

Gizli Markov Modeli ile Muhasebe Perspektifinden Nakit Riski Analizi: BIST Tekstil, Giyim Eşyası ve Deri Sektöründe Bir İnceleme

Murat KURLAR¹

Başvuru Tarihi/Submitted: 13.09.2024 Kabul Tarihi/Accepted: 22.08.2025

Makale Türü/Article Type: Araştırma Makalesi/Research Article

Öz

Bu çalışmada, Borsa İstanbul'da (BIST) Tekstil, Hazır Giyim ve Deri sektöründe faaliyet gösteren şirketlerin 2021-2023 yıllarını kapsayan dönemine ait bağımsız denetim raporlarında yer alan nakit akış tablosu verileri esas alınarak, kurumsal düzeyde nakit riski dinamiklerinin incelenmesi amaçlanmaktadır. Bu doğrultuda, gizli durumların zaman serisi içerisindeki geçişlerini modellemek üzere Gizli Markov Modeli (GMM) kullanılmış; elde edilen çıktılar ise benzer nakit risk profillerine sahip şirket gruplarını belirlemek amacıyla K-Means kümeleme algoritmasıyla analiz edilmiştir. Çalışmada, literatürde ilk kez kullanılan "gizli (potansiyel) nakit sıkıntısı" kavramına yer verilmiştir. Çalışma, şirketlerin nakit akış risklerini bu yeni kavram çerçevesinde analiz ederek, finansal performanslarının derinlemesine incelenmesini kapsamaktadır. Çalışma, 2021-2023 yıllarını kapsayan dönemde şirketlerin nakit akış risklerine göre sınıflandırılması bazı şirketlerin risk seviyelerinde değişim gösterdiğini ortaya koymaktadır. Analiz sonucunda, 2021 yılında nakit riskinin olmadığı sınıfta ATEKS, ARSAN, BRKO, DAGI gibi birçok şirketin, yüksek derece nakit riski bulunan sınıfta BLCYT, BOSSA, DERİM gibi şirketlerin yer aldığı tespit edilmiştir. 2022 yılında DERİM ve ISSEN, nakit riskinin olmadığı sınıfa geçerken, YATAS ve KORDS daha yüksek risk sınıfına kaymıştır. 2023 yılında ise BLCYT, BOSSA, DERİM gibi önceden yüksek riskli olan bazı şirketler, nakit riskinin olmadığı sınıfta yer aldığı belirlenmiştir.

Anahtar Kelimeler: Nakit akışı analizi, Gizli Markov Modeli, gizli (potansiyel) nakit riski, nakit akış tablosu

JEL Kodu: M40, M41, M49

¹Mersin Üniversitesi, Yönetim Bilişim Sistemleri, Erdemli UTİYO, Dr. Öğr. Üyesi, muratkurtlar@mersin.edu.tr, ORCID: 0000-0002-3266-275X

² Bu çalışmada 'gizli (potansiyel) nakit riski' terimi, şirketlerin finansal tablolarında fark edilmeyen ancak ortaya çıkma ihtimali bulunan nakit sıkışıklığı riskini ifade etmektedir. Metinde eş anlamlı olarak kullanılan 'gizli nakit sıkıntısı' ifadesi de aynı anlama gelmektedir. Bu çalışmada tutarlılık adına gizli nakit riski ifadesi kullanılmıştır

Cash Risk Analysis from Accounting Perspective with Hidden Markov Model: A Study in BIST Textile, Wearing Apparel and Leather Sector

Abstract

In this study, Hidden Markov Model (HMM) and K-Means cluster analysis are applied to analyze cash risk using cash flow statement data of companies in Borsa Istanbul (BIST) Textile, Wearing Apparel and Leather sector for the years 2021-2023. The aim of the GMM model is to analyze the variability in cash flows of companies and estimate possible cash shortages. In addition, companies are divided into three classes according to cash flows provided by operating, investment and financing activities using K-Means cluster analysis and the differences between these classes are examined. The study includes the concept of "hidden (potential) cash risk", which is used for the first time in the literature. This concept is used to define situations where companies carry hidden (potential) risks in their cash flows without experiencing any externally visible financial problems. The study analyzes the cash flow risks of companies within the framework of this new concept and provides an in-depth examination of their financial performance. The study reveals that the classification of companies according to their cash flow risks in the period covering the years 2021-2023 shows that some companies have changed in their risk levels. As a result of the analysis, it was determined that many companies such as ATEKS, ARSAN, BRKO, DAGI have in the class with no cash risk in 2021, while companies such as BLCYT, BOSSA, DERIM have in the class with high cash risk. In 2022, DERIM and ISSEN moved to the class with no cash risk, while YATAS and KORDS shifted to a higher risk class. In 2023, some previously high-risk companies such as BLCYT, BOSSA, DERIM have been determined to be in the class with no cash risk.

Keywords: Cash flow analysis, Hidden Markov Model, hidden (potential) cash risk, cash flow statement

JEL Code: M40, M41, M49

Giriş

Tekstil, hazır giyim ve deri gibi ekonomik dalgalanmalara duyarlı sektörlerde likidite riskinin yönetimi son derece önemli olup bu gibi sektörlerde faaliyet gösteren şirketlerin finansal istikrarı ve operasyonel sürekliliği etkileyebilecek nakit akışlarını öngörebilmeleri gerekmektedir. Bu bağlamda likidite riskinin değerlendirilmesi için finansal verilerin detaylı bir şekilde analiz edilmesinde muhasebe bakış açısı önemlidir. Şirketlerin nakit giriş ve çıkışlarını sistematik biçimde raporlayan nakit akış tablosu da, bu analiz sürecinin temel araçlarından biridir. Nakit akış tablosu, yatırımcılara, alacaklılara ve diğer ilişkili taraflara şirketlerin nakit yönetimi ve ödeme gücü hakkında kapsamlı bilgi sunmasından dolayı likidite riskinin doğru şekilde değerlendirilmesine yardımcı olmaktadır.

Şirketlerin finansal anlamda başarısı veya başarısızlığı, ürettiği nakit miktarına bağlıdır. Bu tablo, şirketlerin likidite pozisyonunu göstermekte ve kısa vadeli finansal planlama sürecinde alınacak kararlarda yönetime yardımcı olmayı hedeflemektedir. Ayrıca yönetimin kısa vadeli yükümlülüklerini yerine getirme yeteneğinin değerlendirilmesinde de faydalıdır (Motlagh, 2013, s. 109-110). Nakit akış açığı, şirketlerin finansal sıkıntılarına neden olabilecek kritik bir durum olup şirketlerin alacakları finansman kararları açısından oldukça önemlidir. Şirketler, temerrüde düşme riskini değerlendirirken nakit akışının alacaklılara yapılan ödemeleri karşılama kapasitesini yetersiz bulabilirler. Nakit açığı, şirketlerin mevcut nakit akışlarının yükümlülüklerini yerine getirmede yetersiz kalması durumunu ifade etmektedir. Dolayısıyla borç ödemelerinin zamanında gerçekleştirilmesinde zorluklara yol açabilir. Şirketlerin finansal performansının ve borç ödeme yeteneklerinin analiz edilmesinde nakit akışının etkin bir şekilde yönetilmesi gerekmektedir (Uhrig-Homburg, 2005, s. 1510). Nakit akışlarında beklenmedik olumsuz değişiklikler ya da şirketlerin sürekli olarak işletme faaliyetlerinden nakit akışı üretememesi, şirketlerin faaliyetlerini yerine getirebilmesi ve büyüebilmesi için ihtiyaç duydukları nakit akışını sağlamasında yetersiz kalmalarına yol açabilir (Harris ve Roark, 2019, s. 393). Nakit akışlarında yaşanan dalgalanmalar, mevcut dönemde yüksek finansman maliyetleriyle karşı karşıya olan şirketlerin yatırım kararlarını ertelerken, beklenen asgari getiri eşliğini de yükseltmektedir. Buna karşın, finansman sıkıntısı yaşamayan ancak yatırımı ertelemesi durumunda gelecekte bu riskle karşılaşabilecek şirketler açısından yatırımın geciktirilmesi rasyonel olmayabilir; bu durum, dalgalanmanın aşırı düzeyde olmadığı koşullarda geçerliliğini korur. Bu şirketler, nakit akışlarındaki artan dalgalanmalara bağlı olarak gelecekte ortaya çıkabilecek finansman maliyetlerinin farkına varabilir ve bu maliyetlerden kaçınmak amacıyla yatırımlarını ertelemek yerine bugünden gerçekleştirmeyi tercih edebilirler. (Hirth ve Viswanatha, 2011, s. 1497).

Bu çalışmada, Gizli Markov Modeli (GMM) aracılığıyla nakit riskinin analiz edilmesinde muhasebe odaklı bir yaklaşım kullanılmaktadır. Bu çalışmada, BIST Tekstil, Hazır Giyim ve Deri sektöründe faaliyet gösteren şirketlerin 2021-2023 yıllarını kapsayan döneme ilişkin bağımsız denetim raporlarında yer alan nakit akış tabloları incelenerek potansiyel nakit sıkıntılarının GMM ile ortaya çıkarılması amaçlanmaktadır. Bu amaç doğrultusunda şirketlerin nakit yönetimlerine yönelik stratejilerinin belirlenmesi ile şirket içi ve dışı paydaşlara bu konu ile ilgili bilgiler sunulması sağlanabilecektir. Geleneksel nakit akış tabloları, şirketlerin finansal performansı hakkında temel bilgiler sunmaktadır. Ancak, bu tablolar bazen şirketlerin karşılaşabileceği gizli nakit sıkıntılarını göz ardı edebilir. Bu çalışmada, geleneksel nakit akış analizlerinin ötesine geçerek, gizli nakit sıkıntısı kavramı tanımlanmakta ve bu sıkıntıların belirlenmesi için GMM önerilmektedir. Böylelikle, şirketlerin uzun vadeli finansal performansının daha doğru bir şekilde değerlendirilmesi amaçlanmaktadır. Bu çalışma, yatırımcılar ve finansal analistler için daha kapsamlı bir finansal değerlendirme aracı sunmaktadır. Gizli (Potansiyel) nakit riski analizi, şirketlerin finansal risklerini daha iyi yönetmelerine ve uzun vadeli stratejik kararlar almalarına yardımcı olabilir.

Son yıllardaki istihdam ve şirket sayısı verileri, Türkiye’de tekstil, hazır giyim ve deri sektörünün makroekonomik dalgalanmalara karşı yüksek derecede kırılgan bir yapıya sahip olduğunu göstermektedir. Pandemi sonrası toparlanma sürecinde sektör istihdamı 2021’de yaklaşık 1,17 milyon kişiye, 2022’de ise 1,22 milyon kişiye kadar yükselerek büyüme eğilimi sergilemiştir. Ancak 2023 yılı itibarıyla döviz kurlarındaki volatilité, enerji ve girdi maliyetlerinde yaşanan artış ve işgücü teminindeki güçlükler nedeniyle sektörde keskin bir daralma gözlenmiştir. 2023 yılı sonunda toplam istihdam 1.025.000 seviyesine gerilemiştir (SGK; İHKİB, 2025). Benzer şekilde, 2008-09 küresel finansal krizi de dünya genelinde hazır giyim sanayisini etkilemiş; çok sayıda fabrikanın kapanmasına ve işsizliğin keskin

biçimde artmasına neden olmuştur (World Bank, 2010). Bu veriler, tekstil, konfeksiyon ve deri sektörlerinin ekonomik konjonktürel dalgalanmalara karşı duyarlı olduğunu ortaya koymaktadır.

Literatür Taraması

GMM, finansal zaman serilerinin analizi, döviz kuru tahminleri, borsa endeksi hareketlerinin öngörülmesi ve hisse senedi fiyatlarının tahmini gibi çeşitli alanlarda yaygın olarak kullanılmaktadır. GMM, özellikle ekonomik ve finansal göstergelerin dinamik davranışlarını modellemek ve karmaşık veri setlerinde gizli kalmış yapıların ortaya çıkarılması amacıyla tercih edilmektedir. Literatürde, GMM'nin nakit akış tablolarında yer alan hesap kalemlerine uygulanarak bu kalemlere ilişkin gizli durumların ortaya çıkarılmasına yönelik çalışmalara rastlanmamıştır. Bu çalışma, GMM'ni kullanarak nakit akış tablolarının analizine odaklanmakta ve bu yönüyle alandaki araştırmalara yenilikçi bir katkı sunmaktadır.

Şirketlerin finansal sürdürülebilirliğini sağlamada yalnızca tahminleme odaklı istatistiksel modeller değil aynı zamanda kurumsal nakit yönetimi uygulamaları ve likidite stratejileri de belirleyici rol oynamaktadır. Bu bağlamda literatürde, şirketlerin makroekonomik belirsizlik ortamlarında ihtiyatlı davranarak gelecekte oluşabilecek nakit akışı riskine karşı yüksek düzeyde nakit rezervi tutmaya yöneldikleri ortaya koyulmuştur (Laghari vd., 2022, s. 14). Bununla birlikte, likidite yönetiminin kurumsal yönetim ilkeleriyle uyumlu şekilde yapılandırılması, uzun vadeli finansal istikrar açısından kritik bir unsur olarak değerlendirilmektedir. Adele ve Irechukwu (2024), etkin nakit politikalarının sadece kriz dönemlerinde değil sürdürülebilir büyüme hedefleri çerçevesinde de önemli bir etken olduğunu vurgulamaktadır. Benzer biçimde, Ki ve Adhikari (2022), yüksek ekonomik oynaklık dönemlerinde şirketlerin likidite pozisyonlarını genişleterek kendilerini potansiyel şoklara karşı koruma refleksi gösterdiklerini ampirik bulgularla ortaya koymuştur. Bu çalışmalar, işletmelerin nakit akışı üzerinde oluşabilecek ani riskleri yalnızca tespit etmekle kalmayıp, bu riskleri stratejik yönetim politikaları aracılığıyla önleyebilmelerinin, finansal başarının sürekliliği ve faaliyetlerin sürdürülebilmesi açısından son derece önemli olduğunu ortaya koymaktadır.

Can ve Öz (2009) çalışmasında, Amerikan Doları'nın gelecekteki değerlerini tahmin etmek amacıyla GMM kullanılmaktadır. Bu modelin, 1992-2007 yılları arasında Türkiye'deki dolar kuru ve ekonomik verilerle eğitildiği ve 2008 yılı için yapılan tahminlerin döviz kuru değişimlerinde yüksek bir tutarlılık gösterdiği vurgulanmaktadır. Çalışmada, faiz oranları ve ödemeler dengesi verileri gibi önemli ekonomik faktörlerin döviz kuru tahminlerinde etkili olduğu ve GMM'nin, döviz kuru değişimlerini ve bu değişimleri etkileyen faktörleri belirlemede etkili bir yöntem olduğu ifade edilmektedir. Dağlıoğlu ve Kırıl (2018) tarafından yapılan çalışmada, GMM ile BIST 100 endeksinin değişim oranlarının tahmini yapılmakta ve içsel faktörler olarak döviz kuru, faiz oranı ve para arzı dikkate alınmaktadır. 2013 yılı Temmuz ve 2016 yılı Ekim ayları için yapılan tahminlerde İleri-Geri Yön ve Viterbi algoritmalarıyla elde edilen sonuçların yaklaşık değerlerle örtüştüğü ifade edilmektedir. Bu çalışmada, GMM'nin finansal ve yatırım kararlarında bilgilendirici bir araç olduğu vurgulanmaktadır. İlarıslan (2014), Markov zincirlerinin tahmin problemlerindeki matematiksel altyapısını detaylı bir şekilde açıklamakta ve İMKB Bankacılık 10 endeksindeki on bankanın hisse senetleri üzerinde bir uygulama yapmaktadır. Çalışmada, TSKB hariç diğer dokuz bankanın hisse senedi fiyatlarının bir gün sonraki hareketlerinin başarılı bir şekilde tahmin edildiği ifade edilmektedir. Altan ve Demirci (2022) çalışması, zaman serilerinde yapısal kırılmaların ve rejim geçişlerinin doğru biçimde tespitiyle finansal öngörü performansının nasıl geliştirilebileceğini ortaya koymaktadır. Bu bağlamda çalışmada kullanılan yapay sinir ağları ve ileri seviye makine öğrenmesi yöntemleri, verideki gizli desenleri ve doğrusal olmayan ilişkileri modelleme kapasitesi açısından Gizli Markov Modelleri (GMM) ile kavramsal bir yakınlık taşımaktadır. Her iki yaklaşım da yalnızca geçmiş verilerin değil, aynı zamanda bu verilerde gözlemlenemeyen durumların (rejim değişimleri gibi) modellenmesini esas alır. Dolayısıyla bu çalışmada kullanılan GMM modelinin finansal zaman serilerinde yapısal dinamikleri analiz etme amacına yöntemsel bir zemin sunmaktadır.

Vargeloğlu ve Özdemir (2023) çalışmasında, altın fiyatlarındaki yüzdesel değişim oranlarının ve bu değişimleri etkileyen faktörlerin, GMM kullanılarak tahmin edildiği ve 2013-2023 yılları arasındaki altın, dolar, faiz ve enflasyon verileri üzerinde analiz gerçekleştirildiği belirtilmektedir. Çalışmada, altın fiyatlarındaki yüzdesel değişimin %0,5'ten büyük olma olasılığının %23,6 olarak tespit edildiği ve elde

edilen sonuçların gerçek verilerle yüksek doğruluk oranlarına sahip olduğu ifade edilmektedir. Giampieri, Davis ve Crowder (2005) tarafından yapılan çalışmada, bir tahvil portföyündeki temerrüt olayları basit bir Gizli Markov süreci olarak modellenmektedir. Gizli değişkenin, belirli bir sektör ve bölgedeki tüm tahviller için ortak olduğu varsayılan risk durumunu temsil ettiği ifade edilmektedir. Çalışmada, Standard & Poor's tarafından sağlanan geniş bir veri tabanından alınan gerçek bir senaryo incelenerek model parametrelerinin tahminleri elde edilmektedir. Rao ve Hong (2010) tarafından yapılan çalışmada, hisse senedi fiyatlarının öngörülmesinde hem GMM hem de Destek Vektör Makineleri (DVM) kullanılmıştır. Araştırmada DVM'nin yaklaşık %70 doğruluk oranına ulaştığı belirtilmiştir; ancak bu sonuç, GMM ile elde edilen bulguların tamamlayıcı etkisini göz ardı etmemektedir. Nitekim GMM, zaman serisinde rejim geçişlerini belirleyerek veri üzerindeki yapısal değişimleri modellemiş ve bu geçişler DVM'nin sınıflandırma başarısını artırmada ön koşul verisi olarak değerlendirilmiştir. Bu bağlamda GMM'nin tek başına doğruluk oranı sunulmasa da, modelleme sürecindeki temel rolü, karma modelin tahmin gücünü yükselten bileşenlerden biri olarak kritik önem taşımaktadır. Blümke (2022), muhasebe standartlarının, finansal kuruluşlardan kredi zarar karşılıklarını hesaplarken birden fazla makroekonomik senaryoyu dikkate almalarını ve tahmin etmelerini gerektirdiği ifade edilmektedir. Kredi zarar karşılıklarını, finansal kuruluşları olası zararlar karşısında koruduğu ancak senaryo sayısını objektif bir şekilde belirlemenin ve senaryo olasılıklarını tahmin etmenin çözülmemiş bir sorun olduğu belirtilmektedir. Çalışmada bu sorunun GMM çerçevesine yerleştirildiğinde doğal bir yanıt elde edildiğini göstermektedir. Önerilen GMM ile senaryo olasılıklarının objektif bir şekilde tahmin edilebilir hale geldiği ve uzman görüşüne dayalı olarak belirlenmesine gerek kalmadığı belirtilmektedir. Bu çalışmalar, finansal piyasalarda ve makroekonomik göstergelerde tahmin yapma konusunda GMM'nin etkinliğini ortaya koymaktadır. Bu araştırmalar, GMM'nin hem finansal piyasaların dinamiklerini anlamada hem de yatırım kararlarını desteklemede güçlü bir araç olduğunu ortaya koymaktadır. Özellikle döviz kuru, faiz oranları, enflasyon gibi makroekonomik faktörlerin finansal göstergeler üzerindeki etkilerini modelleyerek doğru tahminlerde bulunma potansiyeli sunan GMM, finansal analizlerde önemli bir yer tutmaktadır.

Nakit akış tablosu

Finansal raporlar, mevcut ve potansiyel yatırımcılara, alacaklılara ve diğer kullanıcılara alacakları kararlarda yardımcı olacak finansal bilgileri sağlamaktadır (Kwok, 2002:348). Gelir tablosu ve bilançonun aksine, nakit akış tablosu yalnızca nakit esasına göre düzenlenmekte ve şirketlerin likiditesine ve finansal yönetimine odaklanmaktadır. Bu nedenle, finansal analistler, şirketlerin değerlendirilmesinde nakit akış bilgilerine daha fazla güvenmektedir ve nakit akış tablosu onların önemli bir bilgi kaynağıdır (Steyn ve Hamman, 2003, s. 182). Şirketlerin faaliyet türlerine göre düzenlenen nakit akış tablosu, likidite durumu, karlılık seviyesi ve değer yaratma yeteneği hakkında kapsamlı bilgiler sunan kritik bir mali tablo niteliğindedir (Erol, 1988, s. 37). Nakit akış tablosunun birincil amacı, bir şirketin bir dönem içindeki nakit tahsilatları ve nakit ödemeleri hakkında bilgi sağlamaktır. Nakit akışları, işletme, yatırım ve finansman faaliyetleri olarak kategorilere ayrılmaktadır (Gaughan, Fuentes ve Bonanomi, 1995, s. 14).

Nakit akış tablosu, bir muhasebe döneminde farklı ticari faaliyetlerden ve özellikle işletme faaliyetlerinden, yatırım faaliyetlerinden ve finansman faaliyetlerinden kaynaklanan nakit akışını açıklamaktadır. Türkiye Muhasebe Standardı (TMS) 7'nin 13. maddesi uyarınca, işletme faaliyetlerinden sağlanan nakit akışlarının düzeyi; borç geri ödemelerinin gerçekleştirilmesi, temettü ödemelerinin dış kaynaklara başvurulmadan yapılabilmesi, yeni yatırımlar için kaynak yaratılabilmesi ve genel faaliyet kapasitesinin sürdürülebilirliği gibi açılardan şirketin finansal sağlığının önemli bir göstergesi olarak kabul edilmektedir. İşletme faaliyetlerinden kaynaklanan nakit akışları, yatırım veya finansman faaliyetlerinden akış olarak sınıflandırılmayan tüm nakit girişlerini ve nakit çıkışlarını kapsamaktadır. Yatırım faaliyetlerine ilişkin nakit akışları ise TMS 7 madde 16 kapsamında; uzun vadeli finansal yatırımların, maddi ve maddi olmayan duran varlıkların, iştirak ve bağlı ortaklık yatırımlarının alım ve satımı gibi kalemleri içermekte, ayrıca iş ortaklıklarından elde edilen temettü ve finansal getiriler de bu kapsamda değerlendirilmektedir. Bu bölümde yalnızca nakit hareketleri dikkate alınmakta, banka kredisi ya da finansal kiralama yoluyla gerçekleştirilen yatırımlar gibi nakit dışı işlemler ise nakit akış tablosuna yansıtılmamaktadır. Öte yandan, forward, opsiyon ve swap gibi türev ürünlerle ilgili nakit hareketleri de kısa vadeli yatırımlarla veya finansman faaliyetleriyle doğrudan bağlantılı değilse yatırım faaliyetleri

içinde raporlanmaktadır. Finansman faaliyetleri ise TMS 7 madde 6'ya göre, işletmenin öz kaynak veya yabancı kaynak yapısında değişikliğe yol açan işlemleri kapsamaktadır. Bu tür faaliyetlerden doğan nakit akışlarının ayrı şekilde raporlanması, işletmeye finansman sağlayan yatırımcı ve kredi verenlerin gelecekteki nakit akışlarını değerlendirmesi açısından büyük önem taşımaktadır. Genellikle yeni hisse ihracından elde edilen gelirleri, hissedarlara yapılan temettü ödemelerini, tahvil, senet vb. finansal araçların ihracından elde edilen nakitleri ve bunlar için yapılan ödemeleri kapsamaktadır (Kousenidis, 2006, s. 646). Yatırım ve finansman faaliyetlerinden sağlanan nakit akışları, bir şirketin varlık ve finansman yapısındaki değişimlerin neden ve nasıl gerçekleştiğini açıklamada önemli bir rol oynar. İşletme faaliyetlerinden sağlanan nakit akışının kısa vadeli borçlara oranı ve toplam borçlara oranı gibi nakit akışı oranları, kısa ve uzun vadeli likiditenin değerlendirilmesinde önemlidir (Whitfield, 2004, s. 16).

Muhasebe bilgileri, dönem içindeki nakit akışlarına ilişkin gerçeğe uygun verilerden elde edilen doğrudan nakit akış tablosu ile daha etkili hale getirilebilir. Bu tabloya dayanarak, gelir tablosu üzerinden hesaplanan oranlarla karşılaştırılabilir ve seçilen finansal raporlama çerçevesinde yapılan varsayımlar üzerinde bir kontrol mekanizması olarak işlev gören bir nakit akış oranları sistemi oluşturulabilir (Duhovnik, 2008, s. 124).

Gizli Markov Modeli (GMM)

GMM, konuşma tanıma, el yazısı analizi ve biyoinformatik gibi örüntü tanıma uygulamalarında yaygın olarak kullanılan istatistiksel bir modeldir. Bu modelde, kullanıcının öncelikle her gözlemlenemeyen durumun arkasında kaç farklı gizli durumun olabileceğine karar verilmesi gerekir. Ayrıca, bu gizli durumların her birinin başlangıçta ne kadar olası olduğunu belirlemek de önemlidir. Modeli oluşturduktan sonra GMM modeli, gözlemlenemeyen her durumla ilişkili olası gözlem sonuçları üzerinde eğitilmelidir. Bu şekilde, model, gözlemlenen veriler üzerinden gizli durumları ve bunların olasılıklarını tahmin edebilir (Rao ve Hong, 2010, s. 5). GMM, sınırlı bir öğrenme kapasitesine sahip stokastik (rastgele) bir sistem olup ve iki temel özelliğe dayanmaktadır. İlk olarak, stokastik süreç, sınırlı sayıda durumdan oluşmaktadır ve her durum, bir olasılık dağılım fonksiyonuna bağlıdır. Farklı durumlar arasındaki geçişler, belirli olasılıklar ile ifade edilir ve bu olasılıklar "geçiş olasılıkları" olarak ifade edilmektedir. İkinci olarak, bu stokastik süreçte, bazı durumlar gözlemci tarafından doğrudan görülememekte, yani "gizlidir," ancak bu gizli durumlar ortaya çıktıkça dolaylı olarak gözlemlenebilir hale gelmektedir. Bu nedenle model, "Gizli Markov Modeli" olarak adlandırılmaktadır. GMM, durumlar, semboller, geçiş olasılıkları, emisyon olasılıkları ve başlangıç olasılıklarının bir araya getirilmesiyle oluşturulmaktadır (Hanif, Sami, Hyder ve Ch, 2017, s. 196).

GMM'de, gizli ve gözlemlenebilir olmak üzere iki durum söz konusudur. Her iki durumun temel süreçleri Markov zincirinin süreçlerini oluşturmaktadır. Gizli durum q_t zamanında gözlemlenemez ve

$$S = \{S_1, S_2, \dots, S_N\}$$

kümesinden herhangi bir elemanı alabilir; burada $N \geq 1$ verilen bir tam sayıdır. Gözlemlenebilir durum O_t zamanında gözlemlenebilir ve

$$V = \{V_1, V_2, \dots, V_M\}$$

kümesindeki herhangi bir elemanı alabilir; burada $M \geq 1$ verilen bir tam sayıdır. Gizli durumlar arasındaki geçiş olasılıkları şu matris ile tanımlanır:

$$A = \{a_{ij}\}, \quad a_{ij} = P(q_{t+1} = S_j \mid q_t = S_i), \quad 1 \leq i, j \leq N.$$

Her bir gizli durumdan gözlemlenebilir çıktılara geçiş olasılıkları ise şu dağılım ile verilir:

$$B = \{b_i(k)\}, \quad b_i(k) = P(O_t = V_k \mid q_t = S_i), \quad 1 \leq i \leq N, \quad 1 \leq k \leq M.$$

Başlangıç durum olasılık dağılımı ise

$$\pi = \{\pi_i\}, \quad \pi_i = P(q_1 = S_i), \quad 1 \leq i \leq N$$

şeklindedir.

Dolayısıyla bir GMM modeli, gizli durumlar S , gözlemlenebilir durumlar V , geçiş olasılık matrisi A , gözlem olasılık dağılım matrisi B ve başlangıç dağılımı π ile tanımlanır (Tai, Ching ve Chan, 2009, s. 609–610).

K-means algoritması

Kümeleme, veri biliminde kullanılan bir modeldir. Aynı küme içindeki en büyük benzerlik ve farklı kümeler arasındaki en büyük farklılık ile karakterize edilen bir veri kümesinde küme yapısını bulmak için kullanılmaktadır (Sinaga ve Yang, 2020, s. 80716). Desen tanıma, görüntü işleme, makine öğrenimi ve istatistik gibi çok çeşitli alanlarda sıklıkla ortaya çıkan temel bir sorun kümeleme sorunudur. Esas olarak kümeleme sorunu, belirli bir veri kümesindeki homojen veri noktaları gruplarını bulma sorunu olarak tanımlanmaktadır. Bu grupların her biri bir küme olarak adlandırılmakta olup nesnelerin yoğunluğunun yerel olarak diğer bölgelere göre daha yüksek olduğu bir bölge olarak tanımlanmaktadır (Likas, Vlassis ve Verbeek, 2003, s. 451). K-means algoritması, belirli bir kriteri karşılamak için K bölümü bulmaya çalışmaktadır. İlk olarak, başlangıç küme odak noktalarını temsil edecek bazı noktalar seçilir; ikinci olarak, kalan örnek noktaları minimum mesafe kriterine göre odak noktalarında toplanır ve ardından başlangıç sınıflandırması elde edilir. Eğer sınıflandırma mantıksızsa, değiştirilir (her küme odak noktasını tekrar hesaplar) ve uygun bir sınıflandırma elde edene kadar tekrar tekrar yinelenir. K-means, bir tür küme algoritmasıdır ve kısalık, verimlilik ve hız avantajlarına sahiptir (Li ve Wu, 2012, s. 1105).

Gizli (potansiyel) nakit riski analizi

Gizli (potansiyel) nakit riski analizi, geleneksel nakit akış tablolarına kıyasla şirketlerin likidite yapısını daha kapsamlı ve dinamik bir şekilde değerlendirme imkânı sunmaktadır. Geleneksel tablolar, çoğunlukla belirli dönemlere ait işletme, yatırım ve finansman faaliyetlerinden kaynaklanan nakit giriş ve çıkışlarını statik biçimde sunar ve bu nedenle dönemsel dalgalanmaların veya yapısal risklerin uzun vadeli etkilerini yeterince yansıtamaz. Ancak GMM temelli gizli nakit riski analizi, zaman içerisinde ortaya çıkan istikrarsızlıkları ve geçici iyileşmeleri saptayarak, yüzeyde istikrarlı görünen şirketlerin altında yatan nakit sıkışıklığı risklerini görünür kılar. Bu yaklaşım, yalnızca hesaplama dayalı bir miktar analizi değil, aynı zamanda nakit akışlarının kaynağını, sürdürülebilirliğini ve dalgalanma yapısını dikkate alan nitelikli bir modellemeye dayanır. Bu sayede, tek seferlik nakit girişlerinin veya borçla finanse edilen geçici likidite fazlalarının yanıltıcı etkileri bertaraf edilerek, şirketlerin uzun vadeli ödeme gücüne ve finansal istikrarına dair daha doğru çıkarımlarda bulunulabilir. Sonuç olarak, gizli nakit riski analizi, geleneksel yöntemlerin ötesine geçerek şirketlerin stratejik finansal yönetimine ve yatırımcıların karar alma süreçlerine daha derinlikli bir perspektif kazandırmaktadır.

Yatırımcılar ve analistler, geleneksel nakit akış tablolarını incelerken bazı kritik unsurları gözden kaçırabilirler. Örneğin, şirketlerin dönemsel nakit akışları dikkat çekici olabilir. Bazı şirketler, belirli dönemlerde yüksek nakit akışı gösterirken, diğer dönemlerde ciddi nakit sıkıntısı yaşayabilir. Ancak, yalnızca yıllık veya çeyrek bazlı nakit akış tablolarına bakıldığında bu dönemsel dalgalanmalar göz ardı edilebilir. Ayrıca, tek seferlik gelirler veya kısa vadeli borçlanmalar, şirketin nakit akışını olumlu gösterebilir, ancak bu tür nakit akışlarının sürdürülebilirliği genellikle sorgulanmamaktadır. İşletme faaliyetlerinden elde edilen nakit akışı ile yatırım ve finansman faaliyetlerinden elde edilen nakit akışı arasındaki farklar da önemlidir. İşletme faaliyetlerinden gelen nakit akışı genellikle daha sağlıklı kabul edilir. Ancak, borçlanma ve finansman ihtiyaçları, şirketin borçlarını ödeme kapasitesi ve bu ihtiyaçların nasıl karşılanacağı, nakit akış tablosunda tam olarak yansıtılamayabilir. Ayrıca nakit akış tablosu genellikle uzun vadeli bir perspektif sağlar; bu nedenle, kısa vadeli likidite riskleri göz ardı edilebilir.

Yöntem

Bu çalışmada, Borsa İstanbul'da (BIST) işlem gören Tekstil, Hazır Giyim ve Deri sektöründeki şirketlerin 2021-2023 yıllarına ait nakit akış tablolarında yer alan finansal veriler kullanılmaktadır. Finansal veriler, www.kap.gov.tr internet adresinden elde edilmiştir. Tekstil, Hazır Giyim ve Deri sektöründe faaliyet gösteren toplam 27 şirket bulunmasına rağmen, çalışmada 26 şirketin verileri kullanılmıştır. İncelenen yıllarda, Artemis Halı (ARTMS) BIST'e kote olmadığından dolayı bu şirketin finansal verileri kullanılmamıştır. Bu çalışmada bağımsız denetim raporlarında yer alan nakit akış tablolarının kullanılmasının sebebi, denetimden geçmiş verilerin güvenilirlik, doğruluk ve karşılaştırılabilirlik açısından daha yüksek bir metodolojik standart sunmasıdır. Bağımsız denetimden geçmiş finansal tablolar, yönetimin finansal durumu gerçeğe uygun biçimde yansıtmaya yükümlülüğü çerçevesinde düzenlendiğinden, çalışmanın ampirik dayanaklarının olası muhasebe yanlışlıklarından arındırılmış olması sağlanmaktadır. Bu yaklaşım, verilerin hem tutarlılığını hem de şirketler arası karşılaştırılabilirliğini güçlendirmektedir (PwC, 2023). Ayrıca, Uluslararası Finansal Raporlama Standartları'na (UFRS) uygunluk taşıyan bu tablolar, farklı şirketlerin farklı raporlama alışkanlıklarından kaynaklanabilecek biçimsel ve içeriksel heterojenliği azaltarak analiz sürecinin yöntemsel bütünlüğünü artırmaktadır. Çoklu örneklem içeren bu tür çalışmalar açısından, veri kaynağının denetlenmiş ve standardize edilmiş olması, model çıktılarının bilimsel geçerliliği ve güvenilirliği açısından da kritik öneme sahiptir.

Veri seti, şirketlerin nakit akışlarını ve likidite riskini değerlendirmenin yanı sıra finansal performanslarını incelemek amacıyla detaylı bir şekilde düzenlenmiştir. Nakit akış tablosunda yer alan dönem net karı/zararı, amortisman ve itfa giderleri ile ilgili düzeltmeler, değer düşüklüğü (iptali) ile ilgili düzeltmeler, karşılıklar ile ilgili düzeltmeler, faiz gelirleri ve giderleri ile ilgili düzeltmeler, vergi geliri/gideri ile ilgili düzeltmeler, gerçeğe uygun değer kayıpları (kazançları) ile ilgili düzeltmeler, duran varlıkların elden çıkarılmasından kaynaklanan kayıplar (kazançlar) ile ilgili düzeltmeler, gerçekleşmemiş yabancı para finansal yatırımlarda artış/azalış, ticari alacaklardaki azalış (artış) ile ilgili düzeltmeler, faaliyetlerle ilgili diğer alacaklardaki azalış (artış) ile ilgili düzeltmeler, stoklardaki azalışlar (artışlar) ile ilgili düzeltmeler, peşin ödenmiş giderlerdeki azalış (artış), ticari borçlardaki artış (azalış) ile ilgili düzeltmeler, faaliyetlerle ilgili diğer borçlardaki artış (azalış) ile ilgili düzeltmeler, ertelenmiş gelirlerdeki artış (azalış), işletme sermayesinde gerçekleşen diğer artış (azalış) ile ilgili düzeltmeler, çalışanlara sağlanan faydalara ilişkin karşılıklar kapsamında yapılan ödemeler, maddi ve maddi olmayan duran varlıkların satışından kaynaklanan nakit girişleri, maddi ve maddi olmayan duran varlıkların alımından kaynaklanan nakit çıkışları, borçlanmadan kaynaklanan nakit girişleri, borç ödemelerine ilişkin nakit çıkışları, ödenen faizler, alınan faizler, yabancı para çevrim farklarının etkisinden önce nakit ve nakit benzerlerindeki net artış (azalış), dönem başı nakit mevcudu, dönem sonu nakit mevcudu değişkenleri veri seti olarak kullanılmıştır.

Analizde kullanılan modellerin kurulmasında Python programla dili kullanılmıştır. GMM kurulumu ve uygulama adımları Şekil 1'de yer almaktadır. Modelin kurulumu kapsamında ilk aşamada; dönem net kârı, amortisman giderleri, değer düşüklüğü zararları, karşılık giderleri, faiz ve vergi gelir/giderlerine ilişkin düzeltmeler, geçmiş yıl zararlarına yönelik düzeltmeler, duran varlık elden çıkışları ve gerçeğe uygun değer farkları gibi kalemler dikkate alınarak faaliyetlerden sağlanan net nakit akışı hesaplanmaktadır. Buna ek olarak, ticari ve diğer alacaklardaki, stoklardaki, peşin ödenen giderlerdeki, ticari borçlar ve diğer yükümlülüklerdeki değişimler de işletme sermayesi hareketlerini yansıtarak nakit akışına pozitif ya da negatif etkide bulunmaktadır. Ayrıca maddi ve maddi olmayan duran varlık alım/satımları, finansal yatırımlardaki değişimler, finansal borçlardan sağlanan veya yapılan ödemeler, ödenen/alınan faizler, yabancı para çevrim farkları ve dönem başı-sonu nakit dengeleri de analiz kapsamına alınmıştır. Bu kalemlerin her biri nakit girişi veya nakit çıkışı yaratan nitelikte olup, analize konu olan net nakit akışları, ilgili unsurların muhasebe ilkeleri çerçevesinde uygun biçimde toplanması veya çıkarılması yoluyla hesaplanmıştır. Dolayısıyla, veri ön işleme süreci yalnızca kalemlerin bir araya getirilmesi değil, aynı zamanda her bir bileşenin nakit üzerindeki etkisinin yönü ve büyüklüğü dikkate alınarak yapılandırılmasını da içermektedir. Eksik değerler ve aykırı veriler temizlenerek her bir şirketin finansal verileri dikkatlice gözden geçirilmiş olup modelleme için uygun özellikler belirlenmiştir. Bu aşamada, tüm finansal kalemler normalleştirilmiş ve ölçeklendirilmiştir. Finansal kalemlerin ölçeklendirilmesi, StandardScaler kullanılarak gerçekleştirilmiş, böylece modelin verileri daha iyi yorumlayabilmesi ve öğrenebilmesi sağlanmıştır. Bu ölçekleme, her bir değişkenin ortalamasını 0, standart sapmasını 1 olacak

şekilde dönüştürmektedir. Böylece model, değişkenler arasında büyüklük farklarından etkilenmeden doğru öğrenme sağlayabilmektedir. Hmmlern kütüphanesinde yer alan Expectation-Maximization (EM) algoritması kullanılmıştır. Bu algoritma, modelin geçiş ve emisyon olasılıklarını iteratif olarak güncelleyerek maksimum olasılık tahmini sağlamaktadır.

Bu çalışmada kullanılan GMM, aşağıdaki üç temel bileşenden oluşmaktadır:

Başlangıç durum vektörü:

$$\pi = \{\pi_1, \pi_2, \dots, \pi_N\} \text{ burada } \pi_i = P(q_1 = S_i), 1 \leq i \leq N$$

Durumlar arası geçiş olasılıkları matrisi:

$$A = \{a_{ij}\}, \text{ burada } a_{ij} = P(q_{t+1} = S_j | q_t = S_i), 1 \leq i, j \leq N$$

Gözlem olasılıkları dağılımı:

$$B = \{b_j(k)\}, \text{ burada } b_j(k) = P(O_t = V_k | q_t = S_j), 1 \leq j \leq N, 1 \leq k \leq M$$

Burada:

$q_t \in S = \{S_1, S_2, \dots, S_N\}$: t zamanında sistemin içinde bulunduğu gizli (gözlenemeyen) durumlar kümesini,

$O_t \in V = \{V_1, V_2, \dots, V_M\}$: t zamanında gözlemlenebilen çıktılar kümesini ifade etmektedir.

GMM'nin teorik altyapısı, Gaussian Mixture Model ile desteklenmektedir. GMM, verilerin birden fazla normal dağılımdan oluştuğunu varsayarak her bir gözlemi bu dağılımlardan birine atamaktadır. Modelde her bir gizli durum, ayrı bir Gauss dağılımı ile temsil edilmiş ve her bir şirketin finansal verileri, bu dağılımlar doğrultusunda sınıflandırılmıştır. Gaussian Mixture Model kullanımı sayesinde her şirketin yıllık finansal verileri, analiz edilerek nakit riski olup olmadığı belirlenmiştir. Dolayısıyla şirketlerin finansal performanslarındaki belirsizlik ve risk faktörleri matematiksel olarak ifade edilebilmiş ve risk seviyeleri daha hassas biçimde sınıflandırılmıştır. Uygulamada, S_1 nakit riskinin olmadığı durumu, S_2 ise nakit riskinin var olduğu durumu temsil etmektedir. Gözlemler (V), şirketlerin nakit akışı ve ilgili finansal göstergelerine karşılık gelmekte olup, modelin her bir gözlem için hangi gizli durumun olduğunu tespit etmesi amaçlanmaktadır.

GMM kurulumu için başlangıç olasılıkları ve durum geçişlerinin olasılıkları tahmin edilmiştir. GaussianHMM sınıfı kullanılarak model kurulmuş ve parametreler Expectation-Maximization (EM) algoritması ile tahmin edilmiştir. Modelin en uygun gizli durum sayısı Akaike Bilgi Kriteri (AIC) ve Bayes Bilgi Kriteri (BIC) karşılaştırması ile 2 olarak belirlenmiştir. Viterbi algoritması kullanılarak, her gözlem için en olası gizli durum sekansı elde edilmiştir. Bu sınıflandırma, her bir şirketin finansal verilerine bağlı olarak modelin iteratif öğrenme süreci sonucunda belirlenmiştir. GMM modelinin başlangıç olasılıkları, Hmmlern algoritması tarafından rastgele ancak sabit (random_state=42) bir başlangıç vektörü üzerinden oluşturulmuştur. Model eğitimi sürecinde bu başlangıç olasılıkları, EM algoritması ile güncellenmiş ve her bir gizli durumun gözlem dizilerinde görülme olasılığı istatistiksel olarak optimize edilmiştir. Başlangıç durum olasılıkları, modelin kararlılığı açısından kontrol edilmiş ve analiz sonuçlarının tutarlı olduğu gözlemlenmiştir.

Model, ölçeklendirilmiş veriler üzerinde 1000 iterasyon boyunca eğitilmiştir. Eğitim sürecinde, her bir veri noktası için olasılıksal olarak en iyi tahmin edilen gizli durumlar belirlenmiştir. Bu gizli durumlar, modelin zaman serisi verileri üzerinde öğrenme sürecini tamamlamasıyla elde edilmiştir ve her bir durum, belirli finansal risk seviyelerini temsil etmektedir. Eğitim tamamlandıktan sonra, her bir gözlem için gizli durumlar tahmin edilmiş ve veri setine eklenmiştir. Gizli durumlar basitçe 0 ve 1 olarak sınıflandırılmıştır: 0, nakit riskinin olmaması; 1, nakit riskinin olması. Ayrıca, nakit riskinin derecelendirilmesi 0 (nakit riskinin olmadığı), 1 (orta derece nakit riski bulunan) ve 2 (yüksek derece nakit riski bulunan) olarak belirlenmiştir. Kısacası, gizli durum sınıflaması model kaynaklı, risk derecesi ise yorumlayıcı sınıflamadır. Bu sınıflandırma, şirketlerin finansal verilerine göre olası risk düzeylerini belirlemeye yardımcı olmaktadır. Son adımda, her bir şirketin risk durumunu açıklamak için belirli finansal kalemlerin negatif veya pozitif etkileri dikkate alınmaktadır. Örneğin, nakit akışının negatif olması veya dönem net karının negatif olması gibi durumlar riskli kabul edilmiştir. Bu faktörlerin kombinasyonu, her bir şirket için

spesifik risk nedenlerini belirlemekte kullanılmıştır. Risk nedenleri, modelin belirlediği gizli durumlarla birlikte değerlendirilmiş ve veriye eklenmiştir. Bu çalışmada kullanılan GMM modeli, şirketlerin yıllık nakit akış tablosunun finansal verilerine dayanarak gizli durumları belirlemekte ve her bir şirketin nakit akışına dayalı finansal risk düzeylerini sınıflandırmaktadır. Modelin belirlediği risk nedenlerinin, şirketlerin finansal durumlarının daha derinlemesine anlaşılmasına katkıda bulunacağı düşünülmektedir.



Şekil 1. GMM iş akışı


Kaynak: Yazar tarafından oluşturulmuştur.

