

Nicel Yöntemlerle Performans, Risk ve Teknoloji Temelli Ekonomik Analizler

Editör
KÜBRANUR ÇEBİ KARAASLAN



BİDGE Yayınları

**Nicel Yöntemlerle Performans, Risk ve Teknoloji Temelli
Ekonomik Analizler**

Editör: KÜBRANUR ÇEBİ KARAASLAN

ISBN: -

1. Baskı

Sayfa Düzeni: Gözde YÜCEL

Yayınlama Tarihi: 2025-12-25

BİDGE Yayınları

Bu eserin bütün hakları saklıdır. Kaynak gösterilerek tanıtım için yapılacak kısa alıntılar dışında yayıncının ve editörün yazılı izni olmaksızın hiçbir yolla çoğaltılamaz.

Sertifika No: 71374

Yayın hakları © BİDGE Yayınları

www.bidgeyayinlari.com.tr - bidgeyayinlari@gmail.com

Krc Bilişim Ticaret ve Organizasyon Ltd. Şti.

Güzeltepe Mahallesi Abidin Daver Sokak Sefer Apartmanı No: 7/9 Çankaya /
Ankara



İÇİNDEKİLER

İSO 500 GIDA ÜRÜNLERİ İMALATI SEKTÖRÜNDEKİ FİRMALARIN LODECI TABANLI MARCOS YÖNTEMİYLE PERFORMANSLARININ İNCELENMESİ	1
--	---

TAHSİN AVCI, EMRE KILIÇ

GELİŞEN EKONOMİLERDE ÜLKE RİSKİ VE TEKNOLOJİ HİSSE SENEDİ PİYASALARI: KAVRAMSAL VE AMPİRİK BİR ÇERÇEVE	24
--	----

SALİH DOĞANAY, GÜLCAN ÇAĞIL

QUANTIFYING EMOTION: AN ECONOMETRIC FRAMEWORK FOR EMOTION ARTIFICIAL INTELLIGENCE RETURN ON INVESTMENT IN MARKETING AND ADVERTISING	55
--	----

CAN MAVRUK

BÖLÜM 1

İSO 500 Gıda Ürünleri İmalatı Sektöründeki Firmaların LODECI Tabanlı MARCOS Yöntemiyle Performanslarının İncelenmesi

Emre KILIÇ¹

Tahsin AVCI²

Giriş

Gıda ürünlerinin imalatı sektörü, ekonomik büyüme, istihdam, dış ticaret dengesi ve gıda arz güvenliği üzerindeki belirleyici etkileri nedeniyle sanayi ekonomilerinde stratejik bir konuma sahiptir (FAO, 2017; UNIDO, 2019; OECD 2020). Bu sektör, tarım ile sanayi arasında güçlü iki yönlü bağlantılar kurarak katma değer yaratmakta ve aynı zamanda temel tüketim mallarının üretimi yoluyla hanehalkı refahını ve fiyat istikrarını doğrudan etkilemektedir (Reardon vd., 2003). Özellikle yükselen piyasa ekonomilerinde gıda imalatı; istihdam esnekliği yüksek olması, ihracata konu olabilen ürün çeşitliliği ve kriz dönemlerinde görece istikrarlı talep yapısı sayesinde makroekonomik istikrarın önemli bir bileşeni hâline gelmektedir.

Türkiye’de son yıllarda artan üretim maliyetleri, finansmana erişim koşullarındaki sıkılaşma ve döviz kuru oynaklığı, özellikle imalat sanayii firmaları arasında performans farklılıklarını daha belirgin hâle getirmektedir. Bu dönemde girdi fiyatlarındaki artışların ve kur geçişkenliğinin yüksek seyretmesi, firmaların

¹ Arş. Gör. Dr., İstanbul Nişantaşı Üniversitesi, Sermaye Piyasaları ve Portföy Yönetimi Bölümü, Orcid: 0000-0003-2900-5123

² Öğr. Gör., Pamukkale Üniversitesi, Uygulamalı Bilimler Fakültesi, Uluslararası Ticaret ve Lojistik Bölümü, Orcid: 0000-0002-7243-8541

maliyet yapılarını ve kârlılıklarını asimetrik biçimde etkileyebilmekte, benzer ölçekte faaliyet gösteren firmalar arasında dahi önemli performans ayrışmalarına yol açabilmektedir. Dolayısıyla aynı sektörde faaliyet gösteren firmaların, benzer makroekonomik koşullar altında neden farklı performans sonuçları ürettiği sorusu, mikro düzeyde firma davranışlarının ve kaynak tahsis kararlarının analizini zorunlu kılmaktadır. Bu çerçevede temel iktisadi soru, gıda ürünlerinin imalatı alanında faaliyet gösteren firmaların üretim faktörlerini ne ölçüde etkin kullandıkları ve gözlenen performans farklılıklarının hangi finansal ve yapısal unsurlardan kaynaklandığıdır. Bu performans farklılıklarının nesnel ve karşılaştırılabilir yöntemlerle ortaya konulması, yalnızca firma veya yıl düzeyinde rekabet gücünün değerlendirilmesi açısından değil; aynı zamanda sektörel ve dönemsel verimlilik artışı, gıda arz güvenliğinin sürdürülebilirliği ve sanayi politikalarının tasarımı bakımından da kritik bir öneme sahiptir (Avcı ve Çağlar, 2016; Avcı ve Ergen, 2022; Geçer ve Afşar, 2023).

Bu çalışmanın temel amacı, İstanbul Sanayi Odası’nın (İSO) “Türkiye’nin 500 Büyük Sanayi Kuruluşu” listesinde (İSO 500) yer alan ve gıda ürünlerinin imalatı alanında faaliyet gösteren firmaların performanslarını çok kriterli karar verme (ÇKKV) yöntemleri ile çerçevede ölçmek ve sıralamaktır. Çalışmada firma performansı; net satışlar, faiz, amortisman ve vergi öncesi kârlılık (FAVÖK) ve ihracat gibi fayda yönlü göstergelerin yanı sıra, özkaynak, aktif toplamı ve çalışan sayısı gibi maliyet yönlü kriterler üzerinden değerlendirilmektedir. Böylece firmaların yalnızca büyüklük veya kârlılık açısından değil, kaynak kullanımı ve üretim yapısı bakımından da karşılaştırılabilmesi amaçlanmaktadır. Bu yaklaşım, sektörel performans farklılıklarının daha net biçimde ortaya konmasına katkı sağlamaktadır. Çalışmanın ampirik analizi iki aşamalı bütünlük bir ÇKKV yaklaşımına dayanmaktadır. İlk aşamada kriter ağırlıklarının belirlenmesinde LODECI (Logarithmic

Decomposition of Criteria Importance) yöntemi kullanılmaktadır. İkinci aşamada ise firmaların performans sıralamasının elde edilmesinde MARCOS (Measurement Alternatives and Ranking according to COMpromise Solution) yöntemi uygulanmaktadır.

Analiz sonuçları FAVÖK kriterinin en önemli kriter olduğunu, çalışan sayısı kriteri ise en önemsiz kriter olduğunu göstermektedir. Elde edilen performans sıralamalarında en iyi üç firmanın sırasıyla Ahmet Ak Gıda ve Tüketim Maddeleri Sanayi ve Pazarlama Ltd. Şti, Arslantürk Tarım Ürünleri San. İhr. ve İth. A.Ş. ve Sunrise Foods International Tarım Ürünleri Ticaret A.Ş. firmalarının olduğu; en kötü performansa sahip olan firmaların ise sırasıyla Pınar Entegre Et ve Un Sanayii A.Ş., Tukaş Gıda San. ve Tic. A.Ş. ve Dardanel Önentaş Gıda Sanayi A.Ş. olduğu görülmektedir. Bu durum, sektörde yüksek ölçeğin tek başına üstün performans anlamına gelmediğini ve çok boyutlu performans yönetiminin belirleyici olduğunu ortaya koymaktadır.

Literatürde firma performansının ölçümüne yönelik çalışmalar incelendiğinde İSO 500 kapsamındaki gıda ürünleri imalatı firmalarını inceleyen kısıtlı çalışmanın var olduğu görülmektedir (bkz. Tablo 1). Bu kapsamda bu çalışma İSO 500 kapsamındaki gıda ürünleri imalatı firmalarının performanslarını inceleyen sınırlı sayıdaki literatüre katkı sunmaktadır. Bildiğimiz kadarıyla gıda sektörü firmaları için performans sıralamasında LODECI ve MARCOS yöntemlerini kullanan ilk girişimdir. Bu bağlamda yöntemsel bir katkı sunulması amaçlanmaktadır. Ayrıca analizde son dönem verilerinin kullanılması literatüre güncel ampirik bulgular sunmaktadır.

Çalışmanın buradan sonraki bölümü şu şekilde yapılandırılmıştır: İkinci bölümde, firma performansının ÇKKV yöntemleri kullanılarak incelendiği çalışmalara ilişkin literatür taramasına yer verilmektedir. Üçüncü bölümde veri seti ve kullanılan yöntemler ayrıntılı olarak açıklanmaktadır. Dördüncü

bölümde ampirik analiz kapsamında gerçekleştirilen uygulamalar ve elde edilen bulgular sunulmaktadır. Son bölümde ise bulgular tartışılmakta ve sonuçlara dayalı değerlendirme ile öneriler geliştirilmektedir.

LİTERATÜR İNCELEMESİ

Firmaların finansal ve operasyonel performanslarını değerlendiren, farklı sektörleri ve dönemleri kapsayan ampirik çalışmalar; örneklem yapıları, kullanılan değişkenler, yöntemler ve temel bulgular çerçevesinde Tablo 1’de özetlenmektedir. Tablo üç panelden oluşmaktadır; Panel A’da İSO 500’de yer alan firmaların performanslarının ölçüldüğü çalışmalar, Panel B’de çalışma kapsamında kullanılan performans kriterlerinin önem ağırlıklarının LODECI yöntemi kullanılarak incelendiği çalışma grubu ve Panel C’de performans sıralamasında kullanılan MARCOS yöntemi kullanılarak yapılmış çalışmalar özetlenmektedir. Bu sınıflandırma aracılığıyla hem İSO 500 firmalarına yönelik mevcut literatürün genel eğilimleri hem de LODECI ve MARCOS gibi yöntemleri kullanan çalışmalara ilişkin bütüncül bir perspektifle sunulmaktadır.

Tablo 1. Literatür Özeti

Yazar(lar) / Yıl	Örneklem / Dönem	Değişkenler	Yöntem	Sonuç
Panel A: İstanbul Sanayi Odası Firmalarını ve Çalışmamızda Yer alan Kriterlerle Yapılan Çalışmalar				
Avcı ve Çağlar (2016)	ISO 500, (2011-2014)	Girdi Değişkenleri: Özkaynak, Aktif Toplamı, Personel Sayısı, Çıktı Değişkenleri: Dönem Kar/Zarar (Model 1), FAVÖK (Model 2)	SSA	Kamu sektöründe etkinlik özel sektörden düşük; 2011-2013 arası etkinlik skorları düşerken 2014’te artış gözlenmiş; 2014 yılında gıda sektörü en yüksek etkinlikte; teknik etkinlik skorlarının çoğu 0,60-0,70 aralığında; Türkiye Petrolleri Anonim Ortaklığı en yüksek etkin firma, Türkiye Taşkömürü Kurumu en düşük etkin firma
Demir (2021)	İSO 1. 500 ve 2. 500 16 firma (2010-2019 dönemi)	Üretimden Satışlar (Net), Net Satışlar, Brüt Katma Değer, Özkaynak, Aktif Toplamı, Dönem Kar/Zarar, EBITDA, İhracat Maliyet, İşlevsellik, Kullanım, Verimlilik ve Hız	TOPSIS	TOPSIS yöntemine göre en etkin olan ilk üç firma sırasıyla, Hugo Boss Tekstil Sanayi Ltd. Şti., Sarar Giyim Tekstil Enerji San. ve Tic. A.Ş. ve Şık Makas Giyim San. ve Tic. A.Ş., olmaktadır.
Dikmen Kavakcı (2022)	ISO 500 (2020),		MACBETH, TOPSIS, COPRAS	En önemli ölçüt maliyet; TOPSIS & COPRAS benzer sonuçlar verdi; S2 ve

Geçer ve Afşar (2025)	Malatya ilinin firmaları ISO 500, 18 BIST şirketi, (2021)	14 Finansal Rasyo	TOPSIS, ARAS ENRTOPI	S4 en uygun ERP yazılımı seçenekleri olarak bulundu Topsis yöntemine göre en etik olan ilk üç firma sırasıyla, KARTN, DEVA ve FROTO yer almaktadır.
Cihan (2025)	ISO 500, Demir-Çelik sektörü, 12 firma (2023)	Girdi Değişkenleri: Çalışan Sayısı, Özkaynak, Aktif Toplamı, Çıktı Değişkenleri: Net Satışlar, FAVÖK (Faiz, Amortisman ve Vergi Öncesi Kar), İhracat	VZA – CCR VE BCC Modelleri	Toplam etkinlik açısından 6 işletme etkin bulunurken, 6 işletme etkin değildir. Teknik etkinlik açısından ise 10 işletme etkin, 2 işletme etkin değildir. Ölçek etkinliği bakımından da 6 işletme etkin, 6 işletme ise etkin değildir.

Panel B: LODECI Ağırlık Metodunu Kullanan Çalışmalar

Pala (2024)	AB Ülkeleri, Sosyal İlerleme İndeksi (SPI) (2021)	Sosyal İlerleme İndeksi (SPI) 12 kriter	LODECI CoCoSo-L	CoCoSo-L yöntemine göre ilk beş ülke Finlandiya, Danimarka, İsveç, Hollanda ve Almanya
Pala, Atçeken, Omurtak ve Şimşir (2024)	BIST Çimento Endeksi 16 firma (2020–2022)	Cari Oran, net kar marjı, özsermaye karlılığı, aktif devir hızı, duran varlık devir hızı, borç oranı	LODECI CRADIS	İncelenen üç yılda da en iyi performansı A7 firması, en son sırada yer alan firma ise genellikle A4 ve A5 firmaları olmaktadır.
Çilek ve Şeyranlıoğlu (2025)	4 reasürans şirketi, (2022-2023)	10 Finansal Performans Göstergesi	LODECI CRADIS AROMAN	Enkinlik sıralaması, Türk Reasürans A.Ş., Türk Katılım Reasürans A.Ş., Milli Reasürans Türk A.Ş. ve VHV Reasürans A.Ş.
Demirhan, Ulutaş ve Pala (2025)	BIST Ticari 10 Banka (2023)	8 Finansal Performans Kriteri	LODECI ARLON	ARLON yönteminin sonuçlarına göre Ticari bankalar arasında en etkin olan ilk üç sıralama, T.C. Ziraat Bankası'nın (TCZ), Türkiye Vakıflar Bankası (TVB) ve Türkiye Garanti Bankası (TGB) olmaktadır.
Tufan ve Ulutaş (2026)	Gıda sektörü, süt ve süt ürünleri tedarikçileri, 15 firma	Masraf, Nitelik, Teslim, Finansal Güç, Kapasite	LODECI CORASO	MSU2 en iyi tedarikçi; MSU4 en sonda yer alan tedarikcidir.

Panel C: MARCOS Sıralama Metodunu Kullanan Çalışmalar

Ayçin & Arsu (2021)	Sosyal Gelişme Endeksi 14 Ülke, (2019)	Beslenme, sağlık, eğitim, kişisel güvenlik, özgürlük, kapsayıcılık vb. 12 kriter	MEREC, MARCOS	MARCOS yöntemine göre ülke sıralamasında en etkin olan ilk üç ülke sırasıyla, Norveç, Finlandiya, Danimarka yer almaktadır.
Çınaroğlu (2021)	Türkiye'deki 50 üniversite, (2020)	Bilimsel ve teknolojik araştırma yetkinliği, Fikri mülkiyet havuzu, İş birliği ve etkileşim, Ekonomik katkı ve ticarileşme	CRITIC MARCOS	Türkiye'deki 50 üniversitenin MARCOS yöntemiyle sıralamaları elde edilip en etkin olan ilk üç üniversite sırayla, ODTÜ, Bilkent ve İTÜ olmaktadır.
Gençtürk, Senal Aksoy (2021)	Türkiye, katılım bankası, 2019Q3–2020Q4 (pandemi öncesi ve pandemi dönemi)	Kriterler: toplanan fonlar, kullanılan fonlar, tasfiye olunacak alacaklar, toplam aktif, özkaynak, net kar, personel sayısı, şube sayısı	CRITIC MARCOS	Her iki dönemde de Vakıf Katılım Bankası en iyi performansı göstermektedir.

Özdağoğlu, Keleş ve İşildak (2021)	Dünyanın en işlek 10 havalimanı, (2018-2019)	Toplam Toplam Toplam Uçuş	Yolcu, Kargo, Uçuş	PIPRECIA-E SMART MARCOS	MARCOS yöntemine göre ilk 3 sırada yer alan havalimanları sırasıyla, Beijing, Chicago ve Los Angeles havalimanları olurken son 3 de yer alanmalr ise Frankfurt, Guangzhou ve Amsterdam havalimanlarıdır.
Altıntaş (2022)	22 Avrupa Ülkesi (2021)	Bilgi Yayılımı, Deney ve Oluşumu, Meşruiyet Uluslararası İşbirliği	Geliştirme Girişimci ve Pazar Sosyal ve	MABAC MARCOS	MARCOS yöntemine göre ülke sıralamasında en etkin olan ilk üç ülke sırasıyla, Finlandiya, Danimarka, İsveç

Notlar: SSA: Stokastik Sınır Analizi, TOPSIS: Technique for Order Preference by Similarity to Ideal Solution, VZA: Veri Zarflama Analizi, TOPSIS: Technique for Order Preference by Similarity to Ideal Solution, MACBETH: Measuring Attractiveness by a Categorical Based Evaluation Technique, COPRAS: Complex Proportional Assessment, ARAS: Additive Ratio ASsessment, LODECI: LOgarithmic DEcomposition Of Criteria Importance, PIPRECIA-E: Pivot Pairwise RELative Criteria Importance Assessment Extended, SMART: Simple Multi-Attribute Rating Technique, MARCOS: Measurement Alternatives and Ranking According to Compromise Solution, MEREC: Method based on the Removal Effects of Criteria, CoCoSo: Combined Compromise Solution, CRADIS: Compromise Ranking of Alternatives from Distance to Ideal Solution, AROMAN: Alternative Ranking Order Method Accounting Two-Step Normalization, CORASO: ACompromise Ranking from Alternative Solutions, CRITIC: CRiteria Importance Through Intercriteria, SMART: Simple Multi-Attribute Rating Technique, MABAC: Multi-Attributive Border Approximation Area Comparison.

Tablo 1’de özetlenen literatür incelendiğinde, İSO 500 firmaları ve benzer performans kriterleri kullanılarak yapılan çalışmaların ağırlıklı olarak etkinlik analizi (VZA, SSA) ve klasik ÇKKV yöntemlerine dayandığı görülmektedir. Bu çalışmalar, firma performansını çoğunlukla kârlılık ve büyüklük göstergeleri üzerinden değerlendirmekte, ancak kriter ağırlıklandırma ve sıralama süreçlerini bütünsel bir çerçevede ele almamaktadır. Özellikle gıda sektörüne odaklanan çalışmaların sınırlı sayıda olduğu ve kullanılan yöntemlerin sektöre özgü çok boyutlu performans yapısını yeterince yansıtamadığı dikkat çekmektedir. Tablo 1’de özetlenen çalışmalar birlikte değerlendirildiğinde, gıda ürünleri imalatı sektörünü doğrudan ele alan ve LODECI tabanlı ağırlıklandırma ile MARCOS sıralama yöntemlerini birlikte kullanan bir çalışmanın bulunmadığı görülmektedir. Bu çalışma, LODECI yöntemiyle kriter ağırlıklarının nesnel biçimde belirlenmesi ve MARCOS yöntemiyle performans sıralamasının elde edilmesi sayesinde, literatürdeki bu boşluğu doldurmayı

amaçlamaktadır. Elde edilen bulguların yüksek ölçeğin tek başına üstün performans anlamına gelmediğini göstermesi, literatürdeki mevcut sonuçları tamamlayıcı ve derinleştirici niteliktedir.

VERİ

Çalışmanın örneklem grubunu İSO 500’de yer alan Gıda Ürünlerinin İmalatı alanında faaliyet gösteren firmalar oluşturmaktadır. Bu kapsamda 2024 yılı için verisine ulaşılabilen maksimum firma sayısı olan 30 firma analize dahil edilmektedir. Örneklem firmaları ve firmalara ait kodlar Tablo 2’de listelenmektedir.

Tablo 2. Çalışma Kapsamında Yer Alan Firmalar ve Firmalara İlişkin Kodlar

Kuruluş Adı	Kuruluş Kodu	Kuruluş Adı	Kuruluş Kodu
Unilever San. ve Tic. T.A.Ş.	C1	Dardanel Önentaş Gıda Sanayi A.Ş.	C16
Banvit Bandırma Vitaminli Yem Sanayi A.Ş.	C2	Kervan Gıda San. ve Tic. A.Ş.	C17
Namet Gıda San. ve Tic. A.Ş.	C3	Kaanlar Gıda San. ve Tic. A.Ş.	C18
Gümüşdoğa Su Ürünleri Üretim İhracat ve İthalat A.Ş.	C4	Akyem Adana Yem Yağ Biodizel Tarım ve San. Tic. A.Ş.	C19
Çay İşletmeleri Genel Müdürlüğü	C5	Teksüt Süt Mamülleri San. ve Tic. A.Ş.	C20
Başhan Agro Gıda San. ve Tic. A.Ş.	C6	Beşler Makarna Un İrmik Gıda San. ve Tic. A.Ş.	C21
Aves Enerji Yağ ve Gıda Sanayi A.Ş.	C7	Tukaş Gıda San. ve Tic. A.Ş.	C22
Pınar Süt Mamülleri Sanayii A.Ş.	C8	Erçal Fındık Otomotiv San. ve Tic. A.Ş.	C23
Durak Fındık San. ve Tic. A.Ş.	C9	Antepsan Kuruyemiş Gıda San. ve Tic. A.Ş.	C24
Oba Makarnacılık San. ve Tic. A.Ş.	C10	Ahmet Ak Gıda ve Tüketim Maddeleri Sanayi ve Pazarlama Ltd. Şti.	C25
Kadooğlu Yağ San. ve Tic. A.Ş.	C11	Ulusoy Un San. ve Tic. A.Ş.	C26
Memişoğlu Tarım Ürünleri Ticaret Ltd. Şti.	C12	Sunrise Foods International Tarım Ürünleri Ticaret A.Ş.	C27

Yörükoğlu Süt ve Ürünleri San. Tic. A.Ş.	C13	Beşler Et Gıda San. ve Tic. A.Ş.	C28
Eksun Gıda Tarım San. ve Tic. A.Ş.	C14	S.S. Marmara Zeytin Tarım Satış Kooperatifleri Birliği	C29
Pınar Entegre Et ve Un Sanayii A.Ş.	C15	Arslantürk Tarım Ürünleri San. İhr. ve İth. A.Ş.	C30

Firma performanslarının ölçülmesinde kullanılan kriterler Tablo 3’te listelenmektedir. Kriterler fayda (maksimum) ve maliyet (minimum) olarak sınıflandırılmaktadır. Çalışmada dikkate alınan kriterlerin belirlenmesinde, Avcı ve Çağlar (2016), Demir (2021), Avcı ve Ergen, (2024) ve Cihan (2025) çalışmaları takip edilmektedir.

Tablo 3. Kriterlere İlişkin Tanımlayıcı Bilgiler

Değişkenler	Kısaltma	Kaynak
Maksimum		İSO 500
Net Satışlar (TL)	F1	
FAVÖK (TL)	F2	
İhracat (Bin \$)	F3	
Minimum		
Özkaynak (TL)	M1	
Aktif Toplamı (TL)	M2	
Ücretle Çalışanlar Ortalaması (Kişi)	M3	


YÖNTEM

Firmaların performanslarının analizinde kullanılan kriterlerin ağırlıklarının belirlenmesinde LODECİ metodu, performans sıralamasında ise MARCOS yöntemi uygulanmaktadır. Bu bölümde LODECİ ve MARCOS yöntemlerine ilişkin metodolojilere yer verilmektedir.

LODECİ Yöntemi

Pala (2024) tarafından literatüre kazandırılan LODECİ yöntemi, kriterlerin objektif ağırlıklandırılmasında kullanılmaktadır. Ağırlıklandırma yöntemi olarak literatürde yer alan ENTROPİ


(Shannon, 1948) ve MEREC (Keshavarz-Ghorabae vd., 2021) metodlarının matematiksel denklemlerinin birleştirilmesiyle elde edilmektedir. Bu yöntemle hesaplanan kriter ağırlık değerlerinin daha dengeli dağılmaktadır (Pala, 2024; Pala vd. 2024). Normalizasyon işlemi yapıldıktan sonra her bir kriter için alternatifler arasındaki maksimum değer hesaplanarak ayrışım yapılmaktadır. Bu yöntemle ilişkin analiz aşamaları beş adımdan oluşmaktadır. Adımlar Şema 1’de gösterildiği şekildedir:



Şema 1: LODECI Yöntemi Analiz Aşamaları

MARCOS Yöntemi

MARCOS yöntemi, Stevic vd., (2020) tarafından literatüre kazandırılan bir ÇÇKV yöntemidir. Alternatiflerin sıralanmasında kullanılan MARCOS yöntemi, karar matrisine referans (ideal (AI) ve anti-ideal (AAI)) çözümlere olan uzaklıklar ilave edilerek uzlaşımçı çözümleri fayda fonksiyonları ile belirlenmektedir. Alternatiflerin dereceleri belirlenirdikten sonra ideale en yakın ve anti-ideale en uzak olanın en iyi performansı göstermektedir (Stevic ve Brkovic, 2020). Yönteme ilişkin analiz aşamaları Şema 2’de gösterilmektedir (Stevic vd., 2020).



Notlar: Alternatiflere ilişkin fayda fonksiyonundan elde edilen $f(K_i)$ skoru büyükten küçüğe doğru sıralanıp en yüksek skora sahip olan en iyi performans göstermektedir.


Şema 2: MARCOS Yöntemi Analiz Aşamaları

AMPIİRİK BULGULAR

Bu bölümde, İSO 500 listesinde yer alan ve gıda ürünlerinin imalatı alanında faaliyet gösteren firmaların performanslarının çok boyutlu bir çerçevede değerlendirilmesine yönelik ampirik bulgular sunulmaktadır. Analiz, bütünleşik bir ÇKKV yaklaşımı benimsenerek iki aşamada yürütülmüştür. İlk aşamada, performans değerlendirmesinde kullanılan kriterlerin göreceli önem düzeyleri LODECI yöntemi aracılığıyla nesnel olarak belirlenmiştir. Bu aşama, firmaların performansını etkileyen finansal ve operasyonel göstergelerin ayırt edicilik gücünü ortaya koymayı amaçlamaktadır. İkinci aşamada ise elde edilen kriter ağırlıkları MARCOS yöntemi kapsamında kullanılarak firmaların nihai performans sıralamaları oluşturulmuştur.

Grafik 1’de ilk aşamaya ilişkin LODECI yöntemiyle elde edilen kriter ağırlıklandırma sonuçları sunulmaktadır.

Grafik 1. LODECI Ağırlıklandırma Yönteminin Sonuçları



Grafik 1’e göre FAVÖK kriteri %17.47 ile en önemli kriter olurken, çalışan sayısı kriteri %15.80 ile son sırada yer almaktadır.

Kriter ağırlıklandırma ve firma performans sıralamanın tespit edilmesinde kullanılan LODECİ ve MARCOS yöntemlerinin ilk aşaması olan karar matrisi Tablo 5’te gösterilmektedir. Karar matrisi firmalara ilişkin ham verilerinden oluşmaktadır.

Tablo 5. LODECİ ve MARCOS Yöntemlerinde Kullanılan Karar Matrisi

KOD	F1	F2	F3	M1	M2	M3
ALL	4579387263	27115887	815	20379672782	32475838838	6552
C1	56419509598	8535006871	95870	20379672782	32475838838	2950
C2	29108496441	6161897124	90691	8806880161	16794311838	5134
C3	22784010409	5088639667	7727	16149461753	19661361865	1576
C4	21452166568	5650686879	303364	14891543030	29615203033	2793
C5	22029032754	2621999824	16516	17250031588	29577106124	6552
C6	17138311865	2008685504	96116	4179492458	9801807216	1100
C7	39545570729	2656339660	195889	7405052775	20919091785	668
C8	12119575165	245601880	42757	2948255391	10671974060	1264
C9	11199903032	485971039	177221	1604790685	8944195705	775
C10	15507134329	1334839050	256994	7449953605	8892895322	1160
C11	10868290432	678321944	185896	2617096161	16897869593	339
C12	11610330754	1177454031	120570	5036558652	10953140544	636
C13	10436677942	1146097518	7353	2188561399	4115811354	1070
C14	9451031156	332723674	47066	2018114027	5032845023	499
C15	7167698787	984202684	4850	4958969935	7650625017	894
C16	6587980284	1240249582	37742	8853873587	13416595377	1433
C17	6588646673	1172102036	148276	4666455648	9634379887	2256
C18	6366308055	691123211	4057	3080736323	5915692237	605
C19	6366319482	27115887	44648	553268444	1784589898	1840
C20	6098872473	1495559719	11307	1507496305	2470323971	803
C21	6129673550	566706511	100452	702109504	3108102857	324
C22	6064210763	1504864325	29040	7149247916	11746586735	1245
C23	10242814093	409738131	24852	2863124014	4564046812	367
C24	5204106839	611575126	4898	1659094986	4185912056	410
C25	5134171050	169627023	51224	377292485	1751403432	219
C26	26054666038	290573123	70035	4091359366	20654132459	460
C27	14506274540	1148439715	252387	861151842	15021570365	227
C28	5002115765	226520670	815	900833528	2138909369	484
C29	4899258900	658940431	35506	4145952355	7486898880	384
C30	4579387263	166300253	46351	425532795	2460929405	205
AL	56419509598	8535006871	303364	377292485	1751403432	205

MARCOS yönteminin ikinci aşaması olan genelleştirilmiş karar matrisi elde edildikten sonra fayda ve maliyet kriterlerine ilişkin dönüştürmeler yapılarak normalize karar matrisi oluşturulmaktadır. Tablo 6’da normalize karar matrisi yer almaktadır.

Tablo 6. Normalize Karar Matrisi

KOD	F1	F2	F3	M1	M2	M3
ALL	0.0812	0.0032	0.0027	0.0185	0.0539	0.0313
C1	1.0000	1.0000	0.3160	0.0185	0.0539	0.0695
C2	0.5159	0.7220	0.2990	0.0428	0.1043	0.0399
C3	0.4038	0.5962	0.0255	0.0234	0.0891	0.1301
C4	0.3802	0.6621	1.0000	0.0253	0.0591	0.0734
C5	0.3905	0.3072	0.0544	0.0219	0.0592	0.0313
C6	0.3038	0.2353	0.3168	0.0903	0.1787	0.1864
C7	0.7009	0.3112	0.6457	0.0510	0.0837	0.3069
C8	0.2148	0.0288	0.1409	0.1280	0.1641	0.1622
C9	0.1985	0.0569	0.5842	0.2351	0.1958	0.2645
C10	0.2749	0.1564	0.8471	0.0506	0.1969	0.1767
C11	0.1926	0.0795	0.6128	0.1442	0.1036	0.6047
C12	0.2058	0.1380	0.3974	0.0749	0.1599	0.3223
C13	0.1850	0.1343	0.0242	0.1724	0.4255	0.1916
C14	0.1675	0.0390	0.1551	0.1870	0.3480	0.4108
C15	0.1270	0.1153	0.0160	0.0761	0.2289	0.2293
C16	0.1168	0.1453	0.1244	0.0426	0.1305	0.1431
C17	0.1168	0.1373	0.4888	0.0809	0.1818	0.0909
C18	0.1128	0.0810	0.0134	0.1225	0.2961	0.3388
C19	0.1128	0.0032	0.1472	0.6819	0.9814	0.1114
C20	0.1081	0.1752	0.0373	0.2503	0.7090	0.2553
C21	0.1086	0.0664	0.3311	0.5374	0.5635	0.6327
C22	0.1075	0.1763	0.0957	0.0528	0.1491	0.1647
C23	0.1815	0.0480	0.0819	0.1318	0.3837	0.5586
C24	0.0922	0.0717	0.0161	0.2274	0.4184	0.5000
C25	0.0910	0.0199	0.1689	1.0000	1.0000	0.9361
C26	0.4618	0.0340	0.2309	0.0922	0.0848	0.4457
C27	0.2571	0.1346	0.8320	0.4381	0.1166	0.9031
C28	0.0887	0.0265	0.0027	0.4188	0.8188	0.4236
C29	0.0868	0.0772	0.1170	0.0910	0.2339	0.5339
C30	0.0812	0.0195	0.1528	0.8866	0.7117	1.0000
AL	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000

LODECİ yöntemi kullanılarak elde edilen kriterlerin ağırlık değerleri ile normalize karar matrisi çarpılarak ağırlıklı normalize karar matrisi oluşturulmaktadır. Oluşturulan ağırlıklı normalize karar matrisi Tablo 7’de gösterilmektedir.

Tablo 7. Ağırlıklı Normalize Karar Matrisi

KOD	F1	F2	F3	M1	M2	M3
ALL	0.0132	0.0006	0.0005	0.0032	0.0088	0.0049
C1	0.1631	0.1747	0.0530	0.0032	0.0088	0.0110
C2	0.0841	0.1261	0.0501	0.0074	0.0171	0.0063
C3	0.0659	0.1042	0.0043	0.0040	0.0146	0.0206
C4	0.0620	0.1157	0.1677	0.0044	0.0097	0.0116
C5	0.0637	0.0537	0.0091	0.0038	0.0097	0.0049
C6	0.0495	0.0411	0.0531	0.0156	0.0293	0.0294
C7	0.1143	0.0544	0.1083	0.0088	0.0137	0.0485
C8	0.0350	0.0050	0.0236	0.0221	0.0269	0.0256
C9	0.0324	0.0099	0.0980	0.0406	0.0321	0.0418
C10	0.0448	0.0273	0.1420	0.0087	0.0323	0.0279
C11	0.0314	0.0139	0.1027	0.0249	0.0170	0.0955
C12	0.0336	0.0241	0.0666	0.0129	0.0262	0.0509
C13	0.0302	0.0235	0.0041	0.0298	0.0697	0.0303
C14	0.0273	0.0068	0.0260	0.0323	0.0570	0.0649
C15	0.0207	0.0201	0.0027	0.0131	0.0375	0.0362
C16	0.0190	0.0254	0.0209	0.0074	0.0214	0.0226
C17	0.0190	0.0240	0.0820	0.0140	0.0298	0.0144
C18	0.0184	0.0141	0.0022	0.0211	0.0485	0.0535
C19	0.0184	0.0006	0.0247	0.1177	0.1608	0.0176
C20	0.0176	0.0306	0.0062	0.0432	0.1162	0.0403
C21	0.0177	0.0116	0.0555	0.0928	0.0924	0.1000
C22	0.0175	0.0308	0.0161	0.0091	0.0244	0.0260
C23	0.0296	0.0084	0.0137	0.0228	0.0629	0.0882
C24	0.0150	0.0125	0.0027	0.0393	0.0686	0.0790
C25	0.0148	0.0035	0.0283	0.1727	0.1639	0.1479
C26	0.0753	0.0059	0.0387	0.0159	0.0139	0.0704
C27	0.0419	0.0235	0.1395	0.0757	0.0191	0.1427
C28	0.0145	0.0046	0.0005	0.0723	0.1342	0.0669
C29	0.0142	0.0135	0.0196	0.0157	0.0383	0.0843
C30	0.0132	0.0034	0.0256	0.1531	0.1166	0.1580
AL	0.1631	0.1747	0.1677	0.1727	0.1639	0.1580

Tablo 8’de MARCOS yöntemi ile elde edilen fayda dereceleri, fayda fonksiyonları ve nihai değerler yer almaktadır. Sıralama sonuçları buradan hareketle ideal ve anti-ideal çözüme göre oluşturulan fonksiyonlar kullanılarak hesaplanmaktadır.

**Tablo 8. MARCOS Yöntemi ile Elde Edilen Fayda Dereceleri,
Fayda Fonksiyonları ve Nihai Değerler**

KOD	Saai	Si	K-	K+	fK-	fK+	fKi
ALL	0.0312						
C1		0.4138	13.2534	0.4138	0.0303	0.9697	0.4134
C2		0.2912	9.3268	0.2912	0.0303	0.9697	0.2909
C3		0.2135	6.8374	0.2135	0.0303	0.9697	0.2133
C4		0.3710	11.8835	0.3710	0.0303	0.9697	0.3707
C5		0.1449	4.6410	0.1449	0.0303	0.9697	0.1448
C6		0.2181	6.9856	0.2181	0.0303	0.9697	0.2179
C7		0.3479	11.1450	0.3479	0.0303	0.9697	0.3476
C8		0.1383	4.4301	0.1383	0.0303	0.9697	0.1382
C9		0.2548	8.1599	0.2548	0.0303	0.9697	0.2545
C10		0.2831	9.0689	0.2831	0.0303	0.9697	0.2829
C11		0.2855	9.1436	0.2855	0.0303	0.9697	0.2852
C12		0.2144	6.8663	0.2144	0.0303	0.9697	0.2142
C13		0.1875	6.0047	0.1875	0.0303	0.9697	0.1873
C14		0.2144	6.8662	0.2144	0.0303	0.9697	0.2142
C15		0.1304	4.1777	0.1304	0.0303	0.9697	0.1303
C16		0.1166	3.7362	0.1166	0.0303	0.9697	0.1165
C17		0.1831	5.8649	0.1831	0.0303	0.9697	0.1829
C18		0.1580	5.0606	0.1580	0.0303	0.9697	0.1578
C19		0.3398	10.8852	0.3398	0.0303	0.9697	0.3395
C20		0.2542	8.1434	0.2542	0.0303	0.9697	0.2540
C21		0.3699	11.8496	0.3699	0.0303	0.9697	0.3696
C22		0.1239	3.9700	0.1239	0.0303	0.9697	0.1238
C23		0.2256	7.2270	0.2256	0.0303	0.9697	0.2254
C24		0.2171	6.9540	0.2171	0.0303	0.9697	0.2169
C25		0.5311	17.0109	0.5311	0.0303	0.9697	0.5306
C26		0.2202	7.0529	0.2202	0.0303	0.9697	0.2200
C27		0.4424	14.1695	0.4424	0.0303	0.9697	0.4420
C28		0.2930	9.3845	0.2930	0.0303	0.9697	0.2927
C29		0.1857	5.9471	0.1857	0.0303	0.9697	0.1855
C30		0.4700	15.0540	0.4700	0.0303	0.9697	0.4695
AL	1						

Tablo 9’da analize dahil edilen 30 gıda ürünleri imalatı firmasına ilişkin MARCOS yöntemiye hesaplanan skorlar listelenmektedir. Sonuçlar incelendiğinde en iyi performansı gösteren ilk üç firmanın sırasıyla Ahmet Ak Gıda ve Tüketim

Maddeleri Sanayi ve Pazarlama Ltd. Şti., Arslantürk Tarım Ürünleri San. İhr. ve İth. A.Ş. ve Sunrise Foods International Tarım Ürünleri Ticaret A.Ş. olduğu görülmektedir. Performans sıralamasında en sonda yer alan son üç firma ise sırasıyla, Dardanel Önentaş Gıda Sanayi A.Ş., Tukaş Gıda San. ve Tic. A.Ş. ve Pınar Entegre Et ve Un Sanayii A.Ş.'dir.

Tablo 9. MARCOS Yöntemine Göre Elde Edilen Nihai Skorlar ve Sıralamalar

Kuruluş Adı	KOD	Nihai Skorlar	Sıralamalar
Unilever San. ve Tic. T.A.Ş.	C1	0.4134	4
Banvit Bandırma Vitaminli Yem Sanayi A.Ş.	C2	0.2909	10
Namet Gıda San. ve Tic. A.Ş.	C3	0.2133	21
Gümüşdoğa Su Ürünleri Üretim İhracat ve İthalat A.Ş.	C4	0.3707	5
Çay İşletmeleri Genel Müdürlüğü	C5	0.1448	26
Başhan Agro Gıda San. ve Tic. A.Ş.	C6	0.2179	17
Aves Enerji Yağ ve Gıda Sanayi A.Ş.	C7	0.3476	7
Pınar Süt Mamülleri Sanayii A.Ş.	C8	0.1382	27
Durak Fındık San. ve Tic. A.Ş.	C9	0.2545	13
Oba Makarnacılık San. ve Tic. A.Ş.	C10	0.2829	12
Kadooğlu Yağ San. ve Tic. A.Ş.	C11	0.2852	11
Memişoğlu Tarım Ürünleri Ticaret Ltd. Şti.	C12	0.2142	19
Yörükoğlu Süt ve Ürünleri San. Tic. A.Ş.	C13	0.1873	22
Eksun Gıda Tarım San. ve Tic. A.Ş.	C14	0.2142	20
Pınar Entegre Et ve Un Sanayii A.Ş.	C15	0.1303	28
Dardanel Önentaş Gıda Sanayi A.Ş.	C16	0.1165	30
Kervan Gıda San. ve Tic. A.Ş.	C17	0.1829	24
Kaınlar Gıda San. ve Tic. A.Ş.	C18	0.1578	25
Akyem Adana Yem Yağ Biodizel Tarım ve San. Tic. A.Ş.	C19	0.3395	8
Teksüt Süt Mamülleri San. ve Tic. A.Ş.	C20	0.2540	14
Beşler Makarna Un İrmik Gıda San. ve Tic. A.Ş.	C21	0.3696	6
Tukaş Gıda San. ve Tic. A.Ş.	C22	0.1238	29
Erçal Fındık Otomotiv San. ve Tic. A.Ş.	C23	0.2254	15
Antepsan Kuruyemiş Gıda San. ve Tic. A.Ş.	C24	0.2169	18
Ahmet Ak Gıda ve Tüketim Maddeleri Sanayi ve Pazarlama Ltd. Şti.	C25	0.5306	1
Ulusoy Un San. ve Tic. A.Ş.	C26	0.2200	16
Sunrise Foods International Tarım Ürünleri Ticaret A.Ş.	C27	0.4420	3
Beşler Et Gıda San. ve Tic. A.Ş.	C28	0.2927	9
S.S. Marmara Zeytin Tarım Satış Kooperatifleri Birliği	C29	0.1855	23
Arslantürk Tarım Ürünleri San. İhr. ve İth. A.Ş.	C30	0.4695	2

SONUÇ

Bu çalışmada, İSO 500’de yer alan ve gıda ürünlerinin imalatı alanında faaliyet gösteren firmaların performansları, çok kriterli bir yapı çerçevesinde değerlendirilmekte ve firmaların performansları güncel yöntemler yardımıyla sıralanmaktadır. Analizde kriter ağırlıklarının belirlenmesinde LODECI yöntemi, performans sıralamasının elde edilmesinde ise MARCOS yöntemi kullanılmaktadır. Bu yaklaşım, firma performansının yalnızca tek bir finansal gösterge üzerinden değil; satış, kârlılık, ihracat, sermaye yapısı, varlık büyüklüğü ve istihdam gibi çok boyutlu unsurlar üzerinden değerlendirilmesine olanak sağlamaktadır.

