

GEÇİCİ KAPAK

*Kapak tasarımı
devam ediyor.*

BİDGE Yayınları

Finansal Kararlar ve Piyasa Dinamikleri

Editör: MELİKE KURTARAN ÇELİK

ISBN: -

1. Baskı

Sayfa Düzeni: Gözde YÜCEL

Yayınlama Tarihi: -

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

TÜRKİYE'DE İPOTEKLİ KONUT SATIŞLARI: EKONOMİK BELİRLEYİCİLER, EĞİLİMLER VE POLİTİKA ANALİZİ	1
<i>ALİ MUTİ</i>	
A STATISTICAL ANALYSIS OF INITIAL PUBLIC OFFERINGS ON BORSA ISTANBUL	17
<i>CANSU TOSUN GAVCAR, ERDOĞAN GAVCAR, NUSRET KARA</i>	
Machine Learning–based Prediction of Post–capital Increase Stock Price Movements	29
<i>İLYAS AKIN AKYİĞİT</i>	
MERKEZİ YÖNETİM BORÇ STOKUNUN GELİŞİMİ	59
<i>FİKRET KARTAL</i>	

BÖLÜM 1

TÜRKİYE'DE İPOTEKLİ KONUT SATIŞLARI: EKONOMİK BELİRLEYİCİLER, EĞİLİMLER VE POLİTİKA ANALİZİ

1. ALİ MUTİ¹

Giriş

Konut piyasası, ekonomilerin ana göstergelerinden birini oluşturmakta; hanehalkı refahını, bankacılık ve finans sektörlerinin sağlığını ve genel makroekonomik dengeleri doğrudan etkileyen stratejik bir sektör olma özelliği göstermektedir. Gelişmekte olan ülkelerde konut finansmanı sisteminin etkinliği, bireylerin barınma hakkına erişimini belirleyen kritik bir faktör olarak öne çıkmaktadır.

Türkiye'de konut piyasası, 2000'li yılların başından itibaren önemli dönüşümler geçirmiştir. Bu süreçte mortgage sisteminin yasal altyapısının oluşturulması (5582 sayılı Konut Finansmanı Kanunu, 2007), kentsel dönüşüm projeleri ve demografik dinamikler konut talebini şekillendiren başlıca sebepler olmuştur. Bununla birlikte, faiz oranlarındaki dalgalanmalar, enflasyon ve döviz kuru baskıları piyasanın seyrini belirleyen en mühim makroekonomik kısıtlar arasında yer almaktadır.

¹ Dr, Tapu ve Kadastro Genel Müdürlüğü-Yakutiye Tapu Müdürlüğü, Orcid: 0000-0003-0254-8419

Bu çalışmanın temel amacı, Türkiye'de ipotekli konut satışlarının tarihsel seyrini arařtırmak, 2013-2025 yılları arasındaki satışları incelemek ve politika önerileri geliřtirmektir. Çalışmada Türkiye İstatistik Kurumu (TÜİK) verileri ve ilgili akademik literatürden yararlanılmıştır.

Literatür Taraması

Konut Piyasası ve Makroekonomik Değişkenler

Konut piyasası ile makroekonomik deęişkenler arasındaki iliřki, iktisat yazınında geniř bir şekilde yer bulmaktadır. Karadař ve Salihoęlu (2020) yapmış oldukları çalışmada Türkiye'deki konut fiyatlarındaki deęişime sebep olan makroekonomik faktörleri incelemiřlerdir. Konut kredilerine uygulanan faiz oranları, konut kredisi hacmi, reel döviz kuru ve tüketici fiyat endeksi konut fiyatlarını negatif yönde, sanayi üretim endeksi ise pozitif yönde etkilediğini tespit etmişlerdir.

Canbay ve Mercan (2020) Türkiye'de konut fiyatları, büyüme ve makroekonomik deęişkenler arasındaki iliřkiyi arařtırmışlardır. Çalışmada 2010Q1-2019Q2 dönemi çeyrek verileri kullanılarak, Granger nedensellik analizi bulguları neticesinde: faiz oranlarından kredi hacmine, kredi hacminden de konut fiyatları ve tüketici fiyat endeksine doęru kısa ve uzun dönemde nedensellik iliřkileri olduęu, ayrıca kısa dönemde faiz oranları ile büyümeye doęru nedensellik iliřkisinin olduęu tespit edilmiştir.

Dięer bir çalışmada konut fiyatları ve makroekonomik faktörler arasındaki iliřki incelenmiştir. Bulgularda Konut fiyat endeksi ile yıllık kredi faiz oranı, yıllık kişisel harcanabilir gelir ve gayrisafı yurtiçi hâsıla arasında pozitif yönlü istatistiksel olarak anlamlı bir iliřki elde edilirken, istihdam ve nüfus ile negatif yönlü bir iliřki olduęu tespit edilmiştir (Çankaya, 2013)

Giuliodori (2004), Demary (2010) ve Bjørnland ile Jacobsen (2010) alıřmaları, para politikasının konut piyasası zerindeki yansımalarını eřitli lkeler iin incelemiř ve faiz oranlarındaki deęiřimlerin konut talebini nemli lde etkilediđini ortaya koymuřtur.

Trkiye zelinde yapılan alıřmalarda Durkaya ve Yamak (2004) Trkiye konut piyasasını talep ynl olarak incelemiř ve konut talebi ile kiři bařına dřen gelir arasında pozitif ve gl iliřkiler olduđu tespit edilmiřtir. ztrk ve Fitz (2009) ise konut piyasasının belirleyicilerini ampirik yntemlerle ele almıřtır.

zim (2022) Trkiye'deki konut satıřı ile TCMB politika faiz oranı ve konut fiyat endeksi arasındaki iliřkinin analizini yapmıřtır. řanlı ve Peker (2023) ise enflasyon, kur, faiz ve gelirin konut satıřlarına etkisini Trkiye rneđinde analiz etmiřtir. Bu alıřmada elde edilen bulgular: FE ve kurlar konut satıřlarını pozitif ynde, konut kredi faiz oranları ise konut satıřlarını negatif ynde etkilediđi tespit edilmiřtir.

Mortgage Sistemleri ve Kredi Eriřimi

Konut finansmanı sistemlerinin etkinliđi, literatrde mortgage piyasasının derinliđi ve eriřilebilirliđi erevesinde deđerlendirilmektedir. Geliřmiř lkelerde konut kredilerinin gayri safi yurt ii hasılaya oranı yzde ellinin zerinde seyrederken (Helgi Library, 2025), Trkiye'de bu oran 2025 yılı itibarıyla %2'nin altında seyrederek (Finansal İstikrar Raporu, 2025) olduka dřk seviyelerde kalmaktadır. Bu durum, yapısal arz kısıtları, yksek faiz ortamı ve gelir yetersizliđi gibi faktrlerin bir yansıması olarak deđerlendirilmektedir.

Torun, Topu ve Varol (2024) tarafından gerekleřtirilen ve 2013 ocak-2024 řubat dnemini kapsayan alıřmada, konut kredisi faiz oranları ile konut satıřları arasında ift ynl ve konut

satışlarından altın fiyatlarına ve nominal döviz kuruna doğru tek yönlü nedensellik ilişkisi tespit edilmiştir.

Veri ve Yöntem

Çalışmada kullanılan veriler, Türkiye İstatistik Kurumu (TÜİK) tarafından kamuya açık platformda paylaşılan bilgilerden elde edilmiştir. Veriler 2013-2025 yılları arasını kapsamaktadır. Türkiye’de toplam konut satışları ve ipotekli konut satışları (ilk el ve ikinci el) kullanılmıştır. Analitik çerçeve olarak dönemsel karşılaştırma yöntemi benimsenmiştir. Grafik ve tabloların oluşturulmasında Microsoft Excel programı da kullanılmıştır. Sayılarak iki boyutlu tablolarda özetlenebilen özellikler için bulgular sayı ve yüzdeler oran olarak hesaplanmış ve istatistiki olarak yorumlanmıştır.

Bulgular

Tablo 1. Yıllara Göre Konut Satış Sayıları (2013–2025)

Yıl	Toplam Satış	İpotekli Satış (Adet)	İpotekli Pay (%)	İpotekli İlk El	İpotekli İkinci El	Diğer Satış
2013	1.226.989	490.200	40%	225.043	265.157	736.789
2014	1.240.914	419.094	34%	191.831	227.263	821.820
2015	1.349.322	456.703	34%	206.882	249.821	892.619
2016	1.417.035	472.521	33%	214.973	257.548	944.514
2017	1.493.086	497.989	33%	221.818	276.171	995.097
2018	1.468.238	293.386	20%	135.398	157.988	1.174.852
2019	1.439.063	356.525	25%	123.830	232.695	1.082.538
2020	1.608.300	606.892	38%	198.430	408.462	1.001.408
2021	1.609.561	314.766	20%	88.873	225.893	1.294.795


2022	1.625.774	304.432	19%	90.953	213.479	1.321.342
2023	1.330.135	190.840	14%	60.481	130.359	1.139.295
2024	1.549.760	166.635	11%	41.089	125.546	1.383.125
2025	1.760.292	248.020	14%	61.398	186.622	1.512.272

Kaynak: TÜİK

Tablo 1'de 2013'te toplam konut satışlarının %40'ı ipotekli gerçekleşirken, bu oran sürekli düşerek 2024'te %10,8'e gerilemiştir. En kritik düşüş 2018'de yaşanmıştır (yüksek faiz ortamıyla %20'ye indi). 2020'de COVID-19 dönemi teşvikleriyle konut satışları 606.892 adede ulaşarak zirveye çıkmış, ardından tekrar gerileme trendine girmiştir. 2025 yılında hafif bir toparlanma sergilediği görülmektedir.


Toplam konut satışları 2013'teki 1.226 milyondan 2025'te 1.760 milyona çıkarak yaklaşık %43 büyümüştür. Ancak bu büyümenin içinde ipotekli satışların payı dramatik biçimde erimştir. 2013'te her 10 konuttan 4'ü ipotekli satılırken, 2024'te bu oran 10'da 1'e düşmüştür (%10,8). 2025'te %14,1'e hafif toparlansa da tarihi ortalamannın çok altında olduğu görülmektedir.

Grafik 1. İpotekli Satışların Toplam Satışların İçindeki Payı (%)



Grafik 1’de ipotekli satışların toplam konut satışları içindeki payları gösterilmiştir. En dikkat çekici kırılma noktaları şunlardır: 2018’de faiz oranlarının sert yükselmesiyle ipotekli konut satış payı %20’ye gerilemiştir. 2020’de pandemi dönemi düşük faiz politikasıyla %37,7 ile artış yönünde önemli bir değişim yaşanmış, ancak daha sonraki yıllarda bu artış devam etmediği için bu yıla özgü bir değişim sergilemiştir. 2021 sonrasında ise hem faiz artışları hem de yükselen konut fiyatları ipotekli satışları kalıcı olarak baskıladığı görülmektedir.

Grafik 2. İpotekli ve Diğer Konut Satışları Grafiği (Adet)



Grafik 2’de ipotekli konut satışları ve diğer satışlar grafiği gösterilmiştir. Grafikte 2020 yılında (COVID-19 dönemi) 606.892 adet konut ipotekli olarak satılmıştır. 2013-2025 yılları analiz edildiğinde, konut satışları içerisinde en yüksek satış adedi 2020 yılında gerçekleştiği görülmektedir.

Tablo 2. İpotekli Konut Satışları İçerisinde İlk El ve İkinci El Satış Sayıları

Yıl	İpotekli Satış (Adet)	İpotekli İlk El	Oran	İpotekli İkinci El	Oran
2013	490.200	225.043	0,46	265.157	0,54
2014	419.094	191.831	0,46	227.263	0,54
2015	456.703	206.882	0,45	249.821	0,55
2016	472.521	214.973	0,45	257.548	0,55
2017	497.989	221.818	0,45	276.171	0,55
2018	293.386	135.398	0,46	157.988	0,54
2019	356.525	123.830	0,35	232.695	0,65
2020	606.892	198.430	0,33	408.462	0,67
2021	314.766	88.873	0,28	225.893	0,72
2022	304.432	90.953	0,30	213.479	0,70
2023	190.840	60.481	0,32	130.359	0,68
2024	166.635	41.089	0,25	125.546	0,75
2025	248.020	61.398	0,25	186.622	0,75

Kaynak: TÜİK

Tablo 2’de ipotekli konut satışlarında ilk el ve ikinci el konut dengesi de dikkat çekici görülmüştür. Öyle ki 2013’te ipotekli ilk el konut satışları %46 oranında iken, son yıllarda bu oranın oldukça düştüğü ve ipotekli konut satışlarının %25’ini ilk el konutlar oluşturduğu görülmektedir. Yani, son yıllarda ipotekli konut satışlarının ağırlıklı olarak ikinci el konutlardan oluştuğu göze çarpmaktadır. Yeni konut fiyatlarının yüksek olması alıcıları ikinci el piyasasına yönlendirdiği gözlemlenmiştir.

TÜRKİYE’DE İPOTEKLİ KONUT PİYASASININ TARİHSEL SEYRİ

Mortgage Sisteminin Kuruluşu ve Erken Dönem (2007-2012)

Türkiye'de mortgage sisteminin yasal dayanağı 2007 yılında yürürlüğe giren 5582 sayılı Konut Finansmanı Kanunu ile başlamıştır. Bu düzenlemeyle birinci el ipotek piyasasında kullanılan kredilerin ikinci el ipotek piyasalarında uygun koşullarda yeniden finanse edilmesi amaçlanmıştır. Ayrıca ikinci el ipotek piyasasının Türkiye'de henüz etkin çalışması yapılamamış olsa da, birinci el ipotek piyasalarında kullanılan kredilerin hacmi artış göstermiş ve Mart 2023 itibarıyla 357,4 milyar TL toplam bakiyeye erişmiştir (Konut Politikaları, 2023: 23).

Söz konusu dönemde ABD kaynaklı küresel mali kriz (2008-2009) konut piyasasını olumsuz etkilemiş ve etkisi kısa sürede küresel çapta hissedilmiştir. Bir ülkede konut piyasasının ekonomik göstergelerle yakın ilişkisi bulunması, ülke ekonomileri için önem arz ettiği görülmektedir (Muti ve Dursun, 2022:370).

Büyüme ve Kırılganlık Dönemi (2013-2019)

2013 yılından sonra Türkiye ekonomisinde sıklıkla yaşanan döviz kuru şokları, inşaat maliyetlerinin önemli ölçüde yükselmesine neden olmuş ve konut satışlarında belirgin dalgalanmalara yol açmıştır. 2018-2019 döneminde yüksek faiz oranları ve zayıflayan tüketici güveni, ipotekli konut satışlarında önemli bir düşüşe neden olmuştur. Kamu bankalarının 2019 yılı ağustos ayında konut kredi faizlerini önemli ölçüde indirmesiyle birlikte piyasada kısmi bir canlanma gözlemlenmiştir.

Pandemi Dönemi ve Düşük Faiz Ortamı (2020-2021)

2020 yılı Türkiye ipotekli konut piyasasında rekor düzeylerin yaşandığı bir dönem olmuştur. TCMB'nin faiz indirim politikası çerçevesinde konut kredisi faizlerinin yüzde birden düşük aylık düzeylere gerilmesi, ipotekli konut satışlarını ciddi biçimde artırmıştır. 2020 yılında 606.892 adet ipotekli konut satışı yapılarak 2013-2025 yılları arasında en yüksek sayıya ulaşmıştır. COVID-19

salgınıyla birlikte konut talebinde yaşanan hızlanma ve fiyatların yükseleceğine dair beklentiler, bu artışı daha da güçlendirmiştir.

