

Şirket Değerlemede Makine Öğrenmesi Algoritmalarının Kullanımı

Using Machine Learning Algorithms in Company Valuation

Tamer KANAK

Aydın Adnan Menderes Üniversitesi, Bilgisayar Mühendisliği Bölümü, tamerkanak75@gmail.com

ÖZET

Piyasada bitmek bilmeyen bir devir daim sonucu her gün milyonlarca finansal işlem yapılmaktadır. Şirketlerin satın alınması, birleşmelere gidilmesi de bu işlemlerden sayılabilir. Dolayısıyla şirket değerleme yöntemleri sık sık kullanılmaktadır. Bugün itibarıyla Gelir Yaklaşımı, Piyasa Yaklaşımı, Maliyet Yaklaşımı gibi yöntemlerle şirketlerin değerlerinin ön görülmesi mümkündür. Ancak birbirlerine göre avantajlar ve dezavantajlar barındıran bu yöntemlerden bir adım öteye giderek, bütün süreci makine öğrenmesi ile sürdürmekte fayda vardır. Zira günümüzde sayısız alanda kendini gösteren makine öğrenmesi, artık veri kaynaklarına kolayca ulaşılabilmesinin de avantajıyla birlikte, verileri daha doğru işleyip yeni tahminler yapma becerisiyle donatılmıştır. Şirketlerin finansal kararlarını verirken makine öğrenmesi ve veri biliminden yararlanacak olması şirketler adına büyük bir avantaj sayılabilir. Bu makalede "Retail Dataset" veri kümesi kullanılarak zaman serisi verilen şirketin gelecek satışları tahminlenmiş, İndirgenmiş Nakit Akışı yardımıyla şirketin değeri belirlenerek makine öğrenmesi ve veri biliminin şirket değerlemede önemli rol oynayabileceği sonucuna ulaşılmıştır.

Anahtar Kavramlar: Şirket Değerleme, Gelir Yaklaşımı, Piyasa Yaklaşımı, Maliyet Yaklaşımı, İndirgenmiş Nakit Akışı, Zaman Serisi, Makine Öğrenmesi, Veri Analizi, Veri Bilimi

ABSTRACT

Due to the incessant turnover in the market, millions of financial transactions are conducted daily. Transactions such as company acquisitions and mergers also fall into this category. Therefore, company valuation methods are frequently utilized. As of today, it is possible to estimate the value of companies using methods such as the Income Approach, Market Approach, and Cost Approach. However, it is beneficial to advance beyond these methods, which have their own advantages and disadvantages, by leveraging machine learning to manage the entire process. Machine learning, which is now prevalent in numerous fields, is equipped with the capability to process data more accurately and make new predictions, thanks to the ease of accessing data sources. The use of machine learning and data science in making financial decisions can be a significant advantage for companies. This paper utilizes the "Retail Dataset" to forecast the future sales of a company using time series analysis and determines the company's value with the help of Discounted Cash Flow, concluding that machine learning and data science can play a crucial role in company valuation.

Keywords: Company Valuation, Income Approach, Market Approach, Cost Approach, Discounted Cash Flow, Time Series, Machine Learning, Data Analysis, Data Science

1 GİRİŞ

Günümüz dünyasında internetin sağladığı pratiklik sayesinde, her saniye birçok mal ve hizmet para karşılığında el değiştirmektedir. Örneğin, dijital ödemeler pazarındaki toplam işlem değeri 2022 yılında 8,3 trilyon dolardan 2023 yılında 9,4 trilyon dolara erişmiştir [1].

Değer, piyasadaki satış fiyatının bir tahminidir. [2] Söz konusu ürünün kalitesi, yararlılığı, arz miktarı gibi ölçütler değer belirlenmesindeki yardımcı etmenlerdendir. Dolayısıyla, bir ürünün kendi değerini ne kadar yansıttığının tespitini yapabilmek basit bir market alışverişi yapan bireyden, büyük ölçekte faaliyet gösteren kuruluşlara kadar büyük önem arz etmektedir.

Gerçek hayatta bir malın veya hizmetin değeri yalnızca satış veya satın alma için değil, aynı zamanda orta ve uzun vadeli planların doğru bir şekilde yapılması için de önemli bir araçtır. Herhangi bir ürün veya varlığa sahip olmak ve gelir elde etmek amaçlandığı zaman değerlendirme teknikleri devreye girer. Örneğin, bir ev satın alacağı zaman insanlar ilgili evin gelecekteki yatırım potansiyelini de göz önünde bulundurmaktadır. Buna benzer şekilde bir şirket değerlendirilirken de şirketin büyüme potansiyeli ve yatırım gelirleri anlamlı bir hal alacağından dolayı yatırımcılar karar süreçlerinde değerlendirme metriklerini göz önünde bulunduracaktır.

Değerleme kavramı, şirketler mevzu bahis olduğunda finansal ve stratejik anlamda karar alırken önemli rol oynamaktadır. Kurumsal finans alanında yer alan herkes için, şirket değerlendirme mekanizmalarını anlamak vazgeçilmez bir gerekliliktir [3]. Ayrıca piyasalarda kabul görmüş, itibarı yüksek kurumların, bir şirketin değerinin belirlenmesi söz konusu olduğunda diğer kurumlara göre daha etkili olması beklendiği bir durumdur.

Çeşitli başlıklara ayrılan değerlendirme yaklaşımlarını kullanarak anlamlı bir fiyat aralığı yakalamak mümkündür. Ancak, değerlendirme sürecindeki problemlerden biri, hangi yaklaşımın tercih edilmesi ve uygulanması gerektiğidir. Zira, farklı üst başlıklar altına ayrılan bu yöntemlerin her birinin alt başlıklarında da belirli konularda kendi avantaj ve dezavantajları mevcuttur.

2 DEĞERLEME YAKLAŞIMLARI

İlgili ve uygun değerlendirme yaklaşımlarına dikkat edilmelidir. Aşağıda tanımlanan üç yaklaşım, değerlendirme işlemlerinde kullanılan başlıca yaklaşımlardır. Bu yaklaşımlar, fiyat dengesi, faydaların beklentisi veya yerine geçme ekonomik prensiplerine dayanmaktadır. Şekil 1’de de görüldüğü üzere temel değerlendirme yaklaşımları şunlardır: Gelir Yaklaşımı, Piyasa Yaklaşımı, Maliyet Yaklaşımı. Hangi kategori üzerinden ilerleneceğine karar vermek ise ancak ana başlıkları irdeleyip ihtiyaca göre karar verdikten sonra mümkün olacaktır. Kısaca bahsetmek gerekirse, *Gelir Yaklaşımı*, şirketin gelecekte üretmesi beklenen tüm fayda akışlarının mevcut değerini hesaplayarak iş değerinin tahmin edilmesini içerir. Örneğin, bir yatırımcı *Gelir Yaklaşımını* kullanarak restoran satın almak istediğinde restoranın piyasa değerini, restoranın gelecekteki toplam kazancını, bugünkü değerine çevirerek belirleyebilir. *Maliyet Yaklaşımı*, bir alıcının bir varlık için, eşdeğer faydaya sahip bir varlığı satın alma veya inşa etme maliyetinden daha fazla ödemeyeceği ekonomik ilkesini kullanarak bir değer göstergesi sağlar. Örneğin, *Maliyet Yaklaşımını* kullanan bir yatırımcı fabrika satın almak istediğinde fabrikanın aynısını güncel fiyatlarla yeniden inşa etmenin veya yerine koymanın ne kadar mül olacağını hesaplar ve fabrika değerini bu şekilde belirler. *Piyasa Yaklaşımı* ise, şirket değerini, konu şirketin bir veya daha fazla yönünü, piyasa değeri olan diğer benzer şirketlerin ilgili yönleriyle karşılaştırarak belirler. Örneğin, bir apartman dairesinin değeri *Piyasa Yaklaşımı* ile belirlenmek isteniyorsa, aynı mahalleden son zamanlarda satışı yapılan benzer dairelerin değerlerinin detaylı incelenmesi ve karşılaştırılması sonucunda dairenin değeri belirlenebilir [5, 6].

François Derrien, Laurent Frésard, Victoria Slabik ve Philip Valta'nın yazmış olduğu “Industry Asset Revaluations around Public and Private Acquisitions” başlıklı makalesinden edindiğimiz veriler ışığında, şirket değerlendirilmesinde,

şirketlerin bilgilerine detaylı olarak sahip olmanın kritik olduğu sonucuna varılmıştır. Araştırma, ABD’li özel ve kamu şirketlerini içeren geniş bir örneklem üzerinde yapılmıştır. 1990-2015 dönemindeki 7.994 adet yatay işlem incelenmiş ve 252.979 benzersiz kümülatif anormal getiri (KAG) hesaplanmıştır. Sonuçlar, kamu ve özel hedeflerin dahil olduğu işlemlerde akranların değer artışlarında keskin farklılıklar bulunduğunu göstermektedir. Özel hedeflerle ilgili anlaşma duyurularından sonra akranların değer artışı önemli ölçüde negatifken, kamu satın almalarını takiben pozitif yönde etkilenmiştir. Bu bulgular, şirket değerlemede daha derinlemesine bilginin önemini vurgular niteliktedir [7]. Örneğin bir şirketin ticari ilişkileri, ticari amaçlarla imzalanan sözleşmeleri, alınmışsa bankadan alınan kredilerin şartları gibi faktörlerin bilinmesi durumunda daha derinlemesine bir sonuç alınabilir.



Şekil 1: Şirket Değerleme Yaklaşımları ve Alt Başlıkları

2.1 Gelir Yaklaşımı

Şirket değerlendirme süreçlerinde kullanılan, geleneksel yöntemlerden biri olan gelir yaklaşımı, yukarıda kısaca açıklandığı üzere şirketin gelecekte üretmesi beklenen tüm fayda akışlarının bugünkü değerini hesaplayarak işletme değerinin tahmin edilmesine dayanmaktadır [4]. Bir şirketin gelecekteki 5 yıl boyunca elde edeceği tahmini nakit akışının değerinin hesaplanıp bugüne indirgenerek şirketin değerinin belirlenmesi, gelir yaklaşımının bir örneğidir. Gelir yaklaşımının bir parçası olarak, gelecekteki nakit akışlarının tahmin edilmesinde kullanılan birkaç metot bulunmaktadır. Group Inc'e göre, Gelir Yaklaşımı iki metoda ayrılır: Kazançların Sermayeleştirilmesi ve İndirgenmiş Nakit Akışı (DCF) [9]. Gelir Yaklaşımı başlığı altında, İndirgenmiş Nakit Akışı (DCF) metoduna odaklanılacak olup, Kazançların Sermayeleştirilmesine veya sektördeki diğer metodlara yer verilmeyecektir.

2.1.1 İndirgenmiş Nakit Akışları (DCF) Yöntemi

İndirgenmiş nakit akışı modelinin amacı, devam eden bir işletmenin özsermayesini değerlemektir [7]. Bu yöntem, şirketin gelecekteki performansı ve risklerine göre şirket değerini belirler [8]. DCF, genellikle şirketin gelecekteki büyümeyi garanti eden yatırımlardan kaçınmadan hissedarlarına verebileceği nakit akışlarının toplamı olarak yorumlanır. İşletme değerini tahmin etmek için temel olarak DCF modelinde serbest nakit akışı sıkça kullanılır. Serbest nakit akışı, tüm finansal yükümlülüklerin, faizler de dahil olmak üzere, karşılanması ve gerekli yatırımların gerçekleştirilmesinden

sonra kalan nakit akışıdır [4]. Bu yöntemin genellikle büyüme odaklı, istikrar odaklı olmasından ötürü istikrarlı büyüyen şirketler ve ileride büyümesi öngörülebilir şirketler için daha uygun olduğu söylenebilir. Gelecekteki nakit akışlarının bugünkü değerine ulaşmak için, modelden elde edilen iskonto oranı, eldeki şirketin finansmanı ile ilgili risk temelinde iskonto oranı uygular. Gelecekteki nakit akışlarının bugünkü değerini hesaplamak için kullanılan formül (1) [9]:

$$PV = \sum_{t=0}^{\infty} \frac{CF_t}{(1+r_t)^t} \quad (1)$$

Bu formülde, PV - Mevcut Değer, CF_t - yıl t'deki net nakit girişi, r - iskonto oranı, t - yıl anlamına gelmektedir [9]. Şirketin bugünkü değerini hesaplayabilmek için öncelikle şirkete en uygun nakit akışı türü seçilmelidir. İkinci olarak, nakit akışı tahmini için ise en uygun açık dönem belirlenmelidir. Üçüncü olarak, bu dönem için nakit akışı hazırlanmalıdır. Ardından, açık tahmin döneminin sonunda, konu varlık için bir terminal değerinin uygun olup olmadığı ve varlığın niteliğine uygun terminal değer belirlenip belirlenemeyeceği belirlenmelidir. Bundan sonra, uygun bir iskonto oranı belirlenmelidir. Son olarak, tahmin edilen gelecekteki nakit akışı, varsa terminal değer de dahil edilerek uygulanmalıdır [9].

Nakit akışı seçimi yaparken temel nakit akışlarını anlamak ve bu nakit akışlarına uygun iskonto türü seçmek gereklidir.

Tablo 1: Nakit Akışı – İskonto Tipi Eşleşmeleri

Nakit Akışı Tipi	Uygun İskonto Oranı
FCF. Serbest Nakit Akışı	WACC. Ağırlıklı Ortalama Sermaye Maliyeti
ECF. Öz Sermaye Nakit Akışı	Ke. Öz Sermaye Maliyeti
CFd. Borç Nakit Akışı	Kd. Borç Maliyeti

Tablo 1'de bir şirket tarafından üretilen farklı nakit akışları ve her bir akış için uygun iskonto oranları gösterilmektedir [3]. İskonto oranı ve diğer değişkenler birbiriyle uyumlu seçilmelidir [9].

Serbest nakit akışı (FCF), şirketin toplam değerinin elde edilmesini sağlar. Özkaynak nakit akışı (ECF), borcun değeri ile birleştirildiğinde, şirketin toplam değerinin belirlenmesini de sağlayacak olan özkaynak değerinin elde edilmesini sağlar. Borç Nakit Akışı (CFd), borç için ödenecek faizlerin ve ana para geri ödemelerinin toplamıdır [3].

Ağırlıklı Ortalama Sermaye Maliyeti (WACC), yatırımcıların şirketten almayı beklediği getiridir [10]. Öz Sermaye Maliyeti (Ke), adından da anlaşıldığı üzere öz sermaye için gereken getiri anlamına gelmektedir. Aynı şekilde Borç Maliyeti (Kd) de borç için gereken getiriyi ifade eder.

Serbest Nakit Akışı (FCF) Formülü [9]:

$$FCF = EBIT \cdot (1 - T) + Dep - FCInv - WCInv \quad (2)$$

Formül (2)'de değişkenler şunlardır:

- FCF: Serbest nakit akışı
- EBIT: Faiz ve vergi öncesi kar (Earnings Before Interest and Taxes)
- T: Vergi oranı
- Dep: Amortisman giderleri
- FCInv (CAPEX): Sabit sermaye yatırımları
- WCInv: Çalışma sermayesi yatırımları

Serbest Nakit Akışı (FCF) Formülü [9]:

$$FCF = EBIT - [Taxes + Tm \cdot (interest)] - Net Investments \quad (3)$$

Formül (3)'te değişkenler şunlardır:

- FCF: Serbest nakit akışı
- EBIT: Faiz ve vergi öncesi kar (Earnings Before Interest and Taxes)
- Taxes: Vergiler
- Tm: Marjinal vergi oranı
- interest: Faiz giderleri
- Net Investments: Net yatırımlar

İlk Serbest Nakit Akışı formülü (2), faaliyetlerden elde edilen nakit akışını daha detaylı şekilde ele alır. Bu yöntem, nakit çıkışı gerektirmeyen amortisman kalemlerini dikkate alırken, ikinci formül (3) doğrudan EBIT üzerinden faiz ve vergi giderlerini çıkartarak daha yalın bir yaklaşımla Serbest Nakit Akışını hesaplar. Kullanılacak olan formül şirketin odaklandığı finansal detaylara ve şirketin finansal yapısına bağlı olarak değişmektedir.

Öz Sermaye Nakit Akışı (ECF) Formülü [11]:

$$ECF = FCF - [interest payments \times (1 - Tm)] - principal repayments + new debt \quad (4)$$

Formül (4)'te değişkenler şunlardır:

- FCF: Free Cash Flow, işletmenin serbest nakit akışı.
- Interest payments: Faiz ödemeleri, borçların faiz giderleri.
- Tm: Vergi oranı, faiz ödemelerinden düşülecek vergi indirimi.
- Principal repayments: Anapara ödemeleri, borçların geri ödenen anaparası.
- New debt: Yeni borç, işletme tarafından alınan yeni borç miktarı. [11]

Ağırlıklı Ortalama Sermaye Maliyeti (WACC), şirketin genel maliyet yapısına farklı sermaye maliyetlerini ağırlıklandırır [11].

Ağırlıklı Ortalama Sermaye Maliyeti Formülü (WACC) [12]:

$$WACC = \frac{Equity}{Debt + Equity} * Cost of Equity + \frac{Debt}{Debt + Equity} * Cost of Debt \quad (5)$$

Öz Sermaye Maliyeti Formülü [11]:

$$Cost of Equity = r_f + \beta(r_m - r_f) \quad (6)$$

Formül (6)'da değişkenler şunlardır:

- r_f : Risk-free rate, risksiz getiri oranı.
 - β (Beta): Beta, hisse senedinin piyasa riskine duyarlılığı.
 - r_m : Market return, piyasa getirisi.
- anlamalarına gelmektedir.

Borç Maliyeti Formülü [11]:

$$Cost of Debt = r_d * (1 - t) \quad (7)$$

Formül (7)'de değişkenler şunlardır:

- r_d : Debt interest rate, borç faiz oranı.
- t : Tax rate, vergi oranı.

Şirketin değeri, ağırlıklandırılmış ortalama sermaye maliyetinin tüm bileşenleri, gelecekteki nakit akışları ve tahminler belirlendikten sonra hesaplanabilir [9].

$$value = \frac{FCF_{t=1}}{WACC-g} \quad (8)$$

Formül (8)'de g - gelirlerin büyüme oranı anlamında kullanılmıştır.

İndirgenmiş Nakit Akışları yöntemi, bir şirketin değerini belirlemek için gelecekteki nakit akışlarının bugüne indirgenmesini sağlar. Bu analiz, uygun nakit akışının belirlenmesi ve bu akışın, kendisine uygun iskonto tipiyle iskonto edilmesiyle gerçekleştirilir. Yukarıdaki formüllere dayanarak, Ağırlıklı Ortalama Sermaye Maliyeti (WACC), şirketin hem özkaynak maliyetini hem de borç maliyetini hesaba katarak belirlenir. Özkaynak maliyeti, risksiz getiri oranı, beta ve piyasa risk primi üzerinden hesaplanırken, borç maliyeti ise borç faiz oranının vergi sonrası değeri ile hesaplanmaktadır. Tüm bunların ışığında, şirketin değerine gelecekteki nakit akışlarının WACC ile indirgenmesi ve akışın sürekli büyüme oranı (g) ile düzeltilmesiyle ulaşılmaktadır. Bu yöntem, şirketlerin potansiyelini değerlendirirken yatırımcılar ve analistlere geniş bir bakış açısı sunmaktadır.

2.1.1.1 İndirgenmiş Nakit Akışı (DCF) Yönteminin Avantajları

Gelir yaklaşımında kullanılan İndirgenmiş Nakit Akışı (DCF) yöntemini öne çıkaran bazı maddeler bulunmaktadır. Bu önemli maddelerden biri, şirketin gelecekteki nakit akışının bugüne indirgenmesinin ardından objektif bir şekilde şirketin değerinin tahmin edilmesiyle birlikte yatırımcılara ve analistlere şirketin değeri hakkında net bir fikir vermesidir. DCF, şirketin performansını ve potansiyelini göz önünde bulunduran bir yöntem olduğundan dolayı istikrarlı bir şekilde büyümekte olan ve potansiyel barındıran şirketler açısından çok uygun bir metottür. DCF yöntemi ekonomik olarak sağlam şirketlerin çoğu değerlemede açıkça hakimdir. Ayrıca, diğer yöntemler oldukça basittir ve desteklemek için sofistike teorilere veya matematik modellere ihtiyaç duymazlar. Ancak DCF yöntemi ihtiyaç duyar. DCF yöntemi, karlı ve ekonomik olarak sağlam şirketlerin değerini en iyi şekilde yakalar [13]. Marc Goedhart, Timothy Koller ve David Wessels gibi hatırı sayılır araştırmacılar da projeleri, bölümleri ve şirketleri değerlendirmek için en doğru ve esnek yöntem olarak indirimli nakit akışını (DCF) işaret etmektedir [14].

2.1.1.2 İndirgenmiş Nakit Akışı (DCF) Yönteminin Dezavantajları

Avantajlarının yanında dezavantajları da bulunduran bu yöntemin öncelikle belirtilmesi gereken dezavantajı işlem karmaşıklığıdır. Yukarıdaki formüllerden yola çıkarak diğer yöntem ve metodlara nazaran daha karmaşık bir yöntem olduğu söylenebilir. Bir diğer yandan, gelecekteki nakit akışlarının doğru şekilde belirlenmesinde tahmin riski unsuru barındırmaktadır. Bu durum özellikle piyasanın belirsiz olduğu ve piyasanın değişken bulunduğu senaryolarda geçerlidir. Ana değerlendirme formülündeki girdilerin küçük miktarda yanlışlıkları bile sonucu son derece fazla etkilemektedir. Björn Lunden'in de bahsettiği gibi DCF, işletmedeki büyüme ve marjların yanı sıra getiri gerekliliğine ilişkin hangi varsayımların yapıldığına duyarlıdır [15]. Yani DCF içerisinde doğru varsayımlar yapılmasını gerektiren kısımlar da mevcuttur. Aksi takdirde büyük ölçüde yanlış değer sonuçlarıyla karşılaşmak mümkündür. Gelecekteki gelir akışlarının tahmin edilmesi ve indirim oranının seçilmesi genellikle spekülasyon ve subjektiftir. Bu kısmen, şirketlerin gelecekteki gelişimi oldukça belirsiz olduğu ve liste dışı şirketler için beta olmadığı için öz sermaye maliyetini tahmin etmede zorluklar yaşanmasından kaynaklanmaktadır [4].

2.2 Piyasa Yaklaşımı

Piyasa Yaklaşımının arkasındaki genel fikir, bir varlığın veya şirketin gerçek değerinin, piyasanın benzer veya karşılaştırılabilir varlıklar veya şirketler için ödeyebileceği satış fiyatıdır [16]. Yani, piyasada işlem gören benzer varlıklarla karşılaştırılarak yapılan ampirik bir değerlemedir [17]. Örneğin, bir şirket değerlendirme sürecinde, Piyasa Yaklaşımı kullanılarak benzer alanlardaki, benzer koşullardaki, benzer özellikteki şirketlerin değerlerini saptamak mümkündür. Bunlara ek olarak, piyasa yaklaşımları, diğer şirketlerin bilinen piyasa fiyatlarını kullanarak çarpanlar hesaplar ve bu çarpanları değerlemeyi yapılacak şirkete uygular [18]. Şirket değerlemesine piyasa perspektifinden yaklaşırken iki yöntem kullanılabilir: Karşılaştırılabilir Şirketler Yöntemi ve Karşılaştırılabilir İşlemler Yöntemi. Bu makalede yalnızca Karşılaştırılabilir Şirketler Yöntemine değinilecektir [19].