LODECI yöntemiyle elde edilen kriter ağırlıkları incelendiğinde, performans değerlendirmesinde kârlılık ve faaliyet verimliliğini temsil eden göstergelerin belirleyici bir rol oynadığı görülmektedir. Özellikle FAVÖK kriterinin en yüksek ağırlığa sahip olması, gıda imalatı sektöründe operasyonel kârlılığın ve maliyet yönetiminin firma performansını ayırt eden temel unsurlar arasında yer aldığını göstermektedir. Buna karşılık çalışan sayısı kriterinin görece düşük ağırlık alması, sektör özelinde ölçek büyüklüğünden ziyade kaynakların etkin kullanımı ve verimlilik düzeyinin daha belirleyici olduğunu ortaya koymaktadır. Bu bulgu, gıda imalatı firmalarında yüksek istihdamın tek başına üstün performans anlamına gelmediğine işaret etmektedir.

MARCOS yöntemiyle elde edilen sıralama sonuçlarına göre Ahmet Ak Gıda ve Tüketim Maddeleri Sanayi ve Pazarlama Ltd. Şti, Arslantürk Tarım Ürünleri San. İhr. ve İth. A.Ş. ve Sunrise Foods International Tarım Ürünleri Ticaret A.Ş. en yüksek performans gösteren ilk üç firma olarak öne çıkmaktadır. Bu firmaların analizde dikkate alınan kriterler dahilinde iyi performans skoruna sahip olması, satış hacmi, kârlılık ve ihracat göstergelerini dengeli bir biçimde yönetebildiklerine ve aynı zamanda maliyet ve kaynak kullanımında görece etkin bir yapı sergilediklerine işaret etmektedir. Tersî şekilde performans sıralamasının alt sıralarında yer alan firmalar incelendiğinde ise Pınar Entegre Et ve Un Sanayii A.Ş., Tukaş Gıda San. ve Tic. A.Ş. ve Dardanel Önentaş Gıda Sanayi A.Ş.’nin alt sıralarda yer alması, büyük ölçekli ve marka bilinirliği

yüksek firmaların dahi çok boyutlu performans kriterleri dikkate alındığında görece düşük performans sergileyebileceğini ortaya koymaktadır. Bu durum, sektörde ölçek avantajlarının her zaman etkinlik ve verimlilikle örtüşmediğini ortaya koymaktadır.

Çalışmanın bulguları hem sektör yöneticileri hem de politika yapıcılar açısından önemli çıkarımlar sunmaktadır. Firma yöneticileri açısından sonuçlar, operasyonel kârlılığı artırmaya yönelik maliyet kontrolü, ihracat odaklı büyüme stratejileri ve kaynak kullanım etkinliğinin performans üzerindeki kritik rolünü ortaya koymaktadır. Politika yapıcılar açısından ise, gıda imalatı sektörüne yönelik destek ve teşvik mekanizmalarının firma ölçeğinden ziyade performans profili ve verimlilik göstergeleri dikkate alınarak tasarlanmasının daha etkin sonuçlar doğurabileceğine işaret etmektedir.

Kaynakça

- Altıntaş, F. F. (2022). Avrupa ülkelerinin enerji inovasyonu performanslarının analizi: MABAC ve MARCOS yöntemleri ile bir uygulama. *İşletme Akademisi Dergisi*, 3(2), 188-216. <https://doi.org/10.26677/TR1010.2022.1027>
- Avcı, T., & Çağlar, A. (2016). Stokastik Sınır Analizi: İstanbul Sanayi Odası'na Kayıtlı Firmalara Yönelik Bir Uygulama. *Siyaset, Ekonomi ve Yönetim Araştırmaları Dergisi*, 4(2), 17-57.
- Avcı, T., ve Çağlar, A. (2016). Stokastik Sınır Analizi: İstanbul Sanayi Odası'na Kayıtlı Firmalara Yönelik Bir Uygulama. *Siyaset, Ekonomi ve Yönetim Araştırmaları Dergisi*, 4(2), 17-57.
- Avcı, T., & Ergen, E. (2022). Kalkınma Planlarının Çok Kriterli Karar Verme Yöntemleriyle Araştırılması. *Pamukkale Üniversitesi İşletme Araştırmaları Dergisi*, 9(1), 90-106. <https://doi.org/10.47097/piar.1096563>
- Avcı, T., ve Ergen, E. (2024). MEREC Tabanlı MAIRCA Yöntemleriyle Firma Performanslarının Analizi: Fortune 500'deki Enerji Sektöründen Kanıtlar. *Pamukkale Journal of Eurasian Socioeconomic Studies*, 11(2), 82-94. <https://doi.org/10.34232/pjess.1559533>
- Ayçin, E., ve Arsu, T. (2021). Sosyal gelişme endeksine göre ülkelerin değerlendirilmesi: MEREC ve MARCOS yöntemleri ile bir uygulama. *İzmir Yönetim Dergisi*, 2(2), 75-88.
- Cihan, Y. (2025). ISO 500'de Yer Alan Demir-Çelik İşletmelerinin Etkinliklerinin Veri Zarflama Analizi Yöntemiyle

İncelenmesi. Necmettin Erbakan Üniversitesi Siyasal Bilgiler Fakültesi Dergisi, 7(1), 82-97.

Çınaroğlu, E. (2021). CRITIC temelli MARCOS yöntemi ile yenilikçi ve girişimci üniversite analizi. Journal of Entrepreneurship and Innovation Management, 10(1), 111-133.

Çilek, A., ve Şeyranlıoğlu, O. (2025). Measuring the financial performance of reinsurance companies in Türkiye with LODECI, CRADIS and AROMAN MCDM methods. International Journal of Business and Economic Studies, 7(1), 1-18. <https://doi.org/10.54821/uiecd.1587675>

Demir, A. (2021). “ISO 1. 500 ve 2. 500 NİCE Kodu 322 Olan Firmaların Topsis Araştırma Yöntemine Göre İncelenmesi”, International Journal of Disciplines Economics ve Administrative Scienvs Studies, (e-ISSN:2587-2168), Vol:7, Issue:32; pp:636-651, <http://dx.doi.org/10.26728/ideas.459>

Demirhan, A., Ulutaş, A., ve Pala, O. BİST’te İşlem Gören Seçili Ticari Bankaların LODECI ve ARLON Yöntemleriyle Performansının Değerlendirilmesi. İzmir İktisat Dergisi, 40(3), 918-941. <https://doi.org/10.24988/ije.1595885>

Dikmen, F. C., ve Kavakcı, I. (2022). Bütünleşik Olarak Kullanılan Macbeth, TOPSIS ve COPRAS Yöntemleri ile Kurumsal Kaynak Planlama Yazılım Seçimi. Ağrı İbrahim Çeçen Üniversitesi Sosyal Bilimler Enstitüsü Dergisi, 8(1), 205-238. <https://doi.org/10.31463/aicusbed.1067579>

FAO. (2017). *The future of food and agriculture – Trends and challenges*. <https://openknowledge.fao.org/server/api/core/bitstreams/2e90c833-8e84-46f2-a675-ea2d7afa4e24/content>, Food and

Agriculture Organization of the United Nations (Eriřim Tarihi: 11/12/2025).

Geçer, N., & Afřar, B. (2025). ISO 500 2021 Listesinde Yer Alan ISO Üyesi řirketlerin Finansal Performansının Topsis ve Aras Yöntemleriyle Deęerlendirilmesi. *İřletme ve İktisat Çalışmaları Dergisi*, 11(2), 36-53.

Gençtürk, M., Senal, S., ve Aksoy, E. (2021). COVID-19 pandemisinin katılım bankaları üzerine etkilerinin bütünleşik CRITIC-MARCOS yöntemi ile incelenmesi. *Muhasebe ve Finansman Dergisi*, (92), 139-160.
<https://doi.org/10.25095/mufad.937185>

İSO 500, <https://www.iso500.org.tr/500-buyuk-sanayi-kurulusu?yil=2024>, (Eriřim Tarihi: 22.08.2025)

Keshavarz-Ghorabae, M., Amiri, M., Zavadskas, E. K., Turskis, Z., ve Antucheviciene, J. (2021). Determination of objective weights using a new method based on the removal effects of criteria (MERECE). *Symmetry*, 13(4), 525.
<https://doi.org/10.3390/sym13040525>

OECD (2020). *Global value chains in agriculture and food: A synthesis of OECD analysis*. OECD Food, Agriculture and Fisheries Papers, No. 139, OECD Publishing.
<http://dx.doi.org/10.1787/6e3993fa-en> (Eriřim Tarihi: 11/12/2025).

Özdaęoęlu, A., Keleş, M. K., ve Iřıldak, B. (2021). Dünyanın En İřlek Havalimanlarının Pıprecia-E, Smart Ve Marcos Yöntemleri İle Deęerlendirilmesi. *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakóltesi Dergisi*, (58), 333-352.
<https://doi.org/10.18070/erciyesiibd.856842>

- Pala, O. (2024). Assessment of the social progress on European Union by logarithmic decomposition of criteria importance. *Expert Systems with Applications*, 238, 121846. <https://doi.org/10.1016/j.eswa.2023.121846>
- Pala, O., Atçeken, Ö., Omurtak, H., ve Şimşir, B. (2024). BİST çimento sektöründe LODECI ve CRADIS ile finansal performans analizi. *Alanya Akademik Bakış*, 8(3), 956-970. <https://doi.org/10.29023/alanyaakademik.1452960>
- Reardon, T., Timmer, C. P., Barrett, C. B., & Berdegue, J. (2003). The rise of supermarkets in Africa, Asia, and Latin America. *American journal of agricultural economics*, 85(5), 1140-1146. <https://www.jstor.org/stable/1244885>
- Shannon, C. E. (1948). A mathematical theory of communication. *Bell System Technical Journal*, 27, 379-423, 623-656.
- Stević, Ž., Pamučar, D., Puška, A., ve Chatterjee, P. (2020). Sustainable supplier selection in healthcare industries using a new MCDM method: Measurement of alternatives and ranking according to COMpromise solution (MARCOS). *Computers ve industrial engineering*, 140, 106231. <https://doi.org/10.1016/j.cie.2019.106231>
- Stević, Ž., ve Brković, N. (2020). A novel integrated FUCOM-MARCOS model for evaluation of human resources in a transport company. *Logistics*, 4(1), 4. <https://doi.org/10.3390/logistics4010004>
- Tufan, D., ve Ulutaş, A. (2026). Supplier Selection in the Food Sector: An Integrated Approach Using LODECI and CORASO Methods. *Spectrum of Decision Making and Applications*, 3(1), 40-51. <https://doi.org/10.31181/sdmap31202631>

UNIDO. (2019). *Industrial development report 2020: Industrializing in the digital age*.
<https://www.unido.org/sites/default/files/unido-publications/2023-03/UNIDO-IDR2020-main-report-en.pdf>, United Nations Industrial Development Organization (Eriřim Tarihi: 11/12/2025).

BÖLÜM 2

GELİŞEN EKONOMİLERDE ÜLKE RİSKİ VE TEKNOLOJİ HİSSE SENEDİ PİYASALARI: KAVRAMSAL VE AMPİRİK BİR ÇERÇEVE*

SALİH DOĞANAY¹
GÜLCAN ÇAĞIL²

Giriş

Bu bölüm, gelişen ekonomilerde ülke riskinin teknoloji hisse senedi piyasaları üzerindeki etkilerini kavramsal ve ampirik bir çerçeve içinde ele almaktadır. Teknoloji sektörünün son yıllarda ekonomik büyüme, verimlilik ve yenilikçilik açısından artan önemine rağmen, bu sektörün makroekonomik ve politik risklere karşı nasıl fiyatlandığına ilişkin literatür sınırlı ve parçalıdır. Mevcut

¹Doktora Öğrencisi, Marmara Üniversitesi Bankacılık ve Sigortacılık Enstitüsü, Sermaye Piyasası ve Borsa Anabilim Dalı, Doktora Programı, Orcid: 0000-0003-3912-7765

² Prof. Dr., Marmara Üniversitesi, Finansal Bilimler Fakültesi, Aktüerya Bilimleri Bölümü, Aktüerya Anabilim Dalı, Orcid: 0000-0003-2632-7856

*Bu çalışma, Marmara Üniversitesi Bankacılık ve Sigortacılık Enstitüsü, Sermaye Piyasası ve Borsa Anabilim Dalı'nda birinci yazarın, ikinci yazar danışmanlığında yürütülen doktora tezinden üretilmiştir.

alıřmalar oęunlukla lke riskini genel piyasa endeksleri zerinden incelemekte ve sektrler arası farklılařmayı yeterince dikkate almamaktadır.

Bu blm, teknoloji hisselerinin maddi olmayan sermaye yoęunluęu, yksek byme beklentileri ve kresel entegrasyon dzeyi gibi ayırt edici zellikleri nedeniyle lke riskine farklı tepkiler verebilme ihtimali zerinde durmaktadır. lke riski, kredi derecelendirme notları ve piyasa temelli gstergeler baęlamında tartıřılmakta; zellikle kredi temerrt takaslarının (CDS) lmdeki rol vurgulanmaktadır. Metodolojik olarak, lke riskinin teknoloji hisseleri zerindeki etkilerinin getiri ve oynaklık kanalları zerinden, farklı zaman ufuklarında ortaya ıkabileceęi dřnlmektedir. Blm, bu erevede sektr bazlı risk analizlerinin nemine ve gelecekteki arařtırma alanlarına dikkat ekmektedir.

lke Riski ve Teknoloji Hisseleri Neden Birlikte Ele Alınmalı?

2000'li yıllar, dijital teknolojilerin ekonomik byme dinamikleri zerindeki etkilerinin belirgin biimde hissedilmeye bařlandığı bir dnm noktasına iřaret etmektedir. Kiřisel bilgisayarların yaygınlařması ve bilgi iřlem kapasitesindeki hızlı artıř, firmaların retim srelerini dnřtrmř; zellikle geliřmiř ekonomilerde verimlilik artıřlarını destekleyen temel unsurlardan biri hline gelmiřtir. Bu dnemde bilgi ve iletiřim teknolojileri, yalnızca belirli sektrlere zg bir yenilik alanı olmaktan ıkarak, ekonominin geneline yayılan yatay bir retim girdisi nitelięi kazanmıřtır (Jorgenson, 2001; Jorgenson, Ho, & Stiroh, 2008).

2000'li yılların ikinci yarısından itibaren ise internet teknolojilerinin hızla yaygınlařması, bu dnřm daha da derinleřtirmiřtir. Dijital platformlar, e-ticaret ve evrimii hizmetler, firmaların leklenme biimlerini kkl řekilde deęiřtirmiř; dřk marjinal maliyetler ve kresel eriřim imknları sayesinde teknoloji řirketlerinin kısa srede byk piyasa deęerlerine ulařabilmesini

mümkün kılmıştır. İnternet tabanlı iş modellerinin yükselişi, teknoloji sektörünü küresel finansal piyasaların merkezî bir bileşeni hâline getirmiştir (Varian, Shapiro, & Farrell, 2004; Goldfarb & Tucker, 2019).

Son dönemde ise yapay zekâ, makine öğrenmesi ve büyük veri uygulamalarındaki gelişmeler, teknoloji temelli büyümenin yeni bir evresine işaret etmektedir. Yapay zekâ destekli otomasyon, karar destek sistemleri ve veri analitiği, firmaların üretkenliğini artırmakta ve kaynak tahsisini daha etkin hâle getirmektedir. Bu gelişmeler, teknoloji sektörünü ekonomik büyüme ve verimlilik artışları açısından stratejik bir konuma taşırken, aynı zamanda bu sektörün geleceğe dönük beklentilere dayalı değerlendirme yapısını daha da güçlendirmektedir (Brynjolfsson & McAfee, 2014; Acemoglu & Restrepo, 2019; Acemoglu et al., 2022).

Bu küresel dönüşüm süreci yalnızca gelişmiş ekonomilerle sınırlı kalmamış, gelişen piyasalarda da teknoloji tabanlı iş modellerinin hızla yaygınlaşmasına zemin hazırlamıştır. Özellikle son on yılda, gelişen ekonomilerde faaliyet gösteren teknoloji şirketleri hem yerel pazarlarda hem de uluslararası ölçekte dikkat çekici büyüme performansları sergilemiştir. Latin Amerika'da Mercado Libre gibi dijital platformlar, gelişen piyasalarda teknoloji şirketlerinin nasıl hızla ölçeklenebildiğini ve küresel yatırımcıların ilgisini çekebildiğini göstermektedir (Goldfarb & Tucker, 2019).

Türkiye de bu küresel eğilimin dışında kalmamıştır. Son yıllarda Türkiye'de faaliyet gösteren teknoloji şirketleri, e-ticaret, dijital platformlar ve mobilite alanlarında önemli bir büyüme süreci yaşamıştır. Trendyol ve Getir gibi şirketler, kısa sürede geniş kullanıcı tabanlarına ulaşarak yalnızca yerel piyasalarda değil, uluslararası ölçekte de görünürlük kazanmıştır. Benzer şekilde, Martı gibi platformlar, teknoloji temelli iş modellerinin Türkiye ekonomisindeki potansiyelini ortaya koymaktadır. Bu gelişmeler,

teknoloji sektörünün Türkiye’de giderek artan ekonomik ağırlığına işaret etmektedir.

Bu bağlamda değerlendirdiğimizde son yıllarda gelişen ekonomilerde faaliyet gösteren teknoloji şirketleri, finansal piyasalardaki dönüşümün en görünür aktörleri hâline gelmiştir. Dijital platformlar, e-ticaret şirketleri ve teknoloji odaklı hizmet firmaları, kısa süre içerisinde ulaştıkları ölçek ve yarattıkları piyasa değerleriyle yalnızca yerel sermaye piyasalarında değil, küresel portföy yatırımcılarının varlık tahsis kararlarında da merkezi bir konum elde etmiştir. Bununla birlikte, bu şirketlerin piyasa performansları, çoğu zaman faaliyet gösterdikleri ülkelerin maruz kaldığı makroekonomik dalgalanmalar, politika belirsizlikleri ve finansal stres dönemleriyle eş zamanlı olarak ciddi oynaklıklar sergilemektedir. Bu eş zamanlılık, teknoloji sektörünün büyüme potansiyeli ile ülke riskinin yarattığı kırılganlıkların aynı anda var olabildiğini göstermekte ve ülke riskinin sektörel yansımalarına ilişkin daha derin bir analizi gerekli kılmaktadır.

Ülke riskinin finansal piyasalar üzerindeki etkileri, uluslararası finans literatüründe uzun süredir incelenmektedir. Bu literatür, ülke riskini genellikle makroekonomik dengesizlikler, politik belirsizlikler ve dış finansman koşulları çerçevesinde ele almakta; söz konusu riskin varlık fiyatları üzerindeki etkilerini çoğunlukla ulusal hisse senedi endeksleri veya piyasa geneli risk primleri üzerinden değerlendirmektedir (Longstaff et al., 2011; Augustin et al., 2018). Bu yaklaşım, ülke riskinin sistemik doğasını vurgulamak açısından güçlü bir çerçeve sunmakla birlikte, finansal piyasaların sektörel bileşimine ilişkin önemli farklılıkları ikincil plana itmektedir.

Oysa hisse senedi piyasaları, ekonomik faaliyetlerin homojen bir yansıması olmaktan ziyade, farklı üretim teknolojilerine, bilanço yapılarına ve finansman modellerine sahip sektörlerin bileşiminden oluşmaktadır. Bu yapısal heterojenlik, ülke riskine verilen tepkilerin

de sektörler arasında anlamlı biçimde farklılaşmasına yol açabilir. Buna rağmen, mevcut literatürde ülke riskinin sektörel düzeydeki aktarım mekanizmaları görece sınırlı biçimde ele alınmıştır. Özellikle teknoloji sektörü gerek değerlendirme dinamikleri gerekse küresel entegrasyon düzeyi nedeniyle ülke riskine karşı farklı bir hassasiyet sergileyebilecek olmasına rağmen, bu bağlamda yeterince sistematik biçimde incelenmemiştir.

Teknoloji sektörünün ülke riskine karşı potansiyel olarak ayrışan bir tepki vermesinin altında yatan temel mekanizmalar çok boyutludur. İlk olarak, teknoloji firmalarının piyasa değerleri büyük ölçüde geleceğe dönük büyüme beklentilerine ve maddi olmayan sermaye stoklarına dayanmaktadır. Bu özellik, teknoloji hisselerini iskonto oranlarındaki değişimlere ve belirsizlik şoklarına karşı özellikle duyarlı hâle getirmektedir (Kogan et al., 2017; Peters & Taylor, 2017). İkinci olarak, bu firmalar genellikle uzun vadeli yatırım projeleri yürütmekte ve bu projelerin finansmanında dış kaynaklara daha yoğun biçimde başvurmaktadır. Dolayısıyla ülke riskindeki artışlar, finansman maliyetleri ve risk algısı üzerinden teknoloji şirketlerinin değerlemesini diğer sektörlerle kıyasla daha güçlü biçimde etkileyebilir.