Bulgular ve Tartışma

Kümeleme analizinde, şirketlerin işletme faaliyetlerinden (CFOA), yatırım faaliyetlerinden (CFIA) ve finansman faaliyetlerinden (CFFA) elde edilen nakit akışları verileri kullanılarak K-Means algoritması ile üç ayrı küme oluşturulmaktadır. Her bir küme, benzer CFOA, CFIA ve CFFA değerlerine sahip şirketleri gruplamak amacıyla belirlenmiştir. K-Means algoritması, verileri önceden belirlenen üç kümede toplarken, kümelerin merkez noktalarını iteratif olarak güncellemekte ve her bir veri noktasını en yakın merkez noktaya atamaktadır. Analiz sonucunda, her küme için CFOA, CFIA ve CFFA değerlerinin ortalamaları hesaplanarak kümeler arası farklar incelenerek kümeleme başarısı değerlendirilmektedir. Son olarak, kümelenmiş veriler yıllara göre görselleştirilerek, şirketlerin farklı kümelerdeki dağılımları analiz edilmektedir. CFOA açısından yapılan analiz, şirketlerin nakit akışları üzerindeki risk seviyelerini değerlendirmek için kritik bir bakış açısı sunmaktadır. Şirketlerin nakit akışlarının sürdürülebilirliği ve finansal esneklikleri temelinde üç farklı küme (Cluster) altında sınıflandırılması Şekil 2'de ve Tablo 1'de yer almaktadır.

2021, 2022 ve 2023 yıllarına ait CFOA analizlerinde, nakit akış riskine göre şirketler üç farklı kümede sınıflandırılmıştır. 2021 yılında, "Nakit Riskinin Olmadığı" sınıfta (Cluster 0) yer alan şirketler ATEKS, ARSAN, BRKO, BRMEN, DAGI, DIRIT, ENSRI, HATEK, KRTEK, LUKSK, MEGAP, RODRG, ROYAL, RUBNS, SKTAS, SNPAM, SUNTK, YATAS ve YUNSA'dır. "Orta Derece Nakit Riski Bulunan" sınıfta (Cluster 1) ise sadece KORDS yer almıştır. "Yüksek Derece Nakit Riski Bulunan" sınıfta (Cluster 2) ise BLCYT, BOSSA, DERIM, DESA, ISSEN ve MNDRS bulunmaktadır. 2022 yılında, Cluster 0'a dâhil olan şirketler büyük ölçüde korunmuş olup, DERIM ve ISSEN de bu gruba eklenmiştir. Cluster 1'de ise MNDRS bulunurken, Cluster 2'de BLCYT, BOSSA, DESA, KORDS ve YATAS yer almıştır. 2023 yılında ise Cluster 0'daki şirketler büyük

oranda aynı kalmakla birlikte, BLCYT, BOSSA, DERIM, DESA ve ISSEN gibi önceki yıllarda daha yüksek risk grubunda olan bazı şirketler bu sınıfta yer almaktadır. Cluster 1'de KORDS'a ek olarak MNDRS yer alırken, Cluster 2'de yalnızca BRKO bulunmaktadır. Bu sonuçlar, bazı şirketlerin zaman içinde nakit akış riskinde iyileşme gösterdiğini, bazılarının ise artan risklerle karşı karşıya kaldığını ortaya koymaktadır.



Şekil 2. CFOA'ya göre yıl bazında kümeleneşmiş şirketler


Tablo 1

CFOA'ya Göre Yıl Bazında Kümeleneşmiş Şirketler

Yıl	Küme	Şirketler
2021	Cluster 0	ARSAN, ATEKS, BRKO, BRMEN, DAGI, DIRIT, ENSRI, HATEK, KRTEK, LUKSK, MEGAP, RODRG, ROYAL, RUBNS, SKTAS, SNPAM, SUNTK, YATAS, YUNSA
2021	Cluster 1	KORDS
2021	Cluster 2	BLCYT, BOSSA, DERIM, DESA, ISSEN, MNDRS
2022	Cluster 0	ARSAN, ATEKS, BRKO, BRMEN, DAGI, DERIM, DIRIT, ENSRI, HATEK, ISSEN, KRTEK, LUKSK, MEGAP, RODRG, ROYAL, RUBNS, SKTAS, SNPAM, SUNTK, YUNSA
2022	Cluster 1	MNDRS
2022	Cluster 2	BLCYT, BOSSA, DESA, KORDS, YATAS
2023	Cluster 0	ARSAN, ATEKS, BLCYT, BOSSA, BRMEN, DAGI, DERIM, DESA, DIRIT, ENSRI, HATEK, ISSEN, KRTEK, LUKSK, MEGAP, RODRG, ROYAL, RUBNS, SKTAS, SNPAM, SUNTK, YATAS, YUNSA
2023	Cluster 1	KORDS, MNDRS
2023	Cluster 2	BRKO

CFFA açısından yapılan analiz Şekil 3'te ve Tablo 2'de yer almaktadır. Finansman faaliyetlerinden kaynaklanan nakit akışlarının istikrarı ve güvenilirliği temelinde üç farklı küme (Cluster) altında sınıflandırılmıştır. 2021, 2022 ve 2023 yıllarına ait CFFA analizlerinde, şirketler finansman faaliyetlerinden sağlanan nakit akışlarının risk seviyelerine göre üç kümeye ayrılmıştır. 2021 yılında, Cluster 0 sınıfında ATEKS, ARSAN, BLCYT, BRKO, BRMEN, BOSSA, DERIM, DESA, DIRIT, KRTEK, MNDRS, RODRG, ROYAL, RUBNS, SKTAS, SNPAM, SUNTK, YATAS ve YUNSA yer almaktadır. Bu şirketler, finansman faaliyetlerinden sağlanan nakit akışlarında herhangi bir risk taşımamaktadır. Cluster 1 sınıfında yalnızca KORDS bulunmakta olup, bu şirketin finansman faaliyetlerinden sağlanan nakit akışlarında belirli bir risk seviyesinin mevcut olduğu gözlemlenmektedir. Cluster 2 sınıfında ise DAGI, ENSRI, HATEK, ISSEN, LUKSK ve MEGAP yer almakta olup, bu şirketler finansman faaliyetlerinden sağlanan nakit akışlarında önemli dalgalanmalar ve belirsizliklerle karşı karşıya kalmaktadır.

2022 yılında, Cluster 0'daki şirketlerin büyük bir kısmı aynı kalmakta olup ENSRI, HATEK, ISSEN gibi şirketler de bu düşük risk sınıfında yer almaktadır. Bu durum, bu şirketlerin finansman faaliyetlerinden sağlanan nakit akışlarındaki risk seviyelerinin azaldığını göstermektedir. Cluster 1'de yalnızca MNDRS, Cluster 2'de ise BOSSA, KORDS, RUBNS ve YATAS yer almaktadır. Cluster 2'deki şirketler, yüksek derecede finansman nakit akışı riski taşımakta olup, finansal sürdürülebilirlik açısından zorlu bir süreç yaşamaktadırlar. 2023 yılında Cluster 0'daki şirketlerin çoğu aynı kalmış ve RUBNS bu sınıfa eklenmekte olup bu durum RUBNS'in finansman faaliyetlerindeki nakit akışı risk seviyelerinde bir iyileşme olduğunu göstermektedir. Cluster 1'de MNDRS bulunurken, Cluster 2'de BOSSA, KORDS ve YATAS yer almakta olup, bu şirketler finansman faaliyetlerinden sağlanan nakit akışlarında yüksek risk taşımaya devam etmektedirler.



Şekil 3. CFFA'ya göre yıl bazında kümelenmiş şirketler


Tablo 2

CFFA'ya Göre Yıl Bazında Kümelenmiş Şirketler

Yıl	Küme	Şirketler
2021	Cluster 0	ARSAN, ATEKS, BLCYT, BOSSA, BRKO, BRMEN, DERIM, DESA, DIRIT, KRTEK, MNDRS, RODRG, ROYAL, RUBNS, SKTAS, SNPAM, SUNTK, YATAS, YUNSA
2021	Cluster 1	KORDS
2021	Cluster 2	DAGI, ENSRI, HATEK, ISSEN, LUKSK, MEGAP
2022	Cluster 0	ARSAN, ATEKS, BLCYT, BRKO, BRMEN, DAGI, DERIM, DESA, DIRIT, ENSRI, HATEK, ISSEN, KRTEK, LUKSK, MEGAP, RODRG, ROYAL, SKTAS, SNPAM, SUNTK, YUNSA
2022	Cluster 1	MNDRS
2022	Cluster 2	BOSSA, KORDS, RUBNS, YATAS
2023	Cluster 0	ARSAN, ATEKS, BLCYT, BRKO, BRMEN, DAGI, DERIM, DESA, DIRIT, ENSRI, HATEK, ISSEN, KRTEK, LUKSK, MEGAP, RODRG, ROYAL, RUBNS, SKTAS, SNPAM, SUNTK, YUNSA
2023	Cluster 1	MNDRS
2023	Cluster 2	BOSSA, KORDS, YATAS

Şekil 4 ve Tablo 3, şirketlerin yatırım faaliyetlerinden elde ettikleri nakit akışlarının risk düzeylerini yansıtmakta ve şirketler üç farklı küme (Cluster) altında sınıflandırılmaktadır.

2021, 2022 ve 2023 yıllarına ait CFIA analizleri, şirketlerin yatırım faaliyetlerinden sağlanan nakit akışlarının risk seviyelerine göre farklı kümelere ayrıldığını göstermektedir. 2021 yılında, Cluster 0'da ATEKS, ARSAN, BLCYT, BRKO, BRMEN, DAGI, DERIM, DESA, DIRIT, ENSRI, HATEK, ISSEN, KRTEK, LUKSK, MEGAP, MNDRS, RODRG, ROYAL, RUBNS, SKTAS, SNPAM, SUNTK ve YUNSA yer almaktadır. Bu şirketler, yatırım faaliyetlerinden sağlanan nakit akışlarında herhangi bir risk taşımamaktadır. Cluster 1 sınıfında KORDS ve YATAS yer almakta olup, bu şirketlerin yatırım faaliyetlerinden sağlanan nakit akışlarında belirli bir risk seviyesinin mevcut olduğu gözlemlenmektedir. Cluster 2 sınıfında ise yalnızca BOSSA yer almakta olup, bu şirketin yatırım faaliyetlerinden sağlanan nakit akışlarında yüksek düzeyde risk bulunduğu belirlenmiştir. 2022 yılında, Cluster 0'daki şirketlerin büyük ölçüde aynı kaldığı görülmüş, KORDS Cluster 1'de kalmaya devam ederken, BOSSA ve YATAS yüksek risk sınıfında (Cluster 2) yer almıştır. Bu durum, bu şirketlerin yatırım faaliyetlerinden sağlanan nakit akışlarında devam eden bir belirsizlik ve risk düzeyine işaret etmektedir. 2023 yılında Cluster 0'da ATEKS, ARSAN, BRKO, BRMEN, DAGI, DERIM, DESA, DIRIT, ENSRI, LUKSK, RODRG, ROYAL, SKTAS ve YUNSA yer almış, bu şirketlerin yatırım faaliyetlerinden sağlanan nakit akışlarında düşük risk taşımaya devam ettiği gözlemlenmiştir. Cluster 1'de KORDS, MNDRS, RUBNS ve YATAS bulunurken, Cluster 2'de BLCYT, BOSSA, HATEK, ISSEN, KRTEK, MEGAP, SNPAM ve SUNTK yer almıştır. Bu şirketlerin yatırım faaliyetlerinden sağlanan nakit akışlarında yüksek risk taşıdığı ve bu riskin yıllar içinde arttığı belirlenmiştir.