2.2.1 Karşılaştırılabilir Şirketler Yöntemi

Piyasada bazen ismi göreceli değerlendirme yöntemi olarak da geçen bu yöntemin amacı, bir şirketi, benzer büyüklükteki, ürün ve coğrafya bazında diğer şirketlerle karşılaştırmaktır [19,20]. Bu yöntem, diğer yöntemlere göre yoğun işlemler ve karmaşık hesaplamalar barındırmadığı için nispeten kolay sayılabilmektedir. Fakat şirketlerin karşılaştırılması sırasında dikkat edilmesi gereken hususlar da vardır. Örneğin, bir ankete göre analistlerin %40'ı karşılaştırılabilir şirketleri seçme sürecini sorunlu buluyor [21]. Bu yüzden yöntemin zor yanları da bulunmaktadır demek mümkün. Aynı zamanda karşılaştırılabilir şirketler yönteminde takip edilmesi gereken bazı aşamalar da mevcuttur. Bu aşamalar sırasıyla **karşılaştırılabilir firmaların seçilmesi, kullanılacak oranların seçilmesi, sektördeki benzer firmaların ortalamasının bulunması, değerlendirilen firmanın performansının tahmin edilmesi, firmanın değerinin bulunması** şeklinde sayılabilir [22]. Bu yöntemde kullanılacak birçok oran ve çarpan mevcuttur. Fakat Toraman ve Körpi'ye göre en çok kullanılan çarpanlar Fiyat/Kazanç(F/K) çarpanı, Piyasa Değeri/Deferi (PD/DD) Çarpanı, Fiyat/Nakit Akım (F/NA) çarpanı, Fiyat/Net Satış (F/S) çarpanı ve Firma Değeri/FAVÖK çarpanlarıdır [22].

2.2.1.1 Fiyat/Kazanç Oranı

Bu oran işletmenin piyasa değerini işletmenin kazançlarıyla ilişkilendirerek hesaplamaya olanak sağlamaktadır [21]. Fiyat/Kazanç oranı, piyasanın genel durumu hakkında mükemmel bir genel görünüm sağlar ve yatırımcıların hisse senedine, kazançlarına kıyasla ne kadar ödemeye istekli olduklarını bize gösterir [19]. Karşılaştırılabilir şirketler seçildikten sonra kullanılacaksa bu oranın formüllemesine ve uygulanmasına geçilebilir. Fiyat/Kazanç oranı ile şirket değeri hesaplanırken basitçe aşağıdaki formüllemeler (9) ve (10) kullanılır [22]:

$$F/K = \text{Hisse Senedi Piyasa Fiyatı} / \text{Hisse Başına Net Kar} \quad (9)$$

$$\text{Firma Değeri} = \text{Seçilen Sektör veya Piyasa Ortalama F/K} * \text{Firma Net Karı} \quad (10)$$

2.2.1.2 Piyasa Değeri/Defter Değeri Oranı (PD/DD)

Bir finansal hizmet firmasının piyasa değeri/defter değeri oranı, hisse başına fiyatın, hisse başına özkaynak defter değerine oranıdır [23]. Bu oran, bir şirketin piyasa değerinin özkaynaklarının kaç katı olduğunu gösterir [22]. Piyasa değeri/defter değeri oranı büyük ölçüde bilançonun şirket varlıklarının piyasa değerinden ne kadar saptığına bağlıdır [4]. Bu oranla şirket değerlemesine aşağıdaki formül (11) ve (12) aracılıklarıyla ulaşılabilmektedir [22]:

$$PD/DD = \text{Hisse Senedi Piyasa Fiyatı} / \text{Hisse Başına Düşen Defter Değeri} \quad (11)$$

$$\text{Firma Değeri} = \text{Seçilen Sektörün veya Piyasanın Ortalama } \frac{PD}{DD} \text{ Oranı} * \text{Şirketin Defter Değeri} \quad (12)$$

2.2.1.3 Fiyat/Nakit Akımı Oranı (F/NA)

Fiyat/Nakit Akımı oranının amacı, hisse senetlerinin nakit akışına göre ne kadar değerli veya değersiz olduğunu göstermektir [24]. Bu oran, piyasa fiyatlarının hisse başına düşen nakit akımı ile oranlanmasından elde edilir. Bazı endüstrilerde hisse fiyatı, net gelirden ziyade daha çok nakit akışına bağlıdır. Bu sebeple yatırımcılar sık sık F/NA oranına bakarlar [25]. Fiyat/Nakit Akımı oranı yardımıyla şirket değeri hesaplanırken aşağıdaki formül (13) ve (14) kullanılmaktadır [22]:

$$F/NA = \frac{\text{Hisse Senedi Piyasa Fiyatı}}{\text{Hisse Senedi Başına Nakit Akımı (Net Kar+Amortisman)}} \quad (13)$$

$$\text{Firma Değeri} = \text{Seçilen Sektör veya Pazarın Ortalama F/NA Oranı} * \text{Şirket Nakit Akımı} \quad (14)$$

2.2.1.4 Fiyat/Net Satış Oranı (F/S)

Fiyat/Net Satış oranı, bir işletmenin veya sermayenin, ürettiği gelire göre değerini ölçer [25]. Adından da anlaşılacağı üzere bu oran şirketin değerinin artmasını satışlara bağlamaktadır. F/S katsayısı, aynı endüstride çalışan firmaların karşılaştırılmasında en çok kullanılan yöntemlerden biridir [22]. O'Shaughnessy, ABD verilerine dayanarak, F/S oranını düşük değerli hisse senetlerini seçmek için en iyi oran olarak nitelendirdi [26]. Ayrıca borsada işlem gören şirketlerin önemli bir bölümünün de fiyat satış oranı ile değerlendirilmekte olduğu bilinmektedir [27]. Fiyat satış oranı ile şirket değerlemenin bağıntısı aşağıda formül (15) ve (16) olarak bulunmaktadır [22]:

$$F/S = \frac{\text{Hisse Senedinin Cari Piyasa Değeri}}{\text{Hisse Başına Satış Geliri}} \quad (15)$$

$$\text{Firma Değeri} = \text{Seçilen Sektör veya Pazarın Ortalama F/S Oranı} * \text{Şirket Hisse Başına Satış Geliri} \quad (16)$$

2.2.1.5 Firma Değeri/FAVÖK Oranı (FD/FAVÖK)

Bir şirketin nakit akışını ve ödeme gücünü ölçmek için ortaya konulan araca Faiz, Vergi ve Amortisman Öncesi Kazanç yani FAVÖK adı verilmektedir [27]. Kısaca FAVÖK; faiz, gelir vergisi, amortisman ve itfa payı çıkarılmadan önceki kârdır ve işletme değeri, işletmeye yatırılan tüm sermayenin piyasa değeridir [28]. Firmanın cari dönemdeki tüm borç ve alacaklarıyla beraber satın alınması durumunda ortaya çıkan değer FD/FAVÖK oranından gelmektedir ve bu oran formül (17) olarak aşağıda verilmiştir [22]:

$$\frac{FD}{FAVÖK} = \frac{\text{Özkaynakların Piyasa Değeri} + \text{Mali Borçların Piyasa Değeri (Mali Borçlar Hazır Değerler)}}{FAVÖK} \quad (17)$$

2.2.2 Piyasa Yaklaşımının Avantajları

Benzer veya karşılaştırılabilir şirketlerin piyasa fiyatlarından yola çıkarak değerlendirme yapmaya yarayan Piyasa Yaklaşımının bir dizi avantajları mevcuttur. Bunlardan bazıları, Karşılaştırılabilir Şirketler Yöntemi gibi basit ve anlaşılır yöntemler kullanarak, benzer alanlardaki ve koşullardaki şirketlerle karşılaştırma yaparak değerlendirme yapmanın yanında Fiyat/Kazanç Oranı, Piyasa Değeri/Defter Değeri Oranı, Fiyat/Nakit Akımı Oranı, Fiyat/Net Satış Oranı ve Firma Değeri/FAVÖK Oranı gibi çarpanlar kullanıp, sektördeki şirketlerin performansını baz alarak kolay ve hızlı sonuçlar elde

etmeyi sağlamaktır. Genellikle halka açık şirketlerin değerlemede daha başarılıdır [29]. Bu yaklaşım, herhangi bir varsayımında bulunması gerekmediğinden dolayı üstündür [4]. Son olarak ise mevcut piyasa fiyatlarına dayanarak piyasanın ruhunu yansıtmakta ve mevcut piyasa duyarlılığını daha iyi yansıtmakta olduğunu tekrardan belirtmekte fayda var.

2.2.3 Piyasa Yaklaşımının Dezavantajları

Avantajlarının aksine Piyasa Yaklaşımının bazı dezavantajları da mevcuttur. Karşılaştırılabilir şirketlerin seçilme süreci, yukarıda da belirtildiği üzere analistlerin %40'ının sorunlu bulduğu bir aşamadır ve bu durum yöntemin başarısını etkileyebilmektedir. Ayrıca, piyasadaki dalgalanmalar ve piyasa koşulları karşılaştırma sürecini zorlaştıran etmenlerden olup sonuçların güvenilirliğini azaltabilmektedir. Bir diğer yandan, bu yöntem sektördeki diğer karşılaştırılabilir şirketlerin performansına ve piyasadaki verilere dayalı olduğundan dolayı şirketin özel koşullarını ve potansiyelini göz ardı ederek bir değerlendirme süreci gerçekleştirebilmektedir. Son olarak ise yöntemde, değer tahmin edilmesinde şeffaflık sorunları ve manipülasyona açıklık nedeniyle tutarsız saptamalar yapılabilmekte, ayrıca büyüme oranlarının ve riskin açık bir şekilde ifade edilememesi de bu yöntemin olumsuzlukları arasında yer almaktadır [30].

2.3 Maliyet Yaklaşımı

Maliyet yaklaşımını kullanarak, zaman, rahatsızlık, risk veya diğer faktörler devrede olmadıkça, bir tüketicinin eşit fayda sağlayan bir varlığı elde etmek için ödeyeceği maliyetten daha fazla ödeme yapmayacağı ekonomik prensibi doğrultusunda önlem alınır [9]. Yani şirketin gelecekteki nakit akışlarıyla veya piyasadaki benzer şirketlerin değerleriyle ilgilenilmediği zaman kullanılan bir yaklaşımdır. Bazı kaynaklarda Aktif Bazlı Yaklaşım ve Varlık Yaklaşımı olarak belirtilen bu yaklaşım, bir tüketicinin eşdeğer faydaya sahip bir varlığı elde etmek için ödeyeceği maliyetten fazlasını ödemeyeceği ekonomik prensibini esas alır [9,31,32]. Tüm bunlardan dolayı bu yöntem, diğer yöntemler uygulanmadığında veya firmanın değeri özellikle tesis veya ekipman gibi belirli varlıklara bağlıysa kullanılabilir [33]. Bu yaklaşımda firmanın değerinin bilançoda belli olduğu, bilançodan görüldüğü kabul edilir [30]. Aynı zamanda bu yaklaşımda, şirket değerlemesi yapılırken şirketin tüm maddi ve maddi olmayan duran varlıklarının ve yükümlülüklerinin değeri dikkate alınır [34]. Genel olarak Defter Değeri, Tasfiye Değeri, Net Aktif Değeri gibi yöntemler aktif bazlı firma değerlendirme yöntemleri arasındadır. [30].

2.3.1 Defter Değeri Yöntemi

Defter değeri, bir varlığın bilançoda görülen kayıtlı değeridir [35]. Defter değeri yönteminde, firmanın değerinin tespiti esnasında bilançodan hareket edilmektedir [34]. Defter değeri aşağıdaki formül (18) ile ifade edilmektedir [3]:

$$\text{Defter Değeri} = \text{Toplam Varlıklar} - \text{Toplam Borçlar} \quad (18)$$

Şirketin toplam varlıklarından toplam borçlarının çıkarılmasıyla birlikte şirketin defter değeri elde edilmiş olur. Aynı zamanda öz sermaye değeri olarak da adlandırılabilen defter değerinin toplam hisse adedine bölünmesinin ardından hisse başı defter değeri elde edilir [35].

2.3.2 Tasfiye Değeri Yöntemi

Tasfiye değeri, bir firmanın iflas etmiş kabul edilip tüm varlıklarının parçalar halinde satılarak nakde dönüştürülmesi sonucu ulaşılan değerdir [30]. Ancak, bu her zaman şirketin minimum değerini temsil eder, çünkü bir şirketin değeri, faaliyetlerine devam edeceği varsayıldığında, tasfiye değerinden daha yüksektir [3]. Çok dar bir kapsamı temsil ettiğinden

dolayı kullanım alanı pek bulunmayan bir yöntemdir. Şirketin tasfiye değeri, şirketin potansiyelini ve geleceğini yansıtmadığı için genellikle yalnızca iflas ve zorunlu satış durumlarında kullanılmaktadır. Bu bilgilerden yola çıkarak Tasfiye Değeri Yöntemi ile değerlendirme formülünü aşağıdaki formül (19) gibi yazmak mümkündür:

$$\text{Tasfiye Değeri} = \text{Varlıkların Satış Değeri} - \text{Toplam Borçlar} \quad (19)$$

2.3.3 Net Aktif Değeri Yöntemi

Bir diğer adıyla düzeltilmiş defter değeri olan net aktif değeri, şirketin varlıklarının ve kaynaklarının piyasa değerlerinin bulunmasıyla elde edilen değerdir. Bu yöntem, şirketin yeniden kurulması sırasında ortaya çıkan maliyeti, şirketin sahip olduğu varlıkların piyasa değerinin tespiti ve varlıklarının satışı sonucunda hesaplanan geliri ifade eder. Bu yöntemde varlıkların piyasa değerleri yeniden hesaplandıktan sonra borçların güncel değerlerinden çıkarılır ve net aktif değeri elde edilmiş olur. [30, 34].

$$\text{Net Aktif Değer} = \text{Şirketin Varlıklarının Piyasa Değeri} - \text{Şirketin Yükümlülüklerinin Piyasa Değeri}$$

Net Aktif Değeri Yöntemi ile şirketin varlıklarının piyasa değeri kullanılarak değerlendirme yapıldığından ötürü gerçekçi bir değerlendirme yapılabilir. Örneğin şirketin varlık havuzunda bulunan bir gayrimenkuller ciddi bir değer artışı yaşamış olabilir. Bunun sonucunda, bu yöntemin şirketin varlıklarındaki değer artışını göz önünde bulundurarak değerlendirme yaptığını söylemek mümkündür. Fakat bazı durumlarda varlıkların piyasa değerini belirlemek uzun ve maliyetli olabilir. Bununla birlikte ise eksperlere danışıp, uzman görüşüne başvurulması gerekebilmektedir. Kısacası net aktif değeri yöntemi ile değerlendirme yapmak doğru ve iyi sonuçlar verebilir fakat bazı durumlarda uzun zaman ve ek maliyet gerektirebilmektedir.

2.3.4 Maliyet Yaklaşımının Avantajları

Maliyet Yaklaşımının avantajlarından birisi, şirketin varlıkların defter değerleri, borçları gibi hesaplanması mümkün olan somut bilgilere dayalı olmasıdır. Bu yüzden maliyet yaklaşımı somut varlıklara sahip şirketler için daha güvenilir çıktılar verebilmektedir. Maliyet yaklaşımı diğer yaklaşımlara nazaran daha az spekülasyon olduğundan dolayı değerlendirme açısından daha net şeyler sunabilmektedir. Maliyet yaklaşımıyla değerlendirme yapabilmek eğer gerekli veriler sağlanmışsa gayet kolaydır [36]. Yaklaşımın, değeri varlıklar ve yükümlülükler arasında bölmesi hangi varlığın şirkete ne kadar ekonomik fayda sağladığına dair sağlam bir tablo sağlamaktadır. Son olarak ise satış veya satın alma müzakerelerinde varlıkların ve yükümlülüklerin değerleri belli olduğundan ilgili tarafa avantaj sağladığı söylenebilir [4].

2.3.5 Maliyet Yaklaşımının Dezavantajları

Maliyet yaklaşımının sayılabilecek kritik dezavantajlarından birisi, şirketin potansiyelini ve büyümesini göz ardı ederek değerlendirme yapmasıdır. Yöntem yalnızca şirketin varlıkların ve yükümlülüklerine bağlı olarak hesaplamalar içerdiği için gelecekteki nakit akışı, piyasa koşulları ve şirketin rekabet unsuru gibi parametreleri arka planda bırakmaktadır. Bundan dolayı gelecek potansiyeli kuvvetli olan ve hızlı büyüyen şirketler için maliyet yaklaşımı gerçekçi bir yaklaşım olmayabilir. Ayrıca yukarıda da belirtildiği üzere bazı varlıkların maliyetini belirlemek kolay olmayabilir. Buna bağlı olarak da daha fazla zaman ve para harcamak söz konusu olabilir. Bu yaklaşımın uygulanabilmesi, şirketin tüm bilgilerine tam erişim gerektirdiği için veriye ulaşmanın da zor olduğu ifade edilmektedir [4].

3 MAKİNE ÖĞRENMESİNİN ŞİRKET DEĞERLERKEN KULLANIMI

Verinin çoğu sektörde yığınla elde edilebilmesi, bu verilerin işlenebilmesini ve aynı veriler üzerinden öngörüler ve tahminler yapılabilmesini mümkün kılabilir. Bilgisayarların gücündeki sismik artış ve veri artışı makine öğrenmesi teknikleri ve algoritmalarının kullanımına olanak sağlamaktadır [37]. Bu anlamda elde edilen verilerden yola çıkarak makine öğrenmesi tekniklerini ve algoritmalarını kullanarak şirket değerlemesi yapmak da mümkündür. Finans alanında ise indirgenmiş nakit akışı yöntemi ile şirket değeri hesaplanması planlandığı zaman şirketin gelecekteki nakit akış aralığını makine öğrenmesi yardımıyla tahminleyebilmek bilgisayarların işlem kapasitesini kullanarak ve bu kapasite ile elde edilen verileri işleyerek gerçekleştirilmektedir. Kısacası, bu makalede makine öğrenmesinden yararlanarak ilgili şirketlerin gelecekteki nakit akışlarının tahmini yapılacak ve buna bağlı olarak şirketin değerine ulaşılacaktır.

4 MAKİNE ÖĞRENMESİ

Makine öğrenmesi, bilgisayarların geçmiş deneyimlere dayalı olarak öğrenmelerini ve zekâ kazanmalarını sağlayan algoritmalar ve tekniklerin geliştirilmesidir. Bu, Yapay Zekâ (AI) alanının bir dalıdır ve istatistikle yakından ilişkilidir. Öğrenme, sistemin girilen verileri tanıyıp anlaması ve bunlara dayanarak kararlar ve tahminler yapabilmesini ifade eder [38]. Bunun sonucu olarak, insanlar verilerden anlam çıkaramadığı durumlarda makine öğrenmesi uygulamayı tercih etmektedir. Birçok alanda kullanılmaya müsait olan makine öğrenmesinin temel amacı verilerden öğrenmektir [39]. Makine öğrenmesi teknikleri, sağlık, finans, sosyal medya, seyahat, e-posta spam ve zararlı yazılım filtreleme, çevrimiçi müşteri desteği, arama motoru sonuçlarını iyileştirme, ürün tavsiyeleri ve daha birçok uygulamada kullanılmaktadır [40].

Finans sektörü, her zaman zaman serisi verilerinin başarılı bir şekilde tahminlenmesine ilgi duymuştur [41]. Zaman serileri, zaman içinde ardışık ölçümler sonucu ortaya çıkan verilerin koleksiyonunu ifade etmektedir [42]. Finansal alanda zaman serisi verilerini bir hisse senedinin gün içindeki değişimi, bir şirketin aylık ve yıllık satış gelirleri olarak örneklemek mümkündür. Makine öğrenmesi teknikleri yardımıyla, zaman serileri hem analiz edilebilmektedir hem de tahminlenebilmektedir.

Bu makalede bir perakende şirketinin 2019 yılından 2023 yılının ilk 3 ayına kadarki günlük satış gelirleri üzerinden bir zaman serisi tahminlemesi yapılması amaçlanmaktadır. Tahminlerden elde edilen net satış gelirleri kullanılarak ilgili şirketin değerinin hesaplanması planlanmıştır. Şirketin değeri hesaplanırken İndirgenmiş Nakit Akışı yöntemi kullanılacaktır. Veriler, veri bilimi ve makine öğrenmesi platformu Kaggle üzerinde bulunan “Retail Data Set” [43] adlı veri kümesinden alınmıştır.

4.1 Verinin Keşfi ve Analizi

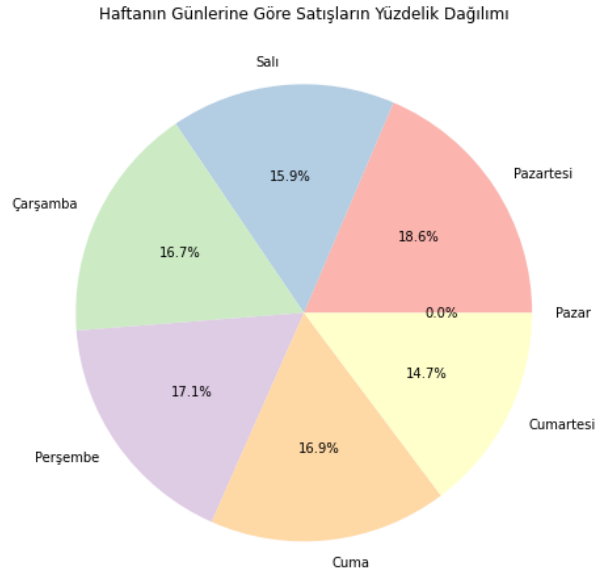
Retail veri kümesinde 29.103 satır verinin bulunduğu gözlemlenmiştir. Veride herhangi bir boş satır veya veri bulunmamaktadır. Her bir satır şirketin müşterilerine yaptığı bir satışı ifade etmektedir. 8 sütundan oluşan bu veri kümesinde “Date” sütunu hariç bütün sütunlar numerik değerler içermektedir. Veri kümesindeki “TotalSales” isimli sütunda 0 değerine sahip bazı satırlara rastlanmıştır. Bu değerlerin, şirket ile müşteri arasındaki bir promosyon nedeniyle oluştuğu anlaşılmaktadır. Bu satırların toplam satışa bir etkisi olmayacağından veri kümesinden çıkarılmasına gerek duyulmamıştır. Bunlara ek olarak şirketin pazar günleri hiçbir satış yapmadığı gözlemlenmiştir. Tablo 2’de veri kümesindeki sütunların özellikleri sunulmuştur:

Tablo 2: Retail Veri Kümesi

Sütun İsmi	Açıklama	Veri Tipi
Unnamed: 0	Veri Kümesinin İndeksi.	int64


Sütun İsmi	Açıklama	Veri Tipi
InvoiceID	İşlem Numarası	int64
Date	İşlemin Tarihi	object
ProductID	Ürün Numarası	int64
TotalSales	Satış Geliri	float64
Discount	Satış İndirimi	float64
CustomerID	Müşteri Numarası	int64
Quantity	Ürün Adeti	int64

Veri kümesinde “Unnamed: 0” isimli sütun satırların indexini belirttiği için bu sütuna ihtiyaç duymayıp veri setinden çıkartılmıştır. Bunun dışında ise herhangi bir talep tahmini veya analizi yapılmayacağından “InvoiceID”, ”ProductID”, “CustomerID” ve “Quantity” gibi genellikle işlem, ürün ve müşteri bilgilerini içeren sütunların veri setinden çıkartılması uygun görülmüştür. Bazı kullanıcıların aktif olmadığı ve örneğin en az 6 aydır işlem yapmamış olduğu saptandığı gibi bazı ürünlerin ise aylardır satışının yapılmadığı yani satıştan kaldırıldığı sonucuna varılmıştır. Bu satırlar veri kümesinden çıkartılmadan veri kümesini işlenmiştir, çünkü bu tarz senaryolarla şirketlerin ileride de karşılaşması muhtemeldir. Bu satış senaryolarını da göz ardı etmemekte fayda olacaktır. Sonuç olarak tahminlemeler öncesinde veri kümesinde “Date”, “TotalSales” ve “Discount” sütunları işleme alınmıştır. Ayrıca satırlardaki işlemler günlük bazda toplanıp günlük verilere çevirildikten sonra veri kümesi 1544 satıra indirgenmektedir.




Şekil 2: Haftanın Günlerine Göre Satışların Yüzdeleri Dağılımı

Şekil 2’de satışların yüzdeleri olarak günlere dağılımı verilmiştir. Bu grafikten anlaşıldığı üzere de Pazar günü satış yapılmadığı yorumuna ulaşılabilmektedir. Pazar günlerinde oluşan bu durum satışların genel grafiğine de yansımaktadır.




Şekil 3: Günlük Toplam Satışlar

Şekil 3'te görüldüğü üzere pazar günü satışların 0 olması grafikte ani düşüşlere sebep olmaktadır. Daha temiz bir şekilde satış verilerini grafikte inceleyebilmek adına Pazar günlerinin veri kümesinden çıkartılması kararı alınmıştır.



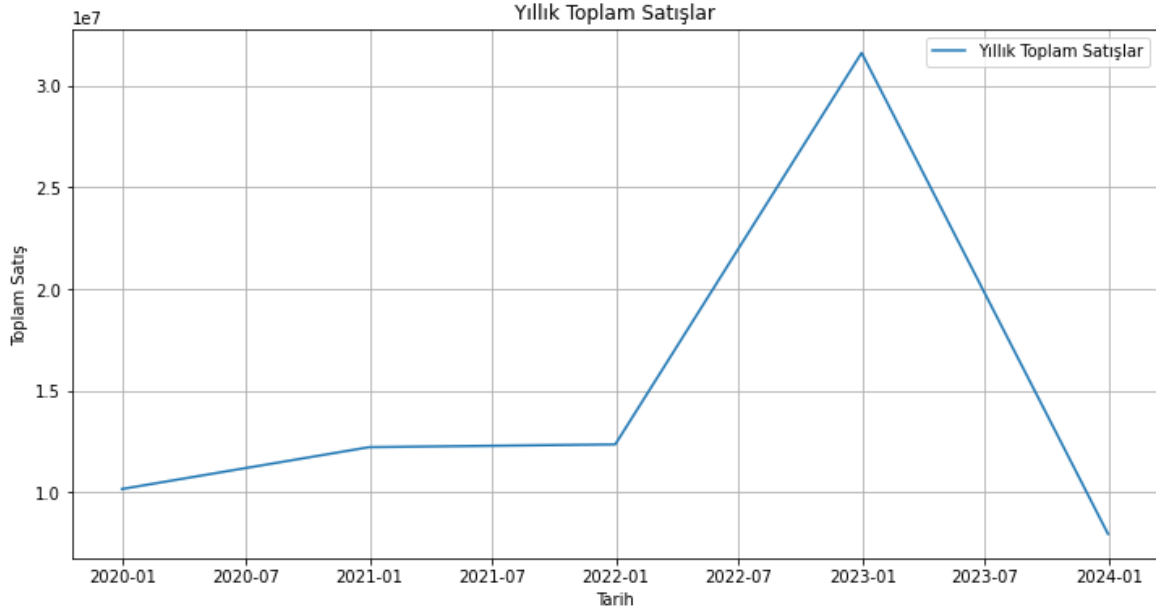
Şekil 4: Günlük Toplam Satışlar

Pazar günlerinin çıkartılmasının ardından veri kümesinin 1268 satıra indiği gözlemlenmektedir. Buna bağlı olarak ise Şekil 4'te Şekil 3'e göre daha analize yatkın ve temiz bir grafik ortaya çıkmaktadır. Şekil 4 incelendiğinde, veri kümesinin ani iniş-çıkışlar içermesi ve dağınık bir yapıya sahip olması, tahminlemeyi zorlaştırabilen etmenler arasında yer almaktadır.




Şekil 5: Aylık Toplam Satışlar

Şekil 5'te satış verilerinin günlük periyottan aylık periyota dönüştürülmüş hali yer almaktadır. Bu grafiğe göre 2019 yılından 2023 yılına doğru satışlarda net bir yükseliş görülmektedir. Makalenin devamında tahminler ve öngörüler aylık satışlar üzerinden olacağı için bu grafik önemle incelenmelidir.



Şekil 6: Yıllık Toplam Satışlar

Şekil 6’da veri kümesindeki satış verilerinin yıllık periyotta grafiklendirmesi görüntülenmektedir. Bu grafikte 2019 yılından verinin son tarihi olan 25 Mart 2023’e kadar satışların yükseldiği gözlemlenmektedir. X eksenindeki 01-2023’e denk gelen kısımda grafikteki ani kırılmannın sebebinin 2023 yılının toplam satışlarının mart ayına kadar bulunmasından dolayı olduğu sonucuna varılmaktadır.



Şekil 7: Günlük Net Satışlar

Şirketin değerlemesini yapabilmek adına toplam satışlardan ziyade şirketin yaptığı net satışa sahip olmamız gerekmektedir. Bunu sağlamak amacıyla yapılan toplam satışlardan indirim miktarı düşülmüştür ve net satış gelirleri elde edilmiştir. Şekil 7’de ise son durumdaki net satış gelirleri görselleştirilmesi mevcuttur. Şekil 4’teki günlük toplam satışlardan farklı olarak Şekil 7’de satış skalasının düştüğü söylenebilir.

4.2 Veriyi Hazırlama

Veri, aylık bazlara dönüştürülüp 50 satıra indirilmiştir ve modeller için hazırlanmaya başlanmıştır. Bu makalede şirketin nakit akışını tahminlerken 8 farklı algoritma kullanılacaktır. Bu 8 algoritmanın tamamında aylık veriler ile çalışılacaktır. Zaman serisi verilerinde veriyi durağan hale getirmeden çalışma yapmak sağlıklı sonuçlar doğuracaktır. Öncelikle aylık verilerdeki durağanlığı tespit etmek adına Python’da bulunan “statsmodels” sınıfından “adfuller” fonksiyonu çağırılmıştır. Bu test sonucunda görüntülenen değerlerden durağanlık tespit etmek mümkündür. ADF birim kök testi olarak bilinen bu teste ait hipotezler:

- i. H_0 : Değişkenlere ait seriler durağan değildir.
- ii. H_1 : Değişkenlere ait seriler durağandır.

Analiz sonucunda elde edilen test sonuçlarına göre, p değerinin 0.05’ten küçük olması durumunda H_0 hipotezi reddedilir ve seri durağan olur. Aksi hald, p değeri 0.05’ten büyük ise H_0 hipotezi reddedilemez ve serinin durağan olduğu kabul edilir [44]. Aylık veriler üzerine uyguladığımız ADF testinin sonucunda:

- o ADF Test Statistic: 0.017
- o p-value: 0.960

olarak elde edilmiştir. Burada p değeri 0.05’ten büyük olduğu için H_0 hipotezi reddedilemez ve serinin durağan olduğu sonucuna varılır. Seriyi durağan hale getirmek için veriler üzerinde fark alma veya log alma, karekök alma tarzı dönüşümler yapılabilir. İlk olarak serinin log1p dönüşümü sağlanıp tekrar ADF testine girmesine karar verilmiştir. Test sonuçları:

- o ADF Test Statistic: -0.812
- o p-value: 0.816

olmak üzere elde edilmiştir. Buradan anlaşılacağı üzere p hala 0.05’ten büyük olduğu için H_0 hipotezi reddedilemez ve serinin durağan olduğu kabul edilir. Log1p dönüşümünün ardından seriyi durağan hale getirmek adına serinin farkı alınıp tekrar ADF testine tabii tutulmuştur. Buna göre:

- o ADF Test Statistic: -4.123
- o p-value: 0.001

sonuçları elde edilmiştir. Test sonuçlarına göre p değeri 0.05’ten küçük olduğundan dolayı H_0 hipotezi reddedilir ve serinin durağan olduğu kabul edilir. Bu sırada fark alındığı için veri kümesinin ilk satırında oluşan boş satır veri kümesinden çıkartılmıştır.

Veri kümesi durağan hale getirildikten sonra makine öğrenmesi algoritmalarına hazırlanmak üzere küçük bir öznitelik mühendisliğine gidilmiştir. Öznitelik mühendisliğine istinaden veri kümesinin son haline algoritmalara sunulmak üzere 6 adet özellik daha eklenmiştir.

Tablo 3: Veri Kümesinin Son Hali

Sütun İsmi	Açıklama	Veri Tipi
Month	Ay	int64
Year	Yıl	int64
Day_of_Week	Haftanın Günü	int64
Week_of_Year	Yılın Haftası	int32

Sütun İsmi	Açıklama	Veri Tipi
Day_of_Year	Yılın Günü	int64
Quarter	Çeyrek	int64
TotalSales	Toplam Satış	float64
Log_TotalSales	Log1p Dönüşümlü TotalSales	float64
Diff_TotalSales	Diff Alınmış Log_TotalSales	float64

Tablo 3'te veri kümesinin dönüşümler ve öznitelik mühendisliklerinden sonraki hali mevcuttur. Bu özellikler modellerden elde edilen başarıya göre eklenmiştir. Tablo 3'te listelenen özelliklerden "Month", "Year", "Day_of_Week", "Week_of_Year", "Day_of_Year", "Quarter" bağımsız değişken olarak alınmak üzere üretilmiştir. "Diff_TotalSales" ise log1p dönüşümü ve fark alma işlemlerinin ardından durağanlaşmış bir şekilde bağımlı değişken olarak alınmıştır. Tahminler sonrası bu dönüşümlerin geri alınması sağlanacaktır.

Veri kümesinin başarısının değerlendirilmesi için eğitim ve test olarak ikiye bölünmesi kararı alınmıştır. Bu amaçla, veri kümesinde bir nakit akışı için baz alınabilecek en son uzun dönem olarak 2022 yılının 12 ayı test kümesi olarak seçilmiştir. 2022 yılının öncesinde bulunan 35 aylık veri ise eğitim kümesi olarak alınmıştır. Eğitim ve test kümesine bölünen veri kümesi son olarak X_train, y_train, X_test ve y_test olmak üzere dört ayrı parçaya ayrılmıştır.

