

Türkiye İmalat Sektörünün Kredi ve Finansman Yapılarının Muhasebe Perspektifinden Risk Analizi: Kısıtlı Boltzmann Makinesi Yaklaşımı

Murat Kurtlar¹

Özet

Bu çalışma, Türkiye Cumhuriyet Merkez Bankası (TCMB) tarafından açıklanan imalat sektörü verilerini kullanarak, 2017-2023 yılları arasında faaliyet gösteren şirketlerin finansal durumunu ve sektör risklerini analiz etmeyi amaçlamaktadır. Çalışmada, sektör riskini temsil eden kısa ve uzun vadeli nakdi krediler, gayri nakdi krediler, tahviller ve leasing amaçlı fon kullanımı gibi değişkenler incelenmiş olup kısa vadeli nakdi krediler TL ve kısa vadeli nakdi krediler yabancı para olmak üzere, finansman kaynaklarının değişimi ve bunların sektörel etkileri detaylı bir şekilde değerlendirilmektedir. Ayrıca, PCA (Principal Component Analysis) yöntemiyle verilerin boyut azaltımı gerçekleştirilerek, temel bileşenlerin sektörel riskle olan ilişkisi ortaya koyulmuştur. Çalışmada, 35 finansal oran ve 17 adet sektör riskine ilişkin kredi ve finansman hesap kalemleri kullanılarak Kısıtlı Boltzmann Makinesi ile gizli durumlar ve enerji seviyeleri ortaya çıkarılmıştır.

1. Giriş

İşletmelerin faaliyetlerini sürdürebilmesi için alınması gereken yatırım ve finansman kararları, stratejik kararlardır. Bu kararların alınmasında kullanılan finansal bilginin kalitesi, alınan kararları, uygulanan planları ve dolayısıyla işletmenin değerini doğrudan etkilemektedir (McMenamin, 2002:15; Morgan, 2011:38). İşletmelerde finansal yönetim, uzun vadeli başarıyı etkileyen kritik bir unsurdur. İşletmelerin finansal yapıları, stratejik kararlarını doğrudan etkiler ve bu bağlamda, finansal verilerin analizi, yöneticilerin karar alma süreçlerine rehberlik ederken, yatırımcılar için de riskleri ve fırsatları değerlendirme imkanı sunmaktadır. Günümüzde

1 Dr. Öğr. Üyesi, Mersin Üniversitesi, muratkurtlar@mersin.edu.tr, 0000-0002-3266-275X

kullanılan veri analizi yöntemleri, bu süreci daha da kolaylaştırarak, büyük veri kümelerinden anlamlı bilgiler çıkarılmasına olanak tanımaktadır. Derin öğrenme, büyük verileri anlamlı bilgilere dönüştürerek, karar alıcılara gerçek zamanlı performans ölçümleri ve maliyetler hakkında bilgi sunmaktadır.

Finansın temelinde, bir varlığın gelecekteki davranışı, fiyatları ve getirebileceği kâr veya zararlarla ilgili belirsizlikler yer almaktadır. Risk kavramı, varlığın gerçek getirisinin, yatırımcının başlangıçta beklediği getiriden farklı olma olasılığını ifade etmektedir. Riskin ölçümü, getirilerin dağılımına bağlı olup bu durum da volatilitiyi tanımlamaktadır. Zaman içinde bir fiyat serisinin ne kadar değişkenlik gösterdiği genellikle logaritmik getirilerin standart sapmasıyla ölçülmektedir. Riski azaltmak için ilgili varlığın davranışının analiz edilmesi ve piyasa bilgileriyle ilişkilendirilmesi gerekmektedir. Bu alan, hem teorik hem de pratik açıdan büyük zorluklar barındıran finansal tahminlerin konusudur. Yapay zeka teknikleri bu tür problemlerin çözümünde özellikle başarılı olmaktadır (Orús, Mugel & Lizaso, 2019:2). Muhasebe, işletmelerin finansal durumunu analiz etmede ve değerlendirmede kritik bir rol oynamaktadır. Özellikle kredi ve finansman yapıları, bir işletmenin finansal durumunu belirlemede hayati öneme sahiptir. İmalat sektöründeki işletmelerin borç yönetimi ve karlılık ilişkisi muhasebe verileri aracılığıyla izlenerek yüksek borç seviyelerinin karlılık üzerindeki olumsuz etkisi ortaya çıkarılmaktadır. Ayrıca, kredi ve finansman yapılarındaki değişimlerin maliyetler üzerindeki etkisi, finansal tablolar aracılığıyla analiz edilerek sektör risklerinin değerlendirilmesine katkıda bulunmaktadır. Nakit akışının yönetimi, varlık değerlemesi ve finansal analiz, sektör performansının belirlenmesinde muhasebe verilerinin önemini ortaya koymaktadır. Dolayısıyla işletmelerdeki muhasebe bilgi sisteminin güvenilirliği, işletmelerin sektörel riskleri etkin bir şekilde analiz etmelerine ve yönetmelerine olanak tanımaktadır. Bu bağlamda, muhasebe bilgi sisteminin ürettiği bilgiler sadece işletmelerin finansal durumunu yansıtmakla kalmaz aynı zamanda finansal risklerin zamanında tespit edilmesini ve bu risklerin ortadan kaldırılmasına yönelik finansal stratejilerin geliştirilmesini sağlamaktadır.