Buna ek olarak, gelişen piyasalardaki teknoloji firmaları çoğunlukla küresel değer zincirlerine entegre durumdadır. İthal ara mallar, yabancı para cinsinden gelir akımları ve döviz cinsinden borçlanma yapıları, bu firmaları döviz kuru oynaklığına ve küresel finansal koşullardaki değişimlere karşı daha kırılgan hâle getirmektedir. Bu bağlamda, ülke riski ile döviz kuru stresi arasındaki etkileşim, finansal piyasalara olan etkilerin yalnızca getiri kanalıyla değil, aynı zamanda belirsizlik ve oynaklık dinamikleri üzerinden de şekillenebileceğine işaret etmektedir. Özellikle gelişen piyasalarda, sermaye akımları, döviz kuru baskıları ve risk alma davranışları aracılığıyla işleyen bu mekanizma, ülke riskinin finansal piyasalara aktarılmasının çok boyutlu bir süreç olduğunu

göstermektedir (Bruno & Shin, 2015). Sonuç olarak ülke riski ile döviz kuru stresi arasındaki etkileşim, teknoloji hisseleri üzerinde de etkilerin yalnızca getiri kanalıyla değil, aynı zamanda belirsizlik ve volatilité kanalıyla da ortaya çıkmasına neden olmaktadır. Bu mekanizma, özellikle gelişen piyasalarda ülke riskinin finansal piyasalara aktarımının çok boyutlu bir süreç olduğunu göstermektedir.

Bu bölümün temel amacı, ülke riski ile teknoloji hisse senedi piyasaları arasındaki ilişkiyi kavramsal ve ampirik bir çerçeve içinde sistematik biçimde incelemektir. Bölümün ana argümanı, ülke riskindeki artışların teknoloji gibi kırılganlığı yüksek sektörleri, diğer sektörlerle kıyasla daha belirgin ve daha hızlı biçimde etkileyebileceğidir. Bu etki, özellikle ortalama getirilerden ziyade volatilité dinamikleri üzerinden kendini göstermektedir. Mevcut literatürde de vurgulandığı üzere, belirsizlik şoklarının ve risk algısındaki ani değişimlerin varlık fiyatlarına yansımaları çoğu zaman oynaklık kanalı üzerinden gerçekleşmektedir (Campbell & Hentschel, 1992; Bollerslev et al., 2009).

Bu çerçevede bölüm, ülke riskinin teknoloji hisseleri üzerindeki etkilerinin frekansa duyarlı bir bakış açısıyla ele alınması gerektiğini savunmaktadır. Düşük frekansta incelenen ortalama getiri serileri, ülke riskindeki dalgalanmaların piyasalara yansımalarını sınırlı ölçüde yakalayabilirken; yüksek frekansta gözlenen volatilité dinamikleri, yatırımcı algısındaki ve risk değerlendirmelerindeki değişimleri daha doğrudan yansıtabilmektedir (Engle, 2001; Ghysels et al., 2005). Bu ayrım, özellikle politika belirsizliğinin ve makroekonomik şokların sık yaşandığı gelişen ekonomiler bağlamında daha da kritik hâle gelmektedir.

Türkiye örneği, bu kavramsal çerçevenin somutlaştırılması açısından açıklayıcı bir vaka sunmaktadır. Yüksek ve dalgalı ülke risk primleri, belirgin döviz kuru oynaklığı ve sık değişen politika

ortamı, Türkiye’yi ülke riskinin sektörel yansımalarını incelemek için doğal bir laboratuvar hâline getirmektedir. Bu bölümde Türkiye, genellenebilir nedensel çıkarımlar üretmek amacıyla değil; ülke riski ile teknoloji hisseleri arasındaki etkileşimin nasıl şekillenebileceğini betimleyici biçimde ortaya koyan bir örnek olarak ele alınmaktadır; bu yaklaşım, kriz dönemlerinde eş-hareketlerin yorumlanmasına ilişkin metodolojik uyarılarla uyumludur (Forbes & Rigobon, 2002).

Bölümün geri kalanında, öncelikle ülke riskinin piyasa temelli bir göstergesi olarak kredi temerrüt takaslarının (CDS) rolü ve literatürdeki yeri ele alınmaktadır. Ardından teknoloji sektörünün ayırt edici yapısal özellikleri detaylandırılmakta ve ülke riskine karşı neden farklı bir hassasiyet sergileyebileceği tartışılmaktadır. Daha sonra, frekansa duyarlı metodolojik bir yaklaşımın gerekçesi ortaya konulmakta ve Türkiye’ye ilişkin betimleyici gözlemler sunulmaktadır. Son olarak, bu çerçevenin ortaya çıkardığı açık araştırma soruları ve gelecekteki ampirik çalışmalar için potansiyel yönelimler değerlendirilmektedir.

Ülke Riski, CDS ve Finansal Piyasalar

Ülke riski, bir ekonomide faaliyet gösteren yatırımcıların ve firmaların karşı karşıya kaldığı politik, makroekonomik ve kurumsal belirsizliklerin bileşik bir yansıması olarak tanımlanabilir. Bu risk unsurları; kamu borç dinamikleri, dış finansman bağımlılığı, para ve maliye politikalarının öngörülebilirliği ile kurumsal yapıların etkinliği gibi çok sayıda faktörü içermektedir. Uluslararası finans literatüründe ülke riski, söz konusu belirsizliklerin sermaye akımları, varlık fiyatları ve finansal istikrar üzerindeki etkilerini açıklamak üzere merkezi bir kavram olarak ele alınmaktadır.

Ülke riskinin ölçülmesine yönelik yaklaşımlar tarihsel olarak önemli bir evrim geçirmiştir. Erken dönem çalışmalarda ülke riski çoğunlukla kredi derecelendirme notları veya makroekonomik göstergeler aracılığıyla temsil edilmiştir. Ancak bu tür göstergeler,

düşük frekanslı olmaları ve geriye dönük bilgi içermeleri nedeniyle finansal piyasalardaki hızlı risk algısı değişimlerini yakalamakta sınırlı kalmaktadır (Cantor & Packer, 1996; Reinhart, 2002). Bu sınırlılıklar, piyasa temelli risk göstergelerine olan ilgiyi artırmış ve kredi temerrüt takaslarını (credit default swaps, CDS) ülke riskinin ölçümünde merkezi bir konuma taşımıştır.

CDS sözleşmeleri, bir borçlunun temerrüde düşmesi riskine karşı sigorta sağlayan türev araçlar olarak tanımlanmaktadır. Egemen CDS'ler (sovereign CDS), yatırımcıların bir ülkenin kamu borcuna ilişkin temerrüt riskine dair beklentilerini doğrudan yansıtan piyasa temelli göstergeler sunmaktadır. Bu özellikleri sayesinde CDS spread'leri, kredi derecelendirme notlarına kıyasla daha yüksek frekansta güncellenmekte ve piyasa katılımcılarının risk algısındaki ani değişimleri daha hızlı biçimde fiyatlara yansıtmaktadır (Duffie, 1999; Pan & Singleton, 2008).

Mevcut literatür, egemen CDS spread'lerinin yalnızca temerrüt olasılığını değil, aynı zamanda küresel risk iştahı, likidite koşulları ve makroekonomik belirsizlik gibi unsurları da bünyesinde barındırdığını göstermektedir. Longstaff ve arkadaşları (2011), CDS spread'lerinin önemli bir bölümünün küresel risk faktörleriyle ilişkili olduğunu ve bu nedenle egemen CDS'lerin ülke riskinin çok boyutlu bir ölçüsü olarak değerlendirilmesi gerektiğini vurgulamaktadır. Bu bulgu, CDS'lerin finansal piyasalardaki aktarım mekanizmalarını incelemek için neden sıklıkla tercih edildiğini açıklamaktadır.

Ülke riskinin finansal piyasalara aktarımı, literatürde çoğunlukla hisse senedi piyasaları üzerinden incelenmiştir. Bu etkiler birden fazla kanal aracılığıyla ortaya çıkabilmektedir. İlk olarak, **iskonto oranı kanalı** ülke riskinin varlık fiyatlamasındaki temel mekanizmalarından biridir. Ülke riskindeki artışlar, yatırımcıların talep ettiği risk primlerini yükselterek gelecekteki nakit akımlarının daha yüksek oranlarla iskonto edilmesine yol

açmakta ve hisse senedi değerlemeleri üzerinde aşağı yönlü baskı yaratmaktadır. Politika belirsizliği ve risk primleri arasındaki bu ilişki, literatürde yaygın biçimde belgelenmiştir (Pastor & Veronesi, 2012).

İkinci olarak, **finansman maliyeti kanalı**, özellikle dış finansmana bağımlı firmalar açısından önem taşımaktadır. Ülke riskindeki artışlar, borçlanma maliyetlerini yükselterek firmaların yatırım ve büyüme kararlarını sınırlandırabilmektedir. Literatür, egemen riskteki bozulmaların firma düzeyinde finansman koşullarına hızla yansiyabildiğini ve bu durumun hisse senedi piyasaları üzerinde olumsuz etkiler yaratabildiğini göstermektedir (Augustin et al., 2018).

Üçüncü olarak, **belirsizlik ve volatilité kanalı**, ülke riskinin hisse senedi piyasalarına aktarımında giderek daha fazla önem kazanan bir mekanizma olarak öne çıkmaktadır. Risk algısındaki ani değişimler ve belirsizlik şokları, yatırımcı davranışlarını etkileyerek piyasa oynaklığını artırabilmektedir. Ülke riskinin hisse senedi piyasalarına olan etkisinin yalnızca beklenen getiriler üzerinden değil, aynı zamanda volatilité dinamikleri üzerinden de ortaya konmasının önemli olduğu vurgulamaktadır. Belirsizlikteki artışlar ve risk algısındaki ani değişimler, yatırımcı davranışlarını ve portföy tahsis kararlarını etkileyerek piyasa oynaklığını artırabilmektedir. Bu bağlamda, CDS spread'lerindeki yükselişler, çoğu zaman hisse senedi piyasalarında artan volatilitéyle eş zamanlı olarak gözlemlenmektedir. Literatürde bu mekanizma, riskin fiyatlanmasında oynaklık kanalının önemine işaret eden çalışmalarla da uyumlu görünmektedir (Campbell & Hentschel, 1992; Bollerslev et al., 2009). Bu durum özellikle gelişmekte olan ülkelerin maruz kaldığı riskler açısından incelemeye değer bir durum ifade etmekte ve gelişen ülkelerin dinamik yapısı açısından daha anlamlı sonuçlar ortaya koymaktadır.

Genel olarak bu alıřmalar egemen riskteki artıřların firmaların finansman maliyetlerini ykselttiğini, yatırım kararlarını sınırladığını ve sonu olarak hisse senedi deęerlemelerini olumsuz etkilediğini gstermektedir. zellikle son dnemdeki arařtırmalar, egemen risk ile firma dzeyindeki risk arasında gl bir baęlantı bulunduęunu ve lke riskindeki řokların firma bilanolarına ve piyasa deęerlerine yansıyabildiğini ortaya koymaktadır (Augustin et al., 2018).

Bununla birlikte, lke riskinin hisse senedi piyasalarına etkilerine iliřkin bulguların byk lde piyasa geneli dzeyinde raporlandığı grlmektedir. Ulusal hisse senedi endeksleri veya ortalama piyasa getirileri zerinden yapılan analizler, lke riskinin sistemik etkilerini yakalamak aısından faydalı olmakla birlikte, sektrler arası heterojenlięi oęu zaman gz ardı etmektedir. Oysa firmaların faaliyet gsterdikleri sektrler, maruz kaldıkları risk trleri ve bu risklere verdikleri tepkiler aısından nemli farklılıklar gstermektedir. Bu durum, lke riskinin sektrel dzeydeki aktarım mekanizmalarının daha ayrıntılı biimde ele alınmasını gerekli kılmaktadır.

zetle, lke riskinin piyasa temelli bir gstergesi olarak CDS'ler, finansal piyasalardaki risk algısını yksek frekansta ve ok boyutlu biimde yansıtan gl bir ara sunmaktadır. Ancak mevcut literatr, bu aracın sektrel dzeyde nasıl farklılařtığını ve zellikle teknoloji gibi belirli sektrlerde lke riskinin hangi kanallar zerinden daha belirgin etkiler yarattığını sınırlı lde ele almaktadır. Bu bořluk, lke riski ile sektr bazlı hisse senedi dinamikleri arasındaki iliřkinin daha sistematik biimde incelenmesini gerekli kılmaktadır.

Bir sonraki blmde, teknoloji sektrnn yapısal zellikleri ayrıntılı biimde ele alınmakta ve bu sektrn neden lke riskine karřı farklı bir hassasiyet sergileyebileceęi tartıřılmaktadır.

Neden Teknoloji Sektörü? Sektörel Farklılaşma ve Kırılğanlıklar

Ülke riskinin finansal piyasalara etkilerinin sektörel düzeyde ayrışabileceği fikri, hisse senedi piyasalarının yapısal heterojenliğine dayanmaktadır. Sektörler, üretim teknolojileri, varlık kompozisyonları, finansman yapıları ve küresel entegrasyon düzeyleri ve ölçekleri bakımından önemli farklılıklar göstermekte; bu farklılıklar, makroekonomik ve politik şoklara verilen tepkilerin de sektörler arasında ayrışmasına yol açabilmektedir. Bu bağlamda teknoloji sektörü, sahip olduğu özgün özellikler nedeniyle ülke riskinin aktarım mekanizmalarını incelemek açısından ayrıcalıklı bir konumda yer almaktadır.

Teknoloji firmalarının ayırt edici özelliklerinden ilki, piyasa değerlerinin büyük ölçüde maddi olmayan varlıklara ve geleceğe dönük büyüme beklentilerine dayanmasıdır. Geleneksel sektörlerde firma değeri çoğunlukla mevcut fiziksel sermaye ve cari nakit akımları üzerinden şekillenirken, teknoloji firmalarının değeri büyük ölçüde henüz realize edilmemiş yatırım projelerine ve büyüme opsiyonlarına dayanmaktadır. Bu durum, teknoloji hisselerini iskonto oranlarındaki değişimlere ve belirsizlik şoklarına karşı daha duyarlı hâle getirmektedir (Kogan et al., 2017; Peters & Taylor, 2017). Ülke riskindeki artışlar, sermaye maliyetini yükselterek bu büyüme opsiyonlarının değerini orantısız biçimde azaltabilir. Bu durum gelişen ülkeler için özellikle anlamlı hale gelmektedir.

İkinci olarak, teknoloji sektöründe faaliyet gösteren firmalar genellikle uzun vadeli ve yüksek riskli yatırım projeleri yürütmekte, bu projelerin finansmanında ise dış kaynaklara ve küresel sermaye piyasalarına daha yoğun biçimde bağımlı olmaktadır. Özellikle gelişen piyasalarda, yerel finansal piyasaların derinliğinin sınırlı olması, teknoloji firmalarını yabancı para cinsinden borçlanmaya veya uluslararası yatırımcıların fon akımlarına daha açık hâle

getirmektedir. Bu durum, ülke riskindeki artışların finansman maliyetleri ve risk algısı üzerinden teknoloji firmalarının piyasa değerlerini diğer sektörlere kıyasla daha güçlü biçimde etkileyebilmesine yol açmaktadır. Literatür, egemen riskteki artışların firmaların borçlanma maliyetlerini yükselttiğini ve finansman koşullarını sıkılaştırdığını göstermektedir (Augustin et al., 2018).

Teknoloji sektörünün ülke riskine karşı görece yüksek hassasiyetinin bir diğer kaynağı, bu firmaların küresel değer zincirlerine olan yoğun entegrasyonudur. Yazılım, e-ticaret, dijital platformlar ve teknoloji odaklı hizmetler, çoğu zaman sınır ötesi faaliyetler, ithal ara mallar ve uluslararası müşteri ağları üzerinden yürütülmektedir. Bu yapı, teknoloji firmalarını döviz kuru hareketlerine ve küresel finansal koşullardaki dalgalanmalara karşı daha kırılgan hâle getirmektedir. Ülke riskindeki artışlar sıklıkla döviz kuru oynaklığı ve sermaye çıkışlarıyla birlikte seyrettiğinden, bu etkileşim hisse fiyatları üzerinde ek bir belirsizlik kanalı yaratmaktadır (Bruno & Shin, 2015).

Buna ek olarak, teknoloji firmaları çoğunlukla düzenleyici çerçevelere, veri politikalarına ve kamu müdahalelerine duyarlı faaliyet alanlarında faaliyet göstermektedir. Dijital platformların regülasyonu, veri güvenliği, rekabet politikaları ve vergi uygulamaları gibi konular, özellikle gelişen piyasalarda sık değişen politika ortamlarının bir parçasıdır. Bu durum, teknoloji hisselerinin politika belirsizliği ve ülke riskindeki dalgalanmalara karşı daha yüksek bir duyarlılık sergilemesine neden olabilmektedir. Politika belirsizliğinin büyüme hisseleri üzerindeki etkilerine ilişkin literatür de bu mekanizmayla tutarlı bulgular sunmaktadır (Pastor & Veronesi, 2012).

Bu özellikler bir arada değerlendirildiğinde, teknoloji sektörünün ülke riskine karşı hassasiyetinin yalnızca beklenen getiri kanalıyla sınırlı olmadığı görülmektedir. Aksine, ülke riskindeki

artışlar, teknoloji hisselerinde çoğu zaman belirsizlik ve oynaklık dinamikleri üzerinden daha hızlı ve daha belirgin biçimde kendini gösterebilmektedir. Bu durum, teknoloji sektörünü ülke riskinin finansal piyasalara aktarımını incelemek açısından özellikle elverişli bir alan hâline getirmektedir. Literatürde volatilité kanalının varlık fiyatlamasında oynadığı role ilişkin bulgular, bu yaklaşımı desteklemektedir (Campbell & Hentschel, 1992; Bollerslev et al., 2009).

Son olarak, gelişen piyasalarda teknoloji sektörünün görece yeni ve hızlı büyüyen bir alan olması, bu sektördeki firmaların bilgi asimetrilerine ve yatırımcı duyarlılığına daha açık olmasına yol açmaktadır. Kurumsal şeffaflığın sınırlı olduğu veya piyasa derinliğinin düşük olduğu ortamlarda, ülke riskindeki artışlar yatırımcı beklentilerini hızlı biçimde değiştirebilmekte ve bu değişim teknoloji hisselerinde daha keskin fiyat değişimi ve oynaklık tepkilerine neden olabilmektedir. Bu özellik, teknoloji sektörünü ülke riskinin dinamik etkilerini gözlemlemek açısından doğal bir laboratuvar hâline getirmektedir.

Özetle, teknoloji sektörü; büyüme opsiyonlarına dayalı değerlendirme yapısı, dış finansman bağımlılığı, küresel entegrasyon düzeyi ve politika belirsizliğine olan duyarlılığı nedeniyle ülke riskine karşı diğer sektörlerden sistematik biçimde ayrışabilecek bir profil sergilemektedir. Bu ayrışma, ülke riskinin teknoloji hisseleri üzerindeki etkilerinin yalnızca ortalama getiriler üzerinden değil, aynı zamanda volatilité ve belirsizlik dinamikleri üzerinden de incelenmesini gerekli kılmaktadır. Bir sonraki bölümde, bu çok boyutlu etkileşimi analiz edebilmek için neden frekansa duyarlı bir metodolojik çerçevenin benimsenmesi gerektiği ayrıntılı biçimde ele alınmaktadır.

Metodolojik Çerçeve: Getiri ve Oynaklık Temelli Bir Yaklaşım

Ülke riskinin hisse senedi piyasalarına etkilerini analiz etmeye yönelik ampirik çalışmalar, büyük ölçüde kullanılan veri frekansına ve metodolojik çerçeveye bağlıdır. Makroekonomik belirsizlikler, politika şokları ve finansal stres dönemleri, piyasalara farklı hızlarda ve farklı kanallar üzerinden yansiyabilmektedir. Bu nedenle ülke riskinin teknoloji hisseleri üzerindeki etkilerini tek bir frekans veya tek bir modelleme yaklaşımıyla incelemek, söz konusu etkileşimin dinamik doğasını tam olarak yakalamakta yetersiz kalabilir.

Geleneksel varlık fiyatlama literatürü, ülke riskinin hisse senedi getirileri üzerindeki etkilerini çoğunlukla düşük frekanslı veriler üzerinden incelemektedir. Aylık veya çeyreklik getiriler kullanılarak kurulan faktör modelleri, ülke riskinin beklenen getiriler ve risk primleri üzerindeki kalıcı etkilerini değerlendirmek açısından uygun bir çerçeve sunmaktadır. Ancak bu yaklaşım, belirsizlik şoklarının ve risk algısındaki ani değişimlerin piyasalara yansımaları büyük ölçüde ortalamalar üzerinden değerlendirmekte ve kısa vadeli dinamikleri ikincil plana itmektedir.

Buna karşılık, finansal piyasalarda belirsizlik ve risk algısındaki değişimler çoğu zaman volatilité dinamikleri üzerinden daha hızlı ve daha belirgin biçimde ortaya çıkmaktadır. Volatilité, yatırımcı beklentilerindeki dağılmayı, bilgi akışının hızını ve riskten kaçınma davranışlarını yansıtan temel bir gösterge olarak kabul edilmektedir. Bu bağlamda, ülke riskindeki artışların teknoloji hisseleri üzerindeki etkilerinin yalnızca beklenen getiri kanalıyla değil, aynı zamanda volatilité kanalıyla da incelenmesi gerekmektedir. Literatürde volatilitenin varlık fiyatlamasında oynadığı role ilişkin bulgular, bu yaklaşımı desteklemektedir (Campbell & Hentschel, 1992; Bollerslev et al., 2009).

Bu bölümde benimsenen metodolojik yaklaşım, ülke riskinin teknoloji hisse senedi piyasalarına etkilerini frekansa duyarlı bir çerçeve içinde ele almaktadır. Bu çerçeve, düşük frekansta beklenen

getiri dinamiklerini ve yüksek frekansta oynaklık dinamiklerini birbirinden ayırarak analiz etmeyi amaçlamaktadır. Bu ayrım, ülke riskinin finansal piyasalara aktarımının çok boyutlu doğasını daha açık biçimde ortaya koymayı mümkün kılmaktadır.

Düşük frekanslı analizlerde, ülke riskinin teknoloji hisseleri üzerindeki etkileri, faktör temelli modeller aracılığıyla değerlendirilmektedir. Bu modeller, ülke riskini temsil eden göstergelerin (örneğin egemen CDS spread'leri veya döviz kuru hareketleri) teknoloji hisse senedi getirileriyle olan ilişkisini, piyasa geneli faktörler kontrol edilerek incelemeye olanak tanımaktadır. Bu yaklaşım, ülke riskinin uzun vadeli ve kalıcı etkilerinin ortalama getiriler üzerinden nasıl fiyatlandığını değerlendirmek açısından uygundur. Bununla birlikte, düşük frekanslı getirilerin ülke riskindeki kısa vadeli dalgalanmalara verdiği tepkiler sınırlı olabilir ve bu durum, riskin fiyatlanmasının yalnızca bir boyutunu yansıtabilir.

Yüksek frekanslı analizler ise, ülke riskinin teknoloji hisseleri üzerindeki etkilerini volatilité dinamikleri üzerinden incelemeyi mümkün kılmaktadır. Günlük veriler kullanılarak tahmin edilen koşullu varyans modelleri, risk algısındaki değişimlerin ve belirsizlik şoklarının piyasalara nasıl yansıdığını daha doğrudan yakalayabilmektedir. Özellikle GARCH ailesine ait modeller, finansal zaman serilerinde gözlenen oynaklık kümelenmesi, asimetri ve kaldıraç etkileri gibi olguları modellemek için yaygın biçimde kullanılmaktadır (Engle, 2001).

Bu bağlamda, koşullu varyans modelleri, ülke riskindeki artışların teknoloji hisselerinin oynaklığı üzerindeki etkilerinin zaman içinde nasıl değiştiğini incelemek için uygun bir araç sunmaktadır. Standart GARCH modelleri, oynaklığın geçmiş şoklara verdiği tepkileri simetrik biçimde ele alırken; genişletilmiş modeller, negatif ve pozitif şokların oynaklık üzerindeki etkilerinin farklılaşmasına izin vermektedir. Bu özellik, ülke riskindeki

artışların teknoloji hisselerinde yarattığı belirsizliğin doğasını daha ayrıntılı biçimde analiz etmeyi mümkün kılmaktadır.

Frekansa duyarlı bu metodolojik yaklaşım, aynı zamanda literatürde vurgulanan zamansal toplulaştırma sorunlarına da yanıt vermektedir. Ghysels ve arkadaşları (2005), düşük frekanslı verilerle yapılan analizlerin, yüksek frekanslı dinamikleri maskeleyebileceğini ve risk–getiri ilişkisine dair yanlış çıkarımlara yol açabileceğini göstermektedir. Bu nedenle, ülke riski gibi hızlı değişebilen bir olgunun, farklı frekanslarda ayrı ayrı ele alınması metodolojik açıdan önem taşımaktadır.

Özetle, bu bölümde sunulan metodolojik çerçeve, ülke riskinin teknoloji hisse senedi piyasalarına etkilerini tek boyutlu bir yaklaşımla ele almak yerine, frekansa duyarlı bir analiz stratejisi benimsemektedir. Bu strateji, düşük frekansta ülke riskinin beklenen getiriler üzerindeki etkilerini, yüksek frekansta ise belirsizlik ve volatilité dinamiklerini incelemeye olanak tanımaktadır. Bu yaklaşım, ülke riskinin teknoloji sektörü üzerindeki etkilerini daha kapsamlı ve bütüncül bir perspektiften değerlendirmek için gerekli metodolojik zemini sunmaktadır.

Özetle, ülke riskinin teknoloji hisse senedi piyasalarına aktarımının çok boyutlu ve zamana duyarlı bir yapıya sahip olduğu tartışılmıştır. Bu tartışma, ülke riskinin yalnızca ortalama getiriler üzerinden değil, aynı zamanda belirsizlik ve volatilité dinamikleri aracılığıyla da fiyatlandığını göstermektedir. Bu bağlamda, tek bir model veya tek bir veri frekansı kullanılarak yapılan analizlerin, ülke riskinin finansal piyasalara aktarım mekanizmalarını tam olarak yakalaması güçleşmektedir.

Bu bölümün geri kalanında, ülke riskinin teknoloji hisse senedi piyasalarına etkilerini incelemek üzere kullanılan ekonometrik yaklaşımlar, **teorik çerçeve**, **ampirik temsil**, **zamansal esneklik** ve **belirsizlik kanalı** ayrımı gözetilerek ele

alınmaktadır. Amaç, kullanılan modelleri sonuç üretmekten ziyade, kavramsal ve metodolojik rollerini açık biçimde tanıtmak ve izlenen yaklaşımın neden frekansa duyarlı bir yapı gerektirdiğini ortaya koymaktır. Sonraki bölümde, bu çerçevenin betimleyici bir örnek üzerinden nasıl somutlaştırılabileceği Türkiye piyasaları özelinde değerlendirmektedir.

Teorik Çerçeve: APT ve Çok Faktörlü Varlık Fiyatlama

Varlık getirilerinin sistematik risk faktörleri aracılığıyla açıklanması fikri, modern finans teorisinin temel yapı taşlarından biridir. Bu yaklaşımın çok faktörlü ve arbitraj temelli formülasyonu, Ross (1976) tarafından geliştirilen **Arbitrage Pricing Theory (APT)** ile sistematik bir çerçeveye kavuşturulmuştur. APT, arbitraj fırsatlarının bulunmadığı bir piyasada, varlıkların beklenen getirilerinin birden fazla sistematik risk faktörüne olan duyarlılıklarının doğrusal bir fonksiyonu olarak ifade edilebileceğini öne sürmektedir.

APT'nin temel fiyatlama eşitliği şu şekilde ifade edilmektedir:

$$E(R_i) = R_f + \sum_{k=1}^K b_{ik} \lambda_k$$

Bu eşitlikte, $E(R_i)$ varlık i 'nin beklenen getirisini, R_f risksiz getiri oranını, b_{ik} ilgili risk faktörüne olan duyarlılığı ve λ_k ise faktör risk primini temsil etmektedir. Bu çerçeve, varlık getirilerinin hangi sistematik riskler karşılığında fiyatlandığını kavramsal olarak ortaya koymakta; özellikle makroekonomik ve ülkeye özgü risklerin fiyatlama sürecindeki rolünü vurgulamaktadır (Ross, 1976; Connor, 1984).

Bu çalışmada APT, katı bir ampirik fiyatlama modeli olarak test edilmekten ziyade, ülke riskinin teknoloji hisse senedi getirileri üzerindeki rolünü anlamaya yönelik **teorik bir referans noktası** olarak ele alınmaktadır.

Ampirik Temsil: Aşırı Getiri ve Faktör Regresyonları

APT'nin teorik fiyatlama eşitliğinde yer alan risk primleri ve faktör şokları doğrudan gözlemlenebilir değildir. Bu nedenle ampirik literatürde, APT çoğunlukla gözlemlenebilir faktörler kullanılarak kurulan zaman serisi regresyonları aracılığıyla temsil edilmektedir. Bu yaklaşım, teorik fiyatlama ilişkisinin birebir testi olarak değil, sistematik birlikte hareketlerin ampirik olarak incelenmesi şeklinde yorumlanmaktadır (Cochrane, 2005).

Bu ampirik temsilin temel adımlarından biri, varlık getirilerinin risksiz getiri oranından arındırılarak **aşırı getiri (excess return)** biçimine dönüştürülmesidir. Fama ve MacBeth (1973), risk primlerini aşırı getiriler üzerinden ölçerek, ortak risksiz getiri bileşenini ayırtıran ve dönemler arası karşılaştırmaya imkân veren bir ampirik çerçeve sunmaktadır. Aşırı getiri aşağıdaki şekilde tanımlanmaktadır:

$$R_{i,t}^e = R_{i,t} - R_{f,t}$$

Bu dönüşüm sonrasında kurulan temel faktör regresyonu şu şekilde ifade edilebilir:

$$R_{i,t}^e = \alpha_i + \sum_{k=1}^K \beta_{ik} F_{k,t} + \varepsilon_{i,t}$$

Bu bağlamda excess return kullanımı, APT'nin kendisi değil, teorik çerçevenin ampirik veriye indirgenmesini sağlayan bir **normalizasyon ve temsil aracı** olarak değerlendirilmelidir.

Zamanla Değişen Duyarlılıklar: Rolling Beta Yaklaşımı

Faktör regresyonları, genellikle risk duyarlılıklarının zaman içinde sabit kaldığı varsayımına dayanmaktadır. Ancak özellikle gelişen piyasalarda, politik belirsizlikler, makroekonomik dalgalanmalar ve küresel finansal koşullardaki değişimler, bu varsayımın güçlü biçimde ihlal edilebileceğine işaret etmektedir. Ferson ve Harvey (1999), risk faktörlerine olan duyarlılıkların zaman içinde anlamlı ölçüde değişebildiğini göstermektedir.

Bu bağlamda **rolling beta yaklaşımı**, alternatif bir varlık fiyatlama modeli olarak değil, faktör duyarlılıklarının zaman içindeki evrimini betimlemeye yönelik bir **tahmin tekniği** olarak ele alınmaktadır. Bu yaklaşım, belirli bir pencere uzunluğu boyunca tahmin edilen katsayıların zaman içinde yeniden hesaplanmasına dayanmakta ve ülke riskinin teknoloji hisseleri üzerindeki etkilerinin dönemsel olarak nasıl değiştiğini incelemeye imkân tanımaktadır.

$$R_{i,t}^e = \alpha_{i,t} + \sum_{k=1}^K \beta_{ik,t} F_{k,t} + \varepsilon_{i,t}$$

Bu yöntem, risk duyarlılıklarının durağan olmadığı varsayımını dikkate alarak, ülke riskinin finansal piyasalara aktarımının zamana bağlı doğasını daha görünür hâle getirmektedir.

Belirsizlik Kanalı: Koşullu Varyans ve GARCH Ailesi Modeller

Ülke riskinin finansal piyasalara etkileri yalnızca ortalama getiriler üzerinden değil, aynı zamanda belirsizlik ve oynaklık dinamikleri aracılığıyla da ortaya çıkmaktadır. Finansal zaman serilerinde volatilitenin zaman içinde değişken olduğu ve belirli dönemlerde kümелendiği olgusu, Engle (1982) tarafından geliştirilen **ARCH** modeli ile sistematik biçimde modellenmiştir. Bollerslev

(1986) ise bu yaklaşımı genelleştirerek **GARCH** modelini önermiştir.

$$\sigma_t^2 = \omega + \alpha \varepsilon_{t-1}^2 + \beta \sigma_{t-1}^2$$

Zamanla, negatif şokların volatilité üzerindeki etkilerinin pozitif şoklara kıyasla daha güçlü olabildiği gözlemi, asimetrik volatilité modellerinin geliştirilmesine yol açmıştır. Nelson (1991) tarafından geliştirilen **EGARCH** ve Glosten, Jagannathan ve Runkle (1993) tarafından önerilen **GJR-GARCH** modelleri, bu asimetrik tepkileri yakalamayı amaçlamaktadır. Bu modeller, ülke riskindeki artışların teknoloji hisse senedi piyasalarında yarattığı belirsizliğin dinamik ve doğrusal olmayan doğasını analiz etmek için tamamlayıcı araçlar sunmaktadır.

Türkiye’den Betimleyici Bulgular: Açıklayıcı Bir Vaka

Önceki bölümlerde geliştirilen kavramsal ve metodolojik çerçevenin somutlaştırılması amacıyla, bu bölümde Türkiye teknoloji hisse senedi piyasası betimleyici bir vaka olarak ele alınmaktadır. Türkiye, yüksek ve zaman içinde dalgalı seyreden ülke risk primleri, belirgin döviz kuru oynaklığı ve sık değişen makroekonomik ve politika ortamı nedeniyle, ülke riskinin finansal piyasalara aktarım mekanizmalarını incelemek açısından doğal bir laboratuvar ortamı sunmaktadır. Bu bağlamda Türkiye, genellenebilir nedensel çıkarımlar üretmek amacıyla değil; ülke riski, döviz kuru stresi ve teknoloji hisseleri arasındaki etkileşimin nasıl gözlemlenebileceğini açıklayıcı biçimde ortaya koyan bir örnek olarak değerlendirilmektedir.

Türkiye’ye ilişkin betimleyici gözlemler, ülke riskinin teknoloji hisseleri üzerindeki etkilerinin zaman içinde homojen olmadığını göstermektedir. Egemen CDS spread’lerindeki artışların ve döviz kuru oynaklığındaki yükselişlerin yoğunlaştığı dönemlerde, teknoloji endekslerinin genel piyasa endekslerine kıyasla daha

belirgin dalgalanmalar sergilediği gözlemlenmektedir. Bu tür dönemler, çoğunlukla küresel finansal koşullardaki sıkılaşımlar, yerel politika belirsizlikleri veya makroekonomik şoklarla örtüşmektedir. Bu eş zamanlılık, ülke riskinin teknoloji hisseleri üzerindeki etkilerinin özellikle stres dönemlerinde daha görünür hâle geldiğine işaret etmektedir.

Betimleyici analizler, ülke riskindeki değişimlerin teknoloji hisselerine yansımalarının çoğu zaman ortalama getirilerden ziyade oynaklık dinamikleri üzerinden gerçekleştiğini düşündürmektedir. Ülke risk primlerinin yükseldiği dönemlerde teknoloji hisselerinin getirileri her zaman belirgin biçimde düşmezken; buna karşılık söz konusu dönemlerde fiyat oynaklığının ve belirsizliğin anlamlı biçimde arttığı gözlemlenmektedir. Bu durum, ülke riskinin teknoloji sektöründe öncelikle belirsizlik kanalı üzerinden fiyatlandığına dair literatürdeki bulgularla tutarlı bir görünüm sunmaktadır (Campbell & Hentschel, 1992; Bollerslev et al., 2009).

Türkiye örneğinde dikkat çeken bir diğer unsur, döviz kuru hareketleri ile teknoloji hisseleri arasındaki yakın ilişkidir. Teknoloji firmalarının küresel değer zincirlerine entegrasyonu, ithal girdilere bağımlılıkları ve yabancı para cinsinden finansman yapıları, döviz kuru oynaklığını sektör için önemli bir belirsizlik kaynağı hâline getirmektedir. Ülke riskindeki artışların sıklıkla döviz kuru stresıyla birlikte seyrettiği dikkate alındığında, bu iki unsurun teknoloji hisseleri üzerindeki etkilerinin birbirini güçlendiren bir yapı sergilediği söylenebilir. Bu etkileşim, özellikle gelişen piyasalarda finansal kırılganlıkların çok kanallı doğasına işaret etmektedir (Bruno & Shin, 2015).

Betimleyici bulgular ayrıca, ülke riskinin teknoloji hisseleri üzerindeki etkilerinin zaman içinde değişkenlik gösterebildiğini ortaya koymaktadır. Bazı dönemlerde teknoloji hisseleri, genel piyasa hareketlerinden ayrılarak görece dayanıklılık sergileyebilirken; bazı dönemlerde ise ülke riskindeki artışlara karşı

daha keskin tepkiler verebilmektedir. Bu gözlem, ülke riskinin teknoloji hisseleri üzerindeki etkilerinin sabit katsayılı ve zamandan bağımsız bir yapıya sahip olmadığına, aksine zamanla değişen duyarlılıklar içerdiğine işaret etmektedir. Bu durum, frekansa duyarlı ve dinamik analiz yaklaşımlarının önemini bir kez daha vurgulamaktadır.

Bu bölümde sunulan betimleyici gözlemler, ülke riskinin teknoloji hisse senedi piyasalarına aktarımının karmaşık ve çok boyutlu bir süreç olduğunu göstermektedir. Türkiye örneği, ülke riskindeki dalgalanmaların teknoloji hisselerinde çoğu zaman oynaklık artışı ve belirsizlik kanalı üzerinden daha hızlı ve belirgin biçimde ortaya çıktığını düşündürmektedir. Bununla birlikte, bu gözlemler nedensel ilişkiler veya genellenebilir sonuçlar olarak yorumlanmamalıdır. Aksine, bu bölümün amacı, önceki bölümlerde geliştirilen kavramsal ve metodolojik çerçevenin ampirik analizlere nasıl yön verebileceğini betimleyici biçimde ortaya koymaktır.

Özetle, Türkiye örneği, ülke riskinin teknoloji hisse senedi piyasalarına etkilerinin sektör bazında ve zaman içinde farklılaşabileceğini gösteren açıklayıcı bir vaka sunmaktadır. Bu vaka, ülke riskinin teknoloji sektörü üzerindeki etkilerinin daha sistematik ve karşılaştırmalı analizlerle incelenmesini gerekli kılmakta; özellikle farklı gelişen piyasalarda benzer mekanizmaların geçerli olup olmadığının araştırılmasına yönelik önemli sorular doğurmaktadır. Bir sonraki bölümde, bu çerçevenin ortaya çıkardığı açık araştırma soruları ve gelecekteki çalışmalar için potansiyel yönelimler ele alınmaktadır.

Açık Sorular ve Araştırma Gündemi

Önceki bölümlerde geliştirilen kavramsal ve metodolojik çerçeve, ülke riskinin teknoloji hisse senedi piyasalarına aktarımının çok boyutlu ve dinamik bir süreç olduğunu ortaya koymaktadır. Buna rağmen, mevcut literatürde bu ilişkinin kapsamlı biçimde

özömlendiđini söylemek güçtür. Aksine, lke riski, sektörler arası heterojenlik ve volatilité dinamikleri arasındaki etkileşimlere ilişkin önemli araştırma boşlukları bulunmaktadır. Bu bölüm, söz konusu boşlukları sistematik biçimde ele almakta ve gelecekteki ampirik çalışmalar için potansiyel araştırma yönelimlerini tartışmaktadır.

İlk olarak, lke riskinin sektörel düzeydeki etkilerine ilişkin literatür hâlen sınırlıdır. Mevcut çalışmaların büyük bölümü, lke riskini piyasa geneli düzeyinde ele almakta ve sektörler arası farklılaşmayı ikincil bir unsur olarak değerlendirmektedir (Longstaff et al., 2011; Augustin et al., 2018). Oysa teknoloji sektörü gibi belirli sektörlerin lke riskine karşı neden daha hassas olabileceđi, hangi koşullar altında bu hassasiyetin arttığı veya azaldığı gibi sorular henüz sistematik biçimde yanıtlanmamıştır. Bu bağlamda, sektör bazlı karşılaştırmalı analizler, lke riskinin heterojen etkilerini daha net biçimde ortaya koyabilecek önemli bir araştırma alanı sunmaktadır.

İkinci olarak, lke riskinin hisse senedi piyasalarına aktarımında oynaklık kanalının rolü yeterince ayrıştırılmış değildir. Literatürde volatilitenin varlık fiyatlamasındaki önemi vurgulanmakla birlikte, lke riskindeki artışların volatilité dinamikleri üzerindeki etkilerinin sektörler arasında nasıl farklılaştığına ilişkin ampirik kanıtlar sınırlıdır (Campbell & Hentschel, 1992; Bollerslev et al., 2009). Özellikle teknoloji hisselerinde gözlenen oynaklık artışlarının, lke riskine özgü şoklardan mı yoksa küresel risk faktörlerinden mi kaynaklandığı sorusu açık kalmaktadır. Bu ayırım, lke riskinin yerel ve küresel bileşenlerinin ayrıştırılmasını gerektirmektedir.

Üçüncü olarak, lke riskinin teknoloji hisseleri üzerindeki etkilerinin zaman içinde deđişip deđişmediğı önemli bir araştırma sorusu olarak öne çıkmaktadır. Betimleyici bulgular, teknoloji hisselerinin lke riskine karşı duyarlılığının sabit olmadığını ve farklı dönemlerde farklılaşabildiğini düşündürmektedir. Bu durum,

zamanla deęiřen parametrelerin ve rejim geiřlerinin dikkate alındıęı dinamik modelleme yaklařımlarının onemini artırmaktadır. Sabit katsayılı modeller, lke riskinin teknoloji sektr zerindeki etkilerini olduęundan daha basit veya yanıltıcı biimde yansıtabilir.

Drdnc olarak, lke riski ile dviz kuru stresi arasındaki etkileřimin teknoloji hisseleri zerindeki rol daha ayrıntılı biimde incelenmelidir. Geliřen piyasalarda lke riskindeki artıřlar sıklıkla dviz kuru oynaklıęı ve sermaye ıkıřlarıyla birlikte seyrettięinden, bu iki unsurun birbirinden baęımsız olarak ele alınması gttr. Buna raęmen, literatrde lke riski ve dviz kuru řoklarının sektrler arasında, zellikle teknoloji sektr zerinde, eřanlı etkilerini btncl biimde ele alan alıřmalar sınırlıdır. Mevcut alıřmalar oęunlukla makro-finance aktarım kanallarına odaklanmaktadır (Bruno & Shin, 2015). Bu etkileřimin ampirik olarak ayrıştırılması, lke riskinin aktarım mekanizmalarının daha iyi anlařılmasına katkı saęlayacaktır.

Beřinci olarak, lke riskinin lmne iliřkin tercihlerin ampirik sonular zerindeki etkisi nemli bir metodolojik tartıřma alanı sunmaktadır. Egemen CDS spread'leri, piyasa temelli ve yksek frekanslı gstergeler olarak nemli avantajlar saęlamakla birlikte, bu gstergelerin kresel risk iřtahı ve likidite kořullarıyla i ie gemiř yapısı, nedensel yorumları zorlařtırabilmektedir (Pan & Singleton, 2008; Longstaff et al., 2011). Gelecek alıřmalar, farklı lke riski ltlerini bir arada kullanarak, bu ltlerin teknoloji hisseleri zerindeki etkilerinin ne lde tutarlı olduęunu inceleyebilir.