Makalede işlenecek olan diğer algoritmalarından farklı olarak Prophet algoritması yalnızca iki parametre alabildiği için öznitelik mühendisliklerinden yararlanamamıştır. Prophet algoritmasına veri kümesini hazırlarken veriler aylık baza dönüştürülmüştür. Ardından ise log1p dönüşümü sağlanıp eğitim ve test kümelerine bölünmüştür.

4.3 Makine Öğrenmesi Algoritmaları

Bu makalede, veri kümesinin oluşmasına katkı sağlayan perakende şirketinin gelecekteki satış gelirlerini tahminlemek için çeşitli makine öğrenmesi algoritmaları kullanılacaktır. Zaman serisi analizi ve tahminlerinde öne çıkan algoritmalar olarak ARIMA-SARIMA ailesi, gradient boosting algoritmaları ve SimpleRNN örnek verilebilir. Yapay sinir ağlarından da beslenen bazı popüler algoritmalar mevcuttur fakat bu çalışmada Random Forest, XGBoost, AdaBoost, CatBoost, Decision Tree, H2O Gradient Boosting ve Prophet algoritmalarının kullanılması uygun görülmüştür. Elenen modeller, modellerin gücünün kapsamlı bir gelecek tahminine yetmemesinden ve bu tahminlerde çoğunlukla kötü performans göstermelerinden ötürü elenmiştir. Çalışmada indirgenmiş nakit akışı kullanılacağından dolayı en az 5 yıllık bir tahmin yapılması beklenmektedir.

4.3.1 Random Forest

Random Forest algoritması 2001 yılında Leo Breiman tarafından insanlara tanıtılmıştır. 2001'den bu yana makine öğrenmesinde popüler algoritmalar arasında yer alan Random Forest yüksek boyutlu veriler üzerinde bile iyi performans göstermeleri, hızlı hesaplanmaları ve kolayca ayarlanabilmeleri gibi geniş bir uygulama yelpazesinden kaynaklanmaktadır. Kimya-bilişim, ekoloji, 3D nesne tanıma ve zaman serisi tahminlerinde sıkça öne çıkmaktadır [45]. Karar ormanlarının oluşturulması sırasında elde edilen sonuçlar bir araya getirilir ve tahmin süreci gerçekleştirilir. Bir kökten ağacın yaprağına kadar hiyerarşik olarak düzenlenmiş ve sırasıyla uygulanan bir dizi koşul veya kısıtlama regresyon ağacı tarafından temsil edilir [46].

4.3.2 XGBoost

Li ve Zhang ile Chen ve Guestrin tarafından geliştirilen XGBoost algoritması pratikliği ve hızlı çalışmasıyla bilinen sağlam ve güçlü bir makine öğrenmesi algoritmasıdır. Gradyan artırılmış karar ağaçları kullanarak verimli özellik seçimi

gerçekleştirir [47]. Friedman tarafından önerilen boosting modelini içinde barındıran XGBoost, daha iyi bir tahmin sonucu almak için karar ağaçlarını bir araya getirir ve bu sayede tek başına kullanılan tekniklerden daha da öne çıkar. Enerji, sağlık hizmetleri, kredi skorlama ve daha birçok alanda tercih edilen bir algoritmadır [48].

4.3.3 AdaBoost

1997 yılında Yoav Freund ve Robert Schapire tarafından tanıtılan AdaBoost algoritması, genel bir ayırıcı meta-öğrenme algoritmasıdır. Bu algoritmanın temel metodolojisi, basit bir öğrenme algoritmasını aynı eğitim setinin farklı ağırlıklandırılmalarına tekrar tekrar uygulamaktır [49]. AdaBoost birçok makine öğrenmesi tekniğini bir araya getirir, ağırlıkları sürekli olarak güncelleyerek önyargıyı azaltır ve yanlış sınıflandırılmış gözlemlere daha yüksek ağırlıklar vererek sonraki turda daha iyi tahminlenmelerini sağlar [50].

4.3.4 CatBoost

CatBoost, Prokhorenkova ve arkadaşları tarafından 2018 yılında önerilen yeni sayılabilecek bir gradyan inişi algoritmasıdır. Bu denetimli makine öğrenmesi algoritması, karar ağaçları üzerinde gradyan artırımı uygulayarak kategorik verilerin sınıflandırılmasını sağlar [48]. CatBoost aşırı öğrenme konusunda başarılı bir algoritma olduğu gibi bir diğer yandan da tüm verilerle eğitim yapabilen Greedy TS adıyla bilinen etkili bir strateji kullanır. Veri seti öncelikle rastgele karıştırılır. Ardından her bir veri örneği sayısal bir formata dönüştürülür ve etiket değeri örneğin ait olduğu kategoriye göre hesaplanır. Bu hesaplamalara bir öncelik ağırlığı da eklenir ve bu sayede modelin öğrenmesi iyileştirilir [51].

4.3.5 H2O Gradient Boosting Algoritması

H2O AutoML, açık kaynaklı, ölçeklenebilir ve dağıtılmış makine öğrenmesi kütüphanesi H2O'da uygulanan tamamen otomatik bir öğrenme algoritmasıdır. H2O AutoML, Python'un yanında birkaç programlama dilinde daha kullanılabilir ve web GUI üzerinden de erişim sağlanabilir. Kütüphane, kullanıcıya özelleştirmesi için birçok parametre seçeneği sunar ve modelleme adımlarında kullanıcıyı da otomatikleştirmeye dahil eder [52]. H2O AutoML kütüphanesi XGBoost, H2O GBM, Random Forest, Deep Neural Network ve Generalized Linear Models gibi çok çeşitli bir algoritma yelpazesine sahiptir [53]. Kullanıcının kütüphaneye verileri sağlamasının ardından H2O AutoML veri kümesi için en uygun parametreleri ve algoritmaları kapsamlı hesaplamalar sonucu tespit edebilmektedir.

Gradient Boosting, zayıf tahmin modellerinin topluluğu şeklinde bir model inşa eder. Bu algoritma, inşa ettiği bu modeli aşama aşama geliştirerek tahminlerinde ve performansında iyileştirmeye gitmektedir. Herhangi bir türevlenebilir kayıp fonksiyonunu kullanarak ise genelleştirmeye gitmektedir [54]. Gradient Boosting algoritmasının dağıtılmasının ve genelleştirilmesinin zor olduğu bilinse de H2O kütüphanesi kolayca dağıtılabilir ve genelleştirilebilir bir Gradient Boosting versiyonu sunmaktadır. Ayrıca model ile ilgili tüm ayarlar ve hiperparametreler için ise zahmetsiz bir ortam sunmaktadır [55].

4.3.6 Decision Tree

Karar ağacı regresyon algoritması en basit tanıtılan modeldir. "Eğer" koşullarına dayalı son derece basit bir sıralama modelidir [56]. Karar ağacı algoritması denetimli öğrenme sınıfına ait bir algoritmadır ve genellikle sınıflandırma durumlarında kullanılır. Ancak regresyon durumlarında da kullanılabilir [57]. Karar ağaçlarının diğer modellere kıyasla insanın karar verme yetilerini oldukça iyi yansıttığı kabul edilir. Gözlemlere dayanarak hedef değere ilişkin sonuçlara ulaşan bir karar başlatan tahmin modelidir [58]. Algoritma karar düğümü ve karar düğümlerinin çıktısı olmak

üzere iki tür düğüme sahiptir. Karar ağacı algoritması, sorulan soruya verilen cevabın evet hayır olması durumuna göre ağacı alt dallara bölerek çalışır [59].

4.3.7 Prophet

Facebook™, Prophet tahmin aracını 2017'nin başında halka sunmuştur [59]. Prophet zaman serisi veri kümeleri için tahminler yapmak üzere tasarlanmış bir kütüphanedir. Bu kütüphane verilerdeki trendler ve mevsimler yapıları sağlam bir şekilde tahminlemeye eğilimlidir [6058]. Python ve R dillerinde mevcut olan Prophet, haftalık, yıllık ve mevsimsellik ile tattillerle birlikte doğrusal olmayan trendlerin fit edilmesine dayanan bir algoritmadır. Prophet, eksik verilere karşı dayanıklı olduğu gibi trenddeki değişimi ve uç değişimleri yakalamada yeteneklidir [61].

4.4 Algoritmaların Uygulanması

Bazı algoritmaların veri kümeleriyle eğitilmesinden önce en iyi parametrelerin seçilmesi amacıyla “sklearn” sınıfından GridSearchCV fonksiyonu kullanılmıştır. GridSearchCV ile hiperparametre optimizasyonu uygulanan algoritmalar: Random Forest ve XGBoost olarak yer almaktadır. Ayrıca H2O Gradient Boosting algoritmasının hiperparametre optimizasyonu için H2O içerisinde bulunan “grid” sınıfından çağrılan H2OGridSearch fonksiyonu kullanılmıştır. AdaBoost, CatBoost, Decision Tree ve Prophet algoritmalarında ise GridSearchCV fonksiyonun istenildiği gibi performans vermemesinden ötürü parametreler elle seçilmiştir. Bu şekilde toplamda 7 farklı algoritma ile zaman serisi tahminlemesi yapılacaktır.

Random Forest algoritmasının GridSearchCV ile denenen parametre aralıkları şu şekildedir: 'n_estimators': [50, 100, 200], 'max_depth': [None, 10, 20, 30], 'min_samples_split': [2, 5, 10], 'min_samples_leaf': [1, 2, 4]. Bu aralıklardan elde edilen en iyi kombinasyonun 'max_depth': None, 'min_samples_leaf': 4, 'min_samples_split': 2, 'n_estimators': 200 olduğu belirlenmiştir ve tahminler bu parametreler üzerinden yapılacaktır.

XGBoost algoritmasının GridSearchCV ile denenen parametre aralıkları şu şekildedir 'n_estimators': [50, 100, 200], 'max_depth': [3, 6, 9], 'learning_rate': [0.01, 0.1, 0.2], 'alpha': [0, 0.1, 1]. Bu aralıklardan elde edilen en iyi kombinasyonun 'alpha': 1, 'learning_rate': 0.1, 'max_depth': 3, 'n_estimators': 50 olduğu belirlenmiştir ve tahminler bu parametreler üzerinden yapılacaktır. Ayrıca Random Forest ve XGBoost algoritmalarının hiperparametre optimizasyonu sırasında en doğru sonucu elde etmek adına “sklearn” sınıfından TimeSeriesSplit fonksiyonu çağrılmış ve n_splits=5 olarak alınmıştır.

AdaBoost algoritmasında parametreler n_estimators = 1000 ve loss="square" olarak belirlenmiştir.

CatBoost algoritmasında parametreler learning_rate=0.1, depth=6, iterations=500, loss_function='MAE' olarak belirlenmiştir.

H2O Gradient Boosting Estimator algoritmasının H2OGridSearch fonksiyonu ile hiperparametre optimizasyonunun yapılması sırasında denenen parametre aralıkları şu şekildedir: 'ntrees': [10,50, 100, 150,200], 'max_depth': [5, 10, 15,20], 'min_rows': [1, 5, 10,20], 'learn_rate': [0.05,0.01, 0.1, 0.2,0.5]. Bu aralıklardan elde edilen en iyi kombinasyonun learn_rate=0.5, max_depth=20, min_rows=1, ntrees=50 olduğu belirlenmiştir ve tahminler bu parametreler üzerinden yapılacaktır

Decision Tree algoritması hiperparametre optimizasyonu sonucunda objektifimizden uzaklaştığı için default parametreleriyle eğitime alınmıştır.

