

Derin Öğrenme ve Makine Öğrenmesi Algoritmaları ile Aktif Kârlılığın Tahmin Edilmesi

Estimation of Return on Asset Using Deep Learning and Machine Learning Algorithms

Çalışma Başvuru Tarihi: 08.06.2026

Çalışma Kabul Tarihi: 18.07.2026

Çalışma Türü: Araştırma Makalesi

Emine KAYA*

Doğun DEMİROL**

Ömer KAYA***

Anahtar Kelimeler:

Aktif kârlılığı,
çalışma sermayesi
yönetimi etkinliği,
derin öğrenme,
makine öğrenmesi.

ÖZET

Günümüz ekonomisinde rekabet küresel boyutlara ulaşmıştır. Dolayısıyla şirketlerin kesintisiz bir şekilde faaliyetlerini yürütebilmeleri noktasında varlıkların yönetimi kritik bir öneme sahiptir. İşletme finansının önemli ve güncel bir alanı olması ve toplam varlıklar içindeki payı, satışları beslemesi ve dolayısıyla kârlılık üzerindeki etkisinden dolayı çalışma sermayesi ve etkin yönetimi, akademik anlamda hayati derece önemli bir konudur. Bu araştırma, kurumsal finans bağlamında literatürde yaygın olarak kullanılan finansal performans metriği olan aktif kârlılığının gelecekteki tahmini değerlerini derin öğrenme ve makine öğrenmesi yöntemiyle incelemeyi amaçlamaktadır. BİST imalat sektöründe yer alan 127 imalat firmasının 2015-2022 yılları çeyrek dönemlerine ait kullanım indeksi, performans indeksi, etkinlik indeksi, nakit dönüşüm süresi, kaldıraç oranı ile aktif kârlılıkları verileri kullanılmıştır. Analiz sonuçları, gelecek çeyrek aktif kârlılığı tahmininde hata, naif modele göre %31,8 azalmıştır. Bir yıl sonrası tahmin daha zayıf kalmış ve iyileşme %12,5 olmuştur. Endekslerin kısa vadeli ek katkısı sınırlıdır. Bir yıllık tahminde bazı modellerde küçük katkı görülmüştür. Bir yıl sonraki aynı çeyrek tahmininde ise UI ve PI nin ayrı ayrı kullanılması CatBoost ve LightGBM modellerinde küçük fakat anlamlı bir iyileşme sağlamıştır. Ancak bu sonuç bütün modellerde görülmemiştir. Derin öğrenme ve ağaç modellerinin yakın sonuçlar verdiği saptanmıştır.

Keywords:

Return on asset,
working capital
management efficiency,
deep learning, machine
learning.

ABSTRACT

The aim of this study is to examine the development trends and conceptual structure of scientific publications on digital transformation and artificial intelligence in human resource management through bibliometric analysis. Within the scope of the study, a total of 179 publications indexed in the Web of Science Core Collection database and covering the period between 2018 and 2026 were analyzed. The analysis focused on the distribution of publications by year, publication types, productive countries and sources, citation structures, keyword networks, and thematic trends. The findings reveal that academic interest in digital transformation and artificial intelligence in human resource management has increased significantly, particularly after 2021, with the highest number of publications recorded in 2025. Keyword analysis identified "human resource management," "artificial intelligence," and "digital transformation" as the core concepts shaping the literature. In addition, themes such as e-HRM, HR analytics, big data, automation, and employee experience have gained increasing prominence over time. The results indicate that the field is evolving toward a more data-driven, technology-oriented, and strategically focused structure. Overall, this study provides a comprehensive overview of the current state of the literature on digital transformation and artificial intelligence in human resource management, highlights emerging research trends, and offers valuable insights for future studies.

* Dr. Öğr. Üyesi, Bingöl Üniversitesi, SBMYO, Büro Hizmetleri ve Sekreterlik, ekaya@bingol.edu.tr, ORCID: 0000-0002-1823-162X

** Dr. Öğr. Üyesi, Bingöl Üniversitesi, Genç MYO, Bilgisayar Teknolojileri, ddemirol@bingol.edu.tr, ORCID: 0000-0002-3272-1078

*** Öğr. Gör., Bingöl Üniversitesi, Rektörlük, Kalite Yönetim Koordinatörlüğü, omerkaya@bingol.edu.tr, ORCID:0000-0002-1211-0341

1. GİRİŞ

Modern ekonomik sistemde rekabet koşulları küresel bir boyuta taşınmıştır. Bu doğrultuda, şirketlerin operasyonel faaliyetlerini kesintiye uğramadan sürdürebilmeleri noktasında varlık yönetimi hayati bir ehemmiyet arz etmektedir. Kurumsal finansmanın dinamik ve temel alanlarından biri olan işletme sermayesi ve bu sermayenin rasyonel idaresi; toplam varlıklar içerisindeki ağırlığı, satış hacmini destekleme kapasitesi ve nihayetinde kârlılık oranları üzerindeki doğrudan belirleyiciliği sebebiyle akademik literatürde son derece kritik bir olgu olarak değerlendirilmektedir. İşletme sermayesi kavramı, bir firmanın finansal durum tablosunda raporlanan toplam dönen varlık kalemlerini temsil etmektedir. Etkin bir işletme sermayesi yönetimi ise; kısa vadeli varlıkların ve yükümlülüklerin optimum düzeyde planlanarak kontrol altında tutulması, temerrüt (borç ödeyememe) riskinin minimize edilmesi ve dönen varlıklara yönelik atıl yatırımların engellenmesi süreci olarak tanımlanmaktadır.

Bu araştırma, kurumsal finans literatüründe finansal başarının ölçümünde sıklıkla başvurulmuş bir gösterge olan aktif kârlılığının ilerideki olası değerlerini derin öğrenme algoritmaları vasıtasıyla öngörmeyi hedeflemektedir. İnceleme kapsamında, Borsa İstanbul (BİST) imalat endeksinde faaliyet gösteren 127 sanayi işletmesinin 2015-2022 periyodunu kapsayan çeyreklik verilerinden yararlanılmıştır. Analize temel oluşturan değişkenler; kullanım indeksi, performans indeksi, etkinlik indeksi, nakit döngüsü, finansal kaldıraç oranı ve varlık kârlılığı metriklerinden meydana gelmektedir.

Uluslararası literatürde firmaların aktif kârlılığının makine öğrenmesi yöntemleriyle tahmin edildiği oldukça sınırlı sayıda ampirik araştırma bulunmaktadır (Tutcu vd., 2024; Yıldırım vd., 2024). Türkiye örnekleme bağlamında ise "Derin Öğrenme ve Makine Öğrenmesi" tekniklerini uygulayarak aktif kârlılığının tahmin edilmesine yönelik ampirik bir araştırmaya rastlanmamıştır. Genel itibarıyla finans alanında bu yöntemlerin kullanımına yönelik teorik bilgiler içeren derleme makaleleri son derece kısıtlı olarak mevcuttur. Bu araştırma öncül bir araştırma niteliği taşıması sebebiyle akademik literatüre hem kuramsal hem de metodolojik çerçevede özgün bir katma değer sunmaktadır.

Bununla birlikte, BİST imalat firmalarında çalışma sermayesi etkinliğinin aktif kârlılığı tahminine sağladığı ilave katkıyı farklı tahmin ufuklarında inceleyen çalışmaların son derece sınırlı kaldığı görülmektedir. Bu araştırmanın özgün katkısı, söz konusu katkının dönem dışı değerlendirme, ablasyon analizi ve SHAP yöntemiyle incelenmesinden oluşmaktadır.

Çalışmanın geri kalanı şu şekilde yapılandırılmıştır: İkinci bölümde araştırma literatürü ele alınmaktadır. Üçüncü bölümde, veri ve yöntem detayları açıklanmıştır. Dördüncü bölümde

bulgular ve sonuçlara yer verilmiştir. Beşinci bölümde sonuç ve tartışma başlığı altında detaylara yer verilerek, gelecekteki araştırmalara yönelik öneriler sunulmaktadır.

2. LİTERATÜR

Kusuma ve Bachtiar (2018), 2010-2014 periyoduna ait verilerden yararlanarak, Endonezya Menkul Kıymetler Borsası'na kote 44 işletmenin net işletme sermayesi bileşenleri ile kârlılık düzeyleri arasındaki bağlantıyı regresyon modelleri yardımıyla irdelemiştir. Elde edilen ampirik bulgular; kârlılık ile nakit döngüsü ve cari oran arasında ters orantılı (negatif), buna karşın stok devir hızı ve aktif devir hızı ile kârlılık arasında ise doğru orantılı (pozitif) bir etkileşim bulunduğunu kanıtlamıştır.

Topak (2018), Türkiye sınırları içerisinde ticari faaliyetlerini sürdüren işletmelerde işletme sermayesi idaresinin varlık kârlılığına yansımalarını incelemiştir. Bu hedef bağlamında, 2004 ile 2017 yılları arasını kapsayan süreçte BİST Ticaret Endeksi'ne dâhil olan firmaların mali tablolarından elde edilen veriler üzerinden panel veri analizi uygulanmıştır. Çıktılar, alacakların tahsil süresi, stokların dönüşüm süresi ve nakit döngüsünün işletmelerin aktif kârlılığı üzerinde istatistiksel açıdan anlamlı ve ters yönde (negatif) bir baskı oluşturduğunu teyit etmiştir.

Akomeah ve Frimpong (2019), işletme sermayesi idaresinin kârlılık oranları üzerindeki belirleyiciliğini sınamak maksadıyla, Gana Menkul Kıymetler Borsası'na kayıtlı yedi endüstriyel işletmenin finansal verilerini panel veri ekonometrisi kullanarak analiz etmiştir. Araştırma neticeleri; stok devir ve alacak tahsil sürelerinin işletme kârlılığını anlamlı ölçüde ve olumsuz (negatif) yönde etkilediğine işaret ederken, cari oran ile nakit dönüşüm süresinin kârlılık üzerinde olumlu (pozitif) ve istatistiksel açıdan geçerli bir etki yarattığını gözler önüne sermiştir.

Akyüz vd. (2019), işletme sermayesi ile kârlılık dinamikleri arasındaki bağı çözümlemek gayesiyle, Borsa İstanbul bünyesinde işlem gören 14 şirketin 2011-2016 dönemine ait finansal göstergeleri üzerinde korelasyon ve regresyon testleri uygulamıştır. Gerçekleştirilen değerlendirmeler neticesinde, varlık devir hızının hem kârlılık hem de net işletme sermayesi üzerinde artırıcı (pozitif) bir rol üstlendiği, buna mukabil finansal kaldıraç oranının söz konusu değişkenler üzerinde düşürücü (negatif) bir baskı yarattığı saptanmıştır.

Çerçel ve Sökmen (2019), BİST sanayi işletmelerinde net işletme sermayesi ile finansal kârlılık parametreleri arasındaki etkileşimi irdeledikleri çalışmalarında; nakit döngüsü, stok dönüşüm hızı ve işletme ölçeği ile varlık kârlılığı arasında istatistiksel manada geçerli ve aynı

yönde (pozitif) bir bağ bulunduğunu tespit etmiştir. Öte yandan, aktif kârlılığı ile borçluluk (kaldıraç) oranı arasında ise ters yönde (negatif) ve anlamlı bir korelasyon olduğu bulgusuna ulaşılmıştır.

Eskin ve Güvemli (2020), işletme sermayesini oluşturan unsurların kârlılık oranlarına yansımalarını incelemek amacıyla, BİST 50 endeksinde yer alan ve finans sektörü dışında faaliyet gösteren 33 firmanın 2012-2016 periyodu verileri eşliğinde çoklu regresyon ve korelasyon yöntemlerine başvurmuştur. Ulaşılan sonuçlar dâhilinde, analize konu olan şirketlerin faaliyet kârlılıkları veya varlık kârlılıkları ile nakit döngü süreleri arasında istatistiksel açıdan dikkate değer bir bağlantı saptanamamıştır.

Nguyen, Pham ve Nguyen (2020), net işletme sermayesinin kurumsal kârlılık üzerindeki belirleyici gücünü panel veri ekonometrisi ile çözümleyebilmek için Vietnam Menkul Kıymetler Borsası'na kote edilmiş 119 işletmenin 2010 ile 2018 yılları arasındaki finansal tablolarını analize dâhil etmiştir. Elde edilen ampirik veriler doğrultusunda, nakit döngüsü ile bu döngüyü oluşturan alt bileşenlerin işletme kârlılığı üzerinde istatistiksel olarak anlamlı ve azaltıcı (negatif) bir role sahip olduğu doğrulanmıştır.

Çanakçıoğlu ve Ersan (2020), Borsa İstanbul'da işlem gören 16 çimento üreticisi firma üzerinden hareketle, işletme sermayesinin finansal başarıya etkilerini 2003-2018 dönemi kapsamında panel veri analizleri vasıtasıyla sorgulamıştır. Yapılan değerlendirmeler sonucunda, nakit dönüşüm döngüsünün kârlılık oranları üzerinde herhangi bir istatistiksel anlama sahip olmadığı, stok dönüşüm hızının ise kârlılık seviyesini aşağı çeken (negatif) bir unsur olarak işlev gördüğü saptanmıştır.

Anton ve Afloarei Nucu (2020), Polonya menşeli 719 halka açık şirketin 2007-2016 periyoduna ait finansal verilerinden yararlanarak net işletme sermayesi idaresinin ekonomik kârlılık üzerindeki belirleyiciliğini incelemiştir. Ekonometrik panel veri analizi çerçevesinde Sıradan En Küçük Kareler (OLS), sabit etkiler ve PCSE tahmincilerinden faydalanılmıştır. Elde edilen ampirik sonuçlar, işletme sermayesi seviyesi ile kurumsal kârlılık oranları arasında ters-U biçiminde (non-linear) bir korelasyon bulunduğunu kanıtlamıştır.

İslıcık ve Koçyiğit (2021), devlet hastaneleri özelinde kârlılık oranları ile net işletme sermayesi arasındaki etkileşimi ortaya koymak gayesiyle yürüttükleri araştırmalarında; stok dönüşüm hızı ile varlık kârlılığı arasında aynı yönde (pozitif), kârlılık ile nakit döngüsü arasında ise ters yönde (negatif) bir bağlantı tespit etmiştir. Bununla birlikte, işletme kârlılığı ile alacakların dönüşüm hızı arasında herhangi bir etkileşim kanıtlanamamıştır.

Erbul ve Özdemir (2021), net işletme sermayesi unsurlarının kurumsal kârlılık ve işletme değeri üzerindeki yansımalarını sorgulamıştır. İlgili araştırma, 2007 ile 2016 yılları arasında Borsa İstanbul Yıldız Pazar'da kote edilmiş 44 firmanın verileri etrafında şekillenmiştir. Analiz çıktıları, Tobin Q ve Piyasa Değeri / Defter Değeri (PD/DD) göstergelerinin işletme sermayesine yapılan yatırım oranlarıyla aynı yönde (pozitif) hareket ettiğini; buna karşın finansman oranlarıyla ters yönde (negatif) bir etkileşim içerisinde olduğunu ortaya koymuştur.

Turan ve Bilgin (2021), halka açık işletmeler nezdinde net işletme sermayesi idare stratejilerinin kurumsal piyasa değeri üzerindeki yansımalarını irdelemiştir. Araştırma kapsamında, finans sektörü haricinde faaliyetlerini sürdüren 314 işletmenin 2012-2018 yıllarını kapsayan finansal göstergeleri panel veri ekonometrisi aracılığıyla çözümlenmiştir. Gerçekleştirilen değerlendirmeler neticesinde, işletme değeri ile net işletme sermayesi unsurları arasında istatistiksel manada geçerli bir bağlantı saptanmıştır.

Wassie (2021), net işletme sermayesi yönetim pratiklerinin dış ticaret odaklı işletmelerin finansal başarıları üzerindeki etkilerini Etiyopya piyasasındaki firmalar ekseninde değerlendirmiştir. İlgili çalışmada, ihracat faaliyetleri yürüten 164 işletmeye ait mali veriler regresyon modelleriyle test edilmiştir. Araştırma bulguları uyarınca, rasyonel bir işletme sermayesi yönetiminin, ihracat ağırlıklı operasyonlar yürüten işletmelerin performansını olumlu yönde (pozitif) desteklediği yargısına varılmıştır.

Amponsah-Kwatiah vd., (2021), net işletme sermayesi idaresinin kurumsal kârlılık marjları üzerindeki tesirini araştırdıkları çalışmalarında, Gana imalat endüstrisinde faaliyet gösteren 20 firmanın 2015-2019 dönemine özgü mali tablolarını regresyon analizleriyle incelemiştir. Ampirik bulgular doğrultusunda; stok yönetimi stratejilerinin, sahip olunan dönen varlık hacminin, likidite (cari) oranının ve kurumsal ölçeğin işletme kârlılığı üzerinde artırıcı (pozitif) bir rol üstlendiği teyit edilmiştir.

Finansal tahminleme alanında Elend vd. (2020), çeyreklik finansal verilerle gerçekleştirilen kazanç tahmininde LSTM ve zamansal evrişim ağlarının naif tahmin modelinden daha başarılı sonuçlar ürettiğini ortaya koymuştur. Chen vd. (2022) ise ayrıntılı finansal veriler kullanılarak geliştirilen makine öğrenmesi modellerinin bir yıl sonraki kazanç değişiminin tahmininde geleneksel modellerden ve analist tahminlerinden daha yüksek dönem dışı performans gösterebildiğini belirlemiştir. Bu bulgular, makine öğrenmesi ve derin öğrenme yöntemlerinin finansal performans tahminindeki potansiyelini göstermektedir.

Putri vd. (2022), çalışmalarında Endonezya borsasında işlem gören yiyecek&içecek alt sektöründe faaliyet gösteren 15 imalat firmasının 2016-2021 dönemlerine ait net çalışma sermayelerinin ve sermaye yapılarının firma kârlılığına etkisini incelemişlerdir. Zaman serilerine dayalı panel regresyon analizi ile yaptıkları çalışmanın sonucunda, firma kârlılığı üzerinde borç/aktif oranının anlamlı negatif bir etkiye sahipken net çalışma sermayesi ve borç/özkaynak oranının anlamlı pozitif bir etkiye sahip olduğunu bulmuşlardır.

Finansal tahminleme alanında Chen vd., (2022) ayrıntılı finansal veriler kullanılarak geliştirilen makine öğrenmesi modellerinin bir yıl sonraki kazanç değişiminin tahmininde geleneksel modellerden ve analist tahminlerinden daha yüksek dönem dışı performans gösterebildiğini belirlemiştir. Elend vd., (2020) ise çeyreklik finansal verilerle gerçekleştirilen kazanç tahmininde LSTM ve zamansal evrişim ağlarının naif tahmin modelden daha başarılı sonuçlar ürettiğini ortaya koymuştur. Bu bulgular, makine öğrenmesi ve derin öğrenme yöntemlerinin finansal performans tahminindeki potansiyelini göstermektedir.

Güngör (2022), havacılık endüstrisinde faaliyet gösteren firmalarda net işletme sermayesi yönetimi stratejilerinin kurumsal finansal başarı üzerindeki yansımalarını incelemiştir. İlgili araştırma kapsamında, Amerika Birleşik Devletleri (ABD) pazarında yer alan 10 havayolu işletmesinin 2008 ile 2020 yılları arasındaki finansal göstergelerinden yararlanılarak panel veri ekonometrisi uygulanmıştır. Söz konusu analizde varlık kârlılığı, hisse senedi başına düşen kârlılık ve faaliyet kâr marjı bağımlı değişkenler olarak kurgulanırken; net işletme sermayesi, nakit döngü süresi, likidite (asit-test) oranı, nakit oranı ve faiz karşılama kapasitesi bağımsız değişkenler olarak teste tabi tutulmuştur. Elde edilen ekonometrik çıktılar, işletme performansı ile net işletme sermayesi parametreleri arasında istatistiksel açıdan geçerli ve aynı yönde (pozitif) bir korelasyon bulunduğunu doğrulamıştır.

Lukic (2023), çalışmasında 2013-2021 döneminde Sırbistan'da ticari kârlılık üzerinde net çalışma sermayesinin etkisini incelemişlerdir. Net çalışma sermayesi ve kârlılık arasında güçlü bir korelasyon olduğunu ve net çalışma sermayesinin etkin bir şekilde yönetiminin ticari kârlılık üzerinde çok önemli bir etkiye sahip olduğunu ortaya koymuşlardır.

Serinoğlu ve Güçlü (2023) yılında yapmış oldukları çalışmanın temel amacı, işletme sermayesi yönetimi ile firma kârlılığı arasındaki ilişkiyi panel veri analizi yöntemiyle incelemektir. BİST ana metal sanayi sektöründe işlem gören ve faaliyetlerine devam eden 19 firmanın 1994–2021 dönemine ait veriler kullanılmıştır. Çalışmadaki bağımsız değişkenler ise alacak tahsil süresi, stok tutma süresi, cari oran, nakit oranı, stok bağımlılık oranı, çalışma sermayesi yatırım politikaları ve işletme sermayesi devir hızı gibi finansal rasyolardan

oluşmaktadır. Cari oranın aktif kârlılığı pozitif yönde, stok tutma süresi ve stok bağımlılık oranını ise negatif yönde etkilediği ifade edilmiştir. İşletme sermayesi ile kârlılık arasında güçlü bir ilişkinin bulunmadığı, ancak belirli unsurların düşük seviyede ilişkili olduğu belirtilmiştir.

Kiymaz vd. (2024) yılında yaptıkları çalışmada 2010'dan 2020'ye kadar altı gelişmiş ve 5 gelişmekte olan ülkede faaliyet gösteren 3.336 işletmenin verilerini kullanarak işletme sermayesi yönetimi ile firma performansı arasındaki ilişkiyi araştırmışlardır. Panel veri analizi yöntemi kullanılmış ve bağımlı değişken olarak aktif kârlılık, bağımsız değişkenler olarak nakit dönüşüm süresi, alacak tahsil süresi, borç ödeme süresi ve stok devir süresi belirlenmiştir. Çalışmanın sonucunda her iki ülke grubunda da nakit dönüşüm süresinin işletme performansı üzerinde olumsuz bir etkisi olduğu ifade edilmiştir. Gelişmiş ülkelerde stok devir süresinin işletme performansı üzerinde olumlu etki gösterirken, gelişmekte olan ülkelerde çalışmada kullanılan tüm değişkenlerin performans üzerinde olumsuz etkisi görülmüştür.

Tutcu vd., (2024), BİST Teknoloji Endeksi'nde yer alan firmaların aktif kârlılığı ve öz sermaye kârlılığı değerlerini yapay sinir ağları, çoklu doğrusal regresyon ve karar ağacı regresyonu yöntemleriyle tahmin etmiştir. Yıldırım vd., (2024) ise BİST enerji firmalarının aktif kârlılığı, öz sermaye kârlılığı ve net kâr marjını farklı makine öğrenmesi algoritmalarıyla incelemiş; aktif kârlılığı modelinde Bagged Tree algoritmasının başarılı sonuç verdiğini belirlemiştir. Bu çalışmalar, Türkiye'de finansal performansın makine öğrenmesi yöntemleriyle incelenmeye başlandığını göstermektedir.

Dulyanti (2024), çalışmasında Endonezya borsasında işlem gören otomotiv sektöründe faaliyet gösteren 8 firmanın 2016-2023 dönemlerine ait toplam borçlarının ve net çalışma sermayelerinin net kârlılıklarına etkisini incelemiştir. Toplam borçların net kâr üzerinde anlamlı ve pozitif etkiye sahip olduğu ortaya çıkarken net çalışma sermayesinin tek bir firmada net kâr üzerinde anlamlı ve pozitif etkiye sahip olduğunu belirtmişlerdir.

Rokayah vd. (2024), çalışmalarında tanımlayıcı bir yaklaşımla ilişkili nicel bir yaklaşım kullanarak bir firmanın 2015-2022 yıllarına ait dönemde çalışma sermayesi devir hızının ve net kâr marjının aktif kârlılığı üzerindeki etkisini araştırmışlar. Çalışma sermayesi devir hızının aktif kârlılığı üzerinde kısmen ve önemli ölçüde negatif bir etkiye sahip olduğunu buna karşılık net kâr marjının bir etkiye sahip olmadığını ama çalışma sermayesi devir hızının ve net kâr marjının birlikte eşzamanlı olarak aktif kârlılığı üzerinde etkiye sahip olduğunu bulmuşlardır.

Saidu vd. (2025) yılında Nijerya borsasında işlem gören firmaların işletme sermayesi yönetiminin finansal performans üzerindeki etkisini araştırmışlardır. 2014–2023 yılları arasındaki on şirketin yıllık raporlarından toplanan verileri analiz etmek için regresyon yöntemi tercih edilmiştir. Çalışmanın sonucunda alacak tahsil süresinin kârlılığı artırdığı, stok devir süresinin kârlılığı azalttığı tespit edilmiştir.

Susena vd. (2025) çalışmalarının amacı, işletme sermayesi yönetiminin finansal performans ve likidite üzerindeki etkisini araştırmaktır. 2016–2019 yılları arasında Endonezya'da faaliyet gösteren 41 imalat firmasının verileri bu araştırma için kullanmış ve örneklem, amaçlı örnekleme yöntemiyle seçildi ve moderasyon regresyon analizi (MRA) için panel veri analizi kullanılmıştır. Çalışmada işletme sermayesi yönetiminin likidite üzerinde anlamlı bir etkisinin bulunmadığı, çalışma sermayesi döngüsünün artması likiditeyi azaltmakta, kârlılığın ise bu etkiyi düzeltmede yetersiz kaldığı belirlenmiştir.

Gulo vd. (2025) yılında yaptıkları çalışmada Borsa Endonezya'da (IDX) işlem gören altyapı sektöründeki işletmelerde çalışma sermayesi ve likiditenin kârlılık üzerindeki etkisini incelemişlerdir. Çalışmada, 2020–2023 dönemine ait 45 firmanın finansal verileri nicel araştırma yöntemi ile analiz edilmiş ve çoklu doğrusal regresyon modeli uygulanmıştır. Bağımlı değişken aktif kârlılık, bağımsız değişkenler ise çalışma sermayesi ve likidite oranı olarak ele alınmıştır. Çalışma sermayesi ve likiditenin kârlılık üzerinde güçlü ve pozitif bir etki oluşturduğu tespit edilmiştir.

Huynh vd. (2025) Vietnam Borsası'nda faaliyetlerine devam eden firmaların işletme sermayesi yönetiminin finansal performans üzerindeki etkisini araştırmışlardır. Çalışmada 2012–2022 döneminde 441 firmanın veri setine Pooled OLS, sabit etkiler, rassal etkiler ve genelleştirilmiş en küçük kareler yöntemleri uygulanmıştır. Bağımlı değişkenler aktif kârlılık ve özsermaye kârlılığı olarak belirlenmiştir. Bağımsız değişkenler ise nakit dönüşüm süresi (CCC), alacak tahsil süresi (DSO), stok tutma süresi (DIO), borç ödeme süresi (DPO) ve faaliyet nakit çevrim süresi (OCC) olarak belirlenmiştir. Bulgular, DSO, DIO, CCC ve OCC'nin finansal performans üzerinde negatif ve anlamlı etkiye sahip olduğunu, DPO'nun ise beklenmedik biçimde kârlılığı azalttığını göstermektedir.

Literatür birlikte değerlendirildiğinde, Türkiye'de finansal performansın makine öğrenmesiyle tahmin edildiği araştırmalar oldukça sınırlı olmakla birlikte, BİST imalat firmalarında çalışma sermayesi etkinliğinin aktif kârlılığı tahminine sağladığı ilave katkıyı farklı tahmin ufuklarında inceleyen çalışmaların son derece sınırlı kaldığı görülmektedir. Bu araştırma, söz

konusu katkıyı dönem dışı değerlendirme, ablasyon analizi ve SHAP yöntemiyle incelemesi bakımından mevcut çalışmalardan ayrılmaktadır.

3. VERİ VE YÖNTEM

Çalışmanın veri seti, BİST imalat sektöründe faaliyet gösteren 127 firmanın 2015-Q1/2022-Q4 dönemine ait çeyreklik finansal verilerinden oluşmaktadır. Her firma için 32 çeyrek olmak üzere toplam 4.064 firma-çeyrek gözlemi bulunmaktadır. Araştırma kapsamındaki firmalar Borsa İstanbul sektör sınıflandırmasına göre belirlenmiş, finansal veriler ise Kamuyu Aydınlatma Platformu’nda yayımlanan finansal tablolardan elde edilmiştir. Eksik gözlem yer almamaktadır. Tüm firmaların aynı sektörde faaliyet göstermesi, sektörler arası heterojenliğin ayrıca kontrol edilmesini gereksiz kılmaktadır. Öte yandan bulguların diğer sektörlerle genellenebilirliğini sınırlamaktadır.

Çalışmada bağımlı değişken aktif kârlılıktır ($AK = \text{Net Kâr} / \text{Aktif Toplamı}$). Bağımsız değişkenler ise Kullanım İndeksi (UI), Performans İndeksi (PI) ve bu ikisinin çarpımı olarak tanımlanan Etkinlik İndeksi ($EI = PI \times UI$) ile nakit dönüşüm süresi (NDS) ve kaldıraç oranıdır (KO). Tüm değişkenlerin tanımları ve hesaplama formülleri Tablo 1’de sunulmuştur. $EI = PI \times UI$ özdeşliği, veri setinin tüm satırlarında sayısal olarak doğrulanmıştır. Bu özdeşlik, üç endeksin aynı modelde birlikte kullanılmasının çoklu bağlantı yaratacağı anlamına gelmektedir ve araştırma tasarımında açıkça dikkate alınmıştır.


Tablo 1: Değişken Tanımları ve Hesaplama Formülleri

Değişkenler	Hesaplamalar
	$I_{S,i,t} = \frac{S_{i,t}}{S_{i,t-1}}$
Performans İndeksi (PI)	Burada: $I_{S,i,t} = \frac{S_{i,t}}{S_{i,t-1}}$ $I_{S,i,t}$: cari dönem satışlarının önceki dönem satışlarına oranı $W_{i,j,t}$: i firmasının j'nci dönem varlık alt grubunun t dönemindeki tutarı $W_{i,j,t-1}$: aynı alt grubun önceki dönemdeki tutarı N: dönen varlık alt hesap grubu sayısı
Kullanım İndeksi (UI)	$UI_{i,t} = \frac{A_{i,t-1}}{A_{i,t}}, A_{i,t} = \frac{CA_{i,t}}{S_{i,t}}$ $CA_{i,t}$: i firmasının t dönemindeki dönen varlıkları $S_{i,t}$: i firmasının t dönemindeki satışları $A_{i,t}$: dönen varlıkların satışlara oranı
Etkinlik İndeksi (EI)	$PI_{i,t} = I_{S,i,t} \left[\frac{1}{N} \sum_{j=1}^N \frac{W_{i,j,t-1}}{W_{i,j,t}} \right]$
Nakit Dönüşüm Süresi (NDS)	ATS + SDS - BÖS ATS = 360 / (Satış Gelirleri / Ticari Alacaklar) SDS = 360 / (Satışların Maliyeti / Stoklar) BÖS = 360 / (Satışların Maliyeti / Ticari Borçlar) ATS= Alacak Tahsil Süresi SDS= Stok Devir Süresi BÖS= Borç Ödenme Süresi
Aktif Kârlılığı (AK)	Net Kâr / Aktif Toplamı
Kaldıraç Oranı (KO)	Toplam Yabancı Kaynak / Aktif Toplamı


Değişkenlere ilişkin tanımlayıcı istatistikler Tablo 2'de verilmiştir. Tablo 2'de dikkat çeken ilk özellik, bazı değişkenlerin uç değerler içermesidir. NDS-21.088 ile 7.630 arasında değişmekte, AK 6,80'e, EI ise 957'ye kadar çıkabilmektedir. Veri keşfi sırasında belirlenen uç değerler, ilgili firma ve dönemlere ait KAP finansal tabloları üzerinden kontrol edilmiştir. Yapılan kontroller sonucunda bu değerlerin veri giriş hatasından kaynaklanmadığı ve yayımlanan finansal tablolarla uyumlu olduğu belirlenmiştir. Bu nedenle söz konusu gözlemler silinmemiş veya değiştirilmemiştir. Bunun yerine aykırı değere dayanıklı kayıp fonksiyonları ve değerlendirme ölçütleri tercih edilmiş (bkz. Bölüm 4.5), veri dönüştürme seçenekleri ise ayrı bir duyarlılık analizinde incelenmiştir (bkz. Bölüm 5.6). Değişkenlerin dağılımları Şekil 1'de hem ham hem de işaretli-logaritmik ölçekte gösterilmektedir. Şekil, uç değerlerin ham dağılımlarını ne ölçüde çarpıttığını görsel olarak ortaya koymaktadır.

Tablo 2: Tanımlayıcı İstatistikler

İndex	Count	Mean	Standat Sapma	Min	Max
UI	4064	1,374579	1,052105	0	36,60316
PI	4064	1,87785	3,746286	0	179,1364
EI	4064	3,731335	19,30324	0	957,0482
NDS	4064	118,3	418,1735	-21087,7	7630,459
AK	4064	0,027246	0,143882	-1,10575	6,804566
KO	4064	0,519807	0,513099	0	10,86158

**Şekil 1.** Değişken Dağılımları: Ham ve İşaretli-Logaritmik Ölçek

Veri setinin tahmin tasarımı doğrudan etkileyen iki yapısal özelliği bulunmaktadır. Bunlardan birincisi, çeyreklik finansal kalemlerin yıl içinde kümülatif olarak raporlanmasıdır. Birinci çeyrek yılın ilk üç ayını, ikinci çeyrek ilk altı ayını, dördüncü çeyrek ise yılın tamamını yansıtmaktadır. Bu yapının en önemli sonucu, dördüncü çeyrekten yeni yılın ilk çeyreğine geçişte düzeylerin sıfırlanmasıdır. Şekil 2, bu durumu çeyrek geçişleri bazında göstermektedir. AK'nın bir çeyrekten diğerine sürekliliği yıl içi geçişlerde güçlüyken ($Q2 > Q3$ için Spearman $\rho = 0,89$), $Q4 > Q1$ geçişinde belirgin biçimde zayıflamaktadır ($\rho = 0,54$). Bu özellik hem tahmin görevlerinin tanımında hem de bulguların yorumlanmasında dikkate alınmıştır.

**Şekil 2.** Çeyrek Geçişlerine Göre AK Sürekliliği Ve $Q4 > Q1$ Geçişindeki

İkinci yapısal özellik, 2015-Q1 dönemindeki UI, PI ve EI değerlerinin tüm firmalar için ortak birer başlangıç değeri olarak kodlanmış olmasıdır. Bu satırlar firmaya özgü bilgi taşımadığından, tahmin hedefleri 2015-Q2 ve sonrasını kapsayacak biçimde kurulmuş ve bu

satırların model girdisi olarak kullanılıp kullanılmamasının sonuçlara etkisi ise duyarlılık analizinde ayrıca test edilmiştir (bkz. Bölüm 5.6, Tablo 8).

3.1. Tahmin Görevleri

Çalışmada iki dönem-dışı tahmin görevi tanımlanmıştır. **Görev A**, bir firmanın t çeyreği itibarıyla bilinen değişkenlerini kullanarak $t+1$ çeyreğindeki AK değerini tahmin etmektir. **Görev B** ise aynı bilgilerle bir yıl sonrasının aynı çeyreğindeki, yani $(y+1, q)$ dönemindeki AK değerini tahmin etmektir. Görev B'de kümülatif düzeyler aynı çeyrekler arasında karşılaştırıldığı için görev yöntemsel olarak daha homojendir. Buna karşılık kullanılan bilgi seti hedeften dört çeyrek uzakta olduğundan tahmin doğal olarak daha güçtür. Her iki görevde de hedef döneme ait hiçbir değişken girdi olarak kullanılmamıştır.

3.2. Özellik Setleri ve Ablasyon Tasarımı

Endekslerin ilave tahmin katkısı, aynı modeller ve aynı veri bölünmesi altında kademeli olarak genişletilen özellik setleriyle ölçülmüştür. Referans noktası olarak hiçbir model içermeyen **S0** seti tanımlanmıştır: (i) son gözlemi taşıma ($AK(t+1) = AK(t)$), (ii) önceki yılın aynı çeyreğini taşıma ve (iii) firma bazlı genişleyen geçmiş ortalaması olmak üzere üç naif referanstan oluşmaktadır. **S1** (temel set), AK'nın cari değeri ve gecikmelerini, NDS ile KO'nun cari ve gecikmeli değerlerini, dört çeyreklik hareketli AK ortalamasını, birinci farkları, çeyrek kukla değişkenlerini, zaman indeksini ve Görev A için hedef çeyrek ile yıl geçişi göstergesini içermektedir. Endekslerin hiçbirisi bu sette yer almamaktadır. **S2**, S1'e EI'nin cari ve gecikmeli değerlerini eklemektedir. **S3**, S1'e EI yerine bileşenleri olan UI ve PI'yi (cari ve gecikmeli) eklemektedir. **S4** ise UI, PI ve EI'yi birlikte içermektedir. $EI = PI \times UI$ özdeşliği nedeniyle çoklu bağlantı taşıdığından yalnızca tanısal amaçla raporlanmıştır. Bu tasarımda S1–S2 karşılaştırması EI'nin ilave katkısını, S2–S3 karşılaştırması ise birleşik endeks ile bileşenlerinin ayrık kullanımı arasındaki farkı sınamaktadır.

3.3. Eğitim–Doğrulama–Test Tasarımı ve Veri Sızıntısının Önlenmesi

Veriler rastgele karıştırılmamış, tahmin edilen AK değerinin ait olduğu yıla göre zaman sırasıyla bölünmüştür. Hedef AK değeri 2015–2020 döneminde olan gözlemler eğitim, 2021 yılında olan gözlemler doğrulama, 2022 yılında olan gözlemler ise nihai test kümesine ayrılmıştır. Örneğin 2021'in son çeyreğindeki bilgilerle 2022'nin ilk çeyreği tahmin edildiğinde, bu gözlem hedef yılı 2022 olduğu için test kümesinde değerlendirilmiştir. Modeller ve model ayarları yalnızca 2015–2021 dönemindeki eğitim ve doğrulama sonuçlarına göre belirlenmiştir. 2022 verileri model veya ayar seçiminde kullanılmamış,

yalnızca seçilen modellerin daha önce görmedikleri veriler üzerindeki nihai başarısını ölçmek amacıyla kullanılmıştır. Modellerin farklı yıllardaki kararlılığını incelemek için ayrıca ileriye dönük doğrulama uygulanmıştır. İlk aşamada 2015-2017 verileriyle eğitim yapıp 2018 yılı tahmin edilmiş, sonraki aşamalarda eğitim dönemi birer yıl genişletilerek sırasıyla 2019, 2020 ve 2021 yılları tahmin edilmiştir. Böylece modellerin yalnızca tek bir yılda değil, farklı dönemlerde de benzer sonuç verip vermediği kontrol edilmiştir. Geleceğe ait bilgilerin modellere yanlışlıkla aktarılmasını önlemek için veri hazırlama işlemleri de zaman sırasına uygun gerçekleştirilmiştir. Ölçekleme ve uç değer sınırları yalnızca eğitim verileri kullanılarak belirlenmiştir. Firma numarası, modellerin tahminde kullanabileceği sayısal bir değişken olarak verilmemiştir. LSTM ve GRU modellerinde kullanılan geçmiş dönem pencereleri yalnızca aynı firmaya ait gözlemlerden oluşturulmuş, farklı firmaların verileri birbirine karıştırılmamıştır. Son olarak, her girdinin doğru gelecek döneme ait AK değerini tahmin ettiği otomatik kontrollerle doğrulanmıştır.