Şekil 4. CFIA'ya göre yıl bazında kümelenmiş şirketler

Tablo 3

CFIA'ya Göre Yıl Bazında Kümelenmiş Şirketler


Yıl	Küme	Şirketler
2021	Cluster 0	ARSAN, ATEKS, BLCYT, BRKO, BRMEN, DAGI, DERIM, DESA, DIRIT, ENSRI, HATEK, ISSEN, KRTEK, LUKSK, MEGAP, MNDRS, RODRG, ROYAL, RUBNS, SKTAS, SNPAM, SUNTK, YUNSA
2021	Cluster 1	KORDS, YATAS
2021	Cluster 2	BOSSA
2022	Cluster 0	ARSAN, ATEKS, BLCYT, BRKO, BRMEN, DAGI, DERIM, DESA, DIRIT, ENSRI, HATEK, ISSEN, KRTEK, LUKSK, MEGAP, MNDRS, RODRG, ROYAL, RUBNS, SKTAS, SNPAM, SUNTK, YUNSA
2022	Cluster 1	KORDS
2022	Cluster 2	BOSSA, YATAS
2023	Cluster 0	ARSAN, ATEKS, BRKO, BRMEN, DAGI, DERIM, DESA, DIRIT, ENSRI, LUKSK, RODRG, ROYAL, SKTAS, YUNSA
2023	Cluster 1	KORDS, MNDRS, RUBNS, YATAS
2023	Cluster 2	BLCYT, BOSSA, HATEK, ISSEN, KRTEK, MEGAP, SNPAM, SUNTK

MEGAP şirketi, modelin özellikle yatırım faaliyetlerinden kaynaklanan riskleri tespit etme kapasitesine ilişkin önemli bir gösterge sunmaktadır. Şirketin 2021–2023 dönemine ait nakit akış verileri incelendiğinde, işletme ve finansman faaliyetleri açısından düşük risk sınıfında (Cluster 0) yer almasına

rağmen, yatırım faaliyetleri bakımından yüksek risk sınıfında (Cluster 2) sınıflandırıldığı tespit edilmiştir. Bu durum, modelin geleneksel tablolarla kolayca fark edilemeyen potansiyel yatırım kaynaklı likidite sorunlarını geçmiş verilere dayalı olarak ayırt edebildiğini göstermektedir. MEGAP'ın 2024 yılında konkordato ilan etmiş olması, yatırım faaliyetlerinden kaynaklanan yoğun nakit çıkışlarının gelecekteki finansal sıkıntıların sinyali olabileceğine işaret etmektedir.

Gizli durum ısı haritası

Şekil 5'de yer alan gizli durum ısı haritası, şirketlerin yıllık olarak gizli durum risk sınıflandırmalarını görselleştiren bir analiz sunmaktadır. Gizli durum, risk seviyeleri olarak "0" (nakit riskinin olmaması) ve 1 (nakit riskinin olması) şeklinde iki kategoride sınıflandırılmaktadır. Verilere göre, birçok şirketin gizli durum risk seviyeleri 2021, 2022 ve 2023 yıllarında genellikle "1" (nakit riskinin olması) olarak belirlenmiştir. Bu durum, çoğu şirketin yıllık bazda nakit riskine sahip olduğunu göstermektedir. RSAN, ATEKS, BLCYT, BOSSA, BRKO, BRMEN, DAGI, DERIM, DESA, DIRIT, ENSRI, HATEK, ISSEN, LUKSK, MEGAP, RODRG, ROYAL, RUBNS, SKTAS, SNPAM ve SUNTK şirketlerinin incelenen yıllarda gizli durum risk seviyesi "1" olarak belirlenmiştir. Dolayısıyla bu şirketlerin her yıl nakit riskinin devam ettiği ifade edilebilir. KORDS, MNDRS ve YATAS gibi bazı şirketlerin risk seviyelerinde incelenen yıllar arasında değişiklikler tespit edilmiştir. Örneğin, KORDS şirketinin 2021 ve 2022 yıllarında gizli durum riski "0" ancak 2023 yılında risk seviyesi "1" olarak belirlenmiştir. Bu değişiklik, bu şirketlerin risk profillerinde önemli bir değişiklik yaşadığını göstermektedir. MNDRS şirketinin 2023 yılında gizli durum risk seviyesi "0", önceki yıllarda ise "1" olarak tespit edilmiştir. Benzer şekilde, YATAS şirketinin risk seviyeleri 2022 ve 2023 yıllarında "0" olarak belirlenmiştir. Dolayısıyla bu şirketlerin gizli durum risklerini etkili bir şekilde yönettiği ve risklerini azalttığı ifade edilebilir. Şekil 5 incelendiğinde, şirketlerin tamamına yakınının risk durumları yıllık bazda genellikle "1" olarak tespit edilmiştir. Bu durum, bu şirketlerin gizli durum risklerinin yıl boyunca devam ettiğini ifade etmektedir.




Şekil 5. Gizli durum ısı haritası

Nakit risk sınıflaması ısı haritası

Nakit yönetimi, şirketlerin finansal performansının belirlenmesi açısından kritik bir öneme sahiptir. Şekil 6, şirketlerin nakit risklerinin incelenen yıllardaki değişimlerini göstermektedir. Bu çalışmada, model

sonuçlarının şirket bazında nasıl yansıdığını daha net ortaya koyabilmek için dört şirket özelinde ayrıntılı analiz yapılmıştır. Örneklemede yalnızca dört şirketin seçilmesi, rastlantısal değil; sektör içinde farklı büyüklükte, konumda ve risk düzeyinde olan şirketleri temsil edecek şekilde, bilinçli bir seçimle gerçekleştirilmiştir. Bu şirketler, hem sektör içindeki yerleri hem de nakit akışı risk profilleri bakımından farklı özellikler taşıdıkları için çeşitliliği sağlamaktadır. Bu sayede, analiz edilen şirketler aracılığıyla GMM'nin tespit ettiği gizli nakit riski yapılarına ilişkin farklı senaryolar temsil edilebilmiş ve modelin açıklayıcı gücü ortaya koyulmuştur. Bu derinlemesine analiz, sektörel düzeydeki genel risk sınıflandırmasını göstermekle birlikte her bir şirketin özgün finansal durumunu daha yakından değerlendirme imkânı sunmaktadır. Bu dört şirketin seçimi, çalışmanın yöntemsel şeffaflığını artırmakta ve gizli nakit riski desenlerinin şirket bazında nasıl farklılaştığını göstermek açısından katkı sağlamaktadır.



Şekil 6. Nakit risk sınıflaması ısı haritası


ARSAN şirketinin 2021 ve 2022 yıllarında, nakit akışı negatif olarak belirlenmiştir. 2021 ve 2022 yıllarında faiz gelirleri ve giderleri ile ilgili düzeltmeler, vergi gelir ve gider düzeltmeleri gerçeğe uygun değer kayıpları (kazançları) ile ilgili düzeltmeler nakit akışı üzerinde negatif bir etki göstermektedir. Ticari alacaklardaki azalış (artış) ile ilgili düzeltmeler, faaliyetlerle ilgili diğer alacaklar ve stoklardaki azalışlar (artışlar) ile ilgili düzeltmeler kalemlerinde azalış gerçekleşmiştir. 2021 yılında, yabancı para çevrim farklarının etkisinden önce dönem başı nakit mevcudunun, dönem sonu nakit mevcudundan fazla olduğu belirlenmiştir. 2022 yılında, peşin ödenmiş giderlerdeki azalış (artış) ve işletme sermayesinde gerçekleşen diğer artış (azalış) ile ilgili düzeltmelerde azalış yaşanmıştır. 2023 yılında ARSAN'ın nakit akışı negatif olup bu duruma değer düşüklüğü düzeltmeleri, faiz gelir/gider düzeltmeleri ve gerçeğe uygun değer kayıpları (kazançları) ile ilgili düzeltmeler kalemlerinin negatif etkileri olduğu tespit edilmiştir. Duran varlık alım ve satım farkları negatif etki göstermekte olup, ticari borçlardaki artış (azalış) ile ilgili düzeltmeler, çalışanlara sağlanan faydalara ilişkin karşılıklar kapsamında yapılan ödemeler, faaliyetlerle ilgili diğer borçlarda azalma ve ertelenmiş gelirler kalemlerinde azalış gerçekleşmiştir.

ATEKS'in 2021, 2022 ve 2023 yıllarındaki finansal verileri, belirgin bir nakit sıkıntısını ortaya koymaktadır. 2021 yılında, nakit akışındaki negatif etki, gerçeğe uygun değer kayıpları (kazançları) ile ilgili düzeltmeler ve duran varlık alım/satım farkları, ticari alacaklardaki azalış (artış) ile ilgili düzeltmeler, faaliyetlerle ilgili diğer alacaklar, stoklardaki azalışlar (artışlar) ile ilgili düzeltmeler ve peşin ödenmiş giderlerdeki azalış (artış) kalemlerindeki azalıştan kaynaklanmaktadır. Ayrıca, dönem başı nakit mevcudu, dönem sonu nakit mevcudundan fazla olarak belirlenmiştir. 2022 yılında da nakit akışındaki olumsuz durum devam etmekte olup bu duruma dönem net zararının olması, değer düşüklüğü düzeltmeleri ve vergi gelir/gider düzeltmeleri kalemlerinin etkili olduğu ifade edilebilir. Gerçeğe uygun değer kayıpları (kazançları) ile ilgili düzeltmeler, duran varlık alım/satım farkları ve azalış gerçekleşmiş ve yabancı para çevrim farklarının etkisinden önce dönem başı nakit mevcudunun dönem sonu nakit mevcudundan fazla olduğu tespit edilmiştir. 2023 yılında dönem net zararı olup nakit akışı üzerinde gerçeğe uygun değer kayıpları (kazançları) ile ilgili düzeltmeler ve duran varlık alım/satım farkları gibi kalemler olumsuz etkilere neden olmuştur. Peşin ödenmiş giderlerdeki azalış (artış) ve ticari borçlardaki artış (azalış) ile ilgili düzeltmelerin de etkili olduğu ve genel olarak, ATEKS'in nakit akışındaki olumsuzluklar, üç yıl boyunca çeşitli finansal kalemlerin olumsuz etkileri ve yabancı para çevrim farkları ile ilişkili olduğu ifade edilebilir.