Prophet modelinin eğitime alınması sırasında tek değiştirilen parametresi changepoint_prior_scale=0.6 şeklindedir.

Ayrıca bütün modellerde random_seed = 0 olarak alınmıştır.

4.5 Değerlendirme

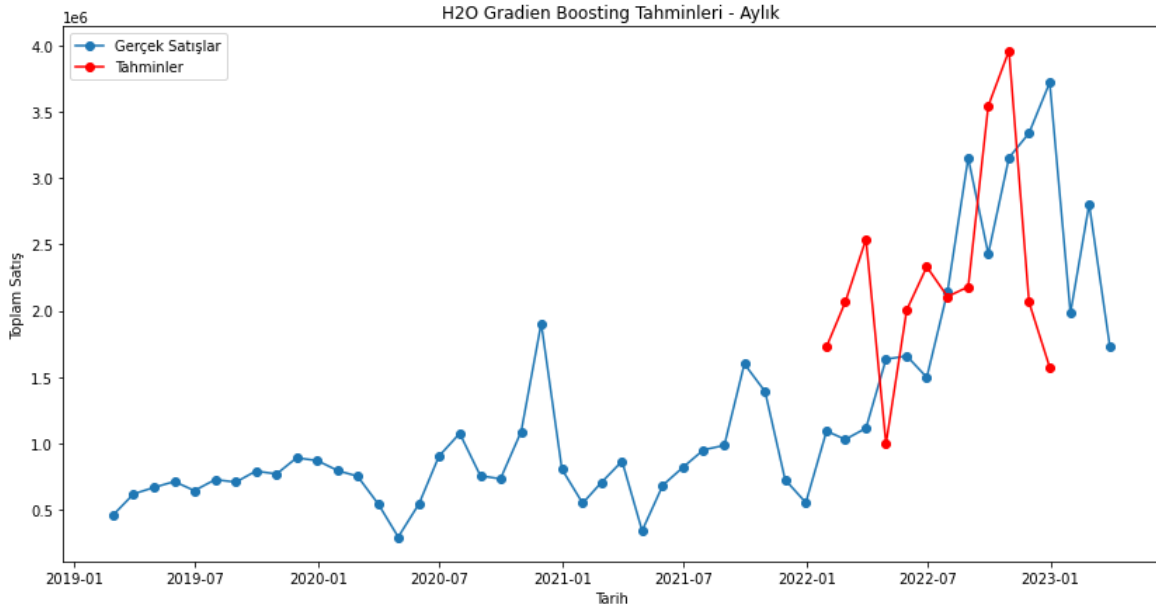
Modellerin test kümesi üzerindeki başarısını değerlendirmek, modelin gelecek 5 yıl hakkındaki öngörülerinin ne kadar tutarlı olduğu hakkında ipuçları içermektedir. Modelin ne kadar etkili tahmin yapabildiğini anlayabilmek adına birtakım metrikler göz önünde bulundurulacaktır. Bu metrikler Root Mean Squared Error (RMSE), Mean Squared Error (MSE) ve bu makalede en çok önem verilecek metrik Mean Absolute Percentage Error (MAPE) olarak listelenmektedir.

Modellerin elde ettiği tahminler log1p dönüşümünden arındırılıp fark alma işleminin geriye döndürülmesinin ardından ölçekli değerlerden gerçek satış değerlerine çevrilmiştir. Bu işlemlerden sonra aylık tahminler yıllık bazda toplanarak RMSE, MSE ve MAPE metrikleri üzerinden değerlendirilmiştir. Metriklerin yıllık bazda değerlendirilme sebebi ise indirgenmiş nakit akışı yönteminin bu makalede yıllık bazda çalışması olarak gerekçelendirilmiştir.

Tablo 4: Yıllık Bazda Hata Metrikleri

Model	MAPE	RMSE	MSE
H2O Gradient Boosting	%4.36	1132448,85	1282440408839,76
Random Forest	%4.87	1264610,59	1599239956016,91
AdaBoost	%5.77	1497801,31	2243408752189
XGBoost	%7.41	1923676,32	3700530593331,60
CatBoost	%18.36	4767979,16	22733625308477,69
Decision Tree	%34.34	8916302,80	79500455534210,33
Prophet	%36.12	9378785,83	87961623651349,11

Eğitilen modellerin tahminlerindeki yıllık bazda hesaplanan hata metriklerini yansıtan Tablo 4'te görüntülediği üzere en başarılı model H2O Gradient Boosting olarak öne çıkmaktadır. Bu modellerin test kümesi üzerindeki başarısını görüntülemek adına algoritmanın test kümesi üzerindeki tahminleri Şekil 8'de verilmiştir.




Şekil 8: H2O Gradient Boosting Algoritması Test Kümesi Tahminleri

Şekil 8’de görüntülediği üzere H2O Gradient Boosting algoritması test kümesi üzerinde son derece başarılıdır. Bu algoritmadan asıl beklenen ise tüm veriler ile eğitildikten sonra gelecekteki 5 yılda şirkete girmesi beklenen nakit akışını başarılı bir şekilde tahminlemesidir. Nitekim bu tahmini gerçekleştirebilmek adına gelecek 60 ayın özniteliklerini içeren bir tahmin kümesi oluşturulmuştur. H2O Gradient Boosting algoritmasının, bütün veriler ile eğitilmesinin ardından oluşturulan tahmin kümesindeki özniteliklere dayanarak her bir ayın satışının öngörülmesi sağlanmıştır.

5 MAKİNE ÖĞRENMESİ İLE ŞİRKETİN DEĞERİNİN TAHMİN EDİLMESİ

Daha önce de belirtildiği üzere bu makalede şirket değerlendirme metodlarından olan İndirgenmiş Nakit Akışı yöntemi kullanılarak şirketin değerlendirilmesine karar verilmiştir. İndirgenmiş Nakit Akışı ile şirketin değerlendirilmesini yaparken makine öğrenmesinin en büyük katkısı gelecek satışların tahmininde olacaktır. Çeşitli veri analizi ve veri manipülasyonlarının ardından veri kümesinin başarıyla modele verilmesi ve eğitilmesi bu süreç dahilindedir. Eğitim sonucu tahminler ise Şekil 9’da yer almaktadır.



Şekil 9: H2O Gradient Boosting Algoritmasının 60 Aylık Tahminleri

Şekil 9’da algoritmanın öngördüğü üzere şirketin gelecek 5 yıldaki satışları gözle görülür bir artış göstermiştir. Sonraki adımda ise şirketin değerini belirleyebilmek adına formül (1) kullanılacaktır. Formül (1)’i uygulamak için gereken bileşenler: net nakit girişi, iskonto oranı, yıl . Öncelikle 5 yıllık bir periyotta değerlendirme yapılması planlandığı için yıl 5 olarak alınmıştır. Net nakit girişi ise içinde bulunan yıldan itibaren 5 yılda da değişmektedir. 2023 yılında tahmini satış geliri 46.038.693 TL, 2024 yılında tahmini satış geliri 209.295.278 TL, 2025 yılında tahmini satış geliri 192.247.198 TL, 2026 yılında tahmini satış geliri 1.065.462.829 TL, 2027 yılında tahmini satış geliri 2.234.215.307 TL olarak kaydedilmiştir.

Şirketin satış gelirlerini nakit akışı olarak kabul edebilmek adına belirli bir yüzdesini alma yoluna gidilmiştir çünkü yalnızca satış geliri kalemine dayalı bir değerlendirme anlamsız olacaktır. Bu yüzdeyi belirleyebilmek adına piyasadaki şirketlerden Aselsan, Derimod ve Jantsa'nın Kamuyu Aydınlatma Platformu'ndan elde edilen mali tablolarına dayanarak Retail Dataset'te olduğu gibi satış gelirleri baz alınmıştır ve diğer kalemlerden de yararlanarak her bir çeyreğin serbest nakit akışları hesaplanmıştır. Satış gelirleri ve serbest nakit akışları her bir yıl için karşılaştırıldığı zaman Aselsan için, 2016-2023 aralığındaki yıl sonu satış gelirlerinin ortalama %19'unun yıl sonu serbest nakit akışlarına denk geldiği sonucuna ulaşılmıştır. Bu sonuç Derimod için %12 olarak bulunmuşken Jantsa için %15 olarak bulunmuştur.

Retail Dataset için bu üç değer ortalama alınarak tahminlenen satış gelirlerinin %15'inin serbest nakit akışı olarak kabul edilmesi uygun görülmüştür. Şirketin değerini hesaplarken ise iskonto oranı %60 olarak belirlenip bu oran dinamik tutulmuştur. %5 sonsuz büyüme oranının da kullanıldığı değerlemenin sonucunda Retail Dataset üzerinde bulunan verilere sahip şirketin değerinin 140.982.934 TL olduğu sonucuna varılmıştır.

6 SONUÇ

Bu makalede makine öğrenmesinin şirket değerlemesi üzerinde olan potansiyeli ve etkisi incelenmiştir. İnceleme sırasında bir perakende şirketinin verileri kullanılarak şirketin gelecekteki nakit akışları makine öğrenmesi yardımıyla tahminlenmiştir. Makine öğrenmesinin verinin analizi, verinin işlenmesi ve gelecek tahmini konularında kullanıcılara ve şirketlere yarattığı avantajlar neticesinde şirket değerlemede etkin bir şekilde rol oynaması ihtiyaç haline gelmektedir.

Veri analiz edilirken 2019 yılından 2023 yılının ilk çeyreğine kadar olan zaman aralığı göz önünde bulundurulmuştur. Analiz ve keşif sürecinde şirketin pazar günleri satış yapmadığı gibi gözlemlere ulaşılmıştır. Bu süreçte şirkete net nakit girişini hesap edebilmek için satış gelirlerinden, indirim tutarlarının çıkarılmasına karar verilmiştir. İşlemlerin günlük bazda incelenmesinin ardından veriler aylık baza dönüştürülmüştür. Özellikle aylık bazdaki gürültünün, günlük bazdaki gürültüye göre daha az olması tahminlerin doğruluğunu önemli ölçüde etkileyen faktörler arasında yer almaktadır.

Zaman serisi analizlerinde ve tahminlerinde halihazırda yapıldığı üzere veri üzerinde uygulanan ADF testi ile verinin durağanlığı test edilmiştir. Uygulanan ilk testin verinin durağan olmadığını göstermesinin ardından satışlar üzerinde öncelikle bir log1p dönüşümü sonrasında ise fark alma işlemi uygulanmıştır. Dönüşümler sonucunda veri kümesinin durağan hale getirilmesi tahminlerin iyileşmesinde etkili olmuştur. Modellerin performansını arttırmak amacıyla uygulanan öz nitelik mühendisliği verinin analizine ve gelecek hakkındaki tutarlı tahminlere yatkınlığı arttırmıştır.

Satışların tahmini için makine öğrenmesi sürecinde XGBoost, AdaBoost, CatBoost, Decision Tree, H2O Gradient Boosting ve Prophet algoritmaları kullanılmıştır. Algoritmaların tamamı titizlikle irdelenmiş ve performanslarının artırılması amaçlanmıştır. Bu bağlamda kullanılan hiperparametre optimizasyonu yöntemi sayesinde birçok modelin performansı gözle görülür derecede iyileştirilmiştir. En iyi performansı gösteren H2O Gradient Boosting algoritmasının yanında Random Forest ve AdaBoost algoritmaları da düşük MAPE oranlarıyla öne çıkmıştır. Algoritmalar anlamında gradient boosting algoritmalarının bu veri kümesi ile yüksek doğruluk oranları yakaladığını söylemek mümkündür.