TÜİK verilerine göre 2020 yılında toplam konut satışları önceki yıla göre yaklaşık yüzde on iki oranında artış kaydetmiştir. Düşük faiz ortamı, hem ilk kez konut satın alanlar hem de yatırım amaçlı konut edinmek isteyenler açısından finansmanı kolaylaştırmış; bu durum önemli fiyat artışlarını da beraberinde getirmiştir.

Yüksek Enflasyon ve Sıkılaştırma Dönemi (2022-2024)

2022 yılında Türkiye'de enflasyon Tüketici Fiyatları Endeksi'nde yüzde 64 seviyelerinin üzerine çıkmış; ardından hayata geçirilen parasal sıkılaştırma politikaları kapsamında TCMB faizleri hızla artırmaya başlamıştır. Konut kredisi faiz oranları, 2024 yılında ortalama yüzde kırk iki düzeyine ulaşarak tarihi zirveye çıkmıştır. Bu gelişme, ipotekli konut satışlarını derinden olumsuz etkilemiştir.

TÜİK verilerine göre 2024 yılında gerçekleşen ipotekli konut satışları, bir önceki yıla kıyasla yaklaşık yüzde on üç azalarak toplam 166.635 adede gerilemiştir. Toplam 1.549.760 konut satışı içinde ipotekli satışların payı yalnızca yaklaşık yüzde on bir düzeyinde kalarak 2013-2025 döneminin en düşük oranını yansıtmıştır. Bu oran, gelişmiş ülkelerle kıyaslandığında oldukça düşük bir seviyeyi ifade etmektedir.

FAİZ ORANLARI VE İPOTEKLİ KONUT SATIŞLARI İLİŞKİSİ

Faiz oranları ile ipotekli konut satışları arasındaki ters yönlü ilişki, Türkiye özelinde son derece belirgin bir biçimde kendini göstermektedir. TCMB politika faizinin düşük seyrettiği dönemlerde ipotekli satışlar hız kazanırken, sıkılaştırma dönemlerinde satışlar hızla gerilemektedir.

Konut kredisi faiz oranları doğrudan borçlanma maliyetlerini ve konut maliyetini etkilediği için, konut talebi ve konut satışlarını etkilemektedir (Kılıcı, 2019)

Literatür bulguları da bu ilişkiyi destekler niteliktedir. Torun, Topçu ve Varol (2024) konut kredisi faiz oranları ile ipotekli konut satışları arasındaki çift yönlü nedensellik ilişkisini ampirik olarak doğrulamıştır. Söz konusu çalışmada döviz kuru ve altın fiyatları ile satışlar arasındaki tek yönlü nedensellik ilişkisinin varlığı da ortaya konmuş; bu bulgu, Türkiye konut piyasasının güçlü yatırım boyutuna işaret etmektedir.

Konut kredi faiz oranları ile konut talebi arasında negatif bir ilişki bulunduğu (Çınar, 2022), yine kısa dönemde konut kredisi faiz oranlarının konut fiyatları üzerinde negatif bir etki olduğu (Kolcu ve Yamak, 2018). Konut talebi ve faiz oranları arasında negatif yönlü bir ilişkinin bulunduğu tespit edilmiştir (İslamoğlu ve Buluş 2018).

İPOTEKLİ KONUT SATIŞLARININ BÖLGESEL DAĞILIMI

2024 yılı verilerine göre Türkiye genelinde ipotekli konut satışlarında İstanbul 35.716 adet ile birinci sırada yer almakta; bunu 22.830 adet ile Ankara ve 11.019 adet ile İzmir izlemektedir. En düşük ipotekli konut satışlarının gerçekleştiği kentler ise sırasıyla Hakkâri (27 adet), Bayburt (48 adet) ve Ardahan (66 adet) illeridir.

Büyükşehirler konut satışlarında ağırlıklı paya sahip olmakla birlikte, hem yüksek fiyat düzeyleri hem de artan finansman maliyetleri bu şehirlerde ipotekli satışların toplam içindeki payını giderek baskı altına almaktadır. Özellikle İstanbul'da ortalama konut fiyatlarının yüksekliği, standart ipotekli finansman modellerini geniş kesimler için erişilemez kılmaktadır.

Batı illerinin aksine, iç ve doğu bölgelerindeki iller hem konut fiyatları hem de toplam satış hacimleri açısından belirgin biçimde daha düşük seviyelerdedir. Kırsal ve görece az gelişmiş

bölgelerde ipotekli konut finansmanına erişim oldukça sınırlı kalmakta; bu durum, bölgeler arası derin yapısal eşitsizliklere zemin hazırlamaktadır.

2025 YILI GELİŞMELERİ VE GÖRÜNÜM

2025 yılı itibarıyla TCMB'nin faiz indirim sürecine başlaması ve konut kredisi faizlerinin yüzde kırk seviyelerinde seyretmesiyle ipotekli konut satışlarında kısmi bir toparlanma gözlemlenmiştir.

2025 yılında ipotekli konut satışlarının bir önceki yıla göre yüzde 49'luk bir artış kaydettiği dikkat çekmektedir. Bununla birlikte, söz konusu satışların toplam konut satışları içindeki payının hâlâ istenilen düzeyin gerisinde kaldığı da görülmektedir. Konut kredisi faiz oranlarının yüzde yirmi bandına gerilemesi halinde ipotekli satışlarda daha belirgin bir canlanmanın yaşanabileceği düşünülmektedir.

2025 yılında Türkiye genelinde 248.020 adet ipotekli konut satışı gerçekleşmiştir. Bu sayı ile bir önceki yıla göre yüzde on üçlük bir artış yaşanmıştır. İstanbul, Ankara, İzmir, Bursa ve Antalya ipotekli konut satış hacmiyle öne çıkan beş il olma özelliğini göstermiştir.

POLİTİKA ÖNERİLERİ

Türkiye'de ipotekli konut piyasasının sağlıklı işleyişi ve sürdürülebilir büyümesi için birbirini tamamlayan politika adımlarına ihtiyaç duyulmaktadır.

Birinci olarak, faiz oranlarının istikrarlı ve öngörülebilir bir zeminde kademeli olarak indirilmesi, ipotekli konut talebinin güçlenmesine katkı sağlayacaktır. Konut kredisi erişilebilirliğinin artırılması, son yıllarda daralan talebin yeniden genişlemesi açısından hayati önem taşımaktadır.

İkinci olarak, ilk kez konut sahibi olmak isteyenler için özgün destekleme programlarının hayata geçirilmesi büyük önem taşımaktadır. Kamu bankaları aracılığıyla sunulacak sübvansiyonlu faiz uygulamaları ya da vergisel teşvik mekanizmaları, bu kesimin erişimini kolaylaştırabilecektir. Özellikle orta ve düşük gelir grupları için destek sağlanması gerektiği düşünülmektedir.

Üçüncü olarak, değişken faizli mortgage ürünlerinin artırılması faydalı olabilir. Türkiye'de değişken faizli konut finansmanı sözleşmelerinde tüketici fiyat endeksi esas alınmakla birlikte, faiz indirim dönemlerinden alıcıların gerçek anlamda yararlanabilmesi için ürün çeşitliliğinin artırılması gerekmektedir.

Dördüncü olarak, konut arzının artırılmasına yönelik politikalara ağırlık verilmesi önem arz etmektedir. İpotekli satışların yapısal olarak güçlendirilmesi, tek başına finansman koşullarının iyileştirilmesiyle mümkün olmayacaktır. Uygun fiyatlı konut arzının geliştirilmesi, sektörün dengeli büyümesi açısından zorunlu bir tamamlayıcı unsurdur.

Beşinci olarak, uzun vadeli konut finansmanı araçlarının güçlendirilmesi gereklidir. Konut finansmanında varlığa dayalı menkul kıymet piyasasının derinleştirilmesi, bankaların uzun vadeli sabit faizli ürün sunma kapasitesini artıracak ve piyasanın istikrarlı işleyişine katkı sağlayacaktır.

SONUÇ

Bu çalışmada Türkiye'de ipotekli konut satışlarının tarihsel seyri ve ekonomik belirleyicileri incelenmiş; makroekonomik kırılگانlıkların konut finansman piyasası üzerindeki derin etkileri ortaya konmuştur.

Temel bulgular birkaç önemli noktada yoğunlaşmaktadır. Konut kredisi faiz oranları, ipotekli konut satışlarının en güçlü belirleyicisi olma özelliğini sürdürmektedir. Faiz oranlarındaki

belirgin yükseliş, ipotekli satışların toplam konut satışları içindeki payını tarihi düşük düzeylere çekmiştir. 2024 yılında bu oran yaklaşık yüzde on bir düzeyine gerilemiş olup, gelişmiş konut finansmanı sistemleriyle doğrudan karşılaştırıldığında oldukça sınırlı kalmaktadır. Bunun yanı sıra konut piyasası belirgin biçimde yatırım güdümlü bir yapı sergilemekte; alıcıların konutu bir yatırım aracı olarak tercih etme eğilimi, enflasyon ve döviz kuru baskılarının yoğun olduğu dönemlerde özellikle öne çıkmaktadır. Öte yandan, bölgesel eşitsizlikler derinliğini korumakta; büyük metropoller ile küçük şehirler ve kırsal alanlar arasındaki konut finansmanı erişimindeki uçurum açılmaya devam etmektedir.

Türkiye'de gayrimenkul piyasasının büyümeye devam ettiğini göstermektedir. Ancak bu büyümenin giderek artan oranda nakit/diğer finansman kaynaklarıyla gerçekleştiği ortaya çıkmıştır. Yüksek faiz ortamı nedeniyle konut alımlarında banka kredisine erişim oldukça zor hale gelmiştir. Bu durum hem orta gelirli alıcıları piyasadan dışlamakta hem de piyasanın nakit sahiplerine ve kurumsal yatırımcılara yönelmesine neden olmaktadır. 2025'teki kısmi toparlanma (%14,1) faiz politikasındaki olası gevşemenin etkisiyle açıklanabileceği, ancak sürdürülebilirliği hususunda belirsizliğin devam ettiği söylenebilir.

Türkiye'nin demografik yapısı ve kentleşme eğilimleri, önümüzdeki dönemde konut talebinin güçlü seyrini sürdüreceğine işaret etmektedir. Sürdürülebilir enflasyon kontrolü ve istikrarlı faiz politikalarıyla desteklenen bir ortamda, ipotekli konut satışlarının güçlü bir toparlanma sürecine girmesi beklenmektedir. Bu bağlamda, konut finansmanına erişimi kolaylaştıracak yapısal reformların ve etkin politika araçlarının hayata geçirilmesi büyük önem taşımaktadır.

Kaynakça

- Bjørnland, H. C. ve Jacobsen, D. H. (2010). The role of house prices in the monetary policy transmission mechanism in small open economies. *Journal of Financial Stability*, 6(4), 218-229.
- Canbay, Ş., & Mercan, D. (2020). Türkiye’de Konut Fiyatları, Büyüme ve Makroekonomik Değişkenler Arasındaki İlişkinin Ekonometrik Analizi. *Yönetim ve Ekonomi Araştırmaları Dergisi*, 18(1), 176-200.
- Çankaya, S. (2013). Konut Fiyatları ve Makroekonomik Faktörler Arası İlişkiye Global Bakış. *Maliye ve Finans Yazıları*, 1(100), 143-154.
- Çınar, M. (2022). Fiyat, gelir ve faiz oranlarının konut talebi üzerindeki etkisi: Panel veri yaklaşımı. *International Journal of Social Inquiry*, 15(2), 295–309. <https://doi.org/10.37093/ijsi.1095419>
- Demary, M. (2010). The interplay between output, inflation, interest rates and house prices: international evidence. *Journal of Property Research*, 27(1), 1-17.
- Durkaya, M. ve Yamak, R. (2004). Türkiye’de konut piyasasının talep yönlü analizi. *İktisat İşletme ve Finans Dergisi*, 19(217), 75-83.
- Giuliodori, M. (2004). Monetary policy shocks and the role of house prices across European countries. *Scottish Journal of Political Economy*, 51(4), 519-543.
- Helgi Library (202). Mortgage Loans as % of GDP. URL: <https://www.helgilibrary.com/indicators/mortgage-loans-as-of-gdp/> (Erişim Tarihi: 23.04.2026)

- İslamođlu, B., & Buluş, A. (2018). Mortgage Piyasası ve Para Politikasının Konut Fiyatlarına Etkisi: Türkiye Üzerine Bir Uygulama. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 23(2), 455-466.
- Karadaş, H. A., & Salihoglu, E. (2020). Seçili Makroekonomik Deđişkenlerin Konut Fiyatlarına Etkisi: Türkiye örneđi. *Ekonomik ve Sosyal Araştırmalar Dergisi*, 16(1), 63-80.
- Kılıcı, E. N. (2019). Konut kredisi faiz oranları ile ipotekli konut satışları arasındaki ilişkinin analizi; Türkiye örneđi. *Turkish Studies-Economics, Finance, Politics*, 14(1), 95-107.
- Kolcu, F., & Yamak, N. (2018). Gelir ve Faiz Oranlarının Konut Fiyatları Üzerindeki Kısa ve Uzun Dönem Etkileri. *Uluslararası İktisadi ve İdari İncelemeler Dergisi*, 141-152.
- Muti, A., & Dursun, A. (2022). Konut fiyatlarına etki eden faktörlerin hedonik fiyat modeli ile belirlenmesi: Erzurum ili örneđi. *Bingöl Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 6(2), 349-380.
- Özçim, H. (2022). Türkiye'deki konut satışı ile TCMB politika faiz oranı ve konut fiyat endeksi arasındaki ilişkinin analizi. *Neşehir Hacı Bektaş Veli Üniversitesi SBE Dergisi*, 12(1), 523-533.
- Öztürk, N. ve Fitöz, E. (2009). Türkiye'de konut piyasasının belirleyicileri: ampirik bir uygulama. *ZKÜ Sosyal Bilimler Dergisi*, 5(10), 21-46.
- Şanlı, O. ve Peker, O. (2023). Enflasyon, kur, faiz ve gelirin konut satışlarına etkisi: Türkiye örneđi. *Journal of Economic Policy Researches*, 10(1), 37-60.

Torun, M., Topçu, U., & Varol, G. (2024). Türkiye’de Konut Piyasasında Uygulanan Konut Kredisi Faiz Politikasının Değerlendirilmesi. *Girişimcilik ve Kalkınma Dergisi*, 19(1), 37-45.

Türkiye Cumhuriyet Merkez Bankası [TCMB]. (2025). Finansal İstikrar Raporu (Mayıs 2025). Sayı:40. Ankara. (Erişim Tarihi: 23.04.2026)

Türkiye İstatistik Kurumu (TÜİK). Konut Satış İstatistikleri (Çeşitli Dönemler). <https://data.tuik.gov.tr/>

T.C. Cumhurbaşkanlığı Strateji ve Bütçe Başkanlığı. (2023). On İkinci Kalkınma Planı (2024-2028), https://www.sbb.gov.tr/wp-content/uploads/2025/08/Konut-Politikalari-OIK-Raporu_01082025.pdf (Erişim Tarihi:20.04.2026)

BÖLÜM 2 **A STATISTICAL ANALYSIS OF INITIAL PUBLIC OFFERINGS ON BORSA ISTANBUL**

CANSU TOSUN GAVCAR¹

ERDOĞAN GAVCAR²

NUSRET KARA³

1. INTRODUCTION

The main objective of this study is to analyze the performance of the companies that went public on Borsa Istanbul between 2021 and 2024, as well as certain statistical characteristics of the IPO process.