2021, 2022 ve 2023 yıllarında, BLCYT'nin nakit akışının negatif olduğu tespit edilmiştir. Bu yıllarda, nakit akışı üzerinde karşılıklarla ilgili düzeltmeler ve faiz (gelirleri) ile giderleri ile ilgili düzeltmeler, gerçeğe uygun değer kayıpları (kazançları) ile ilgili düzeltmeler, duran varlık alım/satım farkları kalemlerinin negatif etkisi olmuştur. Ayrıca, stoklardaki azalışlar (artışlar) ile ilgili düzeltmeler, ticari alacaklardaki azalış (artış) ile ilgili düzeltmeler, peşin ödenmiş giderlerdeki azalış (artış), ertelenmiş gelirler ve işletme sermayesinde gerçekleşen diğer artış (azalış) kalemlerinde de azalış tespit edilmiştir. 2022 yılında, ayrıca nakit akışını vergi gelir/gider düzeltmeleri, faaliyetlerle ilgili diğer alacaklarda azalış olması ve ticari borçlardaki artış (azalış) ile ilgili düzeltmeler ve çalışanlara sağlanan faydalara ilişkin karşılıklar kapsamında yapılan ödemeler negatif etkilemektedir. 2023 yılında ayrıca değer düşüklüğü düzeltmeleri kaleminin de negatif etkisinin olduğu tespit edilmiştir. BOSSA'nın 2021 ve 2022 yıllarında, nakit akışını vergi gelir/gider düzeltmeleri kalemi negatif yönde etkilemekte olup duran varlık alım/satım farkları, ticari alacaklardaki azalış (artış) ile ilgili düzeltmeler, stoklardaki azalışlar (artışlar) ile ilgili düzeltmeler, peşin ödenmiş giderlerdeki azalış (artış) ve işletme sermayesinde gerçekleşen diğer artış (azalış) kalemlerinde azalış tespit edilmiştir. Ayrıca 2022 yılında, ertelenmiş gelirlerde azalış gerçekleşmiştir. 2023 yılı itibarıyla, BOSSA'nın gerçeğe uygun değer kayıpları (kazançları) ile ilgili düzeltmeler, duran varlık alım/satım farkları ve ticari alacaklardaki azalış (artış) ile ilgili düzeltmeler kalemlerindeki azalışlarının nakit akışına negatif etkilerinin ayrıca dönem başı nakit mevcudu dönem sonu nakit mevcudundan fazla olduğu tespit edilmiştir. Düzeltme kalemleri, şirketlerin finansman stratejileri, yatırım tercihleri ve faaliyet kârlılığı hakkında önemli sinyaller sunmaktadır. Örneğin, faiz giderlerine yönelik yapılan düzeltmeler, şirketlerin borçla finansman kullanımının arttığını ve bu nedenle faiz yükünün bilanço üzerindeki etkisinin büyüdüğünü ortaya koyabilir. Benzer şekilde, yatırım faaliyetlerinden kaynaklanan yüksek tutarlı negatif nakit akımları, şirketlerin sermaye harcamalarını artırdığını veya uzun vadeli varlık yatırımlarına yöneldiğini işaret edebilir. Bu bağlamda, her bir düzeltme kalemi, şirketin geleceğe yönelik stratejik kararlarını anlamak açısından önemlidir. Yatırımcılar açısından da, yüksek faiz giderine katlanan şirketler, kırılgan bir yapıya sahip olabilirken, yatırım harcamaları artmasına rağmen borçluluğunu kontrol altında tutan şirketler uzun vadeli büyüme potansiyeli bakımından daha olumlu değerlendirilebilir. Bu nedenle, düzeltme kalemlerine yalnızca geçmiş performansın bir parçası olarak değil, aynı zamanda şirketin likidite yapısı, borç ödeme kapasitesi ve sermaye yönetimi hakkında stratejik göstergeler olarak yaklaşılmalıdır. Diğer şirketlerin nakit akışı üzerinde negatif etkilerinin olduğu kalemlere ilişkin bilgiler Tablo 4'te yer almaktadır. Tablolarda negatif etkiler "1", negatif etkilerin olmaması ise "0" ile ifade edilmektedir.


Tablo 4

Nakit Akışı Üzerinde Negatif Etkiler Tablosu




Tablo 4

Nakit Akışı Üzerinde Negatif Etkiler Tablosu (Devamı)



Tablo 4

Nakit Akışı Üzerinde Negatif Etkiler Tablosu (Devamı)



Elde edilen bulgular, şirketlerin nakit akışı yapılarında gözlemlenen gizli/potansiyel risk durumlarının gerek yatırımcılar gerekse yönetim açısından stratejik bir karar destek aracı olarak değerlendirilmesi gerektiğini ortaya koymaktadır. Özellikle, görünürde sağlam finansal göstergelere sahip olsa da, GMM uygulaması sonucunda gizli nakit riski taşıdığı belirlenen şirketlerin önceden tespit edilmesi, yatırımcılar açısından portföy optimizasyonu ve risk dağılımı süreçlerinde önemli bir avantaj sağlamaktadır. Bu tür modellere dayalı analizler, geleneksel finansal tablolar aracılığıyla doğrudan görünür olmayan risk yapılarını açığa çıkararak yatırımcıların daha bilinçli stratejiler geliştirmesine olanak tanımaktadır. Ayrıca, yatırımcıların bu tür gizli risk göstergeleri doğrultusunda şirket yönetimleriyle şeffaflık düzeyinin artırılması, risk iletişimi ve nakit pozisyon yönetimi konularında etkileşime geçmeleri, yönetim kalitesini doğrudan etkileyebilecek bir araç niteliği taşımaktadır. Öte yandan, şirket yöneticileri açısından bakıldığında, GMM temelli bulguların bir tür erken uyarı sistemi olarak değerlendirilmesi mümkündür. Model tarafından üretilen gizli durum sinyalleri, karar alıcılara nakit akışı projeksiyonlarının revize edilmesi ve operasyonel finansman politikalarının yeniden yapılandırılması yönünde stratejik kararlar alma fırsatı sunmaktadır. Du et al. (2020) tarafından yapılan çalışmada belirtildiği üzere, finansal olarak sağlıklı görünen şirketlerin bile derin yapıdaki gizli risk göstergeleri aracılığıyla incelenmesi, kurumsal performans analizinde yeni bir katman oluşturmaktadır. Bu bağlamda, GMM, yalnızca ampirik bir analiz aracı değil, aynı zamanda finansal kırılganlıkların erken teşhisine yönelik proaktif bir yönetim mekanizması olarak da değerlendirilmelidir.

Sonuç

Bu çalışmada, GMM'nin nakit akış tablosu verilerinin analizinde kullanılmasına yönelik bir yaklaşım sunulmaktadır. Klasik yöntemlerin genellikle yüzeysel analizlerle sınırlı kaldığı finansal tablolarda, GMM, zaman içinde değişen finansal durumları ve gizli nakit risklerini daha derinlemesine inceleme fırsatı sunmaktadır. Modelin, gözlemlenen verilerle birlikte, veriler arasındaki gizli durumları ve geçiş dinamiklerini ortaya koyma yeteneği, klasik yöntemlerin kaçırabileceği önemli detayları ortaya çıkarmaktadır. Bu çalışma, nakit akışındaki anomalilerin ve potansiyel risklerin önceden tespit edilmesini sağlayarak GMM'nin finansal analizde kapsamlı bir araç olduğunu göstermektedir.

Bu çalışmada gizli durum ısı haritası analizi, genel olarak şirketlerin gizli durum risklerinin çoğunlukla 1 (nakit riskinin olması) olduğunu ve yıllar arasında belirgin bir değişiklik göstermediğini ortaya koymaktadır. Ancak, bazı şirketlerde risk seviyelerinde yıllık bazda değişiklikler yaşandığı ve risklerin azalma veya artma eğiliminde olduğu görülmektedir. Bu analiz, şirketlerin gizli durum risklerini anlamak ve yönetim stratejilerini değerlendirmek açısından önemli bir araçtır. Risklerin izlenmesi ve yönetilmesi, şirketlerin finansal performansını koruma ve risklere karşı hazırlıklı olma stratejilerini geliştirme süreçlerinde kritik bir rol oynamaktadır. İncelenen şirketlerin çoğunda dönemin başından sonuna kadar negatif nakit akışları belirlenmiştir. Bu durum, şirketlerin finansal performanslarını sürdürebilmesi ve nakit yönetimini iyileştirebilmesi için stratejik önlemler almalarının gerektiğini göstermektedir.

Bu çalışmada analiz edilen şirketlerden olan MEGAP'ın 2024 yılında konkordato ilan etmiş olması, modelin yatırım faaliyetlerinden kaynaklanan riskleri tespit etme potansiyeline işaret eden dikkat çekici bir örnek sunmaktadır. Şirketin 2021, 2022 ve 2023 yıllarına ait nakit akışları incelendiğinde, işletme ve finansman faaliyetlerinden sağlanan nakit akışları açısından düşük riskli (Cluster 0) olarak sınıflandırıldığı, ancak yatırım faaliyetleri açısından yüksek riskli (Cluster 2) olarak değerlendirildiği tespit edilmiştir. Bu durum, modelin özellikle yatırım kaynaklı riskleri belirleme konusunda duyarlılık gösterebildiği ifade edilebilir. Yatırım faaliyetlerinden kaynaklanan bu tür riskler; agresif yatırım stratejileri, büyük ölçekli projelere aşırı sermaye tahsis veya piyasa belirsizlikleri gibi faktörlerden kaynaklanabilir. Bu bağlamda, MEGAP örneği, söz konusu modelin yatırım faaliyetlerine ilişkin risk göstergelerini geçmiş verilere dayalı olarak tespit edebilme kapasitesini sergilemektedir. Bununla birlikte, yalnızca tek bir şirketin gelecekteki mali durumu üzerinden modelin genel geçerliliğine dair çıkarım yapmak uygun olmayacaktır. Bu nedenle MEGAP vakası, modelin açıklayıcı gücüne dair bir göstergedir, ancak daha geniş örneklem grupları ve uzun dönemli karşılaştırmalarla desteklenmelidir. Sonuç olarak, bu tür örnek vakalar, modelin potansiyel katkı alanlarını ve geliştirilmesi gereken yönlerini ortaya koymak açısından önemlidir. Gelecekteki çalışmalarda, benzer örneklerin çoğaltılması ve model çıktılarının gerçek finansal sonuçlarla daha kapsamlı biçimde karşılaştırılması modelin güvenilirliğini güçlendirecektir.

Bu çalışmada, gizli nakit risklerinin finansal tablolar aracılığıyla nasıl ortaya çıkabileceğini gösteren önemli bulgular sunulmakta olup yıllık finansal verilerde genellikle gözden kaçan bu riskler, detaylı nakit akış tablosu analizleri sayesinde ortaya çıkarılmaktadır. Özellikle, ticari alacaklar, stoklar ve peşin ödemeler kalemlerindeki azalışlar nakit sıkışıklığını işaret etmektedir. Şirketlerin dönemin başında güçlü bir nakit mevcudu olmasına rağmen dönem sonuna kadar bu durumun tersine dönmesi, operasyonel ve finansal stratejilerdeki eksiklikleri açıkça ortaya koymaktadır. Bu çalışma, geleneksel finansal analizlerden farklı olarak gizli nakit risklerinin önceden tespit edilmesi ve çözülmesi gerektiğini ortaya koymaktadır. Böylelikle finansal performansın sürdürülebilirliğinin sağlanması için kritik bir bakış açısı sunmaktadır. Dolayısıyla yapılan bu analiz, gelecekteki finansal planlamalar ve risk yönetimi stratejileri açısından önemli bir kaynak oluşturabilir.

Finansal verilerin yıllık bazda düzenlenmiş olması, dönem içi kısa vadeli şoklara duyarlılığı azaltmakta ve analizlerin daha makro bir perspektiften değerlendirilmesine olanak tanımaktadır. Çalışmanın temel amacı, doğrudan kriz etkilerini incelemekten ziyade, kriz ortamı da dâhil olmak üzere şirketlerin nakit akışları üzerinden gizli nakit riski düzeylerinin modellenmesidir. Bu çerçevede, Kovid-19 sonrası döneme özgü finansal belirsizlikler, modelin performansını test edebilmek açısından doğal bir varyans kaynağı olarak değerlendirilmiştir. Gelecekte yapılacak araştırmalarda, veri aralığının 2024 ve sonrasını içerecek şekilde genişletilmesiyle birlikte, daha uzun vadeli ve karşılaştırmalı analizlerin gerçekleştirilmesi mümkün olabilecektir.