Tüm makaleden çıkarılacak sonuç olarak, tanıtılmış olan şirket değerlendirme yöntemlerinin makine öğrenmesi ile uyumlu ve verimli bir şekilde çalışabileceği ve makine öğrenmesinin şirket değerlendirme, finansal analizler gibi konularda etkin bir rol alabileceği görülmüştür. Modellerin yaptığı tahminlemeler, indirgenmiş nakit akışı kullanılırken gerekli olan net nakit akışının tahminini sağlamakta ve şirketlerin değerlendirilmesinde daha tutarlı sonuçlar alınmasına yardımcı olmaktadır. Bu makale makine öğrenmesi yöntem ve tekniklerinin şirket değerlendirilmesinde ne derecede etkili olduğunu yansıtmaktadır ve gelecekteki benzer çalışmalara ışık tutacak niteliktedir.

REFERANSLAR

- [1] Akıncı, G. Y., Akıncı, M., & Yılmaz, Ö. BİST-100 Fiyat Hareketlerindeki Yumuşak Geçiş Sürecinin Fourier KPSS Durağanlık Analizi ile Sınanması. *Politik Ekonomik Kuram*, 8(1), 52-66.
- [2] Gabrielli, L., & French, N. (2021). Pricing to market: property valuation methods—a practical review. *Journal of property investment & finance*, 39(5), 464-480.
- [3] Fernández, P. (2007). Company valuation methods. The most common errors in valuations. *IESE Business School*, 449, 1-27.
- [4] Sjöqvist, M., & Stepanovych, T. (2008). A review of the business valuation process—in theoretical and practical. rapport nr.: Externredovisning och företagsanalys 07-08-101.
- [5] French, N., & Gabrielli, L. (2018). Pricing to market: Property valuation revisited: The hierarchy of valuation approaches, methods and models. *Journal of Property Investment & Finance*, 36(4), 391-396.
- [6] Derrien, F., Frésard, L., Slabik, V., & Valta, P. (2023). Industry Asset Revaluations around Public and Private Acquisitions. *Journal of Financial Economics*, 147(1), 243-269. (<https://www.sciencedirect.com/science/article/am/pii/S0304405X21004426>)
- [7] Jennergren, L. P. (2011). A tutorial on the discounted cash flow model for valuation of companies. *SSE/EFI Working paper series in business administration*, 1998(1), 1-55.
- [8] Aydin, N. (2017). Mergers and acquisitions: a review of valuation methods. *International Journal of Business and Social Science*, 8(5), 147-151.
- [9] Theron, C. FUNDAMENTAL VALUATION OF NORDECON AS.
- [10] Koller, T., Goedhart, M., & Wessels, D. (2010). *Valuation: measuring and managing the value of companies*. John Wiley & Sons.
- [11] Beitel, T. D. (2016). *Terminal value calculations with the Discounted Cash Flow model: differences between literature and practice* (Master's thesis, University of Twente).
- [12] Brealey, R. A., Meyers, S.C., Allen, F. (2010) Principles of corporate Finance 10th edition (Global Edition) McGraw-Hill-Irwin.
- [13] Capiński, M., & Patena, W. (2008). Company valuation: value, structure, risk. Hochschule Hof.
- [14] Koller, T., Goedhart, M., & Wessels, D. (2005). The right role for multiples in valuation. *McKinsey on Finance*, (15), 7-11.
- [15] Björn, L. (2007). Värdering Av Företag praktisk handbok.
- [16] Solovyev, V. (2016). Comparison of discounted cash flow and economic value added valuation methods: Protect company LLC.
- [17] Vasylieva, K. (2023). Valuation of Visa Inc. Using Selected Valuation Methods.
- [18] Weitzl, G. (2016). Company valuation methods and their practical relevance (Doctoral dissertation, Technische Universität Wien).
- [19] Hirsimäki, J. VALUATION OF LOCKHEED MARTIN CORPORATION USING DISCOUNTED CASH FLOW AND RELATIVE VALUATION METHODS.
- [20] Khan, M. M. (2015). Valuation of the Boeing Company (Master's thesis).
- [21] Mårtensson, D., & Oljemark, S. (2016). Evaluating comparable company valuation-how to derive at the right multiple.
- [22] Toraman, C., & Körpi, M. (2015). Firma değerinin piyasa çarpanları ile tahmin edilmesi: BIST dokuma, giyim eşyası ve deri sanayii sektöründe bir uygulama. *Muhasebe ve Finansman Dergisi*, (66), 41-56.
- [23] Damodaran, A. (2024). The little book of valuation: How to value a company, pick a stock, and profit. John Wiley & Sons.
- [24] Pandey, A. (2012). Cash flow is king in relative valuation: A myth or reality. *Asia-Pacific Journal of Management Research and Innovation*, 8(4), 441-449.
- [25] Baran, J. (2006). Firm Valuation.
- [26] Pinto, J. E. (2020). Equity asset valuation. John Wiley & Sons.
- [27] Yağın, H. (2022). 2020-2021 Döneminde BİST'de İlk Halka Arz Edilen Şirketlerin Değer Tespitinde Piyasa Yaklaşımının Kullanılmasına Yönelik Bir Araştırma. *Maliye ve Finans Yazıları*, (118), 179-198.
- [28] Fang, Z. (2023). Research and Application of Company Valuation Methods. *BCP Business & Management GEBM*, 2023.
- [29] Köseoğlu, S. D., & Almeany, S. S. A. (2020). Introduction to business valuation. In *Valuation Challenges and Solutions in Contemporary Businesses* (pp. 1-23). IGI Global.
- [30] Genç, A. (2020). Firma değeri ve piyasa değeri arasındaki ilişki: Temel değerlendirme yaklaşımlarıyla borsa İstanbul üzerine bir uygulama.
- [31] Navarro Vicent, A. (2019). Valuation of a company, Levantina Ingeniería y Construcción SL.
- [32] Masun, M. A. (2017). Firma Değerlemesi Yaklaşımları ve Otelcilik İşletmesi Örneği. *Marmara Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 39(1), 213-222.
- [33] Fazzini, M., & Fazzini, M. (2018). The Cost Approach. *Business Valuation: Theory and Practice*, 175-181.
- [34] Ekici, H. (2019). Şirket değerlendirilmesinde karşılaşılan özel durumların analizi (Master's thesis, Sakarya Üniversitesi (Turkey)).
- [35] GÜNDOĞMUŞ, M. E., & ÖZTANIR, İ. ŞİRKET DEĞERLEMESİNDE TEORİK ÇERÇEVE ve TÜRKİYE'DE YAPILAN ŞİRKET DEĞERLEMESİ ÇALIŞMALARININ ANALİZİ.

- [36] Sun, Z. (2021, September). Review of the Importance of Technology Company Valuation and Commonly Used Methods. In 2nd International Conference on Management, Economy and Law (ICMEL 2021) (pp. 30-36). Atlantis Press.
- [37] Ndikum, P. (2020). Machine learning algorithms for financial asset price forecasting. arXiv preprint arXiv:2004.01504.
- [38] Kaur, H., & Kumari, V. (2022). Predictive modelling and analytics for diabetes using a machine learning approach. *Applied computing and informatics*, 18(1/2), 90-100.
- [39] Mahesh, B. (2020). Machine learning algorithms-a review. *International Journal of Science and Research (IJSR)*. [Internet], 9(1), 381-386.
- [40] Bansal, R., Singh, J., Kaur, R., & Ahuja, S. (2020). Machine learning and its applications: A Review. *JASC: Journal of Applied Science and Computations*, 6(6), 1392-1398.
- [41] Sezer, O. B., Gudelek, M. U., & Ozbayoglu, A. M. (2020). Financial time series forecasting with deep learning: A systematic literature review: 2005–2019. *Applied soft computing*, 90, 106181.
- [42] Esling, P., & Agon, C. (2012). Time-series data mining. *ACM Computing Surveys (CSUR)*, 45(1), 1-34.
- [43] Sadi Evren SEKER. "Retail Data Set". Kaggle. 2023. <https://doi.org/10.34740/KAGGLE/DS/3067824>
- [44] Baş, G., & Kara, M. (2020). Türkiye’de döviz kuru ile sorunlu krediler ilişkisi: bir zaman serisi analizi. *Kafkas Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 11(22), 997-1023.
- [45] Goehry, B., Yan, H., Goude, Y., Massart, P., & Poggi, J. M. (2023). Random forests for time series. *REVSTAT-Statistical Journal*, 21(2), 283-302.
- [46] Karasu, S., & Altan, A. (2019, November). Recognition model for solar radiation time series based on random forest with feature selection approach. In 2019 11th international conference on electrical and electronics engineering (ELECO) (pp. 8-11). IEEE.
- [47] Oukhouya, H., Kadiri, H., El Himdi, K., & Guerbaz, R. (2024). Forecasting International Stock Market Trends: XGBoost, LSTM, LSTM-XGBoost, and Backtesting XGBoost Models. *Statistics, Optimization & Information Computing*, 12(1), 200-209.
- [48] Jabeur, S. B., Mefteh-Wali, S., & Viviani, J. L. (2024). Forecasting gold price with the XGBoost algorithm and SHAP interaction values. *Annals of Operations Research*, 334(1), 679-699.
- [49] Creamer, G., & Freund, Y. (2010). Using boosting for financial analysis and performance prediction: application to s&p 500 companies, latin american adrs and banks. *Computational Economics*, 36, 133-151.
- [50] Busari, G. A., Kwak, N. W., & Lim, D. H. (2021). An application of AdaBoost-GRU ensemble model to economic time series prediction. *Indian Journal of Science and Technology*, 14(31), 2557-2566.
- [51] Sun, Y., & Tian, L. (2023, July). Research on stock prediction based on LSTM and CatBoost algorithm. In Proceedings of the 2nd International Conference on Bigdata Blockchain and Economy Management, ICBEM 2023, May 19–21, 2023, Hangzhou, China.
- [52] LeDell, E., & Poirier, S. (2020, July). H2o automl: Scalable automatic machine learning. In Proceedings of the AutoML Workshop at ICML (Vol. 2020). San Diego, CA, USA: ICML.
- [53] Omar, I., Khan, M., Starr, A., & Abou Rok Ba, K. (2023). Automated prediction of crack propagation using H2O AutoML. *Sensors*, 23(20), 8419.
- [54] Aiello, S., Click, C., Roark, H., Rehak, L., & Stetsenko, P. (2016). Machine learning with python and h2o. H2O. ai Inc.
- [55] Malohlava, M., & Candel, A. (2016). Gradient boosting machine with H2O.
- [56] GALETA, L. Exchange rate forecast based on algorithmic trading.
- [57] Bansal, M., Goyal, A., & Choudhary, A. (2022). Stock market prediction with high accuracy using machine learning techniques. *Procedia Computer Science*, 215, 247-265.
- [58] Mulwa, C. (2020). Prediction Stacking for long-term forecasting of the bombay stock exchange index by leveraging machine and deep learning models. Sumanth Bijadi Sridhar Rao National College of Ireland Supervisor.
- [59] Weytjens, H., Lohmann, E., & Kleinstüber, M. (2021). Cash flow prediction: MLP and LSTM compared to ARIMA and Prophet. *Electronic Commerce Research*, 21(2), 371-391.
- [60] Alshara, M. A. (2022). Stock Forecasting Using Prophet vs. LSTM Model Applying Time-Series Prediction. *International journal of computer science and network security: IJCSNS*, 22(2), 185-192.
- [61] Yenidoğan, I., Çayır, A., Kozan, O., Dağ, T., & Arslan, Ç. (2018, September). Bitcoin forecasting using ARIMA and PROPHET. In 2018 3rd international conference on computer science and engineering (UBMK) (pp. 621-624). IEEE.