The world's first stock exchange is located in Çavdarhisar, Kütahya. On the stone blocks of Aizanoi, which was used as a food market (Macellum) at the end of the 2nd century AD, there is also a copy of the price regulations issued by the Roman Emperor Diocletian in AD 301 to combat inflation. These inscriptions announced the sale prices of all goods sold in the imperial markets. In this respect, Aizanoi is considered one of the first stock exchange buildings in the World (Kütahya Ticaret Borsası;2021)

Public offerings began with the establishment of stock exchanges. An IPO is the first time a company offers its shares to

¹ Dr., Pamukkale University, Business Administration, ORCID ID: 0000-0003-2750-0112

² Prof. Dr., Mugla Sıtkı Kocman University, , Business Administration, ORCID ID: 0000-0002-2748-3933

³ Dr, Res. Asst., Mugla Sıtkı Kocman University, , Business Administration, ORCID ID: 0000-0002-3296-9364

investors on the stock exchange. Through this process, the company ceases to be a private entity and becomes a publicly traded company.

An IPO involves a company offering its shares to investors in order to raise financing and begin trading on the stock exchange. In this way, the company raises capital from a broad base of investors. The main purposes of public offerings are capital raising, providing liquidity, enhancing recognition and prestige, and advancing institutionalization.

IPOs involve five important stages: preparation, application to the Capital Markets Board, CMB publication, book-building (demand collection), and trading on the stock exchange. Public offerings can be conducted through capital increases, share sales by existing shareholders, or a combination of both.

Investment instruments are financial tools preferred by individuals to allocate their savings and generate income over time. Different investment instruments can be selected based on one's objectives, risk appetite, and maturity preferences. The most common investment instruments are:

1. Time and Demand Deposit Accounts
2. Stocks (Equities)
3. Bonds and Bills
4. Real Estate Investments
5. Gold and Other Precious Metals
6. Foreign Exchange (FX)
7. Investment Funds
8. Cryptocurrencies
9. Individual Pension System

The Istanbul Stock Exchange was established on December 26, 1985, and became operational in Istanbul on January 3, 1986. In 2013, the Istanbul Gold Exchange and the Futures and Options Exchange were merged and renamed Borsa Istanbul. The BIST 500, 100, 50, and 30 indices are used as benchmarks.

As of 2024, the main markets on Borsa Istanbul are divided into six categories: 1. Star Market, 2. Main Market, 3. Sub-Market, 4. Watchlist Market, 5. Emerging Companies Market, and 6. Qualified Investor Trading Market.

By the end of 2024, the number of individual equity investors on Borsa Istanbul had reached 6.8 million, with a total trading volume of TL 34.3 trillion. A record daily trading volume of TL 276.2 billion was set on May 21, 2024. At the end of 2024, the total market capitalization of the companies listed on Borsa Istanbul was recorded at TL 13.42 trillion (Borsa Istanbul;2024)

Unlu analyzed the long-term price performance of banking sector stocks that were offered to the public for the first time in Turkey (Unlu; 2006). Using data from ten banks that went public on Borsa Istanbul between 1990 and 1995, the performance of these stocks over one-, two-, and three-year periods was analyzed using the Ritter methodology (Ritter; 1991). The findings show that banking sector stocks delivered negative returns below the market average in the first two years following the IPO but outperformed the market in the third year. Regression analyses revealed that variables such as IPO method, first-day returns, free float ratio, bank age, and asset size influenced long-term performance. It was argued that short-term negative performance weakened perceptions of IPOs in the sector, whereas long-term positive performance could have a favorable impact on investor confidence.

Küçükkocaoglu and Alagöz conducted a comparative examination of the fixed price and price range methods of public offerings on the Istanbul Stock Exchange (ISE) in Turkey (Kucukkocaoglu and Alagoz; 2009). The aim of the study was to determine which method provides more efficient pricing and is less prone to underpricing. Using data from 178 IPOs between 1993 and 2005, the authors evaluated the factors influencing firms' method preferences using a logit model and analyzed the variables causing first-day underpricing through regression analysis. The findings

reveal that average first-day underpricing was 7.13% for the fixed price method and 10.61% for the price range method, and that market returns, the time between the determination of the IPO price and the trading day, and firm size were influential on this difference. The study further indicates that firms in Turkey tend to time their IPOs during periods of high market returns, and although both methods offer short-term gains to investors, they exhibit poor long-term performance.

Celik aims to analyze the effects of initial public offerings (IPOs) on the operating performance of firms listed on Borsa Istanbul (Celik; 2016). The study examines financial performance indicators such as asset turnover, operating profit margin, net profit margin, return on equity, and return on assets for 56 non-financial firms that conducted IPOs between 2002 and 2011. The Wilcoxon Signed Rank test was used to evaluate changes in performance. The findings show that firms' operating performance declined significantly, particularly in the second year following the IPO, and these declines were statistically significant. Although partial recovery was observed in the third year, none of the performance indicators returned to pre-IPO levels. The results are consistent with many studies in the literature and suggest that IPOs may have a negative impact on firms' long-term operating performance.

2. MATERIALS AND METHODS

In this study, 180 companies that went public on Borsa Istanbul between 2021 and 2024 were considered as the material. In this way, the IPO data of the companies were obtained by individually analyzing the Capital Markets Board (CMB) bulletins. Accordingly, the number of shares (lots) offered to the public, IPO prices, the number of applicants (domestic individual and institutional, foreign individual and institutional, company employees, large investor applications), and the distribution method were evaluated.

To assess the obtained data, the distribution of the data was examined using the Kolmogorov-Smirnov and Shapiro-Wilk tests, and it was found that the data were not normally distributed since $P < 0.05$. The results of these tests are as follows:

Table 1. Normal Distribution Tests of the Data

Data	Kolmogorov-Smirnov ^a			Shapiro-Wilk		
	Statistic	df	Sig.	Statistic	df	Sig.
offered_lots	,226	28	,001	,648	28	,000
dom ind ap plications	,225	28	,001	,790	28	,000
dom ind all ocations	,259	28	,000	,603	28	,000
dom ind pe rcentage	,434	28	,000	,391	28	,000
dom inst ap plications	,316	28	,000	,447	28	,000
dom inst all ocations	,409	28	,000	,258	28	,000
dom inst pe rcentage	,430	28	,000	,375	28	,000
for ind appl ications	,256	28	,000	,780	28	,000
for ind allo cations	,204	28	,004	,722	28	,000
for ind per centage	,399	28	,000	,390	28	,000
for inst app lications	,339	28	,000	,735	28	,000
for inst allo cations	,470	28	,000	,307	28	,000
for inst per centage	,419	28	,000	,251	28	,000

Because the data were not normally distributed, the necessary analyses were conducted using non-parametric tests, including the Chi-Square test, Mann-Whitney U test, and Kruskal-Wallis test.

2.1.Results

A total of 216 companies were publicly offered between 2015 and 2024, 83.2% of which took place in the last four years.

Table 2. Number and Percentage Distribution of IPOs by Year

Years	Number of Companies Publicly Offered	Percentage (%)
2015	6	2,77
2016	2	0,92
2017	3	1,38
2018	11	5,09
2019	6	2,77
2020	8	3,70
2021	52	24,07
2022	38	17,59
2023	56	25,92
2024	34	15,74

Source: Prepared based on data from CMB Bulletins.

The highest number of IPOs was recorded in 2023, with 56 companies going public. The number of listed companies in various countries is presented in Table 3.

Table 3. Number of Listed Companies in Selected Countries as of End-2024

Countries	Stock Exchanges	Number of Listed Com.
China	Shanghai, Shenzhen, Beijing	5363
India	NSE, 2.482 (NSE) + 2.800 (BSE)	5282
United States	NYSE + 2.200 + Nasdaq 3.310	5510
Japan	Japan Exchange Group	3937
Canada	TMX Group (TSX, TSXV)	3575
Hong Kong	Hong Kong Exchanges and Clearing	2610
South Korea	Korea Exchange	2578
Australia	ASX Australian Securities	2002
United Kingdom	London Stock Exchange	1908
Spain	BME Spanish Exchanges	775
Türkiye	Borsa İstanbul	535

Source: Compiled from China.org.cn for China, Investopedia for India, and the World Federation of Exchanges (WFE) for the other countries. (China.org.cn; 2024, Investopedia; 2025, World Federation of Exchanges; 2025)

As of the end of 2024, China ranked first by country with 5,363 companies traded on the stock exchange, followed by India, the USA, Japan, and Canada. The number of companies listed on Borsa Istanbul is 535.

The IPO prices of the 180 companies publicly offered on Borsa Istanbul range from as low as 1.10 TL to 135.00 TL. The total number of lots offered varies between 280,000 and 1,173,405,000 lots.

Two different methods, equal distribution or proportional distribution, were used when the shares were offered to the public. The equal distribution method (equal share allocation) is generally used to protect small investors. The proportional distribution method allocates shares to everyone in proportion to the amount they requested. The data related to these are presented in the table below.

Table 4. Public Offering Methods of Shares

Public Offering Method	Number of IPOS	Percentage (%)
Equal Distribution	140	77,8
Proportional Distribution	40	22,2
Total	180	100,0

According to the table, 77.8% of the companies conducted their public offerings using the equal distribution method, while 22.2% used the proportional distribution method.

Table 5. Number of Distribution Methods by Year

Public Offering Method	Years				Total
	2021	2022	2023	2024	
Equal Distribution	33	21	52	34	140
Proportional Distribution	19	17	4	0	40
Total	52	38	56	34	180

As shown in Table 5, in recent years, the use of proportional distribution has decreased, while equal distribution has increased. This shift has encouraged investors to trade more actively on the stock exchange. The distribution method has varied over the years.

There were six different categories of participation in public offerings: domestic individual investors, domestic institutional investors, foreign individual investors, foreign institutional investors, applications by company employees, and high-volume applications.

Table 6. Number of Public Offering Applications, Allocated Lots, and Percentage Distribution

Subscription Type	Number of Allocated Ins.	Numbers
Domestic Individual Subscription	180	764-4943543
Domestic Individual Allocation	180	1760000-797915400
Domestic Individual Allocation%	180	12,24-99,99
Domestic Institutional Subscription	180	5-1143
Domestic Institutional Allocation	180	35-375000000
Domestic Institutional Allocation%	180	0,01-83,43
Foreign Retail Subscription	57	33-6462
Foreign Retail Allocation	57	7514-373583
Foreign Retail Allocation%	57	0,02-1,67
Foreign Institutional Subscription	91	1-187
Foreign Institutional Allocation	91	7-170185351
Foreign Institutional Allocation%	91	0,01-89,00
Employee Offering Participation	41	15-20439
Employee Allocation	41	54113-102618943
Employee Allocation%	41	0,37-58,64
High Demand Subscription	15	1057-17785
High Demand Allocation	15	2250000-32356486
High Demand Allocation%	15	13,70-60,79

According to the table, while domestic individual and institutional investors participated in all public offerings, foreign individual applications were submitted to 57 companies, and foreign institutional applications were submitted to 91 companies.

The number of applications by individual investors ranged from 764 to 4,943,543, while the number of allocated lots ranged from 1,760,000 to 797,915,400. For domestic institutional investors, the number of applications ranged from 5 to 1,143, and the number of allocated lots ranged from 35 to 375,000,000.

According to the Chi-Square test, the public offering applications of domestic individual investors do not vary based on the share price or the total number of shares offered. In contrast, the applications of domestic institutional investors vary depending on the total number of shares offered but not on the offering price.

The Mann-Whitney U test was used to examine whether there was a significant difference between equal and proportional distribution. The statistically significant results are provided in Table 7.

Table 7. Analysis of the Differences Between Equal and Proportional Distribution

Variables	p-value
Offering Price	0,013
Number of Offered Lots	0,027
Domestic Individual Applications	0,001
Domestic Individual Allocations	0,024
Foreign Individual Applications	0,005

According to the table, while there is a difference between equal and proportional distribution, no significant differences were found among the other variables. Under equal distribution, the offering price, number of lots offered, domestic individual applications, domestic individual allocations, and foreign individual applications are higher compared to proportional distribution.

The Kruskal-Wallis test was used to analyze whether there were differences among the variables across years. The significant findings are presented in Table 8.

Table 8. Differences Among Variables Across Years

Variables	Kruskal-Wallis H Value	p-value
Offering Price	50.000	0.001
Number of Offered Lots	11.253	0.010

Domestic Individual Applications	116.616	0.001
Domestic Individual Allocations	26.260	0.001
Domestic Institutional Applications	18.933	0.001
Foreign Individual Applications	41.271	0.001
Foreign Individual Allocation (%)	24.826	0.001
Allocation to Company Employees (%)	8.320	0.040

According to the table, there are statistically significant differences across years for 8 variables, while no significant differences were found for the other variables.

There is a significant difference over the years in terms of offering price and the number of lots offered. As the years progressed, both offering prices and the number of lots offered increased. While there is no significant difference between 2021 and 2022 regarding domestic individual applications, differences are observed compared to the other years. The highest number of applications was recorded in 2023, with a decrease observed in 2024 compared to 2023.

Regarding domestic individual allocations, there is no difference between 2021 and 2022. The lowest allocation was recorded in 2022. For domestic institutional applications, the lowest number of applications occurred in 2022, while the highest was in 2023. In terms of the percentage of foreign individual allocations, the lowest percentage was recorded in 2022, and the highest in 2021.

3. DISCUSSION AND CONCLUSION

In this study, the IPO processes of 180 companies that went public on Borsa Istanbul between 2021 and 2024 were analyzed using various statistical methods. Based on the findings, it was observed that there has been a significant increase in the number of public offerings in Turkey over the past four years. The fact that 83.2% of the total 216 IPOs took place during this period indicates that Borsa Istanbul has become more attractive to investors and that the capital markets have expanded.

According to the analysis results, the majority of the companies (77.8%) carried out their public offerings using the equal distribution method. Particularly in 2023 and 2024, proportional distribution was almost entirely abandoned in favor of equal distribution, which facilitated greater participation of small investors in the system. This shift contributed to the expansion of the investor base.

It was determined that the highest number of applications and allocations in public offerings came from domestic individual investors. The participation of foreign investors was observed to be more limited. Significant differences were found between distribution methods and offering price, number of lots, and application volumes. Equal distribution generally resulted in higher application numbers and lower offering prices.

In the year-based analyses, it was observed that offering prices and the number of lots offered increased, with the number of individual and institutional applications peaking in 2023. In 2024, there was a partial decline in this intensity. Additionally, significant statistical differences were identified in some variables across years.

In conclusion, the increase in public offerings on Borsa Istanbul in recent years indicates that the capital markets have developed and investor interest has grown. However, the decline in small investor interest in IPOs in 2024 compared to 2023 is also thought-provoking. For example, in 2023, one IPO company hit the upper price limit for 58 consecutive sessions and the lower price limit 16 times, while other companies reached the upper limit 23, 15, 12, and 11 times, respectively. In some cases, however, the stock price fell below the offering price, causing losses for investors. For example, the price of a share offered at 49.18 TL dropped to 30 TL, while another declined from 57.15 TL to 40.52 TL.

The change in distribution methods indicates that the aim has been to protect small investors. In the coming periods, the inclusion of more foreign investors in the process and a more balanced

planning of offering processes will contribute to the further deepening of the capital markets.

