

**GETİRİ EĞRİLERİNİN MODELLENMESİ VE TAHMİNİ:  
PARAMETRİK VE MAKİNE ÖĞRENMESİ TEKNİKLERİNİN  
KARŞILAŞTIRMALI ANALİZİ**

**Pamukkale Üniversitesi  
Sosyal Bilimler Enstitüsü  
Doktora Tezi  
İktisat Ana Bilim Dalı  
İktisat Programı**

---

**Cemal ÖZTÜRK**

**Danışman: Prof. Dr. İsmail ÇEVİŞ**

**Ocak 2025  
DENİZLİ**

Bu tezin tasarımı, hazırlanması, yürütülmesi, arařtırmalarının gerekleřtirilmesi ve bulgularının analiz edilmesi surelerinde bilimsel etik ilkelere ve akademik kurallara titizlikle uyulduėunu; bu alıřmada doėrudan birincil rn olmayan bulguların, verilerin ve materyallerin bilimsel etik kurallarına uygun řekilde kaynak gsterilerek kullanıldıėını ve alıntı yapılan alıřmalara gerekli atıfların yapıldıėını beyan ederim.

Cemal ZTRK

Bu çalışma, Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK) 2211/C Yurt İçi Öncelikli Alanlar Doktora Burs Programı kapsamında desteklenmiştir.

*Eşime*  
*ve*  
*oğluma*

## ÖZET

### GETİRİ EĞRİLERİNİN MODELLENMESİ VE TAHMİNİ: PARAMETRİK VE MAKİNE ÖĞRENMESİ TEKNİKLERİNİN KARŞILAŞTIRMALI ANALİZİ

ÖZTÜRK, Cemal

Doktora Tezi

İktisat ABD

İktisat Programı

Tez Yöneticisi: Prof. Dr. İsmail ÇEVİŞ

Ocak 2025, xiii+221 sayfa

Finansal piyasalarda getiri eğrilerinin doğru bir şekilde modellenmesi ve tahmin edilmesi, ekonomik analiz ve politika yapımı açısından büyük bir öneme sahiptir. Getiri eğrileri, faiz oranlarının vade yapısını ve piyasa beklentilerini yansıtarak ekonomik aktivitelerin öngörülