düşük olan endeks verilerinin tahmin edilmesi diğer menkul kıymetlere göre daha kolaydır. Forex verileri çok sayıda veriye bağımlılık gösterdiği için oldukça yüksek volatiliteye sahip olabilir. Aynı şekilde kripto paralara ait verileri de spekülatif bir finans aracı olarak nitelenebilir. Bu sebeple tahmin modeli oluşturmak endeks verilerine göre daha zordur. Bu açıdan endeksler gibi birden çok verinin ağırlıklandırılması ile elde edilen veriler, aynı veya farklı pazarlar içindeki hisse senetleri veya Forex piyasası gibi büyük, zamana ve birbirine bağımlı hareket eden bir çok veri, bu ilişkileri tespit edebilecek zekaya sahip algoritmalar ile tahminlenebilir. Nitekim incelenen çalışmalar da bunu kanıtlar niteliktedir.

Zaman serisi tahminlemede kullanılan metotlar kapsamında incelenen ve geleneksel bir yöntem olan ARIMA veya diğer adıyla Box-Jenkins metodu sıklıkla kullanılan yöntemlerden biridir. İncelenen çalışmalarda bu metodun başarılı olduğu görülmüştür. ARIMA durağan olmayan zaman serileri üzerinde çalışan kolay anlaşılabilir bir metot olduğu için geleneksel bir model olmasına karşın çalışmalarda görebiliyoruz. Fakat yeni çalışmalarda ilişki keşfi özelliğinden yararlanmak için yapay sinir ağı tabanlı modellerden sıklıkla yararlandığımızı görebiliyoruz. Nitekim incelenen çalışmalar sadece ARIMA ve bir diğeri ARIMA ile sinir ağı modellerin karşılaştırmasını içeriyor. ARIMA standart sapması çok yüksek veya düşük olmayan verilere iyi uyum sağlamıştır. Bazı çalışmalarda veriye sinir ağı tabanlı modellerden bile daha iyi uyum sağlamıştır. Üstel yumuşatma yöntemi kullanılan modeller kısa dönemde modelin iyi tahminler yapabileceğini ortaya koymuştur. Dolayısıyla kısa dönemli ve çok büyük düzensiz hareketlerin olmadığı verilerde bu yöntem veya bu yöntemle hibritlenmiş başka bir yöntem kullanılabilir. Yapay sinir ağları ve sinir ağı tabanlı algoritmalar ARIMA ve üstel yumuşatma ile hibritlendiğinde tek başına kullanıldığından daha iyi performans sergilediği görülmüştür. Ayrıca incelenen çalışmalarda farklı tipte finansal veriler ile farklı metotlar ve hibrit modeller kullanılmıştır. Bunlardan ARIMA-ANN, ES-BPNN hibrit modeli kısa-orta dönem Forex verileri üzerinde başarılı olmuştur. Ayrıca ANN ile Randomwalkhibrit modeli de kendi başına kullanılan yöntemlerden daha başarılıdır. Buradan ANN diğer modelleri destekleyici niteliktedir. RNN-LSTM veya CNN modelleri ile yapılan çalışmalarda farklı eğitim verileriyle eğitilen modellerin farklı test verilerine uyum sağlayabildiği, derin öğrenmenin özellik çıkarımı özelliği sayesinde modelin farklı tipte zaman serisi verileriyle de iyi performans gösterdiği görülmüştür. Çalışmalardan birinde finansal veri olmayan petrol üretim verileri üzerinde bile CNN modelinin başarılı olduğu görüldü. Bu nedenle çok sayıda veri seti ile derin öğrenme modelleri kullanıldığında aralarındaki ilişkiyi tespit ederek iyi bir öngörü modeli oluşturulabileceği düşünülmektedir. LSTM ve CNN hibrit modelinin hem örüntü tanıma hem de farklı veriler arasındaki ilişkiyi tespit ederek düzensiz sapmaları tahmin edebileceği düşünülmektedir. Bu açıdan bu model geleneksel metotlar ile tahmin edilmesi zor olan kısa, orta veya uzun vadeli veriler için tercih edilebilir. İncelenen çalışmalar arasında Facebook Prophet algoritması kullanılan çalışmalarda tek başına veya başka modellerle hibrit olarak kullanıldığında hisse senedi, endeks ve kripto para-rezerv para parite tahminlemelerinde başarılı sonuçlar verdiği görülmüştür. Modeller çok farklı değerlendirme kriterlerine göre değerlendirilmiştir fakat en fazla kullanılan yöntemler RMSE ve MSE/MAPE'dir. Uzun vadeli finansal seri tahminlerinde bu metrikler oldukça büyüyebilir. Bu nedenle R2 metriği kullanılması önerilebilir.

Yapılan bu inceleme çalışması hangi tip verilerle hangi modellerin kullanılabilmesi hakkında faydalı bilgiler sunmaktadır. İleride yapılacak çalışmalarda bu derleme kapsamında incelenen yöntemlerin kullanılması önerilebilir, bu çalışmalar yapılacak olan çalışmaya referans olarak kullanılabilir.

KAYNAKLAR

- [1] 'Fundamental Analysis' (2012) in *The Sector Strategist*. John Wiley & Sons, Ltd, 163–184. doi:10.1002/9781119205333.ch9.
- [2] 'Technical Analysis: Welcome To Technical Analysis' (2012) in *Invest in Penny Stocks*. John Wiley & Sons, Ltd,
- [3] Ponsi (ed.) (2016) 'The Dow Theory', in *Technical Analysis and Chart Interpretations*. Hoboken, NJ, USA: John Wiley & Sons, Inc., 19–26. doi:10.1002/9781119204800.ch4.

- [4] ‘The Dow Theory’ (2016) in *Technical Analysis and Chart Interpretations*. John Wiley & Sons, Ltd, 19–26. doi:10.1002/9781119204800.ch4.
- [5] Bustos, O. & Pomares-Quimbaya, A. (2020) ‘Stock market movement forecast: A Systematic review’, *Expert Systems with Applications*, 156, 113464–113464. doi:10.1016/j.eswa.2020.113464.
- [6] Puschmann, T. (2017) ‘Fintech’, *Business & Information Systems Engineering*, 59(1), 69–76. doi:10.1007/s12599-017-0464-6.
- [7] Oleksiuk, A. (2019) ‘Machine Learning Use Cases in Banking and Finance’, *Intellias* [Preprint]. Available at: <https://intellias.com/5-use-cases-of-machine-learning-in-fintech-and-banking/>.
- [8] Ltd, F.M.I.G. and C.P. (2022) *AI in Fintech Market to Reach US\$ 54 Billion, Globally, by 2032 at 16.5% CAGR: Future Market Insights, Inc., GlobeNewswire News Room*. Available at: <https://www.globenewswire.com/news-release/2022/06/10/2460623/0/en/AI-in-Fintech-Market-to-Rreach-US-54-Billion-Globally-by-2032-at-16-5-CAGR-Future-Market-Insights-Inc.html> (Accessed: 12 June 2022).
- [9] Harvey, A. (2016) ‘Trend Analysis’, in *Wiley StatsRef: Statistics Reference Online*. John Wiley & Sons, Ltd, 1–21. doi:10.1002/9781118445112.stat07817.pub2.
- [10] Gulve, A. (2020) ‘Everything about Components of Time Series: Part-1’, *Medium*, 10 April. Available at: <https://aishwaryagulve97.medium.com/everything-about-components-of-time-series-part-1-7476fb521477> (Accessed: 7 January 2022).
- [11] *Fig. 3 Time series graphs with random, seasonal and trend components in...* (no date) *ResearchGate*. Available at: https://www.researchgate.net/figure/Time-series-graphs-with-random-seasonal-and-trend-components-in-cluster-1_fig1_268153169 (Accessed: 19 January 2022).
- [12] Selvin, S. et al. (2017) ‘Stock price prediction using LSTM, RNN and CNN-sliding window model’, *2017 International Conference on Advances in Computing, Communications and Informatics, ICACCI 2017*, 2017-January, 1643–1647. doi:10.1109/ICACCI.2017.8126078.
- [13] *Stocks / Investor.gov* (no date). Available at: <https://www.investor.gov/introduction-investing/investing-basics/investment-products/stocks> (Accessed: 13 June 2022).
- [14] Marquit, M. (2021a) *Investing Basics: What Are Dividends?*, *Forbes Advisor*. Available at: <https://www.forbes.com/advisor/investing/what-is-dividend/> (Accessed: 13 June 2022).
- [15] Ögel, S. & Fındık, M. (2020) ‘Farklı Kitalarda Yer Alan Borsa Endekslerinin Vix(Korku) Endeksi İle İlişkisi’, *KocatepeİİBF Journal*, 22(1), 127–140.
- [16] Schich, S. (2004) ‘European stock market dependencies when price changes are unusually large’, *Applied Financial Economics*, 14(3), 165–177. doi:10.1080/0960310042000187360.
- [17] Sezer, O.B., Gudelek, M.U. and Ozbayoglu, A.M. (2020) ‘Financial time series forecasting with deep learning: A systematic literature review: 2005–2019’, *Applied Soft Computing Journal*, 90, 106181–106181. doi:10.1016/j.asoc.2020.106181.
- [18] Kumar, R. (2014) ‘Chapter 5 - Stock Markets, Derivatives Markets, and Foreign Exchange Markets’, in Kumar, R. (ed.) *Strategies of Banks and Other Financial Institutions*. San Diego: Academic Press, 125–164. doi:10.1016/B978-0-12-416997-5.00005-1.
- [19] ‘What Is A Stock Market Index? – Forbes Advisor’ (no date). Available at: <https://www.forbes.com/advisor/investing/stock-market-index/> (Accessed: 13 June 2022).
- [20] Tretina, K. (2021) *Investing Basics: What Is A Market Index?*, *Forbes Advisor*. Available at: <https://www.forbes.com/advisor/investing/stock-market-index/> (Accessed: 13 June 2022).
- [21] Marquit, M. (2021b) *What Is The VIX Volatility Index?*, *Forbes Advisor*. Available at: <https://www.forbes.com/advisor/investing/vix-volatility-index/> (Accessed: 13 June 2022).
- [22] *ARIMA Models - Demand- Driven Forecasting - Wiley Online Library* (no date). Available at: <https://onlinelibrary.wiley.com/doi/10.1002/9781118691861.ch7> (Accessed: 13 June 2022).
- [23] Miller, D.M. & Williams, D. (2003) ‘Shrinkage estimators of time series seasonal factors and their effect on forecasting accuracy’, *International Journal of Forecasting*, 19(4), 669–684. doi:10.1016/S0169-2070(02)00077-8.
- [24] Hyndman, R.J., Hyndman, & Rob (2004) ‘The interaction between trend and seasonality’, *International Journal of Forecasting*, 20(4), 561–563.
- [25] *Time Series: Understanding Changes Over Time - Science Direct* (no date). Available at: <https://www.sciencedirect.com/science/article/pii/B9780128200254000142> (Accessed: 13 June 2022).

- [26] Newbold, P. & Bos, T. (1989) 'On exponential smoothing and the assumption of deterministic trend plus white noise data-generating models', *International Journal of Forecasting*, 5(4), 523–527. doi:10.1016/0169-2070(89)90007-1.
- [27] Karakaş, E. (2019) 'Çocuk Yoğun Bakım Ünitesine Olan Talebin Zaman Serisi Yöntemleri ile Tahmin Edilmesi', *European Journal of Science and Technology*, 454–462. doi:10.31590/ejosat.624407.
- [28] Johannet, A. (2010) 'Artificial Neural Network Models', in *Mathematical Models*. John Wiley & Sons, Ltd, 419–443. doi:10.1002/9781118557853.ch14.
- [29] Yildiran, A. & Kandemir, S.Y. (2018) 'Yağış Miktarının Yapay Sinir Ağları ile Tahmini', *Bilecik Şeyh Edebali Üniversitesi Fen Bilimleri Dergisi*, 5(2), 97–104.
- [30] Dayhoff, J.E. & Deleo, J.M. (1999) 'Conference on Prognostic Factors and Staging in Cancer Management: Contributions of Artificial Neural Networks and Other Statistical Methods Artificial Neural Networks Opening the Black Box'. doi:10.1002/1097-0142(20010415)91:8.
- [31] 'Multilayer Neural Networks and Backpropagation' (2016) in *Fundamentals of Computational Intelligence*. John Wiley & Sons, Ltd, 35–60. doi:10.1002/9781119214403.ch3.
- [32] Broussard, R. *et al.* (2008) 'An artificial neural network based matching metric for iris identification', in, 68120. doi:10.1117/12.766725.
- [33] Wythoff, B.J. (1993) 'Backpropagation neural networks: A tutorial', *Chemometrics and Intelligent Laboratory Systems*, 18(2), 115–155. doi:10.1016/0169-7439(93)80052-J.
- [34] Yazan, E. and Talu, M.F. (2022) 'Yönel Türev Tabanlı Yakınsama Yaklaşımlarının Karşılaştırmalı Analizi', 10.
- [35] Kızrak, A. (2020) 'Comparison of Activation Functions for Deep Neural Networks', *Medium* [Preprint]. Available at: <https://towardsdatascience.com/comparison-of-activation-functions-for-deep-neural-networks-706ac4284c8a>.
- [36] Rhanoui, M. *et al.* (2019) 'Forecasting Financial Budget Time Series: ARIMA Random Walk vs LSTM Neural Network', *IAES International Journal of Artificial Intelligence (IJ-AI)*, 8, 317–317. doi:10.11591/ijai.v8.i4.pp317-327.
- [37] 'Recurrent Neural Net' (2019) *nerdcoder*, 3 February. Available at: <https://nerdthecoder.wordpress.com/2019/02/03/recurrent-neural-net/> (Accessed: 8 December 2021).
- [38] Hughes, D. & Correll, N. (2016) 'Distributed Machine Learning in Materials that Couple Sensing, Actuation, Computation and Communication'.
- [39] (PDF) *Deep Learning for Daily Peak Load Forecasting-A Novel Gated Recurrent Neural Network Combining Dynamic Time Warping* (no date). Available at: https://www.researchgate.net/publication/330723201_Deep_Learning_for_Daily_Peak_Load_Forecasting-A_Novel_Gated_Recurrent_Neural_Network_Combining_Dynamic_Time_Warping (Accessed: 10 December 2021).
- [40] CS 230 - *Recurrent Neural Networks Cheatsheet* (no date). Available at: <https://stanford.edu/~shervine/teaching/cs-230/cheatsheet-recurrent-neural-networks> (Accessed: 13 June 2022).
- [41] Van Houdt, G., Mosquera, C. & Nápoles, G. (2020) 'A Review on the Long Short-Term Memory Model', *Artificial Intelligence Review*, 53. doi:10.1007/s10462-020-09838-1.
- [42] Hochreiter, S. & Schmidhuber, J. (1997) 'Long Short-Term Memory', *Neural Computation*, 9(8), 1735–1780. doi:10.1162/neco.1997.9.8.1735.
- [43] Fang, H. *et al.* (2020) 'A LSTM Algorithm Estimating Pseudo Measurements for Aiding INS during GNSS Signal Outages', *Remote Sensing*, 12, p. 256. doi:10.3390/rs12020256.
- [44] Savaş, S. *et al.* (2022) 'Comparison of Deep Learning Models in Carotid Artery Intima-Media Thickness Ultrasound Images: CAIMTUSNet', *Bilişim Teknolojileri Dergisi*, 15(1), 1–12. doi:10.17671/gazibtd.804617.
- [45] Firildak, K. & Talu, M.F. (no date) 'Evrşimsel Sinir Ağlarında Kullanılan Transfer Öğrenme Yaklaşımlarının İncelenmesi', 8.
- [46] *Convolutional neural networks for time series forecasting | Python for Finance Cookbook* (no date). Available at: <https://subscription.packtpub.com/book/data/9781789618518/10/ch10lv11sec63/convolutional-neural-networks-for-time-series-forecasting> (Accessed: 19 January 2022).
- [47] Alfarzaei, M.S. *et al.* (2020) 'Coal/Gangue Recognition Using Convolutional Neural Networks and Thermal Images', *IEEE Access*, 8, pp. 76780–76789. doi:10.1109/ACCESS.2020.2990200.

- [48] Bhatnagar, S., Ghosal, D. & Kolekar, M.H. (2017) ‘Classification of fashion article images using convolutional neural networks’, in *2017 Fourth International Conference on Image Information Processing (ICIIP)*. *2017 Fourth International Conference on Image Information Processing (ICIIP)*, 1–6. doi:10.1109/ICIIP.2017.8313740.
- [49] Savaş, S. (2022) ‘Detecting the Stages of Alzheimer’s Disease with Pre-trained Deep Learning Architectures’, *Arabian Journal for Science and Engineering*, 47(2), 2201–2218. doi:10.1007/s13369-021-06131-3.
- [50] Iqbal, S. *et al.* (2018) ‘Brain tumor segmentation in multi-spectral MRI using convolutional neural networks (CNN)’, *Microscopy Research and Technique*, 81(4), 419–427. doi:10.1002/jemt.22994.