Bu çalışmada, Türkiye Cumhuriyet Merkez Bankası (TCMB) tarafından 2017-2023 yıllarını kapsayan döneme ilişkin açıklanan imalat sektörüne ilişkin finansal oranlar ve sektör riskleri analiz edilerek, finansal risklerin ve performans göstergelerinin belirlenmesine yönelik önemli bulgular sunulmaktadır. Ayrıca, finansal oranlar ve sektör risklerinden oluşan veri setine temel bileşen analizinin uygulanmasıyla finansal verilerin yapılandırılması ve yorumlanması gerçekleştirilmektedir. Özellikle, temel bileşen analizi ile açıklanan varyans oranlarının incelenmesi, finansal bileşenlerin katkılarının

belirlenmesi ve imalat sektöründeki işletmelerin borç yönetim stratejileri üzerindeki etkilerinin analiz edilmesi hedeflenmektedir. Bu analizler kapsamında, 35 finansal oran ve sektör riskine ilişkin 17 göstergeden oluşan hesap kalemlerinin enerji seviyeleri ve gizli durumları Kısıtlı Boltzmann Makinesi ile ortaya çıkarılmaktadır. Kısıtlı Boltzmann Makinesi, verilerdeki gizli kalmış dinamikleri ve doğrusal olmayan ilişkileri çözümleyerek finansal oranların sektör riskleri üzerindeki etkisini derinlemesine incelemeye olanak tanımaktadır. Enerji seviyelerinin ve gizli durumların analizi, finansal veriler arasındaki karmaşık ilişkilerin anlaşılmasını ve imalat sektöründeki işletmelerin risk ve performans göstergelerine ilişkin gerçeğe uygun tahminlerde bulunulmasını sağlamaktadır. Bu yöntem, sektördeki borç yönetim stratejilerinin etkinliğini ve sektörel risklerin dinamiklerini daha kapsamlı bir şekilde ortaya koymada kritik bir rol oynamaktadır. Bu çalışma, işletmelere finansal stratejilerini geliştirmeleri ve risklerini yönetmeleri konusunda veri odaklı bir yaklaşım sunmayı amaçlamaktadır. Ayrıca, analiz sonuçlarının, finansal karar alma süreçlerinde ve gelecekteki stratejik planlamalarda rehberlik etmesi düşünülmektedir.

2. Literatür Taraması

Türkiye imalat sektörünün finansal performansını ve finansal başarısızlık risklerini belirlemeye yönelik birçok çalışma literatürde bulunmaktadır. Bu çalışmalar genellikle geleneksel finansal analiz yöntemleri kullanılarak sektörün finansal yapısını değerlendirmeyi amaçlamaktadır. Ancak, sektör risklerinin ileri düzey makine öğrenme teknikleri ile analiz edilmesi literatürde sınırlı kalmıştır. Özellikle, temel bileşen analizi (PCA) ve Boltzmann Makinesi gibi makine öğrenme modellerinin, imalat sektöründeki risklerin ve gizli kalmış finansal ilişkilerin ortaya çıkarılmasında kullanıldığı kapsamlı bir çalışma bulunmamaktadır. Bu çalışma, sektörel risklerin derinlemesine anlaşılmasına ve literatüre önemli katkı sağlamaktadır. Makine öğrenme yöntemleri aracılığıyla finansal risk ve performans göstergelerinin analiz edilmesi, sektördeki işletmelerin stratejik karar alma süreçlerine daha güçlü bir perspektif sunacağı düşünülmektedir.

Yurttabir ve Kıymetli Şen (2021) tarafından yapılan çalışmada Prophet yöntemi kullanılarak BİST İmalat Sektöründe işlem gören 156 şirketin 2009-2020 yıllarına ait üçer aylık 48 dönemlik verileri analiz edilmiştir. Prophet modeli ile yapılan tahminlerde, özellikle Bağfaş Bandırma Gübre Fabrikaları A.Ş. (BAGFS) şirketi gibi inişli çıkışlı değerlere sahip firmaların tahmin başarısının olumsuz etkilendiği ifade edilmektedir. Dilmaç, Altınkaynak ve Küçükler (2023) çalışmasında, Borsa İstanbul'da işlem gören 91 firmanın finansal performansları ile çeşitli risk faktörleri arasındaki

ilişki panel veri analizi ile incelenmektedir. Çalışma, imalat sektöründe yer alan firmaların satış gelirlerindeki dalgalanmalara karşı daha etkin bir maliyet yönetimi geliştirmeleri gerektiğini ortaya koymaktadır. Ertan ve Ersan (2018), 2000-2014 yılları arasında Borsa İstanbul imalat sektöründe yer alan 208 işletmenin finansal başarısızlık riskini değerlendirmekte ve Cox orantılı riskler modelinin en yüksek başarı oranını elde ettiğini ifade etmektedir. Cuicui Luo ve diğerlerinin (2017) gerçekleştirdiği çalışmada, CDS veri setlerine uygulanan kredi skorlama modellerinin performansları incelenmektedir. Çalışmada, derin öğrenme algoritmalarından biri olan Derin İnanç Ağları (Deep Belief Networks, DBN) ve Kısıtlı Boltzmann Makineleri'nin (Restricted Boltzmann Machines, RBM) sınıflandırma performansları, popüler kredi skorlama modelleri olan lojistik regresyon, çok katmanlı algılayıcı (multi-layer perceptron) ve destek vektör makineleri ile karşılaştırılmaktadır. Çalışmada, performans değerlendirmesi, sınıflandırma doğruluğu ve alıcı işletim karakteristik eğrisinin altındaki alan (AUC) metriği kullanılarak yapılmaktadır. Çalışmanın sonucunda, Derin İnanç Ağları'nın (DBN) diğer modellerle kıyaslandığında en yüksek performansı sergilediği ifade edilmektedir. Jakub ve diğerlerinin (2015) çalışmasında, kredi puanlaması, bireylerin veya kuruluşların kredi başvurularında karşılaştıkları risklerin değerlendirilmesi süreci olarak ele alınmaktadır. Çalışmada bu sürecin, kredi verenlerin, geri ödeme yapma olasılığı yüksek olan başvuru sahipleri ile yeterince güvenilir bulunmayanlar arasında ayırım yapmalarına olanak tanıdığı ifade edilmektedir. Ayrıca çalışmada Kısıtlı Boltzmann Makinesi (ClassRBM) kullanılarak yorumlanabilir bir kredi puanlama modeli geliştirilmiştir. ClassRBM'nin, kredi durumunu öngörebilen bağımsız bir sınıflandırıcı olarak eğitildiği ancak modelin yorumlanabilirliğinin sınırlı olduğu belirtilmektedir. Çalışmanın sonucunda, ClassRBM'nin Bagging, Lojistik Regresyon, CART, RIPPER gibi yöntemlerle karşılaştırıldığında üstün performans sergilediği ve bu başarının Holm-Bonferroni prosedürü ile doğrulandığı ifade edilmektedir. Bayraktar ve diğerlerinin (2018) çalışmasında, kredi talebinde bulunan müşterilerin kredi başvurularının onaylanması veya reddedilmesi sürecini kolaylaştırmak amacıyla bir prototip uygulama geliştirildiği belirtilmektedir. Çalışmada geliştirilen uygulama, Sınıflandırılmış Kısıtlı Boltzmann Makinesi (ClassRBM) ve Çok Katmanlı Yapay Sinir Ağları gibi derin öğrenme yöntemlerini, yaygın olarak kullanılan makine öğrenimi algoritmaları ile karşılaştırmaktadır. Bu algoritmalar, kredi başvurularının değerlendirilme sürecini hızlandırmayı hedeflemekte olup, ClassRBM algoritmasının, faktör seçme işlemine ihtiyaç duymaksızın verideki gizli ve doğrusal olmayan desenleri çıkarma konusunda daha başarılı olduğu belirtilmiştir. Raghavan ve El Gayar (2019) tarafından