8. REFERENCES

- Borsa İstanbul. (2024). *Annual Report 2024*. Retrieved from <https://www.borsaistanbul.com/files/faaliyet-raporu-2024.pdf>. Accessed: April 11, 2025
- China.org.cn. (2024). *China's service trade maintains growth momentum*. Retrieved from https://www.china.org.cn/business/2024-11/04/content_117524306.html. Accessed: April 12, 2025
- Investopedia. Indian Stock Market Exchanges and Indexes. Retrieved from <https://www.investopedia.com/articles/stocks/09/indian-stock-market.asp>. Accessed: April 10, 2025
- Kurtaran Çelik, M. (2016). Firmaların İlk Halka Arz Sonrası Faaliyet Performanslarının Değerlendirilmesi: Borsa İstanbul Örneği. [Evaluation Of Post-Ipo Operating Performance Of Firms: Evidence From Borsa İstanbul]. *Uluslararası Yönetim İktisat ve İşletme Dergisi*, 12(27), 267-282. <https://doi.org/10.17130/10.17130/ijmeh.2016.12.27.1077>
- Küçükkoçaoğlu, G., & Alagöz, A. (2009). İmkb'de Uygulanan Halka Arz Yöntemlerinin Karşılaştırmalı Analizi. [Comparison Of The Initial Public Offering Methods In The Istanbul Stock Exchange]. *Dokuz Eylül Üniversitesi İktisadi İdari Bilimler Fakültesi Dergisi*, 24(2), 65-86.
- Kütahya Ticaret Borsası. Dünyanın İlk Borsası. Retrieved from <https://www.kutbo.org.tr/D%C3%BCnyan%C4%B1n%C4%B0lkBorsas%C4%B1/tabid/9946/Default.aspx>. Accessed: April 13, 2025
- Ritter, J. R. (1991), "The Long-Run Performance of Initial Public Offerings", *The Journal Of Finance*, 46(1), 3-27. <https://doi.org/10.1111/j.1540-6261.1991.tb03743.x>
- Unlu, U. (2006). Türkiye'de İlk Defa Halka Arz Edilen Bankacılık Sektörü Hisse Senetlerinin Uzun Dönem Fiyat Performansları. [Long-Term Price Performance of Banking Sector Stocks Following Initial Public Offerings in Turkey]. *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi* (27).
- World Federation of Exchanges. *Welcome to the Future of Markets*. Retrieved from <https://www.world-exchanges.org>. Accessed: April 12, 2025

Machine Learning–Based Prediction of Post–Capital Increase Stock Price Movements Using Fundamental Analysis: Evidence from Borsa İstanbul

BÖLÜM 3

İlyas Akin Akyigit¹
Sara Naghibzadeh²

Introduction

Modern financial markets are considered among the most complex economic systems, as they are influenced by massive volumes of structured and unstructured data (Fang & Zhang, 2016). In these markets, investor decision-making is no longer based solely on traditional analytical approaches; rather, the speed of information processing, Big Data analytics, and the ability to identify hidden patterns have become key factors in forecasting market behavior. In this context, emerging markets such as Borsa İstanbul provide a suitable environment for the application of artificial intelligence and machine learning techniques due to their higher volatility, strong sensitivity to news, and the presence of information asymmetry (Atak, 2023).

One of the most important sources of information in the Turkish capital market is Kamuyu Aydınlatma Platformu (KAP), through which publicly traded companies disclose financial information, managerial decisions, and strategic

¹ Halic University, Vocational School, Department of Big Data Analytics, ORCID: 0009-0007-6077-8788

² Dr. Lecture, Halic University, Vocational School, Department of Computer Programming, ORCID: 0009-0005-6959-1165.

announcements(Arkan & Yetgin, 2023) . Among these disclosures, capital increase announcements are of particular importance because such events often lead to sudden changes in investor expectations and significant fluctuations in stock prices (D’Augusta & Prencipe, 2024). In many cases, market reactions to these announcements extend beyond the scope of traditional financial analysis and are influenced by behavioral factors, forward-looking expectations, and market liquidity structures (C. Li et al., 2023).

In classical financial literature, the Random Walk Theory and the Efficient Market Hypothesis (EMH) argue that financial asset prices instantaneously reflect all available information; therefore, accurately predicting future market movements is theoretically impossible (NUNES, 2025). However, contemporary studies have demonstrated that financial markets, particularly emerging markets, do not always operate under perfect efficiency, and certain informational events may create detectable patterns and temporary anomalies in stock returns. Events such as capital increases, financial disclosures, and corporate announcements are examples of such anomalies that can be analyzed through data-driven approaches (Roeder et al., 2022).

Within this framework, the Event Study methodology has emerged as one of the most widely used approaches in financial analysis for examining market reactions to specific events (El Ghoul et al., 2022). By measuring abnormal returns around the event date, this method evaluates the impact of new information on market behavior. Despite its extensive application in financial studies, most traditional Event Study research has been limited to the statistical analysis of abnormal returns and has lacked the capability to algorithmically predict future price movements (Nisar & Yeung, 2018).

Simultaneously with the rapid advancement of artificial intelligence technologies, the use of machine learning and deep

learning algorithms in financial forecasting has increased significantly (Paramesha et al., 2024). Among these approaches, Long Short-Term Memory (LSTM) networks have become one of the most effective architectures for financial time-series analysis due to their ability to capture long-term temporal dependencies and model nonlinear structures (Siarni-Namini et al., 2019). LSTM models can identify hidden relationships among price data, trading volume, and fundamental variables, thereby analyzing market behavioral patterns more effectively than classical methods (Song et al., 2020).

Despite substantial progress in deep learning-based financial prediction, the majority of existing studies have focused primarily on price-based or technical indicators while largely neglecting the simultaneous integration of fundamental and event-driven data (Almusned et al., 2026). Although fundamental ratios such as the Price-to-Earnings (P/E) ratio and the Price-to-Book (P/B) ratio provide valuable information regarding firms' financial conditions and investor expectations, the integration of these variables with Kamuyu Aydınlatma Platformu (KAP) disclosures has received limited attention in the literature. This issue highlights an important research gap in AI-driven financial market analysis (Guragain, 2024).

Accordingly, the primary objective of this study is to develop a hybrid framework based on fundamental analysis, event-driven data, and an LSTM deep learning architecture to predict the direction of stock price movements following capital increase announcements in Borsa İstanbul (Chen et al., 2024). In this regard, data from A1 Yenilenebilir Enerji, Hedef Girişim Sermayesi, and İmaş Makine, which announced capital increase processes through Kamuyu Aydınlatma Platformu (KAP) during May 2026, were analyzed. By combining financial time-series data, fundamental ratios, and

probabilistic classification mechanisms, the proposed model aims to generate algorithmic “Buy,” “Sell,” and “Hold” signals.

The primary contribution of this research lies in the integration of fundamental analysis with event-driven deep learning models. This approach may contribute to a better understanding of emerging market behavior, reduce the limitations of traditional financial models, and support the development of AI-based financial decision support systems. Furthermore, the findings of this study may provide a foundation for future research in Natural Language Processing (NLP), financial sentiment analysis, and intelligent algorithmic trading systems.

Methodology And Algorithmic Framework

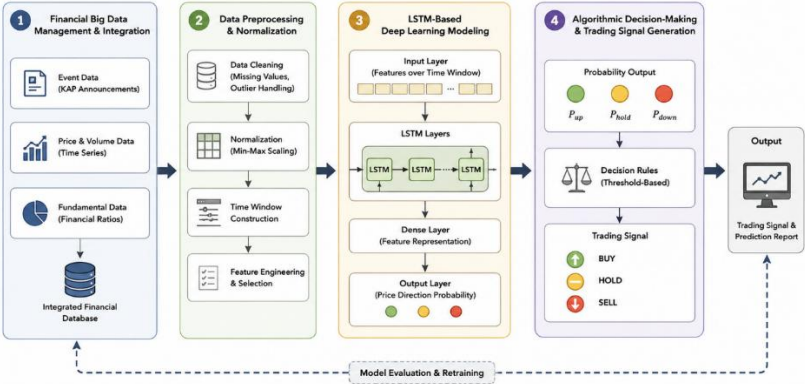
This study was designed to identify and model price anomalies resulting from capital increase announcements in Borsa İstanbul through a comprehensive machine learning and financial data analysis framework. The overall structure of the research was developed as a data-driven pipeline that sequentially performs data collection, data integration, preprocessing, feature extraction, deep learning-based modeling, and trading signal generation.

The primary objective of this framework is to integrate fundamental analysis data with financial time-series and event-driven information in order to predict the direction of stock price movements following capital increase announcements published on Kamuyu Aydınlatma Platformu (KAP). The proposed architecture consists of four main components:

1. Big Data management and financial data integration,
2. Data preprocessing and normalization,
3. LSTM-based deep learning modeling,
4. Algorithmic decision-making and trading signal generation.

As illustrated in Figure 1, the proposed framework follows a sequential data-driven pipeline consisting of four major stages: financial big data integration, data preprocessing and normalization, LSTM-based deep learning modeling, and algorithmic decision-making for trading signal generation. The architecture demonstrates how event-driven financial disclosures, market time-series data, and fundamental analysis indicators are integrated into a unified predictive system for forecasting stock price movements after capital increase announcements.

Figure 1. Overall Framework of the Proposed Methodology



Furthermore, the main innovation of this methodology lies in the simultaneous integration of fundamental data, time-series data, and financial event information within a unified deep learning framework. Unlike many previous studies that focused solely on price-based indicators, this research incorporates both fundamental analysis variables and Kamuyu Aydınlatma Platformu (KAP) disclosures into the deep learning model to achieve a more accurate representation of market decision-making dynamics.

Big Data Management and SQL-Based Data Integration

To construct the dataset used in this study, high-frequency financial data including real-time stock prices, trading volume, and

fundamental indicators related to A1 Yenilenebilir Enerji, Hedef Girişim Sermayesi, and İmaş Makine were collected. These companies announced their capital increase decisions through Kamuyu Aydınlatma Platformu (KAP) during May 2026. Market data were extracted at one-minute intervals in order to capture short-term market reactions surrounding event disclosures.

The final dataset consists of historical financial records covering the period between January 2025 and May 2026. After removing incomplete observations and non-trading periods, more than 150,000 time-series records were retained for model training and evaluation. The dataset includes price-based variables, trading activity indicators, and fundamental financial ratios, resulting in a total of 12 financial features extracted for each time interval.

To prevent data leakage in the time-series structure, the dataset was divided chronologically (Liu et al., 2022). The first 80% of the observations were used as the training set, while the remaining 20% were allocated to the test set. In addition, a sliding window approach with a sequence length of 60 time steps was employed to generate sequential input data for the deep learning model (M. Wang et al., 2023). Accordingly, the model analyzes the previous 60 minutes of market behavior to predict future stock price movements.

Considering the large volume of financial data and the necessity for rapid processing, a T-SQL (Transact-SQL)-based database architecture was designed. The SQL-based structure not only improved data retrieval and processing speed but also enabled simultaneous integration of price data, fundamental indicators, and event-driven information. Within this framework, stock price tables, trading volume records, Kamuyu Aydınlatma Platformu (KAP) event dates, and financial ratio datasets were merged through SQL Join operations to generate the final input table for the machine learning model.

To integrate price-based and fundamental variables, the database architecture was designed so that real-time stock prices, trading volumes, and financial ratios could be extracted from independent tables and consolidated into a unified central dataset. Furthermore, the target variable was generated using the SQL window function *LAG()* in order to determine the direction of price movement relative to the previous time interval. In this structure, if the current stock price was higher than the previous interval, the target class was assigned a value of 1 (bullish movement); otherwise, it was labeled as 0 (non-bullish movement).

A simplified representation of the SQL-based data integration architecture is illustrated in Figure 2, while the structure of the final machine learning dataset is presented in Table 1.

An example of the SQL query logic used in this study is provided below:

```

<> SQL

SELECT
  p.Timestamp,
  p.ClosePrice,
  p.Volume,
  f.PE_Ratio,
  f.PB_Ratio,

  CASE
    WHEN p.ClosePrice >
      LAG(p.ClosePrice) OVER (ORDER BY p.Timestamp)
    THEN 1
    ELSE 0
  END AS Target

FROM PriceData p

JOIN FinancialRatios f
ON p.StockCode = f.StockCode

WHERE p.StockCode IN ('A1YEN', 'HDFGS', 'IMASM');

```

Table 1. Presents a Sample Structure of the Final Dataset Used in the Machine Learning Model.

Stock Code	Timestamp	Close Price	Volume	P/E Ratio	P/B Ratio	Target
A1YEN	2026-05-11 10:00	45.20	10,500	12.50	2.10	0
A1YEN	2026-05-11 10:01	45.50	15,200	12.50	2.10	1
HDFGS	2026-05-11 10:00	12.10	5,000	8.40	1.50	1

IMASM	2026-05-11 10:00	88.00	22,000	15.20	3.40	0
-------	---------------------	-------	--------	-------	------	---

As shown in Table 1, the variables Close Price and Volume represent short-term market dynamics, whereas the fundamental ratios P/E and P/B provide information regarding company valuation and investor expectations. The *Target* variable specifies the direction of the next-period price movement and is used as the classification label during the model training process.

In this study, the Price-to-Earnings (P/E) ratio and Price-to-Book (P/B) ratio were selected as key fundamental financial indicators. These ratios are among the most widely used metrics in fundamental analysis and play a critical role in evaluating firm valuation. The P/E ratio reflects investor expectations regarding future profitability growth, whereas the P/B ratio represents the relationship between a company’s market valuation and its book value (Ghaeli, 2016).

Feature selection was conducted based on financial interpretability and findings from previous studies on emerging market prediction models (Mutinda & Yong, 2026). The objective of this stage was to create a hybrid feature set capable of simultaneously representing both short-term market behavior and long-term firm valuation characteristics. Moreover, integrating Kamuyu Aydınlatma Platformu (KAP)-based event data with financial indicators enables the proposed model to analyze market reactions to capital increase announcements more effectively and identify hidden behavioral patterns among investors.

Data Preprocessing and Normalization

Real-world financial datasets generally contain noise, missing values, and temporal inconsistencies (AlSalehy & Bailey, 2025). In data extracted from financial APIs, missing observations (NaN

values), trading interruptions, time gaps outside market hours, and short-term extreme fluctuations are frequently encountered (Mettu, 2025). Such issues may negatively affect the learning process of deep learning models and reduce prediction performance.

To preserve the temporal integrity of the dataset, an initial data-cleaning procedure was performed using the Pandas library in Python. Missing values were replaced using the Forward-Fill method in order to maintain the continuity of the time series. In addition, non-trading periods, including public holidays, nighttime intervals, and weekends, were removed so that only active market data were included in the training process.

During the labeling stage, if the stock price increased by more than 2% following a capital increase announcement, the corresponding observation was assigned to the “Bullish” class (Class 1). Conversely, if the price change remained below this threshold or exhibited a downward movement, the observation was categorized as the “Non-Bullish” class (Class 0). This threshold was selected to reduce short-term market noise and prevent the model from becoming overly sensitive to minor price fluctuations.

After the data-cleaning phase, all extracted features were subjected to a normalization process. Financial variables generally operate on different numerical scales. For example, trading volume may be represented in millions of units, whereas financial ratios such as the Price-to-Earnings (P/E) ratio or Price-to-Book (P/B) ratio usually have considerably smaller values. Such scale differences may dominate the gradient descent optimization process and reduce training stability.

Therefore, the Min-Max Scaling method was applied to transform all features into the range of $[0,1]$. This normalization technique ensures that all variables are represented on a unified scale, thereby

improving the stability and convergence performance of the neural network during training.

$$X_{norm} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (1)$$

In this equation 1, X represents the original feature value, X_{min} denotes the minimum observed value of the feature, and X_{max} represents the maximum observed value within the dataset.

The preprocessing and normalization stages play a critical role in improving the robustness and generalization capability of the proposed LSTM-based architecture (Rathnayake et al., 2021). By eliminating noisy observations and standardizing feature distributions, the model becomes more capable of identifying meaningful temporal and fundamental patterns associated with capital increase announcements in Borsa İstanbul.