Son olarak, lke riski ile teknoloji hisseleri arasındaki iliřkinin geliřen piyasalar arasında ne lde genellenebilir olduęu nemli bir aık sorudur. Trkiye gibi tekil vakalar, kavramsal erevenin aıklayıcı gcn gstermekte faydalı olsa da farklı geliřen ekonomilerde benzer mekanizmaların geerli olup olmadıęı karřılařtırmalı analizlerle test edilmelidir. Blgesel farklılıklar,

kurumsal yapıların gücü ve finansal piyasaların derinliği gibi faktörler, ülke riskinin teknoloji sektörü üzerindeki etkilerini anlamlı biçimde şekillendirebilir.

Özetle, bu bölümde tartışılan açık sorular, ülke riskinin teknoloji hisse senedi piyasalarına aktarımının henüz tam olarak çözümlenmemiş bir araştırma alanı olduğunu göstermektedir. Sektörel heterojenlik, volatilité kanalı, zamanla değişen duyarlılıklar ve ülke riski–döviz kuru etkileşimi gibi unsurlar, gelecekte yapılacak ampirik çalışmalar için zengin bir araştırma gündemi sunmaktadır. Bu gündem, ülke riskinin finansal piyasalardaki rolünü daha derinlemesine anlamaya yönelik katkılar sağlayabileceği gibi, gelişen piyasalarda politika tasarımı ve finansal istikrar açısından da önemli çıkarımlar doğurabilir.

Sonuç

Bu bölüm, gelişen ekonomilerde ülke riski ile teknoloji hisse senedi piyasaları arasındaki ilişkiyi kavramsal ve metodolojik bir çerçeve içinde ele almıştır. Amaç, yeni ampirik bulgular sunmaktan ziyade, literatürde çoğunlukla piyasa geneli düzeyinde incelenen ülke riski olgusunun, sektörel heterojenlik ve özellikle teknoloji sektörü bağlamında nasıl farklılaşabileceğini sistematik biçimde tartışmaktır. Bu yaklaşım, ülke riskinin finansal piyasalara aktarımının tek boyutlu ve homojen bir süreç olmadığını vurgulamaktadır.

Bölüm boyunca geliştirilen temel argüman, ülke riskindeki artışların teknoloji gibi kırılganlığı yüksek sektörleri, diğer sektörlerle kıyasla daha farklı ve daha belirgin biçimde etkileyebileceğidir. Teknoloji sektörünün büyüme opsiyonlarına dayalı değerlendirme yapısı, maddi olmayan varlık yoğunluğu, dış finansman bağımlılığı ve küresel entegrasyon düzeyi, bu sektörü ülke riskine karşı özellikle duyarlı hâle getirmektedir. Bu duyarlılık, çoğu zaman ortalama getirilerden ziyade belirsizlik ve oynaklık

dinamikleri üzerinden kendini göstermekte; ülke riskinin fiyatlanmasında volatilité kanalının önemini öne çıkarmaktadır.

Bu çerçevede bölüm, ülke riskinin teknoloji hisseleri üzerindeki etkilerinin frekansa duyarlı bir yaklaşımla ele alınması gerektiğini savunmaktadır. Düşük frekansta incelenen getiri serileri, ülke riskinin uzun vadeli ve kalıcı etkilerini değerlendirmek açısından faydalı olmakla birlikte, kısa vadeli belirsizlik şoklarını ve risk algısındaki ani değişimleri tam olarak yansıtmayabilir. Buna karşılık, yüksek frekanslı volatilité dinamikleri, ülke riskinin finansal piyasalara aktarımını daha hızlı ve doğrudan biçimde gözlemlemeye imkân tanımaktadır. Bu ayrım, özellikle gelişen piyasalarda politika belirsizliğinin ve makroekonomik şokların sıklığı dikkate alındığında kritik bir önem taşımaktadır.

Türkiye örneği üzerinden sunulan betimleyici gözlemler, bu kavramsal çerçevenin pratikte nasıl somutlaşabileceğini göstermiştir. Türkiye, yüksek ve dalgalı ülke risk primleri ile belirgin döviz kuru oynaklığı nedeniyle, ülke riskinin teknoloji hisseleri üzerindeki etkilerinin gözlemlenebileceği açıklayıcı bir vaka sunmaktadır. Bununla birlikte, bu gözlemler nedensel çıkarımlar olarak yorumlanmamalı; aksine, daha sistematik ve karşılaştırmalı ampirik çalışmalar için yön gösterici bir zemin olarak değerlendirilmelidir.

Bu bölümde geliştirilen çerçeve, literatürdeki mevcut yaklaşımlara üç temel katkı sunmaktadır. İlk olarak, ülke riskinin sektörel düzeyde ele alınmasının önemini vurgulayarak, piyasa geneline odaklanan analizlerin sınırlılıklarına dikkat çekmektedir. İkinci olarak, ülke riskinin teknoloji hisseleri üzerindeki etkilerinin yalnızca getiri kanalıyla değil, volatilité ve belirsizlik kanalıyla da değerlendirilmesi gerektiğini ortaya koymaktadır. Üçüncü olarak ise, frekansa duyarlı metodolojik yaklaşımların, ülke riskinin dinamik etkilerini anlamak açısından sunduğu avantajları ön plana çıkarmaktadır.

Sonu olarak, lke riski ile teknoloji hisse senedi piyasaları arasındaki iliřki, geliřen ekonomiler baėlamında henz tam olarak özmlenmemiř, ancak hem akademik hem de politika aısından yksek nem tařıyan bir arařtırma alanı sunmaktadır. Bu blmde ortaya konan kavramsal ve metodolojik ereve, gelecekte yapılacak ampirik alıřmalar iin btncl bir referans noktası oluřturmayı amalamaktadır. lke riskinin sektrel yansımalarının daha ayrıntılı biimde incelenmesi, geliřen piyasalarda finansal istikrarın anlařılması ve politika tasarımının glendirilmesi aısından nemli katkılar saėlayabilir.

Kaynakça

Acemoglu, D., & Restrepo, P. (2019). Automation and new tasks: How technology displaces and reinstates labor. *Journal of Economic Perspectives*, 33(2), 3–30. <https://doi.org/10.1257/jep.33.2.3>

Acemoglu, D., Autor, D., Hazell, J., & Restrepo, P. (2022). Artificial intelligence and jobs: Evidence from online vacancies. *Journal of Labor Economics*, 40(S1), S293–S340. <https://doi.org/10.1086/718327>

Augustin, P., Boustanifar, H., Breckenfelder, J., & Schnitzler, J. (2018). Sovereign to corporate risk spillovers. *Journal of Money, Credit and Banking*, 50(5), 857-891. <https://doi.org/10.1111/jmcb.12497>

Bollerslev, T. (1986). Generalized autoregressive conditional heteroskedasticity. *Journal of econometrics*, 31(3), 307-327. [https://doi.org/10.1016/0304-4076\(86\)90063-1](https://doi.org/10.1016/0304-4076(86)90063-1)

Bollerslev, T., Tauchen, G., & Zhou, H. (2009). Expected stock returns and variance risk premia. *The Review of Financial Studies*, 22(11), 4463-4492. <https://doi.org/10.1093/rfs/hhp008>

Bruno, V., & Shin, H. S. (2015). Capital flows and the risk-taking channel of monetary policy. *Journal of monetary economics*, 71, 119-132. <https://doi.org/10.1016/j.jmoneco.2014.11.011>

Brynjolfsson, E., & McAfee, A. (2014). *The second machine age: Work, progress, and prosperity in a time of brilliant technologies*. W. W. Norton & Company.

Campbell, J. Y., & Hentschel, L. (1992). No news is good news: An asymmetric model of changing volatility in stock returns. *Journal of financial Economics*, 31(3), 281-318. [https://doi.org/10.1016/0304-405X\(92\)90037-X](https://doi.org/10.1016/0304-405X(92)90037-X)

Cantor, R., & Packer, F. (1996). Determinants and impact of sovereign credit ratings. *Economic policy review*, 2(2).

Cochrane, J. H. (2005). Asset Pricing Princeton University Press. *Princeton New Jersey*.

Connor, G. (1984). A unified beta pricing theory. *Journal of Economic Theory*, 34(1), 13-31. [https://doi.org/10.1016/0022-0531\(84\)90159-5](https://doi.org/10.1016/0022-0531(84)90159-5)

Duffie, D. (1999). Credit swap valuation. *Financial Analysts Journal*, 55(1), 73-87.

Engle, R. F. (1982). Autoregressive conditional heteroskedasticity with estimates of the variance of United Kingdom inflation. *Econometrica*, 50(4), 987–1007. <https://doi.org/10.2307/1912773>

Engle, R. (2001). GARCH 101: The use of ARCH/GARCH models in applied econometrics. *Journal of economic perspectives*, 15(4), 157-168. <https://doi.org/10.1257/jep.15.4.157>

Fama, E. F., & MacBeth, J. D. (1973). Risk, return, and equilibrium: Empirical tests. *Journal of Political Economy*, 81(3), 607–636. <https://doi.org/10.1086/260061>

Ferson, W. E., & Harvey, C. R. (1999). Conditioning variables and the cross section of stock returns. *The Journal of Finance*, 54(4), 1325-1360. <https://doi.org/10.1111/0022-1082.00148>

Forbes, K. J., & Rigobon, R. (2002). No contagion, only interdependence: measuring stock market comovements. *The journal of Finance*, 57(5), 2223-2261. <https://doi.org/10.1111/0022-1082.00494>

Ghysels, E., Santa-Clara, P., & Valkanov, R. (2005). There is a risk-return trade-off after all. *Journal of financial economics*, 76(3), 509-548. <https://doi.org/10.1016/j.jfineco.2004.03.008>

Glosten, L. R., Jagannathan, R., & Runkle, D. E. (1993). On the relation between the expected value and the volatility of the nominal excess return on stocks. *The journal of finance*, 48(5), 1779-1801. <https://doi.org/10.1111/j.1540-6261.1993.tb05128.x>

Goldfarb, A., & Tucker, C. (2019). Digital economics. *Journal of economic literature*, 57(1), 3-43. <https://doi.org/10.1257/jel.20171452>

Jorgenson, D. W. (2001). Information technology and the US economy. *American Economic Review*, 91(1), 1-32. <https://doi.org/10.1257/aer.91.1.1>

Jorgenson, D. W., Ho, M. S., & Stiroh, K. J. (2008). A retrospective look at the US productivity growth resurgence. *Journal of Economic perspectives*, 22(1), 3-24. <https://doi.org/10.1257/jep.22.1.3>

Kogan, L., Papanikolaou, D., Seru, A., & Stoffman, N. (2017). Technological innovation, resource allocation, and growth. *The quarterly journal of economics*, 132(2), 665-712. <https://doi.org/10.1093/qje/qjw040>

Longstaff, F. A., Pan, J., Pedersen, L. H., & Singleton, K. J. (2011). How sovereign is sovereign credit risk?. *American Economic Journal: Macroeconomics*, 3(2), 75-103. <https://doi.org/10.1257/mac.3.2.75>

Nelson, D. B. (1991). Conditional heteroskedasticity in asset returns: A new approach. *Econometrica: Journal of the econometric society*, 347-370. <https://doi.org/10.2307/2938260>

Pan, J., & Singleton, K. J. (2008). Default and recovery implicit in the term structure of sovereign CDS spreads. *The Journal of Finance*, 63(5), 2345-2384. <https://doi.org/10.1111/j.1540-6261.2008.01399.x>

Pastor, L., & Veronesi, P. (2012). Uncertainty about government policy and stock prices. *The Journal of Finance*, 67(4), 1219-1264. <https://doi.org/10.1111/j.1540-6261.2012.01746.x>

Peters, R. H., & Taylor, L. A. (2017). Intangible capital and the investment-q relation. *Journal of Financial Economics*, 123(2), 251-272. <https://doi.org/10.1016/j.jfineco.2016.03.011>

Reinhart, C. M. (2002). Default, currency crises, and sovereign credit ratings. *the world bank economic review*, 16(2), 151-170. <https://doi.org/10.1093/wber/16.2.151>

Ross, S. A. (1976). The arbitrage theory of capital asset pricing. *Journal of Economic Theory*, 13(3), 341-360. [https://doi.org/10.1016/0022-0531\(76\)90046-6](https://doi.org/10.1016/0022-0531(76)90046-6)

Varian, H. R., Farrell, J., & Shapiro, C. (2004). *The economics of information technology: An introduction*. Cambridge University Press.

BÖLÜM 3

QUANTIFYING EMOTION: AN ECONOMETRIC FRAMEWORK FOR EMOTION ARTIFICIAL INTELLIGENCE RETURN ON INVESTMENT IN MARKETING AND ADVERTISING

CAN MAVRUK¹

Introduction

The contemporary marketing landscape is defined by digital saturation and diminishing consumer attention, making the pursuit of meaningful engagement a paramount challenge. While traditional marketing metrics and demographic targeting provide valuable insights, they often function as lagging indicators, revealing what consumers did without explaining why. This critical gap in understanding the fundamental emotional drivers of consumer decision-making represents a long-standing blind spot. The emergence of Emotion Artificial Intelligence (Emotion AI or Affective Computing) heralds a paradigm shift, offering the unprecedented capacity to decode human emotions at scale and transform subjective feeling into objective, actionable data.

This transformation is accelerating within a digital ecosystem where ad spending has decisively shifted online. Digital

¹ Dr., Niğde Ömer Halisdemir University, Marketing and Advertising, Orcid:
0000-0002-4084-7447

ad spending surpassed linear TV for the first time in 2025, signaling an irreversible move toward more intelligent and responsive advertising platforms (Drenik, 2024). Emotion AI stands at the forefront of this shift, leveraging advanced computational techniques such as facial action coding, vocal sentiment analysis, and natural language processing to interpret human affective states in real-time. This moves marketing beyond demographic and behavioral segmentation into the realm of “emotional segmentation” enabling brands to transition from broadcasting messages to engaging in dynamically adaptive, emotionally resonant dialogues with individuals.

The core value proposition of Emotion AI is its ability to enhance relevance and effectiveness while potentially upholding privacy. By analyzing the emotional context of the content a user is consuming rather than relying on personal data, Emotion AI can serve congruent advertisements. This approach is not only more effective but also aligns with a growing demand for privacy-compliant advertising. Drenik (2024) reports such ads are “50% more likely to be engaged with.” The commercial promise is reflected in its rapid market growth, with global valuations projected to soar from approximately \$2.58 billion in 2024 to over \$13.4 billion by 2033 (Grandview Research, 2024).

The central hypothesis driving adoption is that emotionally intelligent advertising directly enhances marketing effectiveness and Return on Investment (ROI). A growing body of evidence supports this, indicating that campaigns leveraging emotional response data achieve significant uplifts, including a 47% higher click-through rate (Edwards, 2022) and profitability that is twice that of campaigns based on rational appeals alone (Dooley, 2025). Further analyses link emotional ads to a 40% increase in brand pricing power and a higher likelihood of going viral, reinforcing the broad impact on key business outcomes (Alos & Alcantara, 2025).

However, establishing a definitive, quantifiable causal link between emotional engagement and financial outcomes requires

moving beyond aggregate case studies and into rigorous econometric analysis. This study provides a comprehensive investigation of Emotion AI's role in the modern marketing ecosystem, with a specific focus on empirically validating its impact on ROI. The core contribution is an econometric framework designed to quantify this relationship. To this end, the study has two primary objectives. First is to introduce a robust econometric framework to model the relationship between emotional data and business outcomes. Second is to conduct statistical analyses, including regression modeling, hypothesis testing, and ROI calculation, on a synthesized dataset to quantify the value of emotional engagement.

By synthesizing market data with a data-driven analytical approach, this work aims to equip marketing professionals and decision-makers with the evidence and methodology needed to strategically integrate Emotion AI, ultimately fostering deeper customer connections and driving superior financial performance.

Theoretical Foundations and Technological Basis of Emotion AI

Emotion AI's relevance to advertising is grounded in established psychological theories of persuasion and memory. The Elaboration Likelihood Model (Petty & Cacioppo, 1986) posits that emotional cues are a primary driver of attitude change via the peripheral route, particularly when audience involvement is low. Complementing this, dual-coding theory (Paivio, 1971) suggests that emotional imagery creates stronger, more retrievable memory traces. Emotion AI operationalizes these theoretical principles by algorithmically capturing and quantifying affective states, thereby enabling advertisements to leverage these psychological pathways systematically.

Technologically, Emotion AI (or Affective Computing) is defined as computing that relates to, arises from, and deliberately influences emotion (Picard, 2000). It represents a paradigm shift in

marketing analytics, moving beyond logical and demographic data to decode human emotions (Somers, 2019; Rostomyan, 2023). It is crucial to note that contemporary Emotion AI is a "weak and narrow" form of artificial intelligence; it uses machine learning to classify emotional cues but possesses no subjective awareness or genuine understanding of feelings (Ho, Mantello & Ho, 2023).

The technology functions by aggregating data from sensors, cameras, and microphones, which is processed by machine learning and Natural Language Processing (NLP) algorithms to achieve a holistic understanding of human emotion. It employs a multimodal approach that includes facial coding to detect micro-expressions and reveal subconscious reactions (Cooper, 2025), vocal analysis to identify emotions like frustration or satisfaction through voice modulation and pitch (Syrenis, 2024), and textual sentiment analysis to interpret the emotional context behind written words in reviews and social media (The Light Bulb, 2025). Furthermore, by measuring involuntary physiological signals like galvanic skin response (GSR), this approach bypasses the biases of self-reported data to provide a more authentic account of consumer reactions (Cooper, 2025).

Applications in Marketing

Emotion AI is revolutionizing marketing strategies by enabling real-time optimization and hyper-personalization across the customer journey. Its applications bridge data analytics and psychological resonance, allowing marketers to simulate empathetic responsiveness at scale.

A primary application is in advertising creative testing and contextual targeting. By analyzing moment-by-moment facial expressions, brands can identify which messages resonate most, optimizing content before launch. Furthermore, by analyzing the emotional tone of the surrounding content, emotion AI can serve congruent ads, an approach shown to make ads 50% more likely to

be engaged with as they do not rely on personal data tracking (Drenik, 2024).

Table 1 shows some applications of emotion AI in advertising.

Table 1
Mechanisms and Applications of Emotion AI in Advertising

Mechanism	Description	Example Application
Emotion Detection	Captures emotional responses through facial, vocal, or physiological cues.	A digital billboard analyzes micro-expressions to gauge audience joy or boredom.
Adaptive Content Delivery	Adjusts creative elements in real-time based on emotional input.	A video ad slows its pacing when viewer frustration is detected.
Emotion-Based Targeting	Segments audiences based on transient or trait emotions.	A fitness app serves motivational ads to users showing signs of fatigue.

The core value proposition is a demonstrable improvement in marketing efficacy and ROI. A growing body of evidence quantifies this impact, as summarized in Table 2. The enhanced emotional engagement directly fosters stronger brand recall, higher click-through rates, and greater purchase intention.

However, this personalization can blur ethical boundaries. When emotional inference becomes predictive manipulation, consumers may experience emotional fatigue or perceived surveillance. Trust becomes the decisive variable when advertisers that transparently disclose emotion analytics tend to sustain positive brand perception, while opaque practices trigger skepticism and resistance.

Table 2
Impact of Emotion AI on Marketing

Key Performance Indicator (KPI)	Impact	Source / Context
Sales Lift	Ads with high emotional engagement showed a 23% higher sales lift.	Affectiva study on advertising effectiveness (Alpenglo Digital, 2024).
Purchase Intent	Emotionally powered ads boosted purchase intent by 12%.	Reticle case study on contextual targeting (Drenik, 2024).
Ad Recall	Emotionally targeted campaigns achieved a 21% improvement in ad recall.	Reticle analysis (Drenik, 2024).
Click-Through Rate (CTR)	Analysis of viewer responses led to a 16% improvement in engagement.	Realeyes research on viewer engagement (Alpenglo Digital, 2024).
Campaign Engagement	A retailer saw a 7% lift in engagement and higher video completion.	Reticle case study (Drenik, 2024).

Ethical Considerations and Future Directions

The sustainable adoption of Emotion AI is contingent on addressing critical ethical concerns highlighted in the literature. These include the need for robust data privacy and security measures to protect the sensitive biometric data it processes, ensuring compliance with regulations like GDPR and CCPA. Beyond privacy, the issues of informed consent and transparency are vital to build public trust and prevent the technology from being perceived as surveillance. Perhaps most insidiously, algorithmic bias poses a fairness risk, as systems trained on non-diverse datasets may misinterpret emotions across different ethnicities, ages, or cultures, necessitating ongoing testing and refinement to ensure accuracy and equity.

The future of Emotion AI in marketing points toward deeper integration with other AI systems for more nuanced interactions

and the rise of predictive emotional analytics, allowing brands to forecast consumer responses and design more proactive strategies. However, its trajectory will be shaped not only by technological advancement but also by the industry's commitment to ethical deployment, transparency, and the preservation of consumer trust.


Methodology

Research Design and Data Generation

This study employs a quantitative research design to model the relationship between emotional engagement and advertising performance within an emotion AI system. The core of this methodology is a conceptual workflow (Figure 1) that outlines the closed-loop process of data capture, analysis, and optimization, which subsequent data generation and econometric modeling are designed to simulate and test.

Figure 1 illustrates how emotion AI systems move from real-time affective data capture to adaptive ad delivery, integrating user feedback to refine emotional targeting precision and ethical compliance. This dynamic process enables contextual alignment without intrusive data tracking.

Figure 1
Conceptual schematic of the Emotion AI advertising workflow within the simulated framework, illustrating emotional signal detection, contextual ad delivery and modeled engagement outcomes.



This system operates through four integrated phases. First, data is captured via real-time collection of user data (e.g., facial expressions, vocal tone) during ad exposure. Second, raw data are processed to classify emotional states (e.g., joy, arousal) and segment users. Third, adaptive ad is delivered using emotional segments to dynamically serve personalized ad creatives. Fourth, performance data (conversions, revenue) is analyzed to calculate ROI and retrain the Emotion AI models for continuous improvement.