gerçekleştirilen bu çalışmada, dolandırıcılık işlemlerini izlemek ve tespit etmek amacıyla veri madenciliği tekniklerinin kullanılması hedeflenmiştir. Çalışmada, k-en yakın komşu (KNN), rastgele orman (Random Forest) ve destek vektör makineleri (SVM) gibi makine öğrenimi yöntemleri ile otomatik kodlayıcılar (Autoencoders), evrişimli sinir ağları (CNN), kısıtlı Boltzmann makineleri (RBM) ve derin inanç ağları (DBN) gibi derin öğrenme teknikleri karşılaştırılmaktadır. Analizlerin, Avrupa (EU), Avustralya ve Almanya veri setleri üzerinde gerçekleştirildiği ve performans değerlendirmesinin ROC eğrisi altındaki alan (AUC), Matthews Korelasyon Katsayısı (MCC) ve başarısızlık maliyeti gibi üç temel değerlendirme metriği ile yapıldığı ifade edilmektedir. Çalışmada, RBM modeli için elde edilen MCC değeri 0.0984, AUC değeri 0.5524 ve başarısızlık maliyeti 14.160 olarak hesaplanmış olup çalışmada kullanılan RBM modelinin, dolandırıcılık tespiti için Weiman Wang tarafından geliştirildiği ifade edilmektedir.

3. Kavramsal Çerçeve

3.1. Kısıtlı Boltzmann Makinesi

Boltzmann makinesi, simetrik olarak birleştirilmiş stokastik ikili birimlerden oluşan bir ağıdır. Boltzmann Makinesi, çok sayıda zayıf kısıtlama içeren kısıtlama optimizasyon görevlerine çok uygun paralel bir hesaplama organizasyonudur (Ackley, Hinton, & Sejnowski, 1985:149; Hinton, 1989:143; Hinton & Salakhutdinov, 2012:448). Gözetimsiz öğrenmede kullanılan değişkenler, gözlemlenebilen (görünür) birimler ve gizli birimler olmak üzere iki ana bileşenden oluşmaktadır. Görünür birimler, veri setindeki her bir örneği temsil ederken, gizli birimler, bu verilerin daha derin ve soyut özelliklerini öğrenmeye yardımcı olmaktadır. Sistem, bu iki birim arasındaki etkileşimlerle çalışmakta ve her bir birim arasındaki ilişkileri öğrenmektedir. Sistemin belirli bir durumundaki enerji, hem görünür hem de gizli birimlerin birbirleriyle nasıl etkileşime girdiğini ve bu etkileşimlerin ne kadar “maliyetli” olduğunu ölçmektedir. Enerji ne kadar düşükse, o sistemin o durumdaki olasılığı o kadar yüksektir. Bu enerji kavramı, sistemin genel olasılık dağılımını tanımlar ve bu dağılıma göre, sistem veri üzerinde tahminlerde bulunur veya yeni örnekler üretir. Sistemde görünür ve gizli birimler arasındaki ilişkiler enerjiyle açıklanmakta ve bu enerji, sistemin olasılıklarının temelini oluşturur (Welling & Hinton, 2002:1)

Boltzmann Makinesi (Boltzmann Machine- BM) modeli, güçlü bir gözetimsiz öğrenme yeteneğine sahip olup, karmaşık verilerden özellikler çıkarabilmektedir. Ancak, eğitim hızı yavaş ve hesaplama doğruluğu düşüktür, bu da gerekli örnekleri elde etmeyi zorlaştırmaktadır. BM ile

karşılaştırıldığında, Kısıtlı Boltzmann Makinesi (Restricted Boltzmann Machine-RBM), katman içi bağlantısızlık benimseyen yönsüz bir grafiksel modeldir. Yapısı, görünür düğümler ve gizli düğümlerden oluşur. Görünür katman, ağın alt katmanını, gizli katman ise üst katmanını temsil eder. İki katman, ağırlıklarla birbirine bağlanmıştır. Ancak, RBM’de görünür katman biriminin durumu verildiğinde, gizli katman biriminin aktivasyon koşulu bağımsızdır (Ali et al., 2020; Chemweno et al., 2018). RBM, görünür ve gizli birimler içeren bir üretici stokastik ağdır. Bu modelde, görünür birimler ile gizli birimler arasında bağlantı ağırlıkları ve yanlılık terimleri bulunmaktadır. RBM’nin enerji ve olasılık fonksiyonları tanımlanmış olup, modelin performansını artırmak için verinin log-olasılığı maksimize edilmektedir. Bu işlem, veri dağılımı ile model tarafından tanımlanan dağılım arasındaki Kullback-Leibler (KL) sapmasını minimize etmekle eşdeğerdir. Yaklaşık bir posterior dağılım kullanılarak gerçek posterior dağılımı tahmin edilmeye çalışılmakta ve bu süreçte mean-field yaklaşımıyla açıklama yan etkileri azaltılmaktadır. Bu sayede modelin öğrenme süreci daha verimli hale getirilmektedir (Zhang, Ding, Zhang & Xue, 2018:1187-1188).