Hybrid Deep Learning Architecture Based on LSTM

To model temporal dependencies and analyze market behavior before and after capital increase announcements, Long Short-Term Memory (LSTM) networks were employed in this study. LSTM networks are among the most advanced deep learning architectures for time-series analysis and are specifically designed to capture long-term dependencies in sequential data (Lindemann et al., 2021).

Financial markets exhibit non-stationary, nonlinear, and time-dependent characteristic (Vinogradov et al., 2023) . Therefore, traditional models such as Linear Regression or ARIMA often fail to capture the complex relationships among financial variables (Z. Li et al., 2020). By utilizing memory cells and control gates, including input, forget, and output gates, the LSTM architecture is capable of preserving important information over long time intervals while filtering out irrelevant noise. This capability enables the network to

identify hidden market patterns more effectively than conventional statistical approaches.

In the proposed framework, the deep learning architecture consists of two consecutive LSTM layers, two Dropout layers, and a final Dense layer for binary classification. The first LSTM layer is responsible for extracting primary temporal patterns from the financial time series, whereas the second LSTM layer models more complex dependencies and long-term market memory. To reduce the risk of overfitting and improve model generalization, a Dropout layer with a rate of 0.2 was applied after each LSTM layer. Finally, the Dense layer with a Sigmoid activation function generates the probability of upward or downward stock price movement. The overall architecture of the proposed model is illustrated in Figure 3.

To implement the proposed architecture, the TensorFlow/Keras framework in Python was utilized. The model was designed using a Sequential structure so that the temporal data could be processed progressively through memory-based layers. A simplified implementation of the proposed model architecture is presented in Figure 4.

In this architecture, the parameter `units=64` specifies the number of neurons in each LSTM layer. The use of `return_sequences=True` in the first LSTM layer ensures that the entire extracted sequence is transferred to the subsequent LSTM layer, allowing the model to analyze more complex temporal dependencies. In contrast, the second LSTM layer is configured with `return_sequences=False`, meaning that only the final output sequence is forwarded directly to the classification layer.

The Dropout layers with a rate of 0.2 were employed to reduce overfitting and prevent the network from memorizing noisy financial fluctuations. This regularization strategy randomly deactivates a

subset of neurons during each training iteration, thereby improving the robustness and generalization capability of the model on real-world financial data.

The training process was conducted using the Adam optimizer with a learning rate of 0.001. Adam is one of the most widely used optimization algorithms in deep learning architectures because of its high convergence speed and successful performance in financial time-series problems. In addition, the Binary Crossentropy loss function was selected since the objective of the model is to predict the probability of observations belonging to bullish or bearish classes. The Binary Crossentropy loss function is presented in Equation (2).

$$Loss = -\frac{1}{N} \sum_{i=1}^N [y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i)] \quad (2)$$

where y_i represents the actual class label and \hat{y}_i denotes the predicted probability generated by the model.

The model was trained for 50 epochs with a batch size of 32. To control overfitting, the validation loss was continuously monitored during the training process in addition to the use of Dropout layers. The simultaneous stabilization of both training and validation losses indicated that the model was able to learn meaningful market patterns without memorizing random fluctuations.

The most important hyperparameters of the proposed architecture are summarized in Table 2.

Table 2. Hyperparameters of the Proposed LSTM Architecture

PARAMETER	VALUE
OPTIMIZER	Adam
LEARNING RATE	0.001

BATCH SIZE	32
EPOCHS	50
LSTM UNITS	64
DROPOUT RATE	0.2
LOSS FUNCTION	Binary Crossentropy
SEQUENCE LENGTH	60
OUTPUT ACTIVATION	Sigmoid

As shown in Table 2, the proposed architecture combines sequential memory mechanisms with regularization techniques to improve predictive stability in high-frequency financial datasets.

In financial literature, LSTM architectures are widely utilized for stock price prediction, volatility analysis, and algorithmic trading because of their ability to process high-frequency data, preserve market memory, and model nonlinear structures (Aliyu et al., 2024). In this study, the proposed architecture was employed to predict stock price direction following capital increase announcements published through Kamuyu Aydınlatma Platformu (KAP). Furthermore, the integration of fundamental indicators and event-driven data with the LSTM architecture enabled the model to identify complex relationships among investor behavior, company valuation, and market reactions to capital increase announcements more effectively.

Algorithmic Decision-Making Mechanism

In the output layer of the proposed model, the Sigmoid activation function was employed to transform the network output into a probabilistic value within the range of 0 to 1 (Pratiwi et al., 2020). This probability value represents the confidence level of the model

regarding the upward or downward movement of stock prices following capital increase announcements. The mathematical representation of the Sigmoid activation function is presented in Equation (3).

$$\sigma(x) = \frac{1}{1+e^{-x}} \quad (3)$$

Based on the probabilistic output of the neural network, a threshold-based decision-making mechanism was designed. The primary objective of this system is to convert the raw output of the deep learning model into interpretable trading signals for investors. The threshold values were determined empirically according to the volatile characteristics of the market in order to reduce the probability of generating false trading signals under noisy market conditions.

The algorithmic decision strategy was defined as follows:

- If the predicted probability exceeds 0.60, the model anticipates an upward price movement and the stock is classified as a “Buy Signal.”
- If the predicted probability is lower than 0.40, the system predicts selling pressure or a downward movement, and the stock is classified as a “Sell/Avoid Signal.”
- If the predicted probability falls between 0.40 and 0.60, the market condition is considered an “Uncertainty Zone,” and the algorithm refrains from taking any trading position.

The use of an uncertainty zone helps reduce false signals and prevents participation in high-risk trades under highly noisy market conditions (Kochliaridis et al., 2023). This approach is particularly important in volatile emerging markets such as Borsa İstanbul, where investor behavior is often influenced by news announcements,

short-term market sentiment, and information asymmetry (Atak, 2023b).

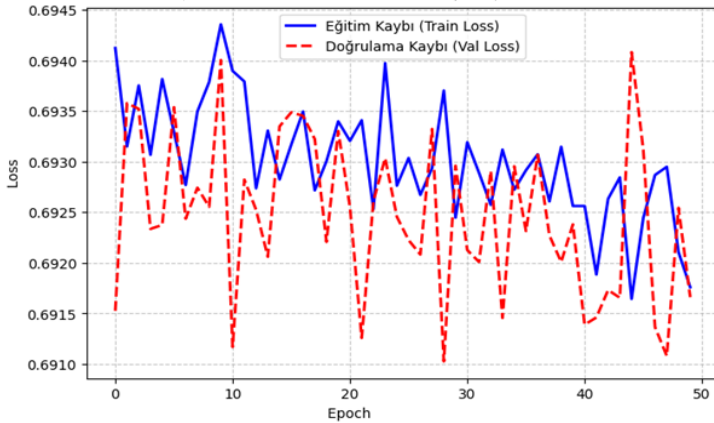
The overall decision-making mechanism of the proposed framework is illustrated in Figure 5. As shown in the figure, the probabilistic outputs generated by the LSTM-based architecture are transformed into interpretable trading decisions through a threshold-based filtering process.

Ultimately, the proposed framework presents a hybrid forecasting system based on fundamental indicators, event-driven financial data, and deep learning networks (Du et al., 2025). This architecture can serve as a foundational infrastructure for the development of intelligent financial decision-support systems and algorithmic trading applications in emerging financial markets (Zhao & Saeed, 2022).

Findings and Model Performance Evaluation

The hybrid deep learning model based on the LSTM architecture developed in this study was trained using structured datasets related to capital increase announcements issued by the companies Al Yenilenebilir Enerji, Hedef Girişim Sermayesi, and İmaş Makine. The datasets were collected through the Kamuyu Aydınlatma Platformu (KAP) and included stock price data, trading volume, and fundamental financial indicators. The model training process was conducted over 50 epochs, and the behavior of the loss function as well as the classification performance of the model were evaluated throughout the learning process, as illustrated in Figure 2.

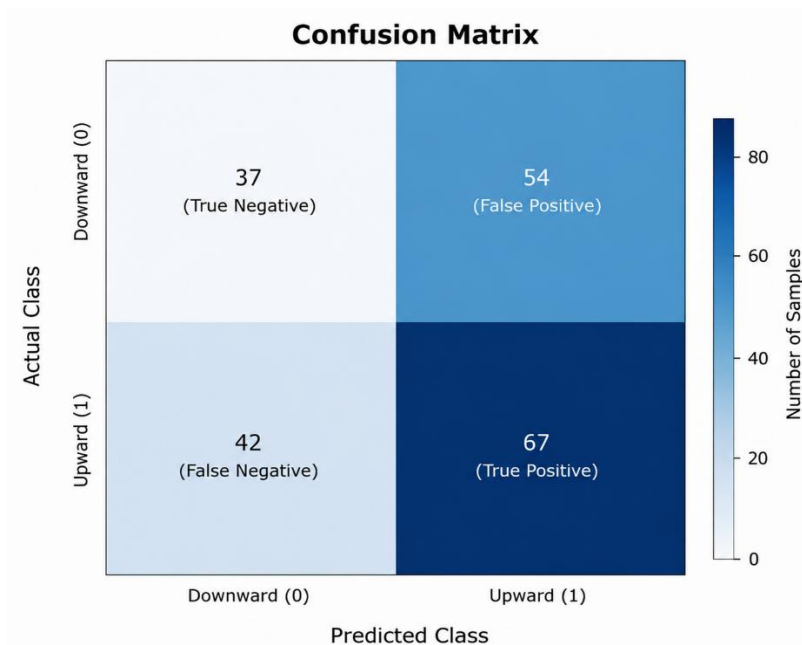
Figure 2. Training and Validation Loss Curves of the Proposed LSTM Model



To analyze the learning dynamics of the network, the variations in Training Loss and Validation Loss were examined based on the Binary Crossentropy cost function. During the initial stages of training, significant fluctuations in the loss values were observed due to the highly noisy nature of financial markets and the volatility of time-series data (Idrees et al., 2019). However, as the training process progressed, both curves gradually converged within a stable range. This behavior indicates that the model was able to learn the structural patterns of the market without memorizing random noise.

The simultaneous stabilization of the training and validation curves demonstrates that the use of Dropout layers and chronological data splitting successfully prevented overfitting (H. Li et al., 2024). As a result, the model was capable of learning not only the training data but also the broader behavioral characteristics of the market.

Figure 3. Confusion Matrix for Stock Price Movement Prediction After Capital Increase Announcements



To further evaluate the classification performance, a Confusion Matrix was generated using 200 test samples, as illustrated in Figure 3. The results showed that the model correctly identified 67 bullish movements as True Positives (TP) and 37 bearish movements as True Negatives (TN). In contrast, 54 samples were incorrectly classified as bullish signals (False Positives – FP), while 42 bullish movements were incorrectly predicted as bearish trends (False Negatives – FN).

These findings suggest that the market reaction to capital increase announcements does not follow a completely random structure and that certain aspects of investor behavior can be analyzed through deep learning models. In fact, the integration of fundamental indicators with event-driven data enabled the model to identify a

portion of the pricing anomalies emerging after Kamuyu Aydınlatma Platformu (KAP) announcements.

Statistical Performance Metrics

To quantitatively evaluate the model performance, standard classification metrics including Accuracy, Precision, Recall, and F1-Score were calculated. These metrics were derived from the values obtained from the confusion matrix (TP=67, TN=37, FP=54, FN=42).

The Accuracy metric indicates the overall proportion of correct predictions generated by the model.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} = \frac{67 + 37}{200} = 52.0\%$$

The results demonstrate that the overall accuracy of the model is 52.0%. Although this value may initially appear modest, even slight improvements above random behavior can be economically meaningful in highly noisy financial markets that are often close to stochastic behavior.

Precision measures the proportion of generated buy signals that actually resulted in upward price movements.

$$Precision = \frac{TP}{TP + FP} = \frac{67}{67 + 54} = 55.3\%$$

The Precision value of 55.3% indicates that the proposed model produced trading signals with higher quality compared to random prediction. This metric is particularly important in algorithmic trading systems because reducing false signals can significantly decrease the risk of unsuccessful trades.

Recall evaluates the model's ability to identify actual bullish market trends.

$$Recall = \frac{TP}{TP + FN} = \frac{67}{67 + 42} = 61.4\%$$

The Recall value of 61.4% suggests that the model achieved a relatively effective performance in detecting market growth opportunities and successfully captured a considerable portion of positive market reactions following capital increase announcements.

The F1-Score represents the harmonic mean of Precision and Recall and evaluates the balance between these two metrics.

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} = 58.2\%$$

The F1-Score of 58.2% indicates that the model achieved a balanced trade-off between identifying genuine bullish trends and minimizing false trading signals.

In financial literature, stock markets are generally considered highly noisy, nonlinear, and strongly influenced by investor behavior, which aligns closely with the Random Walk Theory. According to this perspective, models relying solely on price-based information typically achieve performance levels close to random prediction, usually around 50% accuracy. In such environments, even limited improvements in classification metrics may possess both statistical and economic significance.

In this study, the proposed hybrid framework, which integrates fundamental indicators such as the P/E and P/B ratios with Kamuyu Aydınlatma Platformu (KAP) event-driven data and an LSTM-based architecture, improved the Precision metric to 55.3% and the F1-Score to 58.2%. These findings indicate that capital increase announcements published through the Kamuyu Aydınlatma Platformu (KAP) can generate identifiable and partially predictable anomalies in the market(Özyeşil & Tembelo, 2025).

Although the predictive performance metrics remain moderate, this outcome is consistent with the stochastic and highly noisy nature of financial markets (Nabar & Shroff, 2023). In algorithmic trading environments, even small predictive advantages above random behavior may provide economically meaningful trading opportunities when applied consistently over large numbers of transactions (Cooper et al., 2023). Therefore, the proposed framework should be interpreted as a probabilistic decision-support system rather than a deterministic price prediction model.

Conclusion and Discussion

In this study, the effects of announcements published in markets characterized by high information asymmetry, such as Borsa İstanbul, were analyzed through an artificial intelligence–based algorithmic framework. Within this context, the impact of announcements published through the Kamuyu Aydınlatma Platformu (KAP) on stock prices was investigated (Atak, 2023a).

While traditional Event Study approaches generally analyze price changes only at the moment of the event occurrence, the hybrid LSTM architecture developed in this research is capable of learning the relationship between event-driven information and fundamental analysis ratios, ultimately generating predictive “Buy/Sell/Hold” signals for investors (Song et al., 2020).

The findings demonstrate that machine learning algorithms achieve improved capability in identifying market anomalies when they are not limited solely to price-based data and are instead combined with fundamental and event-driven information (Jahan et al., 2024). This suggests that Kamuyu Aydınlatma Platformu (KAP) announcements may function as a source of partially predictable behavioral patterns in the market.

Although the predictive performance metrics of the proposed model remain moderate, this outcome is consistent with the highly stochastic, nonlinear, and noisy structure of financial markets (Khattak et al., 2023). In emerging markets such as Borsa İstanbul, even limited improvements over random prediction may possess both statistical and economic significance (Kazak et al., 2025). Therefore, the primary objective of the proposed framework is not deterministic market prediction, but rather the identification of probabilistic behavioral patterns and the generation of decision-support signals for algorithmic trading systems.

For future studies, it is recommended that, in addition to numerical financial variables, the textual content of announcements published through the Kamuyu Aydınlatma Platformu (KAP) should also be analyzed using Natural Language Processing (NLP) and Sentiment Analysis techniques and incorporated into the model as an additional analytical layer. Such an approach may contribute to reducing Type I and Type II errors, improving overall model accuracy, and enhancing predictive performance.

Natural Language Processing (NLP) is considered one of the most significant subfields of artificial intelligence, enabling the analysis and interpretation of textual data. In financial markets, an enormous volume of information is published in textual form, including official corporate disclosures, economic news, analytical reports, social media content, and public market announcements. These textual datasets may exert a direct influence on investor behavior and stock price volatility (Dimlo et al., 2024).