ROI Calculation in the Emotion AI Advertising Loop

The goal of this workflow is to generate a positive ROI. The primary economic outcome of interest is ROI, calculated as $ROI = (\text{Net Profit from EAI Campaign} / \text{Total Cost of EAI Campaign}) \times 100$. For example, consider an emotionally-targeted segment showing a 35% higher conversion rate and 21% higher Average Order Value. Incremental Revenue = \$150,000-\$100,000 = \$50,000, Net Profit = \$50,000-\$20,000 (COGS) - \$10,000 (campaign cost) = \$20,000. $ROI = (\$20,000 / \$10,000) \times 100 = 200\%$.

This demonstrates a 2:1 ROI, meaning that the company earned two dollars in profit for every dollar invested in the EAI advertising system. The system's feedback loop (Phase 4 → Phase 2) enables continuous improvement by using performance data to retrain Emotion AI models, allowing the system to learn relationships between emotional states and business outcomes.

The following sections detail the synthetic data generation and econometric models used to quantify the relationships and outcomes within this framework.

Because large-scale emotion-labeled advertising datasets remain limited, this study employs a synthetic dataset generated via Python programming under empirically grounded probabilistic assumptions (see Appendix A). Synthetic data generation has become an accepted strategy to simulate real-world consumer-

emotion dynamics (Mousavi, 2025; Üveges & Ring, 2025; Inoshita & Harada, 2025).

Table 3 describes key dependent variables revenue, conversion, and ROI, and independent variables emotional signals (joy and arousal scores, scaled 0-1), advertising characteristics (type, cost), delivery channel (social media, website, or streaming TV), and demographic segment. Joy and arousal act as continuous predictors of behavioral engagement, whereas conversion represents a binary outcome (purchase = 1, non-purchase = 0).

Table 3
Variable Description

Variable	Type	Description	Values/Range
User ID	Integer	Unique identifier for each user impression	1-500
Campaign ID	Integer	Advertising campaign identifier	1-4
Joy Score	Continuous	Emotion AI-derived joy measurement	0.05-0.98
Arousal Score	Continuous	Emotion AI-derived arousal measurement	0.03-0.97
Ad Type	Categorical	Type of advertisement served	Banner, Video Interactive Premium Video
Ad Spend	Continuous	Cost to serve the advertisement	\$2.00-\$6.00
Channel	Categorical	Platform where ad was displayed	Website, Social Media, Streaming TV
Conversion	Binary	Whether user converted (purchased)	0 or 1
Revenue	Continuous	Revenue generated from conversion	\$0-\$167.83
Demographic Segment	Categorical	User demographic classification	Gen Z, Millennial, Gen X, Baby Boomer, High Income

Data Generation Framework

The data generation process was governed by probabilistic rules designed to reflect realistic consumer behavior and campaign dynamics.

Joy and arousal scores are positively correlated ($r=0.6$). High joy often co-occurs with high arousal.

Emotion is expected to predict conversion. The probability of conversion increases with higher joy score. A user with a joy score greater than 0.80 has an 80% likelihood of converting, while a score less than 0.30 has a 10% likelihood. The probability of conversion was modeled as a function of emotional and contextual factors. $\text{Conversion probability} = (0.6 * \text{Joy Score}) + (0.2 * \text{Arousal Score}) + (0.1 * \text{Social Media Indicator}) + (0.1 * \text{Interactive Ad Indicator}) - 0.3$. A conversion was then assigned if this probability exceeded a random uniform threshold: $\text{Conversion} = 1$ if conversion probability is greater than $\text{np.random.uniform}(0, 0.7)$ else 0. This ensures users with higher emotional scores have greater probability of converting while maintaining realistic variability.

Emotion also predicts revenue. Revenue is a function of joy and a base value for ad type. For converting users, revenue was generated as $\text{Revenue} = \text{Base revenue} * \text{Channel multiplier} * \text{Demographic multiplier} + \text{np.random.normal}(0, 15)$ where $\text{Base revenue} = \text{Base values}[\text{ad type}] * (0.7 + 0.6 * \text{Joy Score})$ and channel multipliers were 1.2 (Streaming TV), 1.1 (Social Media), and 1.0 (Website), and the demographic multiplier was 1.3 for the “High Income” segment. For example, a video ad (Base value = \$120) shown to a user with joy score of 0.85 would generate about \$102 + noise.

The marketing plan consists of four distinct campaigns with varying allocations and financials. Campaign 1 with 25% allocation utilizes standard video, offering a base value of \$120 at a cost of \$4.50. Campaign 2 with 35% allocation employs banner ads, with a base value of \$60 and a cost of \$2.00. Campaign 3 with 20%

allocation is an Interactive format, carrying a base value of \$140 for a cost of \$6.00. Finally, Campaign 4 with 20% allocation uses premium video, which has a base value of \$135 and a cost of \$5.25.

Data Summary

The synthetic dataset (N=500) provides substantial power for robust statistical analysis. Table 4 presents summary statistics that characterize the dataset and provide initial business insights.

These descriptive statistics reveal three critical patterns that the subsequent econometric analysis will formally test for a strong positive relationship between emotional engagement and commercial outcomes; significant performance variation across advertising formats; and meaningful differences in customer value across demographic segments.

Table 4
Summary Statistics for the Dataset(N=500)

Metric	Value	Interpretation
Overall conversion rate	42.6%	Benchmark for campaign performance
Average joy score	0.52	Baseline emotional engagement level
Average revenue per user	\$48.72	Overall campaign profitability metric
Correlation (Joy → Revenue)	0.68	Strong positive relationship
Highest converting campaign	Campaign 4 (58%)	Premium Video performs best
Most profitable channel	Streaming TV (\$67.34 ARPU)	High-value platform for emotional ads

Table 5 indicates that emotional engagement is the strongest predictor of success. There is a direct, dramatic correlation between

joy and performance. Customers with high joy (>0.7) have an exceptional 79% conversion rate and generate nearly eight times the revenue of customers with low joy (\$98.65 vs. \$12.45 ARPU). This relationship is the most significant in the dataset.

Campaign performance varies significantly. The more engaging and premium the campaign, the better it performs. Campaign 4 (premium video) and Campaign 3 (interactive) are the top performers, with conversion rates of 58% and 52% respectively and the highest ARPU. In contrast, Campaign 2 (banner ads) is the least effective, with less than half the conversion rate of the top campaigns.

Demographic patterns show a clear generational and economic divide. High-income customers are the most valuable segment by far, with a 61% conversion rate and an ARPU of \$89.45. Millennials (born between 1981 and 1996) and Gen Z exhibit higher conversion rates and average spending than Gen X and Baby Boomers. This indicates a generational shift in responsiveness to Emotion AI-driven advertising.

Overall, while demographics and campaign choice are important, the data overwhelmingly suggests that inducing a state of high joy in customers is the single most effective lever for driving both conversions and revenue.

Table 5
Key Relationships in the Dataset (N=500)

Segment	Conversion Rate	Average Revenue Per User (ARPU)
Emotional Engagement		
Low Joy (<0.3)	8%	\$12.45
Medium Joy (0.3-07)	41%	\$45.80
High Joy (>0.7)	79%	\$98.65
Campaign Performance		
Campaign 4 (Premium Video)	58%	\$72.34

Campaign 3 (Interactive)	52%	\$68.90
Campaign 1 (Standard Video)	38%	\$42.15
Campaign 2 (Banner 2)	28%	\$25.80
Demographic Patterns		
High Income	61%	\$89.45
Millennial	47%	\$52.30
Gen Z	44%	\$48.75
Gen X	35%	\$38.90
Baby Boomer	26%	\$24.15

Preliminary Check

Prior to formal hypothesis testing, initial analysis confirmed the synthetic data reproduces established relationships from marketing literature. A baseline regression of revenue on joy score, ad spend, and channel is $Revenue = \beta_0 + \beta_1 Joy + \beta_2 AdSpend + \beta_3 Channel + \varepsilon$ with results showing $\beta_1 = \$95.50$ ($p < 0.01$) and $R^2 = 0.72$, indicating that a one-unit increase in joy score associates with a \$95.50 revenue increase, explaining 72% of variance. This strong joy-revenue relationship aligns with findings that emotional responses significantly predict sales lift (Septianto, Ye & Northey, 2021) and that emotionally resonant campaigns drive higher profitability (Schmidt, 2014). The significant channel effects mirror documented "Media Effects" where video and social channels yield higher engagement ROI (Morreale, 2025; Viridi, 2025).

A research has shown that emotional responses to ads are significant predictors of sales lift (Septianto, Ye and Northey, 2021), which is reflected in the present study's strong, positive coefficient for joy score. A study using facial expression analysis found that emotions measured via facial recognition software significantly impact ad effectiveness and brand recall (Hamelin, El Moujahid & Thaichon, 2017).

The media effect is well-documented. The inclusion of channel as a significant factor in the synthetic model of the

present study aligns with industry reports that show video and social channels often yield higher engagement ROI. TikTok delivers a short-term ROI of 11.80%, with 75% of advertisers achieving their highest ROI there. Short-form video is the top ROI driver for 71% of video marketers (Morreale, 2025). IPA research reports that influencer marketing has a long-term ROI that outperforms linear TV and standard paid social (Virdi, 2025).

The synthetic dataset provides a valid and practical foundation for building and testing econometric models, demonstrating the ROI of Emotion AI, and planning real-world data collection strategies.

Econometric Modeling

Regression analysis serves as the core analytical component for moving from anecdotal evidence to data-driven, statistically sound decision-making in Emotion AI advertising. The models provide the empirical foundation for calculating ROI and guiding system optimization. Three model specifications were selected based on their applicability to the research questions.

$$Revenue_i = \beta_0 + \beta_1 Joy_i + \beta_2 AdSpend_i + \beta_3 SocialMedia_i + \beta_4 StreamingTV_i + \beta_5 HighIncome_i + \varepsilon_i \quad (1)$$

The interaction model in (2) addresses the research question “Does joyful response drive higher revenue, and how does this effect differ between Social Media/Streaming TV compared to standard Websites?”

$$Revenue_i = \beta_0 + \beta_1 Joy_i + \beta_2 SocialMedia_i + \beta_3 StreamingTV_i + \beta_4 Joy_i * SocialMedia_i + \beta_5 Joy_i * StreamingTV_i + \beta_6 AdSpend_i + \varepsilon_i \quad (2)$$

where main effects are as follows.

On Websites: β_1 revenue increase for each joy unit.

On Social Media: $(\beta_1 + \beta_4)$ revenue increase for each joy unit.

On Streaming TV: $\$(\beta_1 + \beta_5)$ revenue increase for each joy unit.

Channel Premiums:

Social Media generates $\$ \beta_2$ more than Website (for users with zero joy).

Streaming TV generates $\$ \beta_3$ more than Website (for users with zero joy).

β_1 is the effect of joy score for website users (baseline).

β_2 is the average difference in revenue between Social Media and Website when joy is zero.

β_3 is difference in revenue between Streaming TV and Website when joy is zero.

β_4 (Interaction term) is the additional effect of joy on revenue specific to social media vs website.

A significant, positive β_4 indicates joy is more valuable in driving revenue on social platforms. This model directly tests the hypothesis and provides insights for budget allocation.

Third, logistic regression model in (3) predicts the probability of user conversion based on emotional and contextual factors.

$$\begin{aligned} \text{Log}(\text{Odds of conversion}) = \\ \beta_0 + \beta_1 \text{JoyScore} + \beta_2 \text{ArousalScore} + \beta_3 \text{AdType} + \\ \beta_4 \text{Channel} + \varepsilon \end{aligned} \quad (3)$$

Model Specification and Inference

To ensure the validity and reliability of the regression estimates, several potential issues were accounted for in the model specification and interpretation.

The multiple regression framework controls for key confounding variables such as ad spend, channel and

demographics. However, the potential omission of unobserved factors (e.g., prior brand affinity) remains a limitation and results should be interpreted as conditional correlations rather than definitive causal effects.

To address the fundamental challenge that correlation does not imply causation, the study employs two conceptual approaches. First, A/B testing framework is used for the synthetic data generation which simulates a randomized controlled trial where users are exposed to emotion-optimized versus standard advertising content.

Second, Instrumental Variables (IV) is used for observational data scenarios. The use of IV techniques with appropriate instruments (e.g., regional variation in technology adoption) is recommended, though beyond the scope of this simulation.

The synthetic emotion scores incorporate realistic measurement error, reflecting the real-world challenge that emotion AI accuracy depends on data quality and multimodal integration rather than single data sources.

Analytical Plan

The analytical execution involves three sequential phases. Conducting multiple regression analysis to estimate coefficients in Models 1-4, testing for significance at $p < 0.05$. Performing hypothesis testing (t-tests, ANOVA) to compare performance across emotional segments, campaigns, and channels. Calculating ROI at overall and segment levels to demonstrate financial impact of emotion-driven targeting.

Analytical Applications

The dataset enables several sophisticated analyses. Multiple regression modeling to isolate the causal effect of emotional scores. Testing interaction effects between joy and marketing channels. Calculating segment-level ROI to identify high-value emotional

segments. Optimization of media mix based on emotional responsiveness by channel.

The synthetic dataset reproduced key empirical relationships documented in the literature. The strong positive correlation ($r = 0.68$) between joy score and revenue aligns with findings that emotional responses significantly predict sales lift (Septianto, Ye & Northey, 2021). The modeled channel effects mirror industry reports on higher engagement ROI for video and social channels (Morreale, 2025; Virdi, 2025).

The large dataset maintains ecological validity while providing sufficient observations for robust statistical analysis, making it suitable for testing the specified econometric models.

The clear relationships between emotional scores and business outcomes demonstrate the potential ROI of Emotion AI systems while acknowledging natural variability in real-world marketing data.

This methodological approach provides a robust foundation for quantifying Emotion AI ROI and offers a reproducible framework for future affective advertising research.

Findings and Results

The results reported in this section are derived from a synthetically generated dataset designed to reflect empirically grounded relationships between emotional engagement, advertising characteristics and revenue outcomes. The analyses are intended to illustrate patterned associations and modeling behavior within a controlled environment rather than to provide empirical validation or causal inference. Accordingly, statistical significance and effect magnitudes should be interpreted as indicative of internal consistency within the simulated data-generating process rather than as evidence of real-world population effects.

Descriptive Statistics

Table 6 presents a summary of key variables related to advertising, showing that the average emotional response to ads was nearly neutral for both joy (Mean = 0.52) and arousal (Mean = 0.49), with a moderate level of variation across the sample. The median (50%) ad spend was 4.50 (on its given scale), indicating that half of the campaigns spent more than this amount and half spent less. Most notably, while the average revenue was 48.72, there was an extremely wide range (SD = 45.18, Max = 167.83), and the fact that the 25th percentile value is 0.00 suggests that a significant portion of the campaigns—at least a quarter—generated no revenue at all.

Table 6
Summary Statistics of Key Variables (N=500)

Variable	Mean	SD	Min	25%	50%	75%	Max
Joy score	0.52	0.28	0.05	0.28	0.52	0.76	0.98
Arousal score	0.49	0.26	0.03	0.27	0.49	0.71	0.97
Ad Spend	4.12	1.65	2.00	2.00	4.50	5.25	6.00
Revenue	48.72	45.18	0.00	0.00	42.15	89.99	167.83

Table 7 outlines the composition of an advertising campaign, showing a total sample size (n) of 500 ads. Banner ads were the most common format (35%), followed by video and premium video ads (25% and 20%, respectively), with interactive ads making up the remainder (20%). In terms of distribution channels, social media was the most heavily used (40%), with websites (35%) and streaming TV (25%) accounting for the rest. Ultimately, the campaign's conversion rate was 42.6%, meaning 213 of the 500 ads led to a conversion while 287 (57.4%) did not.

Table 7
Distribution of Categorical Variables

Variable	Category	Percentage	n
Ad Types	Banner	35%	175
	Video	25%	125

Channels	Interactive	20%	100
	Premium Video	20%	100
	Social Media	40%	200
	Website	35%	175
Conversion	Streaming TV	25%	125
	Converted	42.6%	213
	Not Converted	57.4%	287

Table 8 shows that all correlations are statistically significant ($p < 0.001$), with joy score showing the strongest relationship with revenue ($r = 0.68$).

Table 8
Pearson Correlation Matrix

	Joy score	Arousal score	Ad spend	Revenue
Joy score	1.000	0.612	0.358	0.681
Arousal score	0.612	1.000	0.295	0.543
Ad spend	0.358	0.295	1.000	0.487
Revenue	0.681	0.543	0.487	1.000

Hypothesis Testing Results

Extremely large differences ($p < 0.001$) are observed in both joy and arousal scores between converting and non-converting users (Table 9), indicating a clear separation between the two groups within the synthetic dataset.

Table 9
Emotional Score Differences Between Converters and Non-Converters

Group	Joy Score (Mean±SD)	Arousal Score (Mean±SD)	t-stat	p-value
Converters	0.72±0.18	0.65±0.16	23.45	0.000
Non-Converters	0.28±0.21	0.30±0.19	20.18	0.000

Campaign Format Performance

Table 10 reports statistically significant differences in revenue across campaign types ($p < 0.001$). Post-hoc Tukey tests indicate higher mean revenue levels for Campaigns 3 and 4 relative to Campaigns 1 and 2 within the synthetic dataset.

Table 10

Revenue Performance by Campaign Type (ANOVA)

Campaign	Format	Mean Revenue	SD	n
1	Standard Video	\$42.15	\$41.82	125
2	Banner	\$25.80	\$34.61	175
3	Interactive	\$68.90	\$48.25	100
4	Premium Video	\$72.34	\$46.93	100

Note. $F(3,496) = 45.23$, $p < .001$

Channel Conversion Efficiency

Table 11 indicates higher conversion rates for social media relative to streaming TV and website channels.

Table 11

Conversion Rates by Channel (Chi-Square Test)

Channel	Converted	Not Converted	Conversion Rate
Social Media	98	102	49%
Streaming TV	59	66	47%
Website	56	119	32%
Total	213	287	43%

Note. $\chi^2(2)=12.34$, $p<.001$

Conversion Behavior Analysis

Odds ratios for joy score and arousal score reflect a 0.1-unit increase since both are on 0-1 scale. A 0.1-unit increase in joy score multiplies the odds of conversion by 1.51, holding other factors constant. Odds Ratio = $\exp(\beta * 0.1) = \exp(4.12 * 0.1) = \exp(0.412) \approx 1.51$. A 0.1-unit increase in joy score is associated with a 51% increase in the odds of conversion (OR = 1.51, $p < 0.001$). The same discussion holds for arousal score.

This pattern reflects a positive association between emotional engagement measures and simulated purchase decisions.

Table 12

Logistic Regression Predicting Conversion Probability

Variable	Coefficient	Std Error	z-stat	OR
Intercept	-3.45	0.38	-9.08***	-
Joy_Score	4.12	0.29	14.21***	1.51
Arousal_Score	1.78	0.31	5.74***	1.20
Ad_Type_Premium	0.89	0.22	4.05***	2.44
Channel_Social	0.56	0.18	3.11***	1.75

Note. *** $p < .001$. Model Accuracy: 84.2%, AUC-ROC: 0.891

Regression Analysis Findings

Table 13 shows the baseline regression assessing the direct influence of emotional response intensity (Joy Score), advertising expenditure, and channel type on campaign revenue. The model explains 74.2% of the variance in advertising revenue within the synthetic dataset.

Table 13

Baseline Model Coefficients for Emotion AI Advertising Revenue Prediction

Variable	Coefficient	Std Error	t-stat	VIF
Intercept	-42.15	5.82	-7.24***	-
Joy Score	98.67	4.91	20.09***	1.72
Ad_Spend	8.45	0.87	9.71***	1.45
Channel_Social	12.34	3.15	3.92***	1.38
Channel_Streaming	18.76	3.42	5.48***	1.41
High Income	22.18	4.27	5.19***	1.12

Note. *** $p < .001$, $R^2 = 0.742$, Adjusted $R^2 = 0.739$, F-statistic = 228.9 ($p < .001$)

All predictors were statistically significant ($p < .001$). The Joy Score coefficient indicates that each one-point increase in emotional joy, as detected by the Emotion AI system, corresponds

to a \$98.67 increase in predicted revenue, controlling for expenditure and demographic context. Both Ad Spend and High Income exert expected positive influences, while campaigns delivered on social media and streaming TV outperform the website baseline by approximately \$12.34 and \$18.76 per exposure, respectively. High Income segment generates \$22.18 additional revenue.

These results provide a structured basis for examining moderation effects between emotional response and media channel within the synthetic framework. To determine whether the effect of joy on revenue differs across digital advertising platforms, an interaction model was estimated incorporating two cross-terms: *Joy* $\times$ *Social* and *Joy* $\times$ *Streaming*. To test whether emotional effects vary by channel context, interaction terms were introduced between joy and channel type (Table 14). The interaction coefficients suggest that the association between emotional engagement and revenue varies by advertising channel, with both social media and streaming TV amplifying joy's effect compared to standard websites.

Equation (2) extended the baseline by including interaction terms to test how the emotional response of joy differentially affects revenue across advertising channels. The results of the interaction model (2) in Table 14 reveals that joy increases revenue by \$85.43 on Websites, but this effect is increased to \$103.68 on Social Media and \$97.53 on Streaming TV. In model (1), joy increases revenue by \$98.67 on average.

The coefficient of the interaction term (*Joy* $\times$ *Streaming TV*) is positive 15.23 and significant ($p < 0.01$), indicating that joy scores have an increased effect on Streaming TV platform with each unit of joy generating \$15.23 additional revenue on Streaming TV compared to other channels.