3.2. Temel Bileşen Analizi (Principal Component Analysis -PCA)

Karhunen-Loeve genişlemesi olarak da bilinen Temel Bileşen Analizi (Principal Component Analysis-PCA), yüz tanıma gibi desen tanıma ve bilgisayarlı görüş alanlarında yaygın olarak kullanılan klasik bir özellik çıkarma ve veri temsil tekniğidir (Karamizadeh, 2013:173). PCA’nın temel amacı, çok sayıda birbiriyle ilişkili değişkenden oluşan bir veri kümesinin boyutsallığını azaltmak ve veri kümesinde mevcut olan varyasyonun mümkün olduğunca çoğunu korumaktır. Bu durum, ilişkisiz olan ve ilk birkaçının tüm orijinal değişkenlerdeki varyasyonun çoğunu koruyacak şekilde sıralanan temel bileşenleri (PC’ler) yeni bir değişken kümesine dönüştürerek elde edilmektedir (Jolliffe & Morgan, 1992:1). PCA’nın avantajı, çok değişkenli verilerin temel bileşenler, faktörler veya gizli değişkenler olarak adlandırılan daha az sayıda değişkenle temsil edilmesine olanak sağlamasıdır.

PCA, finansal verilerin analizinde sıklıkla kullanılan kullanılmaktadır. PCA, yüksek boyutlu verilerin daha düşük boyutlu bir alt kümesine indirgenmesini sağlar ve karmaşık ilişkilerin daha iyi anlaşılmasına yardımcı olur. Bu yöntem, özellikle birçok değişkenin aynı anda değerlendirildiği finansal analize önemli katkılar sunmaktadır.

4. Veri Seti ve Metodoloji

Bu çalışma, Türkiye Cumhuriyet Merkez Bankası (TCMB) tarafından 2017-2023 yıllarını kapsayan döneme ilişkin açıklanan imalat sektörü

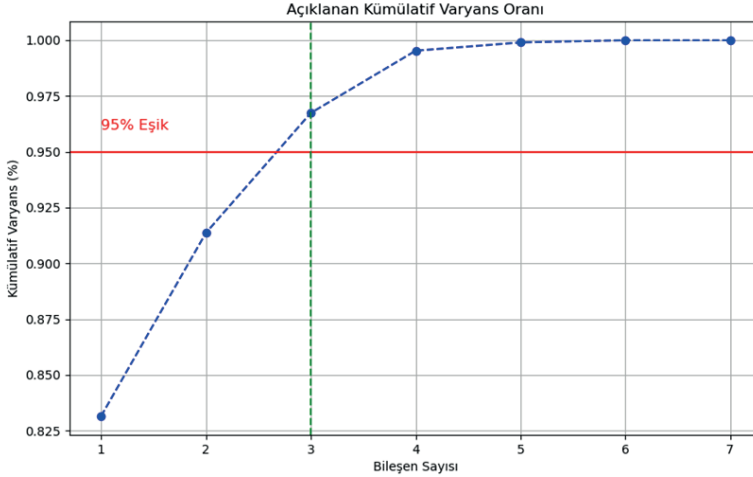
verilerini kullanarak bu sektörün finansal yapılarını ve sektör risklerini analiz etmeyi amaçlamaktadır. Veri seti, Türkiye imalat sektöründe faaliyet gösteren işletmelerin finansal performanslarını ve kredi kullanımını ölçen çeşitli göstergeleri içermektedir. Bu göstergeler arasında kısa ve uzun vadeli nakdi krediler, gayri nakdi krediler, tahviller ve leasing amaçlı fon kullanımı gibi değişkenler yer almaktadır. Veri seti 35 adet finansal oran ve 17 adet sektör riski değişkeninden oluşmaktadır. Finansal oranlar arasında cari oran, öz kaynak oranları, faaliyet kar marjı gibi şirketlerin likidite, kârlılık ve borç ödeme yeteneklerini ölçen oranlar yer alırken, sektör riskine yönelik göstergeler arasında kısa vadeli nakdi kredi TL (KV NKTL), kısa vadeli nakdi kredi yabancı para (KV NKYP), uzun vadeli nakdi kredi TL (UV NKTL), uzun vadeli nakdi kredi yabancı para (UV NKYP), kısa vadeli gayri nakdi kredi TL (KV GNKTL), kısa vadeli gayri nakdi kredi yabancı para (KV GNKYP), uzun vadeli gayri nakdi kredi TL (UV GNKTL), uzun vadeli gayri nakdi kredi yabancı para (UV GNKYP), kısa vadeli tasfiye olunacak kredi TL (KV TOKTL), kısa vadeli tasfiye olunacak kredi yabancı para (KV TOKYP), kısa vadeli tahvil (KV THVL), uzun vadeli tahvil (UV THVL), finansman bonusu (FİNB), kısa vadeli leasing amaçlı fon kullanımı TL (KV LEASTL), kısa vadeli leasing amaçlı fon kullanımı yabancı para (KV LEASYP), uzun vadeli leasing amaçlı fon kullanımı TL (UV LEASTL), uzun vadeli leasing amaçlı fon kullanımı yabancı para (UV LEASYP) hesap kalemleri bulunmaktadır. Bu hesap kalemleri, imalat sektörünün genel finansal yapısını ve risk seviyelerini değerlendirmek için kullanılmıştır.

Çalışmada kullanılan veri seti üzerinde analizler gerçekleştirilmeden önce veri yapısının modellenmesi ve daha iyi yorumlanabilmesi amacıyla Standartlaştırma (StandardScaler) yöntemi uygulanmıştır. Bu işlem, verilerin farklı ölçeklerden etkilenmemesi için yapılmıştır. Veri setindeki ilişkileri ve sektörel riskleri daha derinlemesine analiz edebilmek için RBM kullanılmıştır. Çalışmada kullanılan RBM modeli, verilerin gizli özelliklerini ortaya çıkarmak ve enerji seviyelerini analiz etmek için kullanılmıştır. Özellikle gizli durumlar ve enerji seviyeleri, imalat sektöründeki risklerin ve finansal yapıların hangi durumlarda anormal davranışlar sergilediğini ortaya koymak amacıyla incelenmiştir. Veriler, analiz öncesinde StandardScaler kullanılarak standartlaştırılmıştır. Bu sayede her bir finansal oran ve sektör riski göstergesi, aynı ölçek üzerinden değerlendirilmiştir. Veri setinde yer alan değişkenler arasında daha yüksek seviyedeki ilişkileri öğrenmek amacıyla optimal bileşen sayısı PCA yöntemi ile 3 olarak belirlenmiş ve 1000 iterasyon boyunca öğrenme gerçekleştirilmiştir. PCA yöntemiyle verilerin boyutu azaltılarak temel bileşenlerin sektör riski ile olan ilişkisi ortaya koyulmuştur. Bu sayede, en önemli değişkenlerin sektör riski üzerindeki

etkisi belirlenmiştir. Verilerin gizli durumları kullanılarak her yıl için sektör riskinin enerji seviyesi hesaplanmıştır. Enerji seviyeleri, sistemin belirli bir finansal yapı ve kredi kullanım düzeyinde ne kadar dengede olduğunu göstermektedir. Çalışmada kullanılan modellerin uygulanmasında Python programlama dili kullanılmıştır.