- [51] Ibrahim, A., Kashef, R. and Corrigan, L. (2021) ‘Predicting market movement direction for bitcoin: A comparison of time series modeling methods’, *Computers & Electrical Engineering*, 89, 106905. doi:10.1016/j.compeleceng.2020.106905.
- [52] *Prophet: forecasting at scale - Meta Research* (no date) *Meta Research*. Available at: <https://research.facebook.com/blog/2017/02/prophet-forecasting-at-scale/> (Accessed: 21 December 2021).
- [53] Mondal, P., Shit, L. & Goswami, S. (2014) ‘Study of Effectiveness of Time Series Modeling (Arima) in Forecasting Stock Prices’, *International Journal of Computer Science, Engineering and Applications*, 4(2), 13–29. doi:10.5121/ijcsea.2014.4202.
- [54] Yamak, P.T., Yujian, L. & Gadosey, P.K. (2019) ‘A Comparison between ARIMA, LSTM, and GRU for Time Series Forecasting’, in *Proceedings of the 2019 2nd International Conference on Algorithms, Computing and Artificial Intelligence*. New York, NY, USA: Association for Computing Machinery (ACAI 2019), 49–55. doi:10.1145/3377713.3377722.
- [55] Lai, K.K. *et al.* (2006) ‘Hybridizing Exponential Smoothing and Neural Network for Financial Time Series Predication’, in Alexandrov, V.N. *et al.* (eds) *Computational Science – ICCS 2006*. Berlin, Heidelberg: Springer Berlin Heidelberg (Lecture Notes in Computer Science), 493–500. doi:10.1007/11758549_69.
- [56] Khashei, M. & Bijari, M. (2010) ‘An artificial neural network (p, d, q) model for timeseries forecasting’, *Expert Syst. Appl.*, 37, 479–489. doi:10.1016/j.eswa.2009.05.044.
- [57] Zhang, G.P. (2003) ‘Time series forecasting using a hybrid ARIMA and neural network model’, *Neurocomputing*, 50, 159–175. doi:10.1016/S0925-2312(01)00702-0.
- [58] Babu, C.N. & Reddy, B.E. (2014) ‘A moving-average filter based hybrid ARIMA–ANN model for forecasting time series data’, *Applied Soft Computing*, 23, 27–38. doi:10.1016/j.asoc.2014.05.028.
- [59] Adhikari, R. & Agrawal, R.K. (2014) ‘A combination of artificial neural network and random walk models for financial time series forecasting’, *Neural Computing and Applications*, 24(6), 1441–1449. doi:10.1007/s00521-013-1386-y.
- [60] Akbar & Sima, S.N. (2018) ‘Forecasting Economics and Financial Time Series: ARIMA vs. LSTM’, *arXiv:1803.06386 [cs, q-fin, stat]* [Preprint]. Available at: <http://arxiv.org/abs/1803.06386> (Accessed: 9 December 2021).
- [61] Sagheer, A. & Kotb, M. (2019) ‘Time series forecasting of petroleum production using deep LSTM recurrent networks’, *Neurocomputing*, 323, 203–213. doi:10.1016/j.neucom. 2018.09.082.
- [62] Fang, W.-X. *et al.* (2019) ‘Combine Facebook Prophet and LSTM with BPNN Forecasting financial markets: the Morgan Taiwan Index’, in *2019 International Symposium on Intelligent Signal Processing and Communication Systems (ISPACS)*. *2019 International Symposium on Intelligent Signal Processing and Communication Systems (ISPACS)*, 1–2. doi:10.1109/ISPACS48206.2019.8986377.
- [63] Livieris, I.E., Pintelas, E. & Pintelas, P. (2020) ‘A CNN–LSTM model for gold price time-series forecasting’, *Neural Computing and Applications*, 32(23), 17351–17360. doi:10.1007/s00521-020-04867-x.
- [64] Li, J. (2021) ‘Research on Market Stock Index Prediction Based on Network Security and Deep Learning’, *Security and Communication Networks*. Edited by C.-H. Chen, 2021, 1–8. doi:10.1155/2021/5522375.
- [65] Yusof, U.K. *et al.* (2021) ‘Financial Time Series Forecasting Using Prophet’, in Saeed, F., Mohammed, F., and Al-Nahari, A. (eds) *Innovative Systems for Intelligent Health Informatics*. Cham: Springer International Publishing (Lecture Notes on Data Engineering and Communications Technologies), 485–495. doi:10.1007/978-3-030-70713-2_45.