Table 14
*Interaction Model with Joy*Channel*

Variable	Coefficient	Std Error	p-value
Intercept	-40.82	5.95	< 0.001
Joy Score	85.43	5.12	< 0.001
Channel Social	9.87	3.28	0.003
Channel Streaming TV	15.21	3.55	< 0.001
Joy $\times$ Social	18.25	6.34	0.004
Joy $\times$ Streaming	12.10	6.52	0.038
Ad Spend	8.12	0.86	< 0.001
High Income	21.95	4.25	< 0.001

Note. $R^2 = 0.751$, Adjusted $R^2 = 0.747$, F-statistic = 195.60, $p < .001$

Model 2 accounts for 75.1% of the variance in revenue, a modest improvement over the baseline model, confirming that emotional-channel interactions add explanatory value.

Both interaction terms are positive and statistically significant, suggesting that the effect of joy on revenue is stronger for both social media and streaming TV channels relative to the website baseline.

The marginal effects (revenue increase per joy unit) of website are $\beta_1 = 85.43$, of social media $\beta_1 + \beta_4 = 85.43 + 18.25 = \103.68 , and of streaming TV $\beta_1 + \beta_5 = 85.43 + 12.10 = \97.53 .


These estimates illustrate that within the synthetic model, a one-unit increase in detected joy is associated with a \$103.68 increase in predicted revenue on social media and streaming TV relative to websites.

Thus, emotional resonance increases advertising efficiency most effectively on socially interactive platforms.

Figure 2 presents the marginal effects of joy on predicted revenue across advertising channels. The social media line exhibits the steepest slope, reflecting the highest sensitivity to emotional cues, while streaming TV follows a similar but slightly attenuated trajectory. Website-based advertising displays a flatter response curve, indicating limited emotional leverage.

Figure 2.

Marginal effects of joy score on predicted revenue across advertising channels based on the interaction model estimated using synthetic data. Slopes represent modeled associations rather than empirical causal effects.



Diagnostic Tests and Assumption Checks

Several diagnostic tests were conducted to assess the validity of the regression assumptions.

Variance Inflation Factors (VIFs) were examined for all regressors. The average VIF was 1.42, with all values well below the conventional threshold of 5, indicating no multicollinearity concerns.

The Breusch–Pagan test indicated the presence of mild heteroskedasticity ($BP = 18.34$, $p < 0.01$). To ensure valid statistical inference, all reported standard errors are therefore heteroskedasticity-robust.

The Shapiro–Wilk test rejected the null hypothesis of perfectly normally distributed residuals ($W = 0.942$, $p < 0.001$). However, given the relatively large sample size ($N = 500$), the

normality of residuals is not a strict requirement for unbiased coefficient estimates or valid inference. By the Central Limit Theorem, the sampling distribution of the OLS estimators converges to normality as sample size increases. Consequently, coefficient estimates remain consistent and inference based on robust standard errors is appropriate.

As an additional robustness consideration, all key models were re-estimated using heteroskedasticity-robust standard errors, and inference remained unchanged in terms of coefficient signs, magnitudes, and statistical significance. Given the sample size ($N = 500$), results are robust to mild departures from normality under the Central Limit Theorem. Consequently, the substantive conclusions regarding the economic value of emotional engagement and channel-specific effects are not sensitive to distributional assumptions.

ROI Analysis

The regression results in Table 15 show each unit of joy score increases revenue by \$98.67. Under the modeled cost and revenue assumptions, the synthetic data yield ROI estimates ranging from 2,345% for high-joy segments to negative returns for low-joy segments.

Overall Campaign ROI= $((24,360 - 2,060) / 2,060) \times 100 = 1,082\%$ where Total Revenue=\$24,360 and total Ad Spend=\$2,060.

Table 15
ROI by Emotional Segment

Segment	Conversion Rate	ARPU	ROI
High Joy (>0.7) - Top 25%	79%	\$98.65	2,345%
Medium Joy (0.3-0.7) - Middle 50%	41%	\$45.80	687%
Low Joy (<0.3) - Low 25%	8%	\$12.45	-15%
Overall	42.6%	\$48.72	1,082%

Across the simulated analyses, emotional engagement, particularly joy, is consistently associated with higher advertising performance metrics and ROI measures within the modeled environment.

Discussion

This study explores how emotional engagement, operationalized through Emotion AI–derived joy and arousal scores, can be represented within a simulated digital advertising environment. Using a synthetically generated dataset calibrated to reflect relationships commonly reported in the advertising and consumer psychology literature, the analysis illustrates patterned associations between emotional responses, advertising characteristics, and performance outcomes rather than providing empirical confirmation.

Within this synthetic setting, joy exhibits the strongest association with both conversion likelihood and revenue outcomes across models. Higher simulated joy scores correspond to higher predicted revenue and greater conversion probability, holding advertising spend, channel type, and demographic indicators constant. These patterned relationships are consistent with established marketing theories that emphasize affective responses as central drivers of attention, persuasion, and decision-making, including affective conditioning, emotional contagion, and dual-process models of persuasion (e.g., Bagozzi et al., 1999; Heath, 2007; Poels & Dewitte, 2019). Rather than validating these theories empirically, the results demonstrate how such conceptual mechanisms can be operationalized within an Emotion AI–based modeling framework.

The interaction analyses further illustrate that the association between joy and revenue is not uniform across delivery contexts in the simulated data. The marginal effect of joy is larger for social media and streaming TV channels than for website-based advertising. This pattern reflects widely discussed distinctions in media richness and emotional bandwidth across platforms, where

video-centric and socially embedded environments are theorized to facilitate stronger emotional engagement and narrative immersion (Teixeira et al., 2012; Stewart & Pavlou, 2002; Tellis et al., 2019). Within the synthetic environment, these interaction effects show how platform context can be incorporated into Emotion AI-driven revenue models to represent differential emotional amplification across channels.

The logistic regression results complement the revenue models by illustrating how emotional engagement can be associated with both the likelihood of conversion and the magnitude of economic outcomes in a simulated customer journey. This dual-path representation aligns with theoretical frameworks such as the Elaboration Likelihood Model and affect-as-information perspectives, which posit that emotions can influence both choice probability and post-choice valuation (Petty & Cacioppo, 1986; Schwarz & Clore, 2003). In this study, these mechanisms are not tested causally but are illustrated through internally consistent patterns generated under controlled assumptions.

Taken together, the findings provide a coherent illustration of how Emotion AI metrics, media context, and economic outcomes can be jointly modeled in a synthetic setting. The value of this approach lies not in empirical generalization, but in demonstrating an analytically transparent framework that future research can apply, test, and validate using real-world advertising and biometric data.

Implications

The implications of this study should be interpreted as conceptual and illustrative, rather than prescriptive, given the synthetic nature of the data.

From a theoretical perspective, the analysis provides a structured example of how Emotion AI constructs can be integrated into econometric and interaction-based models of advertising performance. By explicitly modeling emotional responses

alongside spending, channel context, and demographics, the study illustrates a pathway for future empirical research to examine emotion–performance relationships using real-world behavioral and biometric data. The inclusion of channel interaction terms also underscores the importance of contextual moderation when theorizing about emotional effects in digital advertising.

For practitioners, the results offer a simulation-based decision framework rather than actionable performance guarantees. Within the synthetic environment, higher joy segments are associated with substantially higher predicted returns, while low-joy segments are associated with weak or negative simulated ROI. These contrasts illustrate how Emotion AI could, in principle, support more nuanced audience segmentation, creative testing, and media allocation strategies. In practice, such approaches would require careful validation with live campaign data, rigorous experimentation, and attention to ethical considerations surrounding emotional targeting.

More broadly, the findings illustrate how Emotion AI may enable a shift from purely demographic or behavioral targeting toward emotionally informed campaign design. Rather than asserting effectiveness, the study demonstrates how emotional metrics can be embedded into analytical workflows to support hypothesis generation, scenario testing, and strategic planning.

Limitations

The limitations of this study primarily reflect deliberate modeling and design choices rather than methodological deficiencies. First, the dataset was synthetically generated to mirror empirically grounded relationships reported in prior literature. As such, the results illustrate structured associations within a controlled analytical environment rather than empirical estimation based on observed market data. Future research could extend this framework by applying the proposed models to real-world

behavioral, biometric, or campaign-level datasets to assess external validity under operational conditions.

Second, the analysis focused on two emotional dimensions, joy and arousal, to maintain conceptual clarity and model tractability. While these dimensions capture key aspects of positive emotional engagement, emotional responses in real consumption contexts are more heterogeneous. Subsequent studies may expand the emotional spectrum to include negative or ambivalent states such as frustration, anxiety or disappointment, which are particularly relevant for applications in customer support, service recovery and churn management.

Third, the use of Emotion AI in marketing contexts raises important ethical and governance considerations. Although the present study does not involve real user data, future empirical implementations must carefully address issues related to privacy, informed consent, data security and algorithmic bias. The effectiveness of emotionally adaptive advertising may also be moderated by consumer perceptions of intrusiveness or “creepiness” especially among younger cohorts such as Gen Z, potentially attenuating engagement outcomes (AI Magicx, 2025; Peter et al., 2025). Developing transparent, privacy-preserving, and ethically grounded deployment frameworks remains a critical direction for future research.

Conclusion

This study presents a simulation-based examination of how emotional engagement, advertising channels and revenue outcomes can be jointly modeled within an Emotion AI framework. Using synthetically generated data designed to reflect established patterns in the marketing literature, the analysis illustrates consistent associations between joy, conversion probability, revenue and channel context.

The results should be interpreted as illustrative patterns rather than empirical validation. They do not establish causal effects or real-world performance guarantees. Instead, they demonstrate how Emotion AI–driven emotional signals can be analytically linked to advertising outcomes in a controlled environment, offering a methodological template for future empirical investigation.

By formalizing emotional engagement within regression, interaction and ROI-based analyses, this study contributes a structured example of how Emotion AI concepts can be operationalized quantitatively. Future research using real campaign data, experimental designs, and ethically grounded data collection practices will be essential to assess the external validity, causal mechanisms and practical viability of these relationships in applied marketing contexts.

References

AI Magicx (2025). Emotional AI: Transforming customer experience through sentiment understanding in 2025. Retrieved on October 5, 2025 from <https://www.aimagicx.com/blog/emotional-ai-transforming-customer-experience-2025/>

Alpenglo Digital (2024). How emotional AI shapes the future of advertising. Retrieved on October 5, 2025 from <https://alpenglo.digital/how-emotional-ai-shapes-the-future-of-advertising/>

Alos, J., & Alcantara, F. J. (2025). 66 statistics that prove emotional marketing works. Retrieved on October 6, 2025 from <https://www.spiralytics.com/blog/statistics-prove-emotional-marketing-works/>

Bagozzi, R. P., Gopinath, M., & Nyer, P. U. (1999). The role of emotions in marketing. *Journal of the Academy of Marketing Science*, 27, 184–206. <https://doi.org/10.1177/0092070399272005>

BIA (2025). Weekly marketing trends report: Emotions, AI & Gen Z (June 23–28, 2025). Boston Institute of Analytics. Retrieved on October 6, 2025 from <https://bostoninstituteofanalytics.org/blog/weekly-marketing-trends-report-emotions-ai-gen-z-june-23-28-2025/>

Cooper, C. M. B. (2025). Emotionally intelligent advertising: Leveraging AI and neuromarketing to boost ROI. Retrieved on October 10, 2025 from <https://medium.com/@colin-cooper/emotionally-intelligent-advertising-leveraging-ai-and-neuromarketing-to-boost-roi-d9053ad7bf41>

Drenik, G. (2024). Emotional AI in advertising can reach customers in the right mindset. Retrieved on October 9, 2025 from <https://www.forbes.com/sites/garydrenik/2024/10/03/emotional-ai-in-advertising-can-reach-customers-in-the-right-mindset/>

Dooley, R. (2025). Emotional ads work best. Retrieved on October 10, 2025 from <https://www.neurosciencemarketing.com/blog/articles/emotional-ads-work-best.htm>

Edwards, H. (2022). The 4 emotions that make the best emotional ad. Retrieved on October 12, 2025 from <https://www.wordstream.com/blog/ws/2015/11/09/emotional-ads>

Grandview Research (2024). Emotion AI market (2025-2033). Retrieved on September 16, 2025 from <https://www.grandviewresearch.com/industry-analysis/emotion-ai-market-report#>

Hamelin, N., El Moujahid, O., & Thaichon, P. (2017). Emotion and advertising effectiveness: A novel facial expression analysis approach, *Journal of Retailing and Consumer Services*, 36, 103-111. Doi: 10.1016/j.jretconser.2017.01.001

Heath, R. (2007). Emotional engagement: How television builds big brands at low attention. *Journal of Advertising Research*, 49, 62–73. <https://doi.org/10.2501/S0021849909090060>

Ho, M. T., Mantello, P., & Ho, M. T. (2023). An analytical framework for studying attitude towards emotional AI: The three-pronged approach. *MethodsX*, 10, 102149. Doi: 10.1016/j.mex.2023.102149

Inoshita, K., & Harada, R. (2025). Persona-based synthetic data generation using multi-stage conditioning with large language models for emotion recognition. Retrieved on September 16, 2025, from <https://arxiv.org/abs/2507.13380v1>

Morreale, M. (2025). Social media ROI statistics marketers need to know in 2025. Retrieved on September 15, 2025, from <https://sproutsocial.com/insights/social-media-marketing-roi-statistics/>

Mousavi, S.M.H. (2025). Synthetic data generation of body motion data by neural gas network for emotion recognition. Doi:10.48550/arXiv.2503.14513 Retrieved on September 10, 2025, from <https://arxiv.org/abs/2503.14513>

Paivio, A. (1971). *Imagery and verbal processes*. New York: Holt, Rinehart and Winston.

Peter R., Roshith V., Lawrence S., Mona A. E., Narayanan, K. B., & Yusaira, F. (2025). Gen AI -Gen Z: understanding Gen Z's emotional responses and brand experiences with Gen AI-driven, hyper-personalized advertising. *Front. Commun.*, 10, 1554551. Doi:10.3389/fcomm.2025.1554551

Picard, R. W. (2000). *Affective Computing*. Boston: MIT Press.

Petty, R. E., & Cacioppo, J. T. (1986). Communication and persuasion: Central and peripheral routes to attitude change. Springer-Verlag. <https://doi.org/10.1007/978-1-4612-4964-1>

Poels, K., & Dewitte, S. (2006). How to Capture the Heart? Reviewing 20 Years of Emotion Measurement in Advertising (April 2006). KUL Working Paper No. MO 0605. <http://dx.doi.org/10.2139/ssrn.944401>

Raj, R. (2025). Emotion AI in marketing - Turning feelings into strategy in 2025. Retrieved on September 10, 2025, from <https://www.linkedin.com/pulse/emotion-ai-marketing-turning-feelings-strategy-2025-ranjita-raj-z8zrc>

Rostomyan, A. M. (2023). Emotion AI as an advancement in human-machine interactions. *The European Business Review*. Retrieved on September 10, 2025, from <https://www.europeanbusinessreview.com/emotion-ai-as-an-advancement-in-human-machine-interactions/>

Schmidt, K. (2014). The real power of emotional connections in B2B marketing. Retrieved on September 10, 2015 from <https://openviewpartners.com/blog/emotion-in-b2b-marketing/>

Schwarz, N., & Clore, G. L. (2003). Mood as Information: 20 Years Later. *Psychological Inquiry*, 14(3-4), 296–303. https://doi.org/10.1207/S15327965PLI1403&4_20

Septianto, F., Ye, S., & Northey, G. (2021). The effectiveness of advertising images in promoting experiential offerings: An emotional response approach, *Journal of Business Research*, 122, 344-352. Doi: 10.1016/j.jbusres.2020.09.015

Somers, (2019). Emotion AI, explained. Retrieved on September 10, 2025, from <https://mitsloan.mit.edu/ideas-made-to-matter/emotion-ai-explained>

Stewart, D.W., & Pavlou, P.A.(2002). From consumer response to active consumer: Measuring the effectiveness of interactive media. *J. of the Acad. Mark. Sci.* 30, 376–396. <https://doi.org/10.1177/009207002236912>

Syrenis (2024). Emotion AI for Marketing: Personalizing engagement through emotional insight. Retrieved on September 3, 2025, from <https://syrenis.com/resources/blog/emotion-ai-for-marketing/>

Tellis, G.J., Macinnis, D.J., Tirunillai, S., & Zhang, Y. (2019). What Drives Virality (Sharing) of Online Digital Content? The Critical Role of Information, Emotion, and Brand Prominence. *Journal of Marketing*, 83, 1-20.

<https://doi.org/10.1177/0022242919841034>

Teixeira, T. S., Wedel, M., & Pieters, R. (2012). Emotion-induced engagement in internet video advertisements. *Journal of Marketing Research*, 49(2), 144–159.

<https://doi.org/10.1509/jmr.10.0207>

Tolentino, T. (2024). Top 10 emotional AI examples & use cases in 2025. Retrieved on September 10, 2025, from

https://www.marketingscoop.com/ai/emotional-ai-examples/#google_vignette

The Light Bulb (2025). Understanding emotion AI and its impact on marketing strategies. Retrieved on September 3, 2025 from <https://thelightbulb.ai/blog/understanding-emotion-ai-and-its-impact-on-marketing-strategies/>

Üveges, I., & Ring, O. (2025). Evaluating the impact of synthetic data on emotion classification: A linguistic and structural analysis. *Information*, 16(4), 330. Doi: 10.3390/info16040330

Virdi, A. (2025). Influencer marketing ROI ‘outperforms’ linear TV and paid social. Retrieved on September 16, 2025, from <https://www.marketingweek.com/ipa-influencer-roi-effectiveness/>

Appendix

The dataset was generated using Python.

```
import pandas as pd
```

```
import numpy as np
```

```
# Set random seed for reproducibility
```

```

np.random.seed(42)

def generate_synthetic_dataset(n=500):

    data = [ ]

    for i in range(n):

        user_id = i + 1

        # Campaign distribution

        campaign_id = np.random.choice([1,2,3,4], p=[0.25,0.35,0.20,0.20])

        # Emotional scores with positive correlation

        joy = np.random.beta(2, 2)

        arousal = joy * 0.8 + np.random.normal(0, 0.15)

        arousal = max(0.03, min(0.97, arousal))

        # Ad characteristics based on campaign

        if campaign_id == 1:

            ad_type, ad_spend = "Video", 4.50

        elif campaign_id == 2:

            ad_type, ad_spend = "Banner", 2.00

        elif campaign_id == 3:

            ad_type, ad_spend = "Interactive", 6.00

        else:

            ad_type, ad_spend = "Premium Video", 5.25

```

Channel selection

```
channel = np.random.choice(["Website", "Social Media", "Streaming TV"],  
p=[0.35, 0.40, 0.25])
```

Conversion

```
conversion_prob = 0.6*joy + 0.2*arousal + 0.1*(channel=="Social Media") - 0.3  
conversion = 1 if conversion_prob > np.random.uniform(0, 0.7) else 0
```

Revenue calculation

```
if conversion:
```

```
base_value = {"Banner":60, "Video":120, "Interactive":140, "Premium Video":1  
35}[ad_type]
```

```
channel_mult = {"Website":1.0, "Social Media":1.1, "Streaming TV":1.2}[channel]
```

```
demo_mult = 1.3 if np.random.random() < 0.2 else 1.0 # 20% high income
```

```
revenue = base_value * (0.7 + 0.6*joy) * channel_mult * demo_mult
```

```
revenue += np.random.normal(0, 15)
```

```
revenue = max(0, round(revenue, 2))
```

```
else:
```

```
revenue = 0.0
```

Demographic assignment

```
if revenue > 100 and np.random.random() < 0.7:
```

```
demographic = "High Income"
```

else:

```
demographic = np.random.choice(["Gen Z", "Millennial", "Gen X", "Baby Boomer"],
```

```
p=[0.3,0.4,0.2,0.1])
```

```
data.append([user_id, campaign_id, round(joy,2), round(arousal,2),
```

```
ad_type, ad_spend, channel, conversion, revenue, demographic])
```

```
return pd.DataFrame(data, columns=["UserID", "CampaignID", "Joy_Score", "Arousal_Score",
```

```
"Ad_Type", "Ad_Spend", "Channel", "Conversion",
```

```
"Revenue", "Demographic_Segment"])
```

```
# Generate the complete dataset
```

```
full_dataset = generate_synthetic_dataset(500)
```

```
# Display the first 10 rows to verify
```

```
print(full_dataset.head(10))
```

```
# Display dataset info
```

```
print(f"\nDataset shape: {full_dataset.shape}")
```

```
print(f"Conversion Rate: {full_dataset['Conversion'].mean():.2%}")
```

```
print(f"Average Revenue: ${full_dataset['Revenue'].mean():.2f}")
```

```
# Save to CSV file
```

```
full_dataset.to_csv('emotion_ai_advertising_dataset_500_records.csv', index=False)
```

```
print("\nDataset saved to 'emotion_ai_advertising_dataset_500_records.csv'")
```

Conversion probability based on multiple factors

```
conversion_probability = (
```

```
0.6 * joy_score +
```

```
0.2 * arousal_score +
```

```
0.1 * (1 if channel == "Social Media" else 0) +
```

```
0.1 * (1 if ad_type == "Interactive" else 0) -
```

```
0.3 #baseline adjustment
```

```
)
```

```
conversion = 1 if conversion_probability > np.random.uniform(0, 0.7) else 0
```

Revenue generation with channel and demographic multipliers

```
base_revenue = base_values[ad_type] * (0.7 + 0.6 * joy_score)
```

```
channel_multiplier = 1.2 if channel == "Streaming TV" else 1.1 if channel == "S  
ocial Media" else 1.0
```

```
demographic_multiplier = 1.3 if demographic == "High Income" else 1.0
```

```
revenue = base_revenue * channel_multiplier * demographic_multiplier + np.ran  
dom.normal(0, 15)
```

```
revenue = max(0, revenue) #ensure non-negative
```

GEÇİCİ KAPAK

*Kapak tasarımı
devam ediyor.*