5. Analiz ve Bulgular

Şekil 1’de, optimal bileşen sayısı ve bu bileşenler tarafından açıklanan kümülatif varyans oranları yer almaktadır. Şekil 1 incelendiğinde, birinci bileşen toplam varyansın %83,15’ini açıklamaktadır. Bu durum, verideki en yüksek varyansın bu bileşende yoğunlaştığını ve firmaların genel borçlanma yapısı ile finansal eğilimlerinin büyük ölçüde bu bileşende temsil edildiğini göstermektedir. İkinci bileşen ise toplam varyansın %8,22’sini açıklamaktadır. Dolayısıyla bileşenin daha düşük bir açıklayıcılığa sahip olduğunu ve birinci bileşenden daha az bilgi sunduğunu ifade etmektedir. İkinci bileşen, muhtemelen kısa vadeli borç yönetimi veya finansal istikrarla ilgili belirli değişim süreçlerini yansıtmaktadır. Üçüncü bileşen, varyansın %5,37’sini açıklamakta olup bu durum da bileşenin sınırlı bir bilgi sağladığını ortaya koymaktadır. Üçüncü bileşenin daha spesifik finansal değişim dinamiklerine dair ipuçları sunduğu ifade edilebilir.



Şekil 1. Açıklanan Kümülatif Varyans Oranı

Şekil 2’de, PCA bileşen matrisi yer almaktadır. Birinci bileşen, tüm değişkenlerde pozitif katkıya sahiptir. Özellikle KV LEASYP (0,264), UV LEASYP (0,263), KV NKYP (0,261) ve UV GNKYP (0,262) gibi değişkenlerin yüksek katkıya sahip olduğu tespit edilmiş olup bu bileşenin kredi ve leasing işlemlerine dair genel bir eğilimi temsil ettiği ifade edilebilir. Tüm bu değişkenlerin pozitif katkıları, imalat sektöründe yer alan işletmelerin kısa ve uzun vadeli borçlanma ile leasing kalemlerinde paralel bir hareketlilik gösterdiğini ve borçlanma ve leasing faaliyetlerinin ortak bir eğilim izlediğini ortaya koymaktadır. İkinci bileşende, pozitif ve negatif katkılar arasında belirgin farklar bulunmaktadır. Özellikle KV TOKTL (-0,794) ve KV TOKYP (-0.350) gibi değişkenler, yüksek negatif katkılarla öne çıkmaktadır. Bu durum, firmaların kısa vadeli tasfiye olunacak kredileri Türk lirası (KV TOKTL) ile yabancı para (KV TOKYP) cinsinden olan borçları arasındaki eğilimlerin birbirinden farklılaştığını göstermektedir. Ayrıca, UV THVL (0,243) gibi değişkenlerin pozitif katkıları, uzun vadeli tahvillerin, kısa vadeli borç yüklerinden ayrılan bir eğilim sergilediğini ortaya koymaktadır. Bu bileşen, firmaların kısa vadeli borç yönetim stratejilerinin bu bileşende daha belirgin olduğunu göstermektedir. Üçüncü bileşende ise özellikle KV THVL (0,383), FİNB (0.384) ve UV THVL (-0,552) değişkenleri dikkat çekmektedir. UV THVL (uzun vadeli tahviller), negatif katkı ile öne çıkarken, bu durum uzun vadeli tahvillerin firmaların genel borçlanma davranışlarından farklı bir eğilim izlediğini ortaya koymaktadır. Buna karşın, FİNB (0,384) ve KV THVL (0,383) gibi değişkenler, finansman bonoları ve kısa vadeli tahvillerin olumlu bir ilişki gösterdiğini işaret etmektedir. Üçüncü bileşen, uzun vadeli tahviller ile finansman bonoları arasındaki karmaşık ilişkiyi temsil edebilir.