In recent years, the integration of NLP with machine learning and deep learning models has attracted substantial attention in financial market forecasting. Techniques such as Sentiment Analysis, keyword extraction, and Transformer-based language models are capable of identifying positive or negative tones in financial news

and estimating their potential influence on market trends (Khalil et al., 2021).

Although the primary focus of the present study was on numerical financial indicators and fundamental analysis ratios, future research may extend the proposed framework by incorporating the textual analysis of announcements published through the Kamuyu Aydınlatma Platformu (KAP) using NLP techniques. The addition of this textual layer may reduce prediction errors and improve the accuracy of algorithmic decision-making systems (A. Wang et al., 2024).

References

Abdel-Basset, M., Manogaran, G., & Mohamed, M. (2020). COVID-19 drug discovery using computational intelligence methods. *Chaos, Solitons & Fractals*, *140*, 110121. <https://doi.org/10.1016/j.chaos.2020.110121>

Aliyu, I., Salihu, A. A., Musa, S., Adeniyi, A. B., Muhammad, A. Y., & Ahmed, M. (2024). An overview on long short-term memory (LSTM)-based prediction model for stock market volatility. *Faculty of Natural and Applied Sciences Journal of Mathematical Modeling and Numerical Simulation*, *2*(1), 48–56.

Almusned, A., Hassan, M. M., Alkhamees, B., & Al-Qurishi, M. (2026). Integrating heterogeneous data for stock market prediction: A systematic literature review. *International Journal of Advanced Computer Science & Applications*, *17*(3), 252.

AlSalehy, A. S., & Bailey, M. (2025). Improving time series data quality: Identifying outliers and handling missing values in a multilocation gas and weather dataset. *Smart Cities*, *8*(3), 82. <https://doi.org/10.3390/smartcities8030082>

Arikan, E., & Yetgin, F. (2023). Analysis of factors affecting corporate governance maturity level: A research on the companies traded on Borsa İstanbul. *Yildiz Social Science Review*, *9*(1), 36. <https://doi.org/10.51803/YSSR.1170149>

Atak, A. (2023). Exploring the sentiment in Borsa Istanbul with deep learning. *Borsa Istanbul Review*, *23*, S84–S95. <https://doi.org/10.1016/j.bir.2023.12.010>

Chen, W., Hussain, W., Cauteruccio, F., & Zhang, X. (2024). Deep learning for financial time series prediction: A state-of-the-art review of standalone and hybrid models. *CMES - Computer Modeling in Engineering and Sciences*, 139(1), 187–224. <https://doi.org/10.32604/CMES.2023.031388>

Cooper, R., Currie, W. L., Seddon, J. J. M., & Van Vliet, B. (2023). Competitive advantage in algorithmic trading: A behavioral innovation economics approach. *Review of Behavioral Finance*, 15(3), 371–395. <https://doi.org/10.1108/RBF-06-2021-0119>

D'Augusta, C., & Prencipe, A. (2024). Accruals quality, shocks to macro-uncertainty, and investor response to earnings news. *European Accounting Review*, 33(3), 1051–1074. <https://doi.org/10.1080/09638180.2022.2141288>

Dimlo, U. M. F., Rupesh, V., & Raju, Y. (2024). The dynamics of natural language processing and text mining under emerging artificial intelligence techniques. *International Journal of System Assurance Engineering and Management*, 15(9), 4512–4526. <https://doi.org/10.1007/s13198-024-02468-8>

Du, X., Cao, J., Jiang, X., Wang, Q., Xu, B., Liu, Z., Chen, Y., & Yuan, C. H. (2025). Integrating event information and multi dimensional relationships for improved financial time series forecasting. *Scientific Reports*, 15(1), 38099. <https://doi.org/10.1038/s41598-025-22926-y>

El Ghouli, S., Guedhami, O., Mansi, S. A., & Sy, O. (2022). Event studies in international finance research. *Journal of International Business Studies*, 54(2), 344–364. <https://doi.org/10.1057/s41267-022-00534-6>

Fang, B., & Zhang, P. (2016). Big data in finance. In *Big data concepts, theories, and applications* (pp. 391–412). https://doi.org/10.1007/978-3-319-27763-9_11

Ghaeli, M. R. (2016). Price-to-earnings ratio: A state-of-art review. *Accounting*, 2(4), 113–120. <https://doi.org/10.5267/j.ac.2016.7.002>

Guragain, M. (2024). *Determinants of stock price of commercial banks in Nepal* (Master's thesis). <https://hdl.handle.net/20.500.14540/24937>

Idrees, S. M., Alam, M. A., & Agarwal, P. (2019). A prediction approach for stock market volatility based on time series data. *IEEE Access*, 7, 17287–17298. <https://doi.org/10.1109/ACCESS.2019.2895252>

Jahan, N., Pritty, A. A., Ibrahim, M., Zadid, M. U., Fahim, A. S. M., & Mahmud, S. (2024). Machine learning-driven early warning analytics for identifying market manipulation, irregular trading activity, and suspicious market signals in U.S. stock markets. *Journal of Computer Science and Technology Studies*, 6(2), 257–283. <https://doi.org/10.32996/JCSTS.2024.6.2.26>

Kazak, H., Kumar, S., Gündüz, M. A., Akcan, A. T., & Bilgiç, H. H. (2025). Metaheuristic-optimized ANFIS and ANN models for stock price forecasting: Evidence from the Borsa Istanbul 100 index. *Discover Artificial Intelligence*, 5(1), 272. <https://doi.org/10.1007/s44163-025-00395-6>

Khalil, F., & Pipa, G. (2021). Is deep-learning and natural language processing transcending the financial forecasting? Investigation through lens of news analytic process. *Computational Economics*, 60(1), 147–171. <https://doi.org/10.1007/s10614-021-10145-2>

Khattak, B. H. A., Shafi, I., Khan, A. S., Flores, E. S., Lara, R. G., Samad, M. A., & Ashraf, I. (2023). A systematic survey of AI models in financial market forecasting for profitability analysis. *IEEE Access*, *11*, 125359–125380. <https://doi.org/10.1109/ACCESS.2023.3330156>

Kochliaridis, V., Kouloumpris, E., & Vlahavas, I. (2023). Combining deep reinforcement learning with technical analysis and trend monitoring on cryptocurrency markets. *Neural Computing and Applications*, *35*(29), 21445–21462. <https://doi.org/10.1007/s00521-023-08516-x>

Li, C., Yan, Y., Liu, X., Wan, S., Xu, Y., & Lin, H. (2023). Forward looking statement, investor sentiment and stock liquidity. *Heliyon*, *9*(4), e15329. <https://doi.org/10.1016/j.heliyon.2023.e15329>

Li, H., Rajbahadur, G. K., Lin, D., Bezemer, C. P., & Jiang, Z. M. (2024). Keeping deep learning models in check: A history-based approach to mitigate overfitting. *IEEE Access*, *12*, 70676–70689. <https://doi.org/10.1109/ACCESS.2024.3402543>

Li, Z., Han, J., & Song, Y. (2020). On the forecasting of high-frequency financial time series based on ARIMA model improved by deep learning. *Journal of Forecasting*, *39*(7), 1081–1097. <https://doi.org/10.1002/for.2677>

Lindemann, B., Müller, T., Vietz, H., Jazdi, N., & Weyrich, M. (2021). A survey on long short-term memory networks for time series prediction. *Procedia CIRP*, *99*, 650–655. <https://doi.org/10.1016/j.procir.2021.03.088>

Liu, F., Chen, L., Zheng, Y., & Feng, Y. (2022). A prediction method with data leakage suppression for time series. *Electronics*, *11*(22), 3701. <https://doi.org/10.3390/electronics11223701>

Mettu, V. A. (2025). Finance trading algorithms in high-frequency markets: Predictive modeling, reinforcement learning, and real time anomaly detection. *International Journal of Computer Technology and Electronics Communication*, 8(5), 11335–11347. <https://doi.org/10.15680/IJCTECE.2025.0805005>

Mutinda, J. K., & Yong, L. (2026). Hybrid prediction framework using novel stability-enhanced dynamic thresholding feature selection and artificial intelligence methods for financial market trend prediction. *Computational Economics*, 1–79. <https://doi.org/10.1007/s10614-026-11346-3>

Nabar, O., & Shroff, G. (2023). Conservative predictions on noisy financial data. *ICAIF 2023 - 4th ACM International Conference on AI in Finance*, 427–435. <https://doi.org/10.1145/3604237.3626859>

Nisar, T. M., & Yeung, M. (2018). Twitter as a tool for forecasting stock market movements: A short-window event study. *The Journal of Finance and Data Science*, 4(2), 101–119. <https://doi.org/10.1016/j.jfds.2017.11.002>

Nunes, R. (2025). The efficient market hypothesis as an extension of neoclassical theory: A theoretical and empirical critique. *Journal of Economics, Finance and Accounting Studies*, 7(4), 117–134. <https://doi.org/10.32996/JEFAS.2025.7.4.10>

Özyeşil, M., & Tembelo, H. (2025). Unveiling the pricing anomaly: A detailed examination of initial public offerings in Borsa Istanbul in 2023. *Istanbul Journal of Economics*, 75(1), 97–116. <https://doi.org/10.26650/ISTJECON2024-1499157>

Paramesha, M., Rane, N., & Rane, J. (2024). Artificial intelligence, machine learning, deep learning, and blockchain in

financial and banking services: A comprehensive review. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.4855893>

Pratiwi, H., Windarto, A. P., Susliansyah, S., Aria, R. R., Susilowati, S., Rahayu, L. K., Fitriani, Y., Merdekawati, A., & Rahadjeng, I. R. (2020). Sigmoid activation function in selecting the best model of artificial neural networks. *Journal of Physics: Conference Series*, 1471(1), 012010. <https://doi.org/10.1088/1742-6596/1471/1/012010>

Rathnayake, D., Bawantha Perera, P., Eranga, H., & Ishwara, M. (2021). Generalization of LSTM CNN ensemble profiling method with time-series data normalization and regularization. *ICTer 2021 Proceedings*, 7–12. <https://doi.org/10.1109/ICTER53630.2021.9774793>

Roeder, J., Palmer, M., & Muntermann, J. (2022). Data-driven decision-making in credit risk management: The information value of analyst reports. *Decision Support Systems*, 158, 113770. <https://doi.org/10.1016/j.dss.2022.113770>

Siarni-Namini, S., Tavakoli, N., & Namin, A. S. (2019). A comparative analysis of forecasting financial time series using ARIMA, LSTM, and BiLSTM. *arXiv*. <https://arxiv.org/pdf/1911.09512>

Song, X., Liu, Y., Xue, L., Wang, J., Zhang, J., Wang, J., Jiang, L., & Cheng, Z. (2020). Time-series well performance prediction based on long short-term memory (LSTM) neural network model. *Journal of Petroleum Science and Engineering*, 186, 106682. <https://doi.org/10.1016/j.petrol.2019.106682>

Vinogradov, N. A., Lesnaya, A. V., & Savinov, I. D. (2023). Probabilistic models and methods of regression analysis of volatile

financial time series. *Science-Based Technologies*, 57(1), 3–15.
<https://doi.org/10.18372/2310-5461.57.17439>

Wang, A., Kapoor, S., Barocas, S., & Narayanan, A. (2024). Against predictive optimization: On the legitimacy of decision-making algorithms that optimize predictive accuracy. *ACM Journal on Responsible Computing*, 1(1), 1–45.
<https://doi.org/10.1145/3636509>

Wang, M., Zhang, L., Yu, H., Chen, S., Zhang, X., Zhang, Y., & Gao, D. (2023). A deep learning network based on CNN and sliding window LSTM for spike sorting. *Computers in Biology and Medicine*, 159, 106879.
<https://doi.org/10.1016/j.combiomed.2023.106879>

Zhao, X., & Saeed, O. (2022). Intelligent financial processing based on artificial intelligence-assisted decision support system. *Mobile Information Systems*, 2022, 6974246.
<https://doi.org/10.1155/2022/6974246>

BÖLÜM 4

MERKEZİ YÖNETİM BORÇ STOKUNUN GELİŞİMİ

FİKRET KARTAL¹

Giriş

Kamu kesiminin, vergi ve vergi dışı gelirleri ile karşılayamadığı tüketim ve yatırım harcamaları için borçlanması olağan bir durumdur. Denk bütçe hedefi dile getirilmekle birlikte uygulamada bütçe açığı yaygındır. Gelişmiş ülkeler de dâhil olmak üzere küresel bazda yüksek kamu kesimi borçluluk oranları dikkat çekmektedir. Ülkelerin risk yapısının analizinde kamu kesiminin bütçe açığı ve millî gelire oranla borçluluk düzeyi kullanılan ana göstergeler arasındadır.

Gelişmiş ve rezerv paraya sahip olan ülkelerde iç-dış borç ayırımı doğmamakta çünkü bu ülkeler kendi para birimleri üzerinden borçlanma imkânına sahip olmaktadır. Diğer yandan, rezerv parası olmasa dahi dış ticaret fazlası veren ülkelerde de dış borçlanma daha az risk taşımaktadır. Gelişmekte olan ve dış açık veren ülkelerde ise iç ve dış borç ayırımı gündeme gelmektedir. Bir ülkenin yurt dışında

¹ Doç.Dr., Ostim Teknik Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, Ekonomi Bölümü, ORCID: 0000-0002-2354-8621

ihraç ettiği tahviller ve yurt dışından aldığı borçları ifade eden dış borçlar ile yurt içinden temin edilse dahi döviz cinsinden borçlar, çeşitli riskler taşıyor olsa da küresel finansal koşulların uygun olması hâlinde düşük maliyetli ve uzun vadeli borçlanma fırsatı ortaya çıkabilmektedir. Tasarruf açığı ve dış açığı bulunan ülkelerin ödemeler dengesine konu finansman kalemi üzerinden doğrudan ve dolaylı yatırımlar aracılığıyla fon çekmesinin yanı sıra kredi yoluyla borçlanması da yurt içi faaliyetlerin devamlılığı ve ekonominin çarklarının dönmesi açısından bir ihtiyaçtır. Örneğin, Türkiye büyümesinde, üretiminde, ihracatında yüksek düzeyde ithal girdi gereksinimine sahiptir ve bu durum döviz ihtiyacını ve dolayısıyla dövizle borçlanmayı zorunlu kılmaktadır. Hazine aracılığıyla kamu kesiminin sadece kamu yatırımları için değil, özel kesimin döviz ihtiyacını karşılamak için de dış borçlanmaya yönelmesi olağan bir durumdur.

Kamu borcunun miktarının-düzeyinin yanı sıra borcun vade yapısı, ulusal para ve döviz dağılımı, borca konu faizin türü (sabit-değişken) gibi konularda dikkate alınarak borçlulukla ilgili değerlendirmelerde bulunmaktadır. Ayrıca borcun mutlak tutarından çok daha fazla şekilde borcu millî gelir içindeki payı önem kazanmaktadır.

Bu çalışmada, 2018 yılında meydana gelen kur şokunun hemen öncesinden başlanarak merkezi yönetim borç stokundaki miktar ve profil değişimi analiz edilmekte, 2017-2025 dönemine ait yıl sonu verileri kullanılmaktadır. Borç stokunun iç-dış borç dağılımı, faiz yapısı, TL ve döviz kompozisyonu ve borcun millî gelir içindeki payı sunularak değerlendirilmelerde bulunmaktadır.

Literatür Taraması

Türkiye’de kamu borç stokunun yapısı, borcun belirleyicileri ve ilişkide bulunduğu değişkenlerle ilgili yapılan bazı çalışmaların sonuçlarına aşağıda kısaca yer verilmektedir.