3.4. Modeller

Çalışmada dört model sınıfı ve iki hibrit yaklaşım aynı değerlendirme protokolü altında karşılaştırılmıştır. İlk sınıf, gelişmiş modellerin tahmin başarısını karşılaştırmak için kullanılan naif referans modellerinden oluşmaktadır. İkinci sınıfta OLS, Ridge, Lasso, Elastic Net ve aykırı değerlere karşı daha dayanıklı olan Huber regresyonu yer almaktadır. Ayrıca değişkenler arasındaki firma içi ilişkileri betimleyici olarak incelemek amacıyla firma sabit etkili panel regresyonu uygulanmıştır. Standart hatalar firma düzeyinde kümelenmiştir. Araştırmanın temel amacı nedensel etki tahmini değil, dönem dışı aktif kârlılığı tahminidir. Bu nedenle panel regresyon sonuçları yardımcı analiz niteliğinde değerlendirilmiş ve modellerin tahmin performansı karşılaştırmasına dâhil edilmemiştir. Üçüncü sınıf, Random Forest, Extra Trees, Gradient Boosting, XGBoost, LightGBM ve CatBoost modellerinden oluşan ağaç tabanlı topluluk yöntemleridir. Veri setindeki aşırı değerlerin gerçek ekonomik gözlemler olması nedeniyle aday model ayarlarında Huber, MAE ve pseudo-Huber gibi aykırı değerlere daha dayanıklı kayıp fonksiyonlarına da yer verilmiştir. Dördüncü sınıfta derin öğrenme modelleri bulunmaktadır. Bu kapsamda bir veya iki gizli katmana sahip MLP ile LSTM ve GRU modelleri kullanılmıştır. LSTM ve GRU modelleri, her firmanın önceki dört veya sekiz çeyreklik verisini firma sınırlarını aşmadan işlemiştir. Örneklemin sınırlı olması nedeniyle model yapıları bilinçli olarak küçük tutulmuş ve geniş çaplı bir hiperparametre araması yapılmamıştır. Son olarak iki hibrit yaklaşım denenmiştir. İlk yaklaşımda, doğrulama kümesinde en düşük hatayı veren ağaç modeli ile LSTM veya GRU modelinin tahminleri

birleştirilmiştir. Modellerin birleştirme ağırlığı yalnızca 2021 doğrulama kümesindeki sonuçlara göre belirlenmiştir. İkinci yaklaşımda ise LSTM'nin öğrendiği son dönem bilgisi, diğer tablosal değişkenlere eklenerek LightGBM modeline girdi olarak verilmiştir. Her iki hibrit yaklaşımda da 2022 test verisi model seçimi, ağırlık belirleme veya temsil öğrenimi amacıyla kullanılmamıştır.

3.5. Değerlendirme Ölçütleri ve İstatistiksel Karşılaştırma

Aşırı değerlerin varlığında, kare hataya dayalı ölçütler az sayıdaki gözlemden önemli ölçüde etkilenebilmektedir. Bu nedenle çalışmada birincil değerlendirme ölçütleri olarak ortalama mutlak hata (MAE) ve medyan mutlak hata (MedAE) kullanılmıştır. R^2 , RMSE ve Spearman sıra korelasyonu (ρ) ise tamamlayıcı ölçütler olarak raporlanmıştır. Naif modele göre iyileşme, $Skill = 1 - MAE_{model} / MAE_{naif}$ formülüyle hesaplanmıştır. Model çiftleri arasındaki hata farklarının anlamlılığı, panel yapısı dikkate alınarak firma düzeyinde test edilmiştir. Bunun için mutlak hata farkları önce her firma için ortalananmış, ardından firma başına tek gözlem kalacak şekilde 127 firma üzerinde t-testi uygulanmıştır. En iyi modelin MAE değeri için firma bazlı blok bootstrap yöntemiyle %95 güven aralığı hesaplanmış ve bu işlem 2.000 kez tekrarlanmıştır. Tüm rastgele işlemlerde başlangıç tohumları sabitlenmiş, sonuçların beş farklı tohum altındaki kararlılığı ayrıca raporlanmıştır.

4. BULGULAR

4.1. Panel Regresyon Ön Bulguları

Tahmin analizlerinden önce, değişkenler ile gelecek dönem AK arasındaki ilişkiler firma sabit etkili panel regresyonuyla incelenmiştir. Bağımlı değişken olarak bir sonraki çeyreğin AK değeri kullanılmış ve analiz 2015–2021 dönemini kapsamıştır. Tablo 3'teki sonuçlara göre, üç modelde de yalnızca kaldıraç oranı istatistiksel olarak anlamlı bulunmuştur ($\beta = 0,208$; $p < 0,001$). EI, UI, PI ve NDS değişkenlerinin katsayıları ise istatistiksel olarak anlamlı değildir. Modelin firma içindeki değişimi açıklama düzeyi, within R^2 değerine göre 0,159'dur. Havuzlanmış veride KO ile gelecek dönem AK arasındaki sıra korelasyonu negatifken ($\rho = -0,31$), firma içindeki değişimi gösteren panel regresyon katsayısı pozitif çıkmıştır. Bu sonuç, firmaların fon ihtiyacını borçlanma yoluyla sağlayarak vergi avantajı sağlaması ve otofinansman kaynaklarının fon ihtiyacının giderilmesinde kullanılması yerine farklı yatırımlarda kullanılması ve bu yatırımların getirisinin borçlanma maliyetinden daha fazla ($r > k$) olması ile açıklanabilir.

Bu farklılık, firmalar arası karşılaştırma ile aynı firmanın zaman içindeki değişiminin farklı sonuçlar verebildiğini göstermektedir.

Tablo 3: Firma Sabit Etkili Panel Regresyonu Sonuçları


		Katsayı	Standart Hata	T	P
FE_EI	AK	0,058677	0,082641	0,710025	0,477739
	NDS	7,33E-06	8,78E-06	0,834752	0,403918
	KO	0,207715	0,05141	4,040373	5,46E-05
	EI	2,48E-06	2,55E-05	0,097304	0,922491
FE_UI_PI	AK	0,058392	0,082404	0,7086	0,478623
	NDS	7,46E-06	8,92E-06	0,836593	0,402882
	KO	0,207676	0,051444	4,036915	5,54E-05
	UI	0,001198	0,001476	0,811479	0,417149
	PI	0,000177	0,000267	0,661648	0,508243
FE_temel	AK	0,058676	0,082629	0,710116	0,477682
	NDS	7,33E-06	8,78E-06	0,834858	0,403858
	KO	0,207717	0,051403	4,040973	5,44E-05

4.2. Dönem-Dışı Tahmin Performansı: Görev A

Görev A'ya ait 2022 nihai test sonuçları Tablo 4'te, model ailelerinin en iyi özellik setleriyle karşılaştırılması ise Şekil 3'te sunulmuştur. Tablo 4'te, sonuçların daha anlaşılır olması için her model ailesinden en iyi performansı gösteren model ve özellik setine yer verilmiştir. Tüm sonuçlar 508 test gözlemine dayanmaktadır. S1 temel değişkenleri, S2 temel değişkenlere ek olarak EI'yi, S3 ise temel değişkenlere ek olarak UI ve PI'yi içermektedir. Tablo 4'e göre en düşük hata, S3 özellik setini kullanan MLP modelinde elde edilmiştir. Modelin MAE değeri 0,0310, MedAE değeri 0,0110 ve Spearman sıra korelasyonu 0,830'dur. Naif son değer modelinin MAE değeri ise 0,0454'tür. Buna göre MLP modeli, naif modele kıyasla ortalama mutlak hatayı %31,8 azaltmıştır. Firma düzeyinde gerçekleştirilen istatistiksel karşılaştırma, hata farkının anlamlı olduğunu göstermiştir ($t = -4,60$; $p < 0,0001$). MLP modelinin MAE değeri için firma bazlı blok bootstrap yöntemiyle hesaplanan %95 güven aralığı [0,0183; 0,0485] olarak bulunmuştur.


Tablo 4. Görev A İçin 2022 Nihai Testinde Seçilmiş Modellerin Performans Sonuçları

Model ve Özellik Seti	MAE	MedAE	R ²	Spearman ρ	Naife göre iyileşme
MLP, S3	0,0310	0,0110	0,391	0,830	%31,8
LSTM, S2	0,0317	0,0097	0,333	0,854	%30,2
Extra Trees, S1	0,0323	0,0105	0,310	0,847	%28,7
Hibrit Karışım	0,0324	0,0108	0,259	0,855	%28,6
Random Forest, S2	0,0330	0,0113	0,332	0,852	%27,4
Naif Son Değer	0,0454	0,0233	0,314	0,721	Referans




Şekil 3. Görev A: Model Ailelerinin En İyi Özellik Setleriyle 2022 Test

Şekil 3'ün ortaya koyduğu bir diğer önemli bulgu, model sınıfları arasındaki performans farklarının oldukça küçük olmasıdır. LSTM (MAE = 0,0317), Extra Trees (MAE = 0,0323) ve hibrit tahmin karışımı (MAE = 0,0324), en iyi model olan MLP'yi yakın sonuçlarla izlemektedir. Ayrıca en başarılı ilk on modelin MAE değerleri 0,031–0,033 aralığında toplanmıştır. Bu sonuçlar, derin öğrenme modellerinin ağaç tabanlı yöntemlerle başa baş performans gösterdiğini, ancak belirgin bir üstünlük sağlamadığını göstermektedir. En iyi modelin 2022 yılı tahminleri ile gerçekleşen AK değerlerinin karşılaştırılması Şekil 4'te sunulmuştur. Tahminler, özellikle firmaların aktif karlılık sıralaması bakımından gerçekleşen değerlerle güçlü bir uyum göstermektedir.



Şekil 4. Görev A: En İyi Modelin 2022 Gerçekleşme-Tahmin Saçılımı

Modellerin naif referansa göre avantajının hangi çeyrek geçişlerinden kaynaklandığını incelemek amacıyla tahmin hataları, kaynak çeyreğe göre ayrıştırılmış ve sonuçlar Şekil 5'te sunulmuştur. Şekil 5'e göre, kümülatif değerlerin yeni yılda yeniden başladığı Q4>Q1 geçişinde naif modelin MAE değeri 0,0908'e yükselirken, en iyi modelin MAE değeri 0,0334'te kalmıştır. Yıl içindeki diğer çeyrek geçişlerinde ise iki yaklaşım arasındaki fark daha küçüktür. Bu bulgu, modellerin sağladığı katkının önemli bir bölümünün kümülatif raporlama takvimindeki yıl geçişini yakalamasından kaynaklandığını göstermektedir. Genişleyen pencere ile ileriye dönük doğrulama sonuçları da model performansının farklı yıllarda kararlı olduğunu göstermiştir. Örneğin LSTM modelinin ortalama MAE değeri $0,0251 \pm 0,0045$ olarak hesaplanmıştır.



Şekil 5. Görev A'da Hedef Çeyrek Geçişlerine Göre Ortalama Mutlak Hata ve En İyi Model ile Naif Referansın Karşılaştırılması


4.3. Dönem-Dışı Tahmin Performansı: Görev B

Bir yıl sonrasının aynı çeyreğini tahmin etmeyi amaçlayan Görev B'ye ait 2022 nihai test sonuçları Tablo 5'te sunulmuştur. En düşük hata, S3 özellik setini kullanan LSTM modelinde elde edilmiştir. Modelin MAE değeri 0,0476, Spearman sıra korelasyonu ise 0,607'dir. Naif referansa göre hata azalması yüzde 12,5 düzeyinde kalmasına rağmen, firma düzeyinde yapılan istatistiksel karşılaştırma bu farkın anlamlı olduğunu göstermiştir. Test istatistiği -2,91 ve p değeri 0,004 olarak hesaplanmıştır. Tablo 5'teki en dikkat çekici bulgu, bütün modellerin R^2 değerlerinin negatif olmasıdır. En iyi modelin R^2 değeri -0,097'dir. Buna göre modeller, bir yıl sonraki AK tahmininde mutlak hatayı azaltmakta ve firmaların kârlılık sıralaması hakkında belirli ölçüde bilgi sağlamaktadır. Ancak aşırı değerli gözlemlerde oluşan büyük tahmin hataları nedeniyle gerçek AK değerlerindeki değişimi yeterince açıklayamamaktadır. Bu nedenle mevcut bilgi setiyle bir yıl sonraki AK değerinin sayısal olarak tahmin edilme başarısı sınırlı kalmıştır.

Tablo 3: Görev B için 2022 nihai testinde seçilmiş modellerin performans sonuçları


Model ve Özellik Seti	MAE	MedAE	R^2	Spearman ρ	Naife Göre İyileşme
LSTM, S3	0,0476	0,0181	-0,097	0,607	%12,5
MLP, S1	0,0482	0,0200	-0,072	0,619	%11,5
Extra Trees, S1	0,0483	0,0189	-0,057	0,626	%11,2
GRU, S2	0,0483	0,0183	-0,143	0,616	%11,1
Hibrit Karışım	0,0487	0,0190	-0,096	0,595	%10,5
Random Forest, S2	0,0487	0,0183	-0,094	0,619	%10,6
Naif Son Değer	0,0544	0,0214	-0,403	0,617	Referans

Şekil 6'da Görev B kapsamında model ailelerinin tahmin performansları karşılaştırılmıştır. En başarılı modellerin MAE değerleri birbirine yakın olmakla birlikte, bir yıl sonrası tahmininde sağlanan iyileşmenin Görev A'ya göre daha sınırlı kaldığı görülmektedir.



Şekil 6. Görev B'de Model Ailelerinin Tahmin Performanslarının Karşılaştı

Şekil 6'ya göre en düşük tahmin hatası LSTM modelinde elde edilmiştir. MLP, Extra Trees, GRU, Random Forest ve hibrit modelin sonuçları da LSTM'ye oldukça yakındır. Bu modeller naif referanslardan daha düşük hata üretirken OLS, Ridge, Elastic Net ve Lasso modelleri naif referansların gerisinde kalmıştır. Bu sonuç, Görev B'de derin öğrenme ve ağaç tabanlı modellerin daha başarılı olduğunu, ancak en iyi modeller arasındaki farkın oldukça sınırlı kaldığını göstermektedir. En düşük tahmin hatasına sahip LSTM modelinin gerçekleşen ve tahmin edilen AK değerleri ise Şekil 7'de karşılaştırılmıştır.



Şekil 7. Görev B'de LSTM Modelinin Gerçekleşen ve Tahmin Edilen AK Değerlerinin Karşılaştırılması


4.4. Ablasyon Bulguları ve Endekslerin İlave Katkısı

Çalışmanın temel sorularından biri olan endekslerin ilave tahmin katkısına ilişkin ablasyon sonuçları Tablo 6'da özetlenmiştir. Seçilmiş model ailelerinin farklı özellik setlerindeki test hataları ise Şekil 8'de gösterilmiştir. Şekil 8a Görev A'ya, Şekil 8b ise Görev B'ye ait sonuçları göstermektedir. Tablo 6'ya göre Görev A'da EI'nin veya UI ile PI'nin temel modele eklenmesi, tahmin başarısını yalnızca sınırlı düzeyde etkilemiştir. Yapılan kırk firma düzeyindeki karşılaştırmanın yalnızca birinde yüzde 5 anlamlılık düzeyinde iyileşme görülmüştür. Bu sonuç, EI'nin eklendiği Gradient Boosting modelinde elde edilmiştir ($t = -2,23$; $p = 0,028$). En düşük hatayı veren MLP modelinde ise S3 özellik seti, S1'e göre daha düşük hata üretmiş ancak aradaki fark istatistiksel olarak anlamlı bulunmamıştır ($p = 0,38$).

Tablo 6: Endekslerin Temel Modele İlave Katkısının Anlamlı Bulunduğu Karşılaştırmalar

Görev	Model	Karşılaştırma	S1 MAE	Ek set MAE	MAE farkı	t	p	Sonuç
A	Gradient Boosting	S2 ve S1	0,0359	0,0351	-0,0008	-2,23	0,027	İyileşme
B	CatBoost	S3 ve S1	0,0547	0,0509	-0,0038	-3,51	0,0006	İyileşme
B	LightGBM	S3 ve S1	0,0539	0,0521	-0,0018	-3,32	0,0012	İyileşme
B	LightGBM	S4 ve S1	0,0539	0,0518	-0,0021	-3,12	0,0022	İyileşme
B	CatBoost	S2 ve S1	0,0547	0,0512	-0,0035	-2,97	0,0036	İyileşme
B	MLP	S2 ve S1	0,0482	0,0508	0,0027	2,95	0,0038	Kötüleşme
B	XGBoost	S4 ve S1	0,0529	0,0507	-0,0021	-2,57	0,011	İyileşme
B	Gradient Boosting	S2 ve S1	0,0500	0,0515	0,0015	2,49	0,014	Kötüleşme
B	XGBoost	S2 ve S1	0,0529	0,0514	-0,0015	-2,45	0,016	İyileşme
B	CatBoost	S4 ve S1	0,0547	0,0526	-0,0021	-2,02	0,045	İyileşme

Negatif MAE farkı, endekslerin eklenmesiyle tahmin hatasının azaldığını; pozitif fark ise tahmin hatasının arttığını göstermektedir. S2 temel değişkenlere EI'nin, S3 UI ve PI'nin, S4 ise EI, UI ve PI'nin birlikte eklendiği özellik setidir. Toplam 80 karşılaştırma yapılmış, tabloda yalnızca $p < 0,05$ bulunan sonuçlar gösterilmiştir. Veriler yazarların analiz çıktı dosyalarından derlenmiştir.



Şekil 8. Görev A ve Görev B’de Özellik Setlerine Göre 2022 Test MAE Değerlerinin Karşılaştırılması

Görev B’de ise farklı bir sonuç ortaya çıkmıştır. Tahmin ufku dört çeyreğe çıktığında ve geçmiş AK bilgilerinin tahmin gücü azaldığında, bazı gradyan artırma modellerinde endekslerin ek katkı sağladığı görülmüştür. S3 özellik seti, CatBoost modelinde S1’e göre tahmin hatasını anlamlı biçimde azaltmıştır ($t = -3,51$; $p = 0,0006$). Benzer sonuçlar LightGBM S3 ($t = -3,32$; $p = 0,0012$), CatBoost S2 ($t = -2,97$; $p = 0,004$) ve XGBoost S2 ($t = -2,45$; $p = 0,016$) modellerinde de elde edilmiştir. Ancak bu katkı bütün modellerde aynı yönde gerçekleşmemiştir. Gradient Boosting ve MLP modellerinde S2 özellik seti tahmin performansını anlamlı biçimde kötüleştirmiştir. Genel olarak EI’nin birleşik kullanımı ile UI ve PI’nin ayrı kullanımı arasında belirgin bir üstünlük görülmemiştir. Bununla birlikte, anlamlı iyileşmelerin çoğu UI ve PI’nin ayrı kullanıldığı S3 özellik setinde ortaya çıkmıştır.


4.5. Açıklanabilirlik ve SHAP Analizi

Tahminlerde hangi değişkenlerin daha etkili olduğunu incelemek amacıyla, en iyi ağaç tabanlı modele TreeSHAP analizi uygulanmıştır. S1, S2 ve S3 özellik setleri için hesaplanan ortalama mutlak SHAP değerleri Tablo 7’de, değişken önemleri ve katkı dağılımları ise Şekil 9’da sunulmuştur. Tablo 7’ye göre model tahminlerinde en belirleyici değişkenler AK’nın mevcut ve geçmiş değerleridir. S1 özellik setinde cari AK’nın ortalama mutlak SHAP değeri 0,02321, dört çeyreklik AK ortalamasının 0,01261 ve bir dönem gecikmeli AK’nın 0,00536’dır. Bu değişkenleri yıl geçişi, dördüncü çeyrek ve hedef çeyrek bilgileri izlemektedir. Bu sonuç, modelin kümülatif raporlama takvimindeki dönemsel yapıyı tahminlerde kullandığını göstermektedir. KO orta düzeyde katkı sağlarken, NDS’nin katkısı oldukça sınırlı kalmıştır. S2 ve S3 sonuçları da benzer bir sıralama göstermektedir. EI’nin ortalama mutlak SHAP değeri 0,00024, UI’nin 0,00048 ve PI’nin 0,00019 olarak hesaplanmıştır. Bu değerler, işletme sermayesi endekslerinin model tahminlerindeki katkısının geçmiş AK değişkenlerine göre oldukça düşük olduğunu göstermektedir.

Tablo 7: Özellik Setlerine Göre Ortalama Mutlak SHAP Değerleri

Değişken	S1 Temel	S2 Temel ve EI	S3 Temel ve UI-PI
AK	0,02321	0,02358	0,02357
AK dört çeyreklik ortalaması	0,01261	0,01120	0,01140
Bir dönem gecikmeli AK	0,00536	0,00619	0,00579
Hedef çeyrek	0,00401	0,00478	0,00444
Yıl geçişi	0,00465	0,00428	0,00438
Dördüncü çeyrek	0,00458	0,00409	0,00416
KO	0,00266	0,00247	0,00268
AK birinci farkı	0,00244	0,00263	0,00251
Bir dönem gecikmeli KO	0,00207	0,00227	0,00215
İki dönem gecikmeli AK	0,00177	0,00182	0,00168
Zaman indeksi	0,00126	0,00126	0,00115
Üçüncü çeyrek	0,00082	0,00076	0,00080
İkinci çeyrek	0,00066	0,00057	0,00058
Birinci çeyrek	0,00053	0,00059	0,00048
NDS	0,00029	0,00028	0,00027
Bir dönem gecikmeli NDS	0,00025	0,00023	0,00021
NDS birinci farkı	0,00017	0,00018	0,00014
EI	-	0,00024	-
Bir dönem gecikmeli EI	-	0,00019	-
UI	-	-	0,00048
Bir dönem gecikmeli UI	-	-	0,00030
PI	-	-	0,00019
Bir dönem gecikmeli PI	-	-	0,00017


Ortalama mutlak SHAP değerinin yüksek olması, ilgili değişkenin model tahminleri üzerinde daha fazla etkili olduğunu göstermektedir. Boş hücreler, değişkenin ilgili özellik setinde bulunmadığını ifade etmektedir. SHAP değerleri modelin tahmin davranışını açıklamakta, değişkenler arasında nedensel bir ilişki göstermemektedir.




(a) Ortalama mutlak SHAP değerlerine göre değişken önemi (b) Değişken değerlerinin tahminlere katkı dağılımı

Şekil 9. Global Değişken Önemi ve SHAP Katkı Dağılımı


Endeksler modele eklendiğinde ortalama mutlak SHAP değerleri EI için 0,00024, UI için 0,00048 ve PI için 0,00019 düzeyinde kalmıştır. Bu değerler, endekslerin model tahminlerindeki katkısının geçmiş AK değişkenlerine göre oldukça düşük olduğunu göstermekte ve ablasyon bulgularını desteklemektedir. Cari AK, KO ve EI değerlerinin model tahminlerine katkılarının değişken değerlerine göre dağılımı sırasıyla Şekil 10, Şekil 11 ve Şekil 12’de gösterilmiştir. Şekil 10’da cari AK ile SHAP katkısı arasında belirgin ve büyük ölçüde pozitif bir ilişki görülmektedir. Şekil 11’de KO arttıkça SHAP katkısının çoğunlukla azaldığı, ancak birkaç aşırı gözlemin bu genel eğilimden ayrıldığı görülmektedir. Şekil 12’de ise EI ile SHAP katkısı arasında belirgin ve düzenli bir ilişki görülmemektedir. Diğer değişkenlere ait bağımlılık grafikleri ile gözlem düzeyindeki SHAP açıklamaları ek materyalde sunulmuştur. SHAP değerleri yalnızca eğitilmiş modelin tahmin davranışını açıklamakta, değişkenler arasında nedensel bir ilişki göstermemektedir.



Şekil 10. Cari AK Değerinin Model Tahminlerine SHAP Katkısı



Şekil 11. Kaldıraç Oranının Model Tahminlerine SHAP Katkısı



Şekil 12. Etkinlik İndeksinin Model Tahminlerine SHAP Katkısı

4.6. Tematik Eğilimler

Ana bulguların veri işleme tercihlerinden ne ölçüde etkilendiğini incelemek amacıyla, en iyi ağaç tabanlı model altı farklı senaryoda yeniden değerlendirilmiştir. Bu senaryolar ham veri, robust ölçekleme, işaretli logaritma dönüşümü, eğitim verisinden belirlenen yüzde 1 ve yüzde 99 sınırlarıyla winsorizasyon, 2015 yılının ilk çeyreğine ait satırların dışlanması ve farklı firmalarda birebir örtüşen satırların çıkarılmasından oluşmaktadır. Tablo 8'e göre Görev A'daki MAE değerleri tüm senaryolarda 0,0318 ile 0,0325 arasında kalmıştır. Görev B'de ise bu değerler 0,0482 ile 0,0484 arasında değişmiştir. Winsorizasyon, Görev A'da R^2 değerini 0,310'dan 0,341'e yükseltmiş ancak genel bulguları değiştirmemiştir. Beş farklı rastgele başlangıç altında MAE standart sapması her iki görevde de 0,0001'in altında kalmıştır. Bu sonuçlar, ana bulguların veri işleme tercihlerine ve modeldeki rastgeleliğe karşı kararlı olduğunu göstermektedir.

Tablo 8: Sağlamlık ve Duyarlılık Analizi Sonuçları

Görev	Senaryo	R ²	MAE	RMSE	MedAE	Spearman ρ	n
A	Ham veri	0,310	0,0323	0,1223	0,0105	0,847	508
A	Robust ölçekleme	0,310	0,0323	0,1224	0,0105	0,847	508
A	İşaretli logaritma	0,305	0,0323	0,1227	0,0107	0,847	508
A	Winsorizasyon	0,341	0,0318	0,1195	0,0104	0,843	508
A	2015-Q1 hariç	0,310	0,0323	0,1223	0,0105	0,847	508
A	Birebir örtüşen satırlar hariç	0,309	0,0325	0,1226	0,0104	0,845	506
B	Ham veri	-0,057	0,0483	0,1514	0,0189	0,626	508
B	Robust ölçekleme	-0,057	0,0483	0,1514	0,0189	0,626	508
B	İşaretli logaritma	-0,085	0,0484	0,1534	0,0190	0,622	508
B	Winsorizasyon	-0,078	0,0482	0,1529	0,0183	0,631	508
B	2015-Q1 hariç	-0,057	0,0483	0,1514	0,0189	0,626	508
B	Birebir örtüşen satırlar hariç	-0,057	0,0483	0,1514	0,0188	0,625	508

Duyarlılık analizleri Extra Trees ve S1 temel özellik seti kullanılarak gerçekleştirilmiştir. Beş farklı rastgele başlangıç altında ortalama MAE, Görev A için $0,03241 \pm 0,00009$, Görev B için ise $0,04830 \pm 0,00006$ olarak hesaplanmıştır. Birebir örtüşen satırların dışlandığı Görev A senaryosunda test gözlemi sayısı 506'ya düşmüştür.

5. SONUÇ VE TARTIŞMA

Bu araştırmada, BİST imalat sektöründe faaliyet gösteren 127 firmanın aktif kârlılığının bir sonraki çeyrek ve bir yıl sonraki aynı çeyrek için tahmin edilmesi amaçlanmıştır. Bulgular, bir sonraki çeyreğe ilişkin tahminlerde en düşük hatanın S3 özellik setini kullanan MLP modeliyle elde edildiğini göstermiştir. Modelin ortalama mutlak hatası 0,0310 olarak hesaplanmış ve naif modele kıyasla tahmin hatasında %31,8 oranında azalma sağlanmıştır. Bir yıl sonraki aynı çeyreğin tahmininde ise S3 özellik setini kullanan LSTM modeli en düşük hatayı üretmiş; ancak naif modele göre sağlanan iyileşme %12,5 düzeyinde kalmıştır.

Bir sonraki çeyrek tahmininde elde edilen 0,391 düzeyindeki R² değeri, modelin aktif kârlılığındaki değişimin belirli bir bölümünü açıklayabildiğini göstermekte olup tahminlerin %39'unun doğru olduğu anlamına gelmemektedir. Modellerin 0,83-0,85 aralığındaki Spearman korelasyonları, firmaların aktif kârlılık düzeylerine göre sıralanmasında güçlü bir uyuma işaret etmektedir. Buna karşılık bir yıl sonraki tahminlerde R² değerlerinin negatif olması, sayısal tahmin başarısının sınırlı kaldığını göstermektedir. Modellerin naif referansa göre sağladığı iyileşmenin önemli bir bölümü Q4-Q1 geçişinde ortaya çıkmıştır. Kümülatif finansal raporlamanın yeni yılın ilk çeyreğinde yeniden başlaması nedeniyle naif modelin bu geçişteki MAE değeri 0,0908'e yükselirken, en iyi modelin MAE değeri 0,0334 düzeyinde kalmıştır. Bu bulgu, modellerin çeyreklik raporlama yapısındaki dönemsel değişimi naif yaklaşıma göre daha başarılı biçimde temsil edebildiğini göstermektedir.

Ablasyon bulguları, kısa vadeli tahmin başarısının temel olarak geçmiş aktif kârlılık değerleri, kaldıraç oranı ve çeyreklik zaman yapısından kaynaklandığını göstermiştir. EI ile bileşenleri olan UI ve PI'nin temel özellik setine eklenmesi, bir sonraki çeyrek tahmininde genel ve tutarlı bir iyileşme sağlamamıştır. Bir yıl sonraki aynı çeyrek tahmininde ise UI ve PI'nin ayrı kullanımı bazı ağaç tabanlı modellerde anlamlı fakat sınırlı bir katkı sağlamış; bu katkı bütün modellerde gözlenmemiştir. Dolayısıyla çalışma sermayesi endekslerinin tahmin katkısının kullanılan modele ve tahmin ufkuna bağlı olduğu değerlendirilmiştir.

SHAP analizi, model tahminlerinde en yüksek katkının cari ve gecikmeli aktif kârlılık değerleri ile çeyreklik raporlama yapısından kaynaklandığını göstermiştir. Kaldıraç oranının katkısı orta düzeyde kalırken NDS, EI, UI ve PI değişkenlerinin göreceli katkılarının daha düşük olduğu belirlenmiştir. Bununla birlikte SHAP değerleri yalnızca eğitilmiş modelin tahmin davranışını açıklamakta ve değişkenler arasında nedensel bir ilişki bulunduğunu göstermemektedir. Araştırmanın teorik katkısı, çalışma sermayesi etkinlik göstergelerinin aktif kârlılığı tahminindeki ilave bilgi değerinin doğrudan sınanmasıdır. Yöntemsel katkı, farklı model ailelerinin aynı dönem dışı değerlendirme tasarımı altında karşılaştırılması ve endekslerin katkısının ablasyon ile SHAP analizleri aracılığıyla incelenmesidir. Uygulama açısından bulgular, kısa vadeli aktif kârlılığı tahminlerinde geçmiş kârlılık bilgileri ile çeyreklik raporlama yapısının öncelikli olduğunu göstermektedir.

Genel olarak bulgular, aktif kârlılığının bir sonraki çeyrek için naif referanslara kıyasla daha düşük hatayla tahmin edilebildiğini, ancak bir yıl sonraki sayısal tahmin başarısının sınırlı kaldığını göstermektedir. Derin öğrenme ve ağaç tabanlı modellerin birbirine yakın sonuçlar üretmesi, incelenen örnekleme derin öğrenmenin açık bir üstünlüğünden söz edilmesini engellemektedir. Ayrıca tahmin ve SHAP bulguları nedensel etki kanıtı oluşturmadığından, EI veya diğer endekslerin aktif kârlılığını artırdığı ya da azalttığı yönünde bir çıkarım yapılmamalıdır.

5.1. Araştırmanın Sınırlılıkları ve Gelecek Araştırmalar

Araştırmanın başlıca sınırlılığı, örneklemin yalnızca BİST imalat sektöründeki firmalardan oluşmasıdır. Bu nedenle bulguların diğer sektörler ve farklı piyasalara genellenmesi sınırlıdır. Firma başına 32 çeyreklik gözlem bulunması, özellikle LSTM ve GRU modelleri açısından kısa bir zaman serisi oluşturmaktadır. Ayrıca finansal kalemlerin yıl içinde kümülatif olarak raporlanması, çeyrekler arasındaki karşılaştırılabilirliği ve özellikle Q4-Q1 geçişlerini etkilemektedir. Veri setinde firma büyüklüğü, satış büyümesi, enflasyon, faiz ve döviz kuru gibi firma ve makroekonomik düzeyde açıklayıcı değişkenlerin bulunmaması,

modellerin bilgi kapsamını sınırlandırmaktadır. EI'nin PI ve UI'nin çarpımından oluşması nedeniyle bu üç değişkenin birlikte kullanıldığı özellik setinde matematiksel bağımlılık bulunmaktadır. Son olarak araştırmanın tahmin odaklı tasarımı ve SHAP analizi, değişkenler arasında nedensel ilişki kurulmasına imkân vermemektedir.

Gelecek araştırmalarda daha uzun dönemleri ve farklı sektörleri kapsayan veri setlerinden yararlanılabilir. Firma büyüklüğü, satış büyümesi ve nakit akışı göstergelerinin yanı sıra enflasyon, faiz oranı ve döviz kuru gibi makroekonomik değişkenlerin modellere eklenmesi, özellikle uzun vadeli tahmin performansının geliştirilmesine katkı sağlayabilir.

KAYNAKLAR

- Akomeah, J., & Frimpong, S. (2019). Effect of working capital management on profitability of listed manufacturing companies in Ghana. *International Journal of Finance and Banking Research*, 5(2), 29-35.
- Akyüz, K. C., Yıldırım, İ., Akyüz, İ., Ersen, N., Aydın, A., & Üçüncü, K. (2019). Kağıt ve kağıt ürünleri sanayi sektöründe faaliyet gösteren işletmelerde çalışma sermayesi ve kârlılık ilişkisi. *Duzce University Journal of Science and Technology*, 7(3), 1394-1402.
- Amponsah-Kwatiah, K., & Asiamah, M. (2021). Working capital management and profitability of listed manufacturing firms in Ghana. *International journal of productivity and performance management*, 70(7), 1751-1771.
- Anton, S. G., & Afloarei Nucu, A. E. (2020). The impact of working capital management on firm profitability: Empirical evidence from the Polish listed firms. *Journal of risk and financial management*, 14(1), 9.
- Chen, X., Cho, Y. H., Dou, Y., & Lev, B. (2022). Predicting future earnings changes using machine learning and detailed financial data. *Journal of Accounting Research*, 60(2), 467-515.
- Çanakçıoğlu, M., & Ersan, O. (2020). İşletme sermayesi yönetiminin firma performansı üzerindeki etkisi: Çimento şirketleri üzerine bir araştırma. *İşletme Araştırmaları Dergisi*, 12(3), 2749-2763.
- Çerçel, Ö. N., & Sökmen, A. G. (2019). Çalışma sermayesi yönetiminin firma karlılığı üzerindeki etkisi: BİST'te işlem gören metal eşya, makine ve gereç yapım sektörü üzerinde bir araştırma. *Çağ Üniversitesi Sosyal Bilimler Dergisi*, 16(2), 35-42.

- Dulyanti, U. (2024). The effect of total debt and net working capital on net profit. *Journal of Economic Management and Accounting (JEMA)*, 2(2), 311-322.
- Elend, L., Tideman, S. A., Lopatta, K., & Kramer, O. (2020). Earnings prediction with deep learning. In A. Appice, G. Tsoumakas, Y. Manolopoulos, & S. Matwin (Eds.), *Discovery science (Lecture Notes in Computer Science, Vol. 12325, pp. 267–274)*.
- Erbul, M., & Özdemir, F. S. (2021). Çalışma sermayesi yönetiminin firma performansı üzerindeki etkisi: Borsa İstanbul Yıldız Endeksinde bir uygulama. *Ömer Halisdemir Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 14(1), 335-348.
- Eskin, İ., & Güvemli, B. (2020). Çalışma sermayesi yönetiminin kârlılığa etkisi: Borsa İstanbul 50 Endeksi örneği. *Muhasebe ve Finansman Dergisi*, (85), 65-76.
- Gulo, M. K. P., Marshanda, M., Rahman, F. N., Lestari, I., & Azzahra, A. S. (2025). The effect of working capital and liquidity on the profitability of companies in the infrastructure sector that are listed on the BEI in the period 2020–2023. *International Journal of Economic Research and Financial Accounting*, 3(2), 626–636.
- Güngör, H. Y. (2022). Çalışma sermayesi yönetiminin firma finansal performansına etkisi: Havacılık sektörüne yönelik bir çalışma. *Ömer Halisdemir Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 15(4), 866-878.
- Huynh, T. X. T., Nguyen, T. T. H., & Nguyen, C. V. (2025). The impact of working capital management on the financial performance of listed enterprises: an empirical evidence from Vietnam. *Cogent Business & Management*, 12(1), 2473033.
- Islıcık, S., & Koçyiğit, S. Ç. (2021). Çalışma sermayesi ve karlılık ilişkisi: kamu hastane işletmelerine yönelik bir uygulama. *Uluslararası Sağlık Yönetimi ve Stratejileri Araştırma Dergisi*, 7(1), 156-166.
- Kiyamaz, H., Haque, S., & Choudhury, A. A. (2024). Working capital management and firm performance: A comparative analysis of developed and emerging economies. *Borsa Istanbul Review*, 24(3), 634-642.
- Kusuma, H., & Bachtiar, A. D. (2018). Working capital management and corporate performance: Evidence from Indonesia. *Journal of management and business administration. Central Europe*, 26(2), 76-88.
- Lukic, R. (2023). Influence of net working capital on trade profitability in Serbia. *European Journal of Interdisciplinary Studies*, 15(1), 48-67.

- Nguyen, A. H., Pham, H. T., & Nguyen, H. T. (2020). Impact of working capital management on firm's profitability: Empirical evidence from Vietnam. *Journal of Asian Finance, Economics and Business*, 7(3), 115-125.
- Putri, D. R., Isnurhadi, I., Widiyanti, M., & Adam, M. (2022). The influence of net working capital and capital structure on profitability in manufacturing companies in the consumer goods industry sector listed on the Indonesia stock exchange. *International Journal of Business, Economics and Management*, 5(4), 446-452.
- Rokayah, S. ve Rifa, A. A. (2024). The influence of working capital turnover and net profit margin (NPM) on return on asset (ROA) at pt indofood sukses makmur tbk (Case study listed on the Indonesia Stock Exchange for the 2015-2022 period). *Formosa Journal of Social Sciences (FJSS)*, 3(2), 211-232.
- Saidu, I. H., Usman, A. Y. U., & Ahmed, A. U. (2025). Working capital management and financial performance of listed industrial goods firms in Nigeria. *International Journal of Accounting, Management and Economic Review*, 1(2), 12-24.
- Serinoğlu, S., & Güçlü, F. (2023). Çalışma sermayesi yönetiminin firma kârlılığına etkisi: BİST ana metal sanayi sektörü örneği. *Uluslararası Finansal Ekonomi ve Bankacılık Uygulamaları Dergisi*, 4(2), 15-33.
- Susena, K. C., Hidayah, N. R., & Tarigan, H. P. (2025). Analysis of working capital management on liquidity and financial performance of manufacturing companies. *Journal of Management, Economic, and Accounting*, 4(1), 183-188.
- Topak, Ü. M. S. (2018). Çalışma sermayesi yönetiminin karlılığa etkisi: BİST ticaret endeksi üzerine bir araştırma. *Mali Çözüm Dergisi*, 28, 71-93.
- Turan, S., & Bilgin, R. (2021). Türkiye'deki halka açık firmaların net işletme sermayesi yönetiminin firma değerine etkisi. *Yönetim Bilimleri Dergisi*, 19(40), 437-458.
- Tutcu, B., Kayakuş, M., Terzioğlu, M., Ünal Uyar, G. F., Talaş, H., & Yetiz, F. (2024). Predicting Financial Performance in the IT Industry with Machine Learning: ROA and ROE Analysis. *Applied Sciences*, 14(17), 7459.
- Wassie, F. A. (2021). Working capital management and its impact on firms' performance: An empirical analysis on Ethiopian exporters. *Education Research International*, 2021(1), 6681572.

Yıldırım, H. H., Rençber, Ö. F., & Yüksel Yıldırım, C. (2024). Ranking the determinants of financial performance using machine learning methods: an application to BIST energy companies. *Mathematical Modelling and Numerical Simulation With Applications*, 4(5-Special Issue: ICAME'24), 165-186.