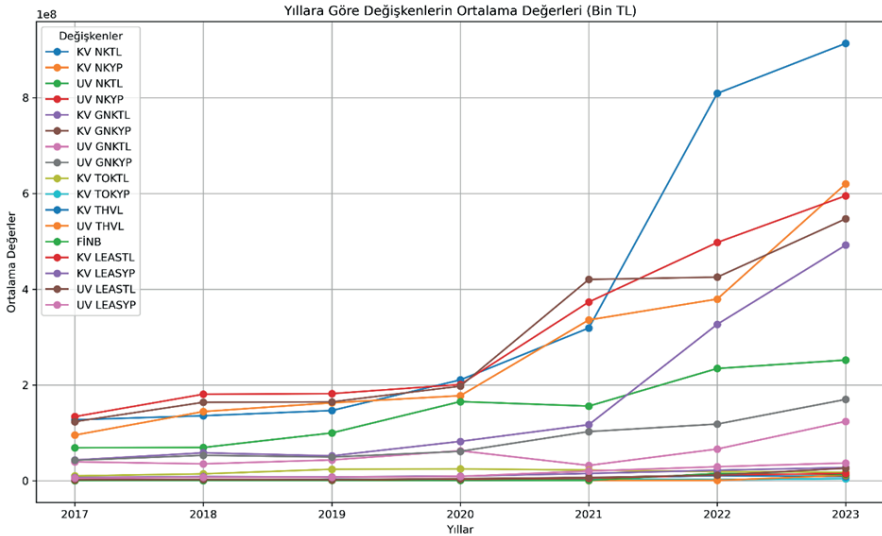


Şekil 2. PCA Bileşenlerinin Değişkenlere Katkısı

Sektör riskini temsil eden değişkenlerin ortalama değerleri Şekil 3'te yer almaktadır. Şekil 3 incelendiğinde, 2017-2023 yıllarını kapsayan dönemde KV NKTL'de önemli bir artış gözlemlenmektedir. 2017 yılında 127 milyar TL olan bu kredi tutarı, 2023 yılı itibarıyla 913 milyar TL'ye artmıştır. Benzer bir eğilim de KV NKYP'de gözlemlenmekte olup bu kredi türü de 2017 yılında 95 milyar TL'den 2023 yılında 620 milyar TL'ye artmıştır. Bu veriler, kısa vadeli nakdi kredi talebindeki belirgin bir artışı yansıtmakta olup işletmelerin likidite sıkıntısı yaşadığını ve bu durumu borçlanma yoluyla finanse ettiklerini ortaya koymaktadır. Uzun vadeli kredi kullanımında da belirgin artışlar yaşanmaktadır. UV NKTL, 2017 yılında 68 milyar TL'den 2023 yılında 252 milyar TL'ye artmıştır. Bu durum, firmaların uzun vadeli borçlanmaya yöneldiğini ve muhtemelen büyüme veya yatırım amaçlı finansman sağladıklarını göstermektedir. 2022 ve 2023 yıllarında bu kalemden belirgin artışlar gözlemlenmektedir. 2023 yılında KV GNKTL, 2017'deki 43 milyar TL'den 2023 yılında 492 milyar TL'ye artmıştır. Bu artış, işletmelerin finansal risklerini yönetmek amacıyla gayri nakdi kredilere yönelmeleri olasılığını ortaya koymaktadır. KV GNKYP'de de benzer şekilde önemli artışlar yaşanmıştır. 2022 yılı itibarıyla finansman bonolarında belirgin bir artış kaydedilmiştir. 2017 yılında 195 milyon TL olan finansman bonusu tutarı, 2022 yılında 15 milyar TL'ye ulaşmıştır. Bu durum, işletmelerin finansman sağlamada bono kullanımını artırdığını ve muhtemelen ekonomik dalgalanmalara karşı dayanıklılıklarını artırmaya çalıştıklarını göstermektedir.

2021-2023 yıllarını kapsayan dönemde kısa vadeli leasing kalemlerinde de belirgin artışlar gözlemlenmektedir. KV LEASTL, 2017 yılında 1,98 milyar TL'den 2023 yılı itibarıyla 15,1 milyar TL'ye artmıştır. Bu artış, işletmelerin varlık edinimlerini leasing aracılığıyla yaptıklarını göstermektedir. Benzer bir durum KV LEASYP için de geçerlidir. Uzun vadeli leasing kalemlerinde de belirgin bir artış gözlemlenmektedir. 2017 yılında 2,4 milyar TL olan UV LEASTL, 2023 yılı itibarıyla 25,9 milyar TL'ye artmıştır. Bu artış, şirketlerin uzun vadeli finansman sağlamak için leasing yöntemini tercih ettiklerini ortaya koymaktadır.

2022 ve 2023 yıllarında tüm kalemlerde gözlemlenen büyük artışlar, ekonomik koşulların kötüleşmesiyle birlikte işletmelerin kredi ve leasing gibi borçlanma yollarına daha fazla yönelmelerinin bir göstergesi olabilir. Ayrıca, bu yıllarda artan ekonomik riskler, finansal borçlanma ve gayri nakdi kredi kullanımında ciddi sıçramalar yaşandığını ortaya koymaktadır. 2021 yılı ve öncesindeki finansal kalemlerdeki artışlar, 2021 sonrası döneme göre daha düşük seviyelerde kalmaktadır. Ancak, 2021 yılından itibaren borçlanma kalemlerinin hızlı bir şekilde artması, ekonomik belirsizliklerde veya piyasa dinamiklerinde meydana gelen değişikliklerin bir göstergesi olabilir. Veriler, özellikle 2021 sonrası dönemde ciddi finansal dalgalanmaların yaşandığını ve işletmelerin borçlanma, kredi ve leasing gibi finansman yöntemlerine yöneldiğini göstermektedir. Özellikle 2022 ve 2023 yıllarında gözlemlenen büyük artışlar, sektördeki artan risklerin ve işletmelerin nakit akışlarını koruma çabalarının bir yansıması olabilir.



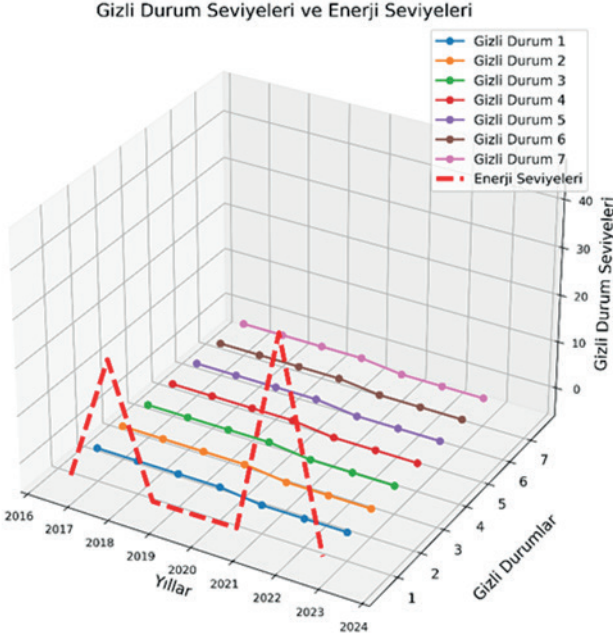
Şekil 3. Sektör Risklerinin Yıllara Göre Ortalama Değerleri