Ülkelerin iç ve dış borç kompozisyonu üzerine odaklanan çalışmada (Eser & Birinci, 2014: 48-49); risk, maliyet ve dışsallıkların iç-dış borç tercihini etkilediği, gelişmekte olan ülkelerin ekonomik kriz ve döviz kuru riski nedeniyle iç borcu tercih edebildiği, kamunun iç borçlanmasında meydana gelen artışın ise özel kesim üzerinde dışlama etkisi yaratabildiği, çoğu gelişmekte olan ülkede özel sektörün de dış borçlanmaya yönelebildiği ifade edilmiştir.

Kamu harcamalarını karşılayacak geliri yaratamayan, yüksek reel faizle borçlanan, sürekli olarak borcunu çeviren ülkelerde borcun alınması ile ödenmesi arasındaki dönemde kamu borç yönetiminin önem taşıdığını belirten çalışmada (Türkal, 2020: 161-162); kamunun finansal piyasalara erişiminin süreklilik kazanması, borçlanma maliyetinin düşük tutulması, borçlanma araçlarının çeşitlendirilmesinin borç yönetiminin temel unsurları olduğu açıklanmıştır.

1990-2012 döneminde kamu borç yönetiminde meydana gelen kurumsal dönüşümü inceleyen çalışmada (Yıldız, 2014: 98-99); 1990-1994 ve 2005-2012 dönemlerinin kamu kesiminin borç göstergeleri bakımından olumlu, 1995-2001 döneminin ise olumsuz bir tablo sergilediği, 2004 sonrasında borcun millî gelir içindeki payında düşüş, dış borç payında gerileme, faiz ödemelerinin milli gelir ve vergi gelirlerine oranında azalmanın meydana geldiği ifade edilmiştir.

Covid-19 salgın krizinin kamu borç stokuna etkilerini analiz eden çalışmada (Oskay, 2022: 187-188); salgın nedeniyle uygulanan genişlemeci politikaların bütçe açığı ve kamu borçlanmasını arttırdığı, kısa vadeli, değişken faizli, döviz cinsinden borçlanmanın yükseldiği, bu durumun faiz ve kur risklerine karşı kırılganlığı arttırdığı belirtilmiştir.

2000-2021 dönemi için borç stoku da dâhil yedi kriter üzerinden kamu mali performansını analiz eden çalışmada (Kete, 2023: 48-49); 2001, 2003 ve 2002 yıllarının sırasıyla en kötü skora sahip, 2011, 2020 ve 2021 yıllarının ise en iyi skora sahip yıllar olduğu, merkezi yönetim net borçlanma gereği, genel yönetim borç stoku, bütçeden faiz ödemelerine ayrılan pay bakımından sürdürülebilir seviyelere ulaşıldığı, ancak Covid-19 salgın krizi ile birlikte bu rasyoların yükseldiği ifade edilmiştir.

Kamu mali performansını 2003-2024 dönemi üzerinden analiz eden diğer bir çalışmada ise (Demir, 2026: 251-252); özellikle yüksek büyüme dönemlerinde artan vergi gelirlerinin kamu borçlanmasını kontrol altına aldığı ve bunun mali performansı yükselttiği, kamu kesimi borçlanma gereğinin toplam borç stokundan daha etkili olduğu, başka bir ifadeyle performansın stok değil, akım değişkenden etkilendiği belirtilmiştir.

Bazı gelişmekte olan ülkelerde sürdürülebilirlik ve risk bakımından sorunlar içeren dış borcu merkezine alan ve 2002-2022 dönemine ait verileri kullanan çalışmada (Oskay, 2024: 17-18); beş gösterge üzerinden Türkiye ve BRICS ülkeleri karşılaştırıldığında dış borç sorununun Türkiye’de öne çıktığı, dış borçta özel sektörün payı ve kısa vadeli borçların ağırlığının Türkiye’yi kırılgan hale getirdiği ifade edilmiştir. Aynı çalışmada üretimde ithal girdi payının azaltılması, dolarizasyonun hafifletilmesi, yurt içi tasarrufun artırılması ve dış borca alternatiflerin geliştirilmesi gibi faktörlerin bu kırılganlığı azaltacağı açıklanmıştır.

Kamu borcunun ekonomiye etkisini, kamu borçlanmasında ana finansman kaynağı olan bankacılık sektörünün kredi kanalı üzerinden araştıran ve 2006-2023 dönemi verilerini kullanan çalışmada (Kasal, 2024: 867-869); iç borç artışının kısa vadede dışlama etkisi yarattığı ancak orta vadede devlet destekli kredi uygulamalarının bu etkiyi kaldırdığı, kamu borçlanma faizindeki artışın üretim ve kredi hacmi üzerinde daraltıcı yönde tesir

oluřturduđu, kamu borçlanmasının dışlama etkisinin azaltılması için kısa-uzun vadeli borç dağılımı ve yatırımcı tabanının genişletilmesinin önem taşıdığı belirtilmiştir.

Türkiye Ekonomi Politikaları Arařtırma Vakfı (TEPAV) bünyesinde kamu borcunu deđerlendirmek amacıyla hazırlanan çalışmada (Cangöz, 2022); 2022-2017 döneminde kamu borç yükünün önemli ölçüde gerilediđi (%67'den %37'ye), 2018 ve sonrasında (2022'ye kadar) ise borçlanma miktarının arttığı, döviz cinsinden iç borçlanmanın yeniden başladıđı, deđişken faizli borçların payının yükseldiđi, daha riskli bir pozisyonun taşınmaya başladıđı, normalde borç portföy yapısının risk seviyesi arttığında borçlanma maliyetinin düşmesinin gerektiđi, ancak 2018 sonrasında hem borç portföyünün risklilik seviyesinin hem de borçlanma maliyetinin yükseldiđi, kamu borcuna yönelik olarak 20 yılda elde edilen kazanımların son dönemde aşındığı ifade edilmiştir.

Veri ve Çalışmanın Yöntemi

Ađustos 2018'de meydana gelen kur řoku sonrasında 2020 yılında salgın krizi meydana gelmiş, Eylül 2021 döneminde düşük nominal faiz ve negatif reel faize dayalı geleneksel olmayan ekonomi politikası tatbik edilmeye başlanmış, Haziran 2023 sonrasında ise geleneksel ekonomi politikalarına kademeli geçiř kapsamında görece yüksek faiz oranı ve deđerli TL politikası uygulamaya konulmuřtur. Çalışmamız tüm bu gelişmeleri içeren Aralık 2017-Aralık 2025 döneminde merkezi yönetim borç stokunda meydana gelen deđişimleri sunmaktadır. Yıllık veriler, yıl sonu (31 Aralık) büyüklüklerine işaret etmektedir.

Hazine ve Maliye Bakanlığı merkezi yönetim borç stoku istatistiklerini; iç ve dış borç, TL ve döviz borcu, faiz yapısına göre borçlar (sabit, deđişken, TÜFE'ye endeksli), enstrümana göre borçlar (bono, tahvil, uluslararası tahvil, kredi) ve vadeye kalan ortalama süreye göre borçlar olarak yayımlamaktadır. Bu çalışmada

iç ve dış borç ile borcun TL-döviz dağılımı ve faiz yapısına konu veriler kullanılmış, ayrıca kilit bir gösterge olan borcun millî gelir (GSYH) içindeki ağırlığı üzerinden değerlendirmelerde bulunulmuştur.

Hazine ve Maliye Bakanlığı (2026a), yurt içi piyasalarda ihraç edilen tahvil ve bonolara ait borçları iç borç, yurt dışında ihraç edilen tahviller ve yurt dışından alınan borçları dış borç olarak tanımlamıştır. TÜFE'ye endeksli borçların yanı sıra “Değişken faiz oranlarında kupon ödeyen senetler” olarak ifade ettiği değişken faizli borçlar da bulunmaktadır. Değişken faizli borçlar, piyasada ağırlığı olan bir faiz oranına (Hazine ihalelerindeki faiz oranı, gösterge tahvil faizi veya TLREF oranı gibi) endekslenmektedir.

İç ve Dış Borç Stokunun Gelişimi

Olağan koşullarda bir ülkenin kendi ulusal para biriminden ve yurt içinden borçlanması tercih edilebilir iken küresel finansman koşulları (düşük faizli borçlanma), tasarruf açığı, cari açık başta olmak üzere döviz ihtiyacı doğuran koşulların varlığı ve yurt içindeki sınırlı fonların kamu tarafından çekilmesi hâlinde özel kesim üzerinde oluşacak dışlama etkisi gibi nedenlerle dış borçlanma da tercih edilmektedir. Ulusal para otoritenin ulusal merkez bankası olması ve döviz borcunun kur riskiyle birlikte borcun vadesinde yeterli döviz temini veya borcun çevrilebilirliği gibi riskler taşıması borçlanmada dikkate alınan hususlar arasındadır.

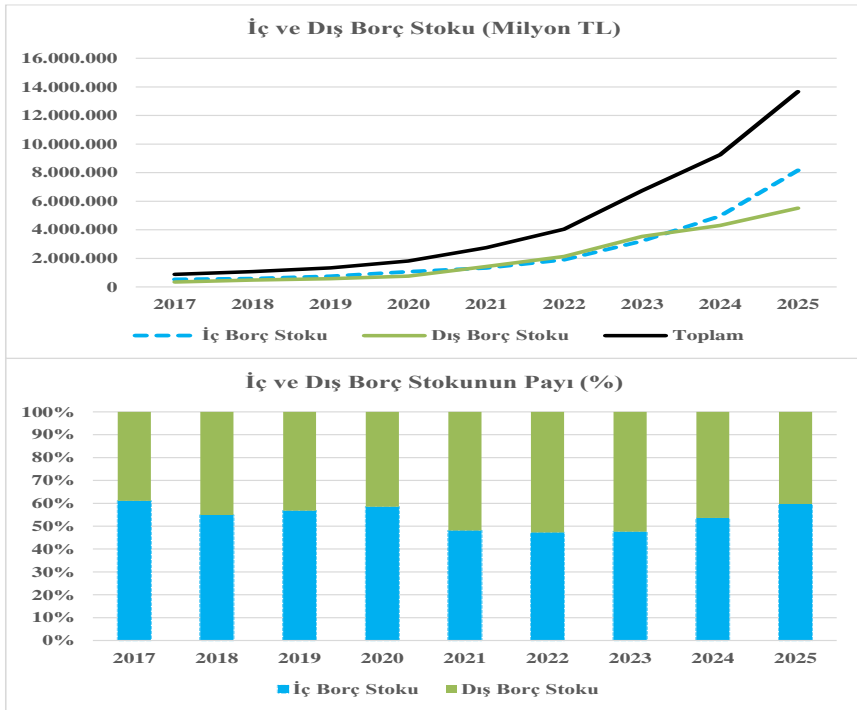
2017-2025 döneminin yıl sonu merkezi yönetim iç-dış borç verileri aşağıda sunulmaktadır.

2017 yıl sonunda 876 milyar TL'lik toplam borç stokunun %61'i iç borç stokundan oluşurken, borç stoku %1.459 artarak 2025 sonunda 13,6 trilyon TL'ye ulaşmış ve borcun %60'ını iç borçlar meydana getirmiştir. Bu dönem zarfında dikkat çeken husus kur şokunu takiben 2019 yılında iç borcun payının %55'e düşmesi, Eylül

2021'den itibaren yaşanan kriz nedeniyle bu payın 2021-2023 döneminde %48 dolayına gerilemesidir. Dolayısıyla kur artışlarının yaşandığı dönemlerde döviz borcunun TL karşılığının artması veya tersten okumayla iç borcun döviz karşılığının azalması nedeniyle döviz borcunun payı %39'lardan %52'ye yükselmiştir. Yüksek enflasyon ortamında 2023 sonrasında izlenen yüksek faiz-düşük kur politikasının TL'de yarattığı değerlenmenin de katkısıyla döviz borcunun payı 2025 sonunda yeniden %40 dolayına düşmüştür.

İç borç stoku içinde sabit faizli borcun payı 2017'de %65, 2025'te %54'dür. Dış borç içinde sabit faizli borcun payı 2017 sonunda %87, 2025 sonunda %82'dir.

Şekil 1 Merkezi Yönetim İç ve Dış Borç Stokunun Gelişimi




Kaynak: Hazine ve Maliye Bakanlığı (2026b) merkezi yönetim borç stoku istatistiklerinden derlenmiştir.

TL ve Döviz Borç Stokunun Gelişimi

Gelişmekte olan, tasarruf açığı ve dış açığı bulunan ve yurt dışı piyasalardan kendi para birimi cinsinden borçlanamayan ülkeler açısından borcun ulusal para ve döviz cinsinden dağılımı kritik önemdedir. İç borçlanmanın bir kısmının döviz cinsinden yapılabilmesi nedeniyle borcun döviz kompozisyonu, iç-dış borç ayırımından farklı bir görünme sahip olabilmektedir.

Merkezi yönetim borç stokunun TL ve döviz cinsinden dağılımı aşağıdaki şekillerde sunulmaktadır. Döviz cinsinden tutarların TL karşılığı verildiği için kur artışlarında döviz cinsi borçların TL karşılığının da arttığı hatırlanmalıdır.

Şekil 2 Merkezi Yönetim Borç Stokunun TL-Döviz Dağılımı



Kaynak: Hazine ve Maliye Bakanlığı (2026b) merkezi yönetim borç stoku istatistiklerinden derlenmiştir.

2017 yılı sonunda merkezi yönetim borç stokunun %39'u döviz cinsinden iken bu oran 2018 yılından itibaren yükselmeye

başlamış, 2018 sonunda %46, 2019’da %50, 2020’de %56’ya ulaşmış, 2021’de ise incelenen dönemin en yüksek yıl sonu değeri olan %66 seviyesinde gerçekleşmiştir. 2018 ve sonrasında bazı dönemlerde kurlarda keskin artışların meydana gelmesi döviz cinsinden borcun TL karşılığını ve dolayısıyla toplam borç içindeki payını artırmıştır. Döviz cinsinden borcun ağırlığı 2022 ve 2023 yıllarında %65 dolayında iken 2024 ve 2025 yıllarında kurların baskılanması ve TL’nin değerlenmesinin de katkısıyla bu pay 2024 yılında %56, 2025 yılında %53’e düşmüştür.

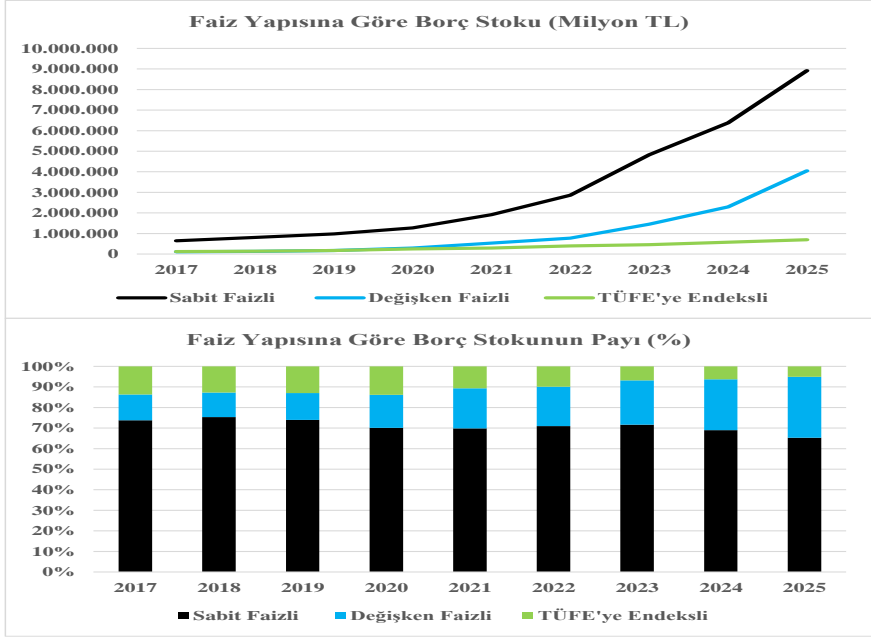
TL borç stoku içinde sabit faizli borçların payı 2017 yılında %65 iken 2025 sonunda %59’a gerilemiştir. Döviz borcunda sabit faizli borcun payı 2017 sonunda %87, 2025 sonunda 71’dir.