Kaynakça

- Adele, M. & Irechukwu, E. N. (2024). Liquidity management and financial sustainability in ruma certified public accountants ltd firm in kigali, Rwanda. *Jetir*, 11(10), 1918-1934.
- Altan, G. ve Demirci, S. (2022). Makine öğrenmesi ile nakit akış tablosu üzerinden kredi skorlaması: XGBoost yaklaşımı. *Journal of Economic Policy Researches*, 9(2), 397-424.
- Blümke, O. (2022). A structural hidden Markov model for forecasting scenario probabilities for portfolio loan loss provisions. *Knowledge-Based Systems*, 249, 108934. <https://doi.org/10.1016/j.knosys.2022.108934>
- Can, T. ve Öz, E. (2009). Saklı Markov modelleri kullanılarak Türkiye’de dolar kurundaki değişimin tahmin edilmesi. *İstanbul Üniversitesi İşletme Fakültesi Dergisi*, 38(1), 1-23.
- Dağlıoğlu, C. ve Kırıl, G. (2018). Hisse senedi piyasa fiyatlarının saklı markov modeli ile tahmin edilmesi: Türkiye örneği. *Uluslararası Ekonomi ve Yenilik Dergisi*, 4(1).
- Du, K., Huddart, S., Xue, L., & Zhang, Y. (2020). Using a hidden Markov model to measure earnings quality. *Journal of Accounting and Economics*, 69(2-3), 101281. <https://doi.org/10.1016/j.jacceco.2019.101281>
- Duhovnik, M. (2008). Improvements of the cash-flow statement control function in financial reporting. *Zbornik Radova Ekonomskog Fakulteta U Rijeci: Časopis Za Ekonomsku Teoriju I Praksu*, 26(1), 123-150.
- Erol, C. (1988). İşletmelerin finansal başarımlarının ölçülmesinde faaliyetler yapıya göre hazırlanmış nakit akış tablosu ve rasyolarının kullanımı, *İ. Ü. İşletme Fakültesi Dergisi*, 17 (1).
- Gaughan, P. A., Fuentes, H. and Bonanomi, L. (1995). Cash flow vs. net income in commercial litigation. *Litigation Economics Digest*, 1(1), 13-23.
- Giampieri, G., Davis, M. and Crowder, M. (2005). Analysis of default data using hidden Markov models. *Quantitative Finance*, 5(1), 27-34. <https://doi.org/10.1080/14697680500039951>
- Hanif, M., Sami, F., Hyder, M. and Ch, M. I. (2017). Hidden Markov model for time series prediction. *Journal of Asian Scientific Research*, 7(5), 196-205.
- Harris, C. and Roark, S. (2019). Cash flow risk and capital structure decisions. *Finance Research Letters*, 29, 393-397. <https://doi.org/10.1016/j.frl.2018.09.005>
- Hirth, S. and Viswanatha, M. (2011). Financing constraints, cash-flow risk, and corporate investment. *Journal of Corporate Finance*, 17(5), 1496-1509. <https://doi.org/10.1016/j.jcorpfin.2011.09.002>
- İstanbul Hazır Giyim ve Konfeksiyon İhracatçıları Birliği [İHKİB]. (2025). Hazır giyim ve tekstil sektör raporu. <https://www.ihkib.org.tr>
- International Accounting Standards Board (2007) IFRS – A Guide through International Financial Reporting Standards. London: International Accounting Standards Committee Foundation
- İlarslan, K. (2014). Hisse senedi fiyat hareketlerinin tahmin edilmesinde Markov zincirlerinin kullanılması: İmkb 10 bankacılık endeksi işletmeleri üzerine ampirik bir çalışma. *Yaşar Üniversitesi E-Dergisi*, 9(35), 6158-6198.
- Kamuyu Aydınlatma Platformu (KAP), www.kap.gov.tr Erişim Tarihi: 22.08.2024
- Ki, Y., & Adhikari, R. (2022). Corporate cash holdings and exposure to macroeconomic conditions. *International Journal of Financial Studies*, 10(4), 105. <https://doi.org/10.3390/ijfs10040105>
- Kwok, H. (2002). The effect of cash flow statement format on lenders' decisions. *The International Journal of Accounting*, 37(3), 347-362.
- Laghari, F., Chengang, Y., Chenyun, Y., Liu, Y., & Xiang, L. (2022). Corporate liquidity management in emerging economies under the financial constraints: evidence from China. *Discrete Dynamics in Nature and Society*, 2022(1), 6086191. <https://doi.org/10.1155/2022/6086191>
- Li, Y. and Wu, H. (2012). A clustering method based on K-means algorithm. *Physics Procedia*, 25, 1104-1109.
- Likas, A., Vlassis, N. and Verbeek, J. J. (2003). The global k-means clustering algorithm. *Pattern Recognition*, 36(2), 451-461.
- Motlagh, A. J. (2013). Accounting: Cash flow statement. *Journal of Business and Management*, 7(4), 109-116.
- PwC. (2023). Financial reporting: Why audit matters. PwC Global. <https://www.pwc.com/gx/en/services/audit-assurance/publications/why-audit-matters.html>. (Erişim tarihi: 21.06.2025)
- Rao, S. and Hong, J. (2010). Analysis of hidden Markov models and support vector machines in financial applications. University of California at Berkeley: Berkeley, CA, USA.
- Sosyal Güvenlik Kurumu [SGK]. (2025). Sektörel istihdam istatistikleri: 2021–2024 dönemi. SGK Yayınları. <https://www.sgk.gov.tr>
- Sinaga, K. P. and Yang, M. S. (2020). Unsupervised K-means clustering algorithm. *IEEE Access*, 8, 80716-80727.
- Steyn, B. W. and Hamman, W. D. (2003). Revamping the cash flow statement. *Meditari Accountancy Research*, 11(1), 181-198.

- Tai, A. H., Ching, W. K. and Chan, L. Y. (2009). Detection of machine failure: Hidden Markov Model approach. *Computers & Industrial Engineering*, 57(2), 608-619.
- TMS 7 Nakit Akış Tablosu, (<https://www.kgk.gov.tr/files/Muhasebe/Standart>), (Erişim tarihi: 01.05.2025)
- Uhrig-Homburg, M. (2005). Cash-flow shortage as an endogenous bankruptcy reason. *Journal of Banking & Finance*, 29(6), 1509-1534.
- V. Kousenidis, D. (2006). A free cash flow version of the cash flow statement: a note. *Managerial Finance*, 32(8), 645-653.
- Vargeloğlu, A. A. ve Özdemir, Y. A. Altın fiyatlarındaki değişimin saklı Markov modeli ile incelenmesi. *The Journal of International Scientific Researches*, 8(3), 466-477.
- Whitfield, B. (2004). Statement of cash flows: time for change. *Financial Analysts Journal*, 60(2), 16-22.
- World Bank. (2010). The global economic crisis: Assessing vulnerability with a poverty lens. World Bank Publications. <https://www.worldbank.org/en/topic/poverty/publication/the-global-economic-crisis-assessing-vulnerability-with-a-poverty-lens>

Extended Abstract

Purpose

The purpose of this study is to analyze the potential cash flow problems of companies operating in the Textile, Wearing Apparel and Leather sectors operating in Borsa Istanbul (BIST) for the years 2021-2023 using the Hidden Markov Model (HMM). The study aims to determine the cash management strategies of companies with an accounting-oriented approach and to contribute to the realistic assessment of financial risks by revealing the hidden cash flow problems of companies. In this context, it is aimed to provide more comprehensive information about cash risk to parties related to companies.

Design and methodology

In the first stage of the modelling process, the data set has been cleaned and missing or outlier values in the data set have been removed. The financial data of the companies were scaled and the data has been normalized using StandardScaler in this process. This allows GMM to better interpret the data and make predictions. The Python programming language and especially the hmmlearn library have been used for the analysis. 2 hidden states (n_components=2) have been used in the GMM model, and each state represents a certain level of cash risk. The model is subjected to an iterative learning process to predict the hidden states depending on the annual financial data of each company. Model training has been performed by processing the data for 1000 iterations. For each data point, the model predicted the most probabilistic latent state. The latent states have been classified as 0 (no cash risk) and 1 (cash risk). In addition, the degree of cash risk has been determined as 0 (no risk), 1 (medium risk) and 2 (high risk). In the final stage of the analysis process, each company's cash risk has been graded based on the hidden situations predicted by the model. Considering the positive and negative effects of financial items, factors such as negative cash flow or low net profit for the period have been evaluated as risk reasons. With this method, the possible financial risks faced by companies have been analyzed in more depth. GMM helps to reveal hidden cash flow problems and provides an important tool for evaluating the long-term financial performance of companies.

Findings

In the analysis conducted in terms of cash flows from operating activities (CFOA), companies have been classified into three clusters according to their cash flow risks. In 2021, companies such as ATEKS and ARSAN have in the low-risk group (Cluster 0), while BLCYT and BOSSA have in the high-risk group (Cluster 2). In 2022, DERIM and ISSEN were added to the low-risk group, while YATAS has been included in the high-risk group. In 2023, some companies that have high-risk in previous years reduced their risks, while BRKO remained in the high-risk group. These results reveal that some companies have been showed improvement in cash flow risk. According to the CFFA analyzes for 2021, 2022 and 2023, companies have been divided into three clusters according to the risk levels of cash flows from financing activities. In 2021, most companies have in the low-risk Cluster 0, while some companies such as DAGI and ENSRI have in the high-risk Cluster 2. In 2022, ENSRI and HATEK moved to the low-risk class, while BOSSA and KORDS have in the high-risk group. In 2023, RUBNS has been reduced its risk and has been included in Cluster 0, while BOSSA, KORDS and YATAS have been remained in the high-risk group. According to CFIA analyses for 2021, 2022 and 2023, companies have been divided into three clusters according to their cash flows from investment activities. In 2021, most companies were in the low-risk Cluster 0, while BOSSA has in the high-risk Cluster 2. In 2022, BOSSA and YATAS have been remained high-risk, while there have no major changes in other companies. In 2023, companies in Cluster 0 have remained low-risk, but BLCYT, BOSSA and some other companies have been included in the high-risk group. In 2021, 2022 and 2023, the latent risk levels of many companies were generally determined as "1" (cash risk), indicating that cash risks continue. While ARSAN, ATEKS, BLCYT, BOSSA and some other companies carry risks every year, changes were observed in the risk levels of companies such as KORDS, MNDRS and YATAS. For example, KORDS increased its risk level to "1" in 2023, while MNDRS decreased to "0" risk level in 2023. The cash flows of ARSAN, ATEKS, BLCYT and BOSSA have negative in 2021-2023. The factors that negatively affect cash flows include fair value losses, fixed asset purchase/sale differences, changes in trade receivables and interest income/expense adjustments. In particular, it has been determined that ARSAN and ATEKS experienced continuous cash shortages in all years, while BLCYT and BOSSA have similarly negative cash flows.

Research limitations

The limitations of this research include that the analyses are based only on financial reporting items and the effects of external economic factors or market conditions on companies are not taken into account. In particular, the effects of external factors such as macroeconomic variables, sectoral developments and market trends are beyond the scope of this research.

Implications (theoretical, practical and social)

This research focuses on internal financial reporting items specific to one sector in the analysis of cash flow risk. Theoretically, comparative studies conducted in different sectors and economic environments can expand theoretical knowledge and provide a more comprehensive analysis.

At the practical level, companies should not limit themselves to internal financial data when evaluating their financial performance. It is recommended that companies integrate their financial reporting and risk management strategies with external economic factors. This can enable them to conduct a more comprehensive risk assessment and develop more effective financial strategies. In particular, regular monitoring and analysis of external factors such as market conditions and macroeconomic variables can increase companies' financial flexibility.

From a social perspective, such financial analyses can support the sustainability and economic stability of companies. Good financial performance management can have positive effects on employment and social well-being. In addition, transparent and comprehensive financial reporting can increase investor confidence and support market stability. In terms of social responsibility, better management of financial risks by companies can reduce the social impact of economic uncertainty.

Originality/value

This study presents a significant innovation by applying the Hidden Markov Model (HMM) method to the analysis of account items in cash flow statements. HMM is widely used in areas such as financial time series analysis, exchange rate forecasting, stock market index movements forecasting and stock price forecasting. However, there is no existing study in the literature on the discovery of hidden situations in account items in cash flow statements by applying HMM. This research makes a valuable contribution to the literature by providing a better understanding of complex structures and hidden situations in financial data by using HMM in this context. This innovative approach can make a significant contribution to the development of financial analysis methods and more accurate evaluation of companies' cash flows.