Yıllara göre imalat sektör riski enerji seviyeleri ve gizli durumları Şekil 4'te yer almaktadır. Ayrıca enerji seviyeleri Tablo 1'de gösterilmektedir. 2017, 2019, 2020 ve 2023 yıllarına ait enerji seviyeleri sıfır olarak hesaplanmıştır. Bu durum, modelin bu yıllarda “anormal” bir enerji durumu yakalamadığını ve finansal oranların nispeten sabit seyrettiğini göstermektedir. Dolayısıyla, bu yıllarda sektörde risklerin düşük olduğu veya finansal performansın dengeli bir şekilde sürdüğü çıkarımı yapılabilir. Diğer bir deyişle, sektör bu yıllarda “düşük enerji” seviyesinde kalmış, herhangi bir olağanüstü durum gözlemlenmemiştir. 2018 (33,2673) ve 2022 (43,6537) yıllarında hesaplanan enerji seviyelerinin yüksekliği sektörde önemli dalgalanmaların ve risk artışlarının yaşandığını göstermektedir. Bu yıllardaki yüksek enerji seviyeleri, özellikle dış ekonomik faktörler, piyasa oynaklıkları ve finansal oranlarda meydana gelen büyük değişimlerle ilişkilendirilebilir. Bu durumu, Türkiye'nin 2018'de başlayan ve 2023'e kadar devam eden ekonomik kriziyle ilişkilendirmek mümkündür. 2018 yılında döviz kurlarındaki hızlı yükseliş ve enflasyonun artması, bu yıl için gözlemlenen yüksek enerji seviyelerinin temel sebeplerinden biri olabilir. Kriz, finansal bulaşma etkisiyle sektörde risklerin artmasına neden olmuştur. Ayrıca, dünya genelinde yayılan COVID-19 salgınının Türkiye'de Mart 2020'de ilk vakanın açıklanmasıyla başlayan etkileri de ekonomik belirsizlikleri derinleştirmiştir.

2022 yılı içinde enflasyonun %85'lere ulaşması (www.tuik.gov.tr), sektördeki enerji seviyelerinin yeniden yükselmesine neden olduğu ifade edilebilir. Yüksek enerji seviyesi, bu dönemde ekonomik göstergelerdeki oynaklığın ve sektördeki risklerin zirveye çıktığını göstermektedir. Buna karşılık, 2021 yılında düşük fakat sıfır olmayan bir enerji seviyesi (0,0843) gerçekleşmiştir. Bu durum, COVID-19 pandemisinin ekonomik etkilerinin devam ettiğini ancak 2018 ve 2022 yıllarına göre daha az olduğunu göstermektedir. Bu bağlamda, Türkiye'nin ekonomik krizi ve salgının etkileri sektörde gözlemlenen enerji seviyelerinin dalgalanmasına yol açmıştır.

Tablo 1. Enerji Seviyeleri

Yıllar	Enerji Seviyeleri
2017	0,0000
2018	26,7377
2019	0,0000
2020	0,0000
2021	0,1182
2022	42,2244
2023	0,0000



2017-2020 yılları arasında, tüm gizli durumların 1,0000 seviyesinde olması, finansal sistemin bu dönemde oldukça kararlı ve istikrarlı olduğunu göstermektedir. Bu sonuç, modelin belirlediği faktörlerin sabit kaldığını ve bu yıllarda risk seviyelerinin düşük olduğunu işaret etmektedir. Bu durum, sistemin tüm faktörler açısından tam kapasite ile çalıştığına ve finansal dengelerin korunduğuna işaret etmektedir. Buna karşılık, 2021-2023 yılları arasındaki gizli durumların tamamının 0,0000 seviyesinde olması, sistemin bu yıllarda “etkin olmadığı” veya düşük aktivite sergilediği anlamına gelebilir. Bu durum, finansal dinamiklerin zayıfladığını veya sektör risklerinin bu yıllarda ya düşük kaldığını ya da model tarafından algılanmadığını göstermektedir. Dalgalanma yaşanan 2018 ve 2022 yıllarında ise, enerji seviyelerinin yüksek olması sektörde önemli ekonomik hareketliliklerin veya krizlerin yaşandığını işaret etmektedir. Bu yıllarda finansal oranların büyük dalgalanmalara uğradığı ve sektör risklerinin arttığı anlaşılmaktadır. Diğer taraftan, 2017, 2019, 2020 ve 2023 yıllarında enerji seviyelerinin sıfır olması, finansal sistemin bu dönemlerde daha stabil olduğunu ve sektörde ciddi risklerin olmadığını göstermektedir. Bu yıllarda gizli durumların tamamının aktif olması da sistemin kararlı bir yapıya sahip olduğunu desteklemektedir. Genel olarak, bu bulgular, sektör risklerinin özellikle 2018 ve 2022 yıllarında arttığını ve finansal oranlarda ciddi dalgalanmaların yaşandığını gösterirken,

diğer yıllarda ise sistemin daha stabil ve risklerin düşük olduğunu ortaya koymaktadır.

6. Sonuç

Bu çalışma, Türkiye imalat sektöründe 2017-2023 yıllarını kapsayan dönemde finansal yapıların ve sektör risklerinin analizini kapsamlı bir şekilde ele almıştır. Çalışmada kullanılan veri seti, likidite oranları, finansal yapı oranları, faaliyet oranları, karlılık oranları, kısa ve uzun vadeli nakdi ve gayri nakdi krediler, tahviller, leasing işlemleri gibi 35 finansal oran ve 17 sektör riskini kapsamaktadır. Bulgular, sektörün borçlanma yapısındaki değişikliklerin ekonomik dalgalanmalarla yakından ilişkili olduğunu göstermektedir. Sonuçlar, özellikle 2021-2023 yıllarında borçlanma ve finansman yöntemlerine yönelimin arttığını ve bu yıllarda kredi ve leasing işlemlerinde önemli artışlar yaşandığını ortaya koymaktadır. Kısa vadeli nakdi kredi kullanımının 2017'den 2023'e kadar belirgin şekilde artması, firmaların likidite yönetiminde zorlandığını ve borçlanmaya yöneldiğini göstermektedir. Aynı zamanda uzun vadeli kredilerdeki artışlar, işletmelerin büyüme ve yatırım finansmanına yönelik ihtiyaçlarını yansıtmaktadır. 2021 sonrası dönemde sektör riskinin hızla artması ve özellikle 2022-2023 yıllarında finansman bonoları ve leasing işlemlerinde yaşanan sıçramalar, sektörün ekonomik belirsizliklere karşı finansal esneklik arayışında olduğunu göstermektedir. 2018 ve 2022 yıllarında hesaplanan yüksek enerji seviyeleri, sektörde önemli finansal dalgalanmaların ve risk artışlarının yaşandığını ortaya koymaktadır. Özellikle 2018'deki döviz krizi ve 2022'deki yüksek enflasyon, sektörün finansal istikrarını olumsuz olarak etkilemiştir. 2017-2020 yıllarında sektörün daha stabil bir performans sergilediğini ve düşük risk seviyeleriyle karakterize olduğunu göstermektedir. Buna karşılık, 2021-2023 döneminde finansal risklerin arttığı ve bu durumun sektörde önemli yapısal değişimlere yol açtığı anlaşılmaktadır. Çalışma, finansal oranlar ve sektör riskleri arasındaki ilişkileri ortaya koyarak, Türkiye imalat sektörünün ekonomik kriz dönemlerinde nasıl etkilendiğini kapsamlı bir şekilde analiz etmiştir.