Faiz Yapısına Göre Borç Stokunun Gelişimi

Kamu kesimi ekonomik konjoktüre, enflasyon ve faiz beklentilerine bağlı olarak sabit veya değışken faiz üzerinden borçlanabilmektedir. Sabit faizli borçlanma, faiz oranlarındaki beklenmeyen yukarı yönlü dalgalanmalara karşı bir koruma sağlarken faizin veya referans alınan göstergenin düşüş eğiliminde bulunduğu dönemlerde ise değışken faizli borçlanma maliyet avantajı sunabilmektedir. Faiz-kupon ödemesi belirli bir faiz göstergesine (Hazine ihale faiz oranları, TLREF gibi) bağlı olan kamu borçlanma senetleri değışken faizli olarak adlandırılmakta, ayrıca TÜFE’ye endekli borçlanma senetleri ise farklı bir başlıkta sınıflandırılmaktadır.

Merkezi yönetim borç stokunun faiz yapısında 2017-2025 döneminde oluşan değışim aşağıdaki gibidir.

Şekil 3 Merkezi Yönetim Borç Stokunun Faiz Yapısı



Kaynak: Hazine ve Maliye Bakanlığı (2026b) merkezi yönetim borç stoku istatistiklerinden derlenmiştir.

2025 sonu itibarıyla 13,6 trilyon TL'lik toplam merkezi yönetim borç stokunun 8,9 trilyon TL'lik bölümü sabit faizli borçlardan meydana gelmektedir. 2017-2023 döneminde sabit faizli borçlar %71-75 arasında bir paya sahip iken 2023 sonrasında izlenen dezenflasyonist politika kapsamında beklenen faiz düşüşüne bağlı olarak 2025 sonunda sabit faizli borçların payı %65'e düşmüştür.

İncelenen dönemde borcun %25-35'lik bölümü ise değişken faizli ve TÜFE'ye endeksli borçlardan oluşmuştur. 2017-2019 döneminde toplam borç içinde %11-13 paya sahip olan değişken faizli borçlar, 2020 yılından itibaren artmaya başlamış ve 2021 yılında %20, 2023 yılında %22, 2025 yılında %30'luk pay edinmiştir.

TÜFE'ye endeksli borçlar 2017-2020 döneminde takriben %13'lük paya sahip iken 2021 yılında meydana gelen kriz ve enflasyondaki keskin yükselişe bağlı olarak kamu kesimi bu tür borçlanmadan kaçınmıştır. TÜFE'ye endeksli borçların payı bu nedenle bir düşüş eğilimine girmiş ve 2025 sonunda %5 düzeyine gerilemiştir.


TÜFE'ye endeksli devlet tahvillerini edinen ticari bankalar ciddi bir gelir elde etmiş ve ağırlıkla bu tahvillerin sunduğu imkânın katkısıyla 2022 yılında nominal %364, reel %170'lik net dönem kârı artışı elde etmişlerdir (Kartal, 2023: 11).

Borç Stokunun Millî Gelir İçindeki Payı

Borç stokunun miktarından çok daha fazla şekilde borcun millî gelirden (GSYH) aldığı pay dikkate alınmaktadır. Cari fiyatlarla GSYH'daki nominal artış genel olarak enflasyonla ilişkilidir; enflasyondan çok daha geniş bir mal-hizmet kaleminin dikkate alınması (deflatör) bu durumu değiştirmemektedir. Bu nedenle GSYH'nın reel büyümesi, enflasyonu aşan bir nominal büyümeye tekabül etmektedir. Merkezi yönetim borç stokunun takriben yarısının döviz cinsinden oluşması ve bu borcun TL karşılığının ifade edilmesi nedeniyle borç miktarının döviz kuruna bağımlılığı açıktır. Dolayısıyla çok genel hatlarıyla döviz kuru değer kazandığında yani enflasyon oranının altında arttığında döviz cinsinden borcun TL karşılığı da reel olarak küçülmektedir. Kur artışının nominal GSYH büyümesini aştığı dönemlerde ise tersi durumla karşılaşılmaktadır. Dolayısıyla kamu borcunun mili gelir içindeki payında meydana gelen değişimin yorumlanmasında daima döviz cinsinden borcun ağırlığı ve kur artış oranı da gözetilmelidir.

Aşağıda merkezi yönetim borç stokunun GSYH içindeki payında meydana gelen değişim sunulmaktadır.

Şekil 4 Merkezi Yönetim Borç Stokunun Mili Gelir (GSYH) İçindeki Payının Gelişimi



Kaynak: Hazine ve Maliye Bakanlığı (2026b) merkezi yönetim borç stoku istatistikleri ve TÜİK (2026) cari fiyatlarla GSYH verilerinden yararlanılmıştır.

2017 ve 2018 yıllarında merkezi yönetim borç stokunun GSYH payı %28 dolayında iken bu oran 2019 yılında %30, 2020'de %35, 2021'de %37'ye yükselmiştir. Bu artışta ilgili dönemlerdeki kur artışlarının ve sınırlı büyümenin etkisi bulunmaktadır. 2021-2023 dönemindeki yüksek büyüme ve 2021 sonundan itibaren enflasyondaki keskin yükseliş ve enflasyonla mücadelede kurun baskılanmasına önem verilmesinin de katkısıyla borç stokunun millî gelir payı 2022 yılında %26'ya, 2023 yılında %25'e, 2024'te %21'e gerilemiş, 2025 yılında ise %22 düzeyinde gerçekleşmiştir.

İç borcun GSYH payı 2017 sonunda %17 iken, 2020 sonunda incelenen dönemin en üst noktası olan %21'e yükselmiş, yüksek enflasyon, görece yüksek büyüme ve bazı yıllardaki negatif reel faizlerin iç borcu eritmesinin de katkısıyla 2022 yılında %12'ye gerileyen rasyo 2025 sonunda %13'dür.

Dış borcun GSYH payı 2017 sonunda %11 iken kur artışlarının da etkisiyle 2021 sonunda %19'a yükselmiş, sonraki dönemde genelde değerli TL politikasının izlenmesi sonucunda 2025'te %9'a gerilemiştir.

Söz konusu oranlar Türkiye'de kamu borcunun düşük oranda olduğunu göstermektedir. Gelişmiş ülkelerde millî geliri aşan borçluluk oranları mevcuttur. Döviz kurunun baskılanmasının bu olumlu sonuçlarda bir miktar etkisinin olduğu bilinmektedir.

Sonuç

Bütçe açığından kaynaklı olarak oluşan borçlanma gereği, kamu kesiminin borçluluk düzeyine tesir etmektedir. Kamu kesiminin tüketim harcamaları ve yatırımları millî gelir, istihdam ve enflasyon üzerinde belirleyicidir. Merkezi yönetim borç stokunun miktar olarak değişiminin yanı sıra profilindeki dönüşümde makroekonomik görünüm ve ülke riski açısından anahtar göstergelerdir.

Ağustos 2018'de meydana gelen kur şokundan itibaren Türkiye, salgın krizi ve Eylül 2021 döneminde başlayan, 2022 yılında büyüyen ve sonrasında farklı derecelerde devam eden bir krizle karşılaşmıştır. Bu gelişmeleri kapsayan Aralık 2017-Aralık 2025 dönemini ele alan bu çalışmada, merkezi yönetim borç stokunun büyüklüğü ve yapısında meydana gelen değişim analiz edilmektedir. İç ve dış borç ile borcun TL-döviz dağılımı ve faiz yapısına konu verileri kullanan çalışmada, borcun millî gelir (GSYH) içindeki ağırlığı üzerinden değerlendirmelerde bulunulmuştur.

2017 yıl sonunda 876 milyar TL'lik toplam borç stokunun %61'i iç borç stokundan oluşurken, borç miktarı %1.459 artarak 2025 sonunda 13,6 trilyon TL'ye ulaşmış ve borcun %60'ını iç borçlar meydana getirmiştir. Ağustos 2018 kur şokunu takiben 2019 yılında iç borcun payı %55'e gerilemiş, Eylül 2021'den itibaren

yaşanan krizle birlikte bu pay 2021-2023 döneminde %48 dolayına gerilemiştir. Kur artışlarının yaşandığı dönemlerde döviz borcunun TL karşılığının artmasıyla döviz borcunun payı %39'lardan %52'ye yükselmiştir. 2023 sonrasında izlenen yüksek faiz-düşük kur politikasının katkısıyla döviz borcunun payı 2025 sonunda %40 dolayına düşmüştür. İç borç stoku içinde sabit faizli borcun payı 2017'de %65 iken 2025'te %54'e düşmüştür. Dış borç içinde sabit faizli borcun payı 2017 sonunda %87 iken 2025 sonunda %82'ye gerilemiştir.

2018 ve sonrasında bazı dönemlerde kurlarda meydana gelen keskin artışlar döviz cinsinden borcun toplam borç içindeki payını artırmıştır. 2017 yılında borç stokunun %39'u döviz cinsinden iken bu oran 2018 sonunda %46, 2019'da %50, 2020'de %56'ya ulaşmış, 2021'de ise incelenen dönemin en yüksek yıl sonu değeri olan %66 seviyesinde gerçekleşmiştir. TL'nin değerlendirilmesinin de katkısıyla bu pay 2024 yılında %56, 2025 yılında %53'e düşmüştür.

Borcun faiz yapısı incelendiğinde, 2017-2023 döneminde sabit faizli borçların %71-75 arasında bir paya sahip olduğu, 2023 sonrasında izlenen dezenfasyonist politika kapsamında beklenen faiz düşüşüne bağlı olarak 2025 sonunda sabit faizli borçların payının %65'e düştüğü görülmektedir. İncelenen dönemde borcun %25-35'lik bölümü değişken faizli ve TÜFE'ye endeksli borçlardan oluşmuştur. 2017-2019 döneminde toplam borç içinde %11-13 paya sahip olan değişken faizli borçlar, 2020 yılından itibaren artmaya başlamış ve 2025 yılında %30'luk pay edinmiştir. TÜFE'ye endeksli borçlar 2017-2020 döneminde takriben %13'lük paya sahip iken, enflasyondaki keskin yükselişe bağlı olarak, bu pay düşüş eğilimine girmiş ve 2025 sonunda %5 düzeyine gerilemiştir.

Borç stokunun GSYH içindeki payı değerlendirildiğinde, 2017 ve 2018 yıllarında %28 olan borç stokunun GSYH payı, 2019 yılında %30, 2020'de %35, 2021'de %37'ye yükselmiştir. Bu artışta ilgili dönemlerdeki kur artışlarının ve görece sınırlı büyümenin etkisi

bulunmaktadır. 2021-2023 dönemindeki yüksek büyüme ve 2021 sonundan itibaren enflasyondaki keskin yükseliş, negatif reel faiz ve baskılanan kurun katkısıyla borç stokunun millî gelir payı 2022 yılında %26'ya, 2023 yılında %25'e, 2024'te %21'e gerilemiş, 2025 yılında ise %22 düzeyinde gerçekleşmiştir. Bu rasyolar, uluslararası standartlar ve diğer ülkelerin göstergelerine göre olumlu bir borçluluk düzeyine işaret etmektedir.

Merkezi yönetim borç stoku makroekonomik gelişmeler ve yaşanan krizlerden doğrudan etkilenmektedir. Kur artışlarının yaşandığı kriz dönemlerinde dış borç ve döviz cinsinden borçların borç stoku içindeki payı artarken, enflasyon ve faiz oranlarında düşüşe tanıklık edilen dönemlerde ise iç borçlar ve değişken faizli-TL cinsinden borçlar artmaktadır. Kamu borç yönetiminde bütçe açığı ve borçlanma gereksinimi ile birlikte borcun kompozisyonu önem taşımaktadır.

Kaynakça

Cangöz, M.C. (2022). Devletin borcu için dertlenmeli miyiz? *TEPAV Değerlendirme Notu*, No: 202227

Demir, H. İ. (2026). 2003-2024 dönemi Türkiye kamu mali performansının çok kriterli karar verme (ÇKKV) yöntemleri ile değerlendirilmesi. *İktisadi İdari ve Siyasal Araştırmalar Dergisi*, 29, 232-258. <https://doi.org/10.25204/iktisad.1814840>

Eser, L.Y., & Birinci, N. (2014). İç ve dış borç tercihini etkileyen faktörler. *Uluslararası Yönetim İktisat ve İşletme Dergisi*, 10(23), 31-52. <https://doi.org/10.17130/ijmeh.2014.10.23.677>.

Hazine ve Maliye Bakanlığı. (2026a). Merkezi yönetim döviz faiz yapısı metaverisi, (1 Haziran 2026 tarihinde <https://www.hmb.gov.tr/kamu-finansmani-istatistikleri> adresinden ulaşılmıştır).

Hazine ve Maliye Bakanlığı. (2026b). Merkezi yönetim borç stoku istatistikleri, (7 Haziran 2026 tarihinde <https://www.hmb.gov.tr/kamu-finansmani-istatistikleri> adresinden ulaşılmıştır).

Kartal, F. (2023). Türk bankacılık sektöründe 2022 yılı kârlılığının belirleyicileri. *Marmara Sosyal Araştırmalar Dergisi*, 19, 1-25. <https://doi.org/10.58793/marusad.1275226>

Kasal, S. (2024). Türkiye’de devlet iç borcu, kredi piyasası ve dışlama etkisi. *Ekonomi Politika ve Finans Araştırmaları Dergisi*, 9(4), 854-876. <https://doi.org/10.30784/epfad.1533993>

Kete, H. (2023). Türkiye’de 2000-2021 döneminde kamu mali göstergelerinin performans analizi. *Kırklareli Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 12(1), 34-54. <https://doi.org/10.53306/klujfeas.1242538>

Oskay, C. (2024). Gelişmekte olan ülkelerde dış borç sorunu: Türkiye ile BRICS ülkelerinin karşılaştırmalı bir değerlendirmesi. *Çağ Üniversitesi Sosyal Bilimler Dergisi*, 21(1), 1-21. <https://izlik.org/JA64MW46XZ>

Oskay, C. (2022). Türkiye’de kamu borç stok yapısındaki değişim ve gelişim: Covid-19 salgın dönemi. *Tarsus Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 3(2), 171-189. <https://doi.org/10.56400/tarsusiibfdergisi.1180190>

Türkiye İstatistik Kurumu (TÜİK). (2026). Dönemsel gayrisafı yurt içi hasıla istatistikleri, (2 Haziran 2026 tarihinde <https://veriportali.tuik.gov.tr/tr/press/58213> adresinden ulaşılmıştır).

Türkal, H. (2020). Borç yönetimi: Türkiye üzerine bir inceleme. *Akademik Araştırmalar ve Çalışmalar Dergisi (AKAD)*, 12(22), 151-163. <https://doi.org/10.20990/kilisiibfakademik.704451>

Yıldız, F. (2014). Türkiye’de 1990-2012 döneminde kamu borç yönetimi ve kamu borç yapısındaki değişim üzerine bir

inceleme. *Sakarya Üniversitesi İktisat Dergisi*, 3(4), 67-104.
<https://izlik.org/JA23CB94DJ>