Sonuç olarak, Türkiye imalat sektöründe 2017-2023 yılları arasında yaşanan finansal süreçler, firmaların borçlanma yapısı ve risk yönetimi stratejileri üzerinde önemli etkiler yaratmıştır. Özellikle kısa vadeli kredilere olan bağımlılık, ekonomik belirsizliklerin yoğun olduğu dönemlerde daha belirgin hale gelmiş ve sektör genelinde finansal risklerin artmasına yol açmıştır. Bu dönemde kredi ve finansman yapılarına yönelik analizler, sektör risklerinin dinamiklerini anlamak açısından değerli bilgiler sunmuştur. Genel olarak, firmaların finansal yönetim süreçlerinde daha proaktif ve

sürdürülebilir stratejiler geliştirmeleri, sektördeki risklerin azaltılmasına katkıda bulunabilir. Bu bağlamda, firmaların sadece borçlanmaya dayalı büyüme politikalarından ziyade, daha sağlam finansal planlamalar ve risk yönetimi uygulamaları benimsemeleri büyük önem taşımaktadır.

Kaynakça

- Ackley, D. H., Hinton, G. E., & Sejnowski, T. J. (1985). A learning algorithm for boltzmann machines. *Cognitive Science*, 9(1), 147-169.
- Ali, S. A., Raza, B., Malik, A. K., et al. (2020). An optimally configured and improved deep belief network (oci-dbn) approach for heart disease prediction based on ruzzo-tompa and stacked genetic algorithm. *IEEE Access*, 8, 65947-65958
- Bayraktar, M., Aktaş, M. S., Kalıpsız, O., Susuz, O., & Bayracı, S. (2018, May). Credit risk analysis with classification restricted boltzmann machine. *26th Signal Processing and Communications Applications Conference (SIU), IEEE*.
- Chemweno, P., Pintelon, L., Muchiri, P. N., et al. (2018). Risk assessment methodologies in maintenance decision making: A review of dependability modelling approaches. *Reliability Engineering & System Safety*, 173, 64-77.
- Dilmaç, M., Altınkaynak, F., & Küçükler, M. (2023). Firmalara özgü risklerin finansal performans üzerindeki etkileri: bist imalat sektörü üzerine bir inceleme. *Muhasebe ve Finans İncelemeleri Dergisi*, 6(2), 188-200.
- Ertan, A. S., & Ersan, Ö. (2018). Finansal başarısızlığı belirleyen etkenler: türkiye imalat sektörü örneği. *Marmara Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 40(2), 181-207.
- Hinton, G. E., & Salakhutdinov, R. R. (2012). A better way to pretrain deep boltzmann machines. *Advances in Neural Information Processing Systems*, 25.
- https://proceedings.neurips.cc/paper_files/paper/2012/file/7d771e0e8f3633ab54856925ccdfc5d-Paper.pdf
- Hinton, G. E. (1989). Deterministic Boltzmann learning performs steepest descent in weight-space. *Neural computation*, 1(1), 143-150. <http://www.cs.toronto.edu/~hinton/absps/dbmNC.pdf>
- Jolliffe, I. T., & Morgan, B. J. T. (1992). Principal component analysis and exploratory factor analysis. *Statistical Methods in Medical Research*, 1(1), 69-95.
- Karamizadeh, S., Abdullah, S. M., Manaf, A. A., Zamani, M., & Hooman, A. (2013). An overview of principal component analysis. *Journal of Signal and Information Processing*, 4(3), 173-175. doi:10.4236/jsip.2013.43B031
- Luo, C., Wu, D., & Wu, D. (2017). A deep learning approach for credit scoring using credit default swaps. *Engineering Applications of Artificial Intelligence*, 65, 465-470.
- McMenamin, J. (2002). *Financial management: an introduction*. Routledge. https://www.academia.edu/download/55276047/_Jim_Mcmenamin__Financial_Management_An_IntroductTUGAS_UASSS_.pdf

- Morgan, M. J. (2001). A new role for finance: Architect of the enterprise in the information age. *Strategic Finance*, 83(2), 36.
- Orús, R., Mugel, S., & Lizaso, E. (2019). Quantum computing for finance: Overview and prospects. *Reviews in Physics*, 4, 100028.
- Raghavan, P., & El Gayar, N. (2019, December). Fraud detection using machine learning and deep learning. In *2019 International Conference on Computational Intelligence and Knowledge Economy (ICCIKE)*, IEEE.
- Tomczak, J. M., & Zięba, M. (2015). Classification restricted Boltzmann machine for comprehensible credit scoring model. *Expert Systems with Applications*, 42(4), 1789-1796. <http://dx.doi.org/10.1016/j.eswa.2014.10.016>
- Türkiye Cumhuriyet Merkez Bankası (TCMB), <https://www.tcmb.gov.tr/> Erişim Tarihi: 09.11.2024
- Türkiye İstatistik Kurumu (TÜİK), www.tuik.gov.tr Erişim Tarihi:09.11.2024
- Welling, M., & Hinton, G. E. (2002, August). A new learning algorithm for mean field Boltzmann machines. In International conference on artificial neural networks (pp. 351-357). Berlin, Heidelberg: Springer Berlin Heidelberg. <http://www.gatsby.ucl.ac.uk/publications/tr/tr01-002.pdf>
- Wentzell, P. D., Andrews, D. T., Hamilton, D. C., Faber, K., & Kowalski, B. R. (1997). Maximum likelihood principal component analysis. *Journal of Chemometrics: A Journal of the Chemometrics Society*, 11(4), 339-366.
- Yurttabir, A., & Şen, İ. K. (2021). Finansal performans tahmininde prophet modeli: imalat sektörü uygulaması. *Journal of Economics Finance and Accounting*, 8(4), 160-166.
- Zhang, N., Ding, S., Zhang, J., & Xue, Y. (2018). An overview on restricted Boltzmann machines. *Neurocomputing*, 275, 1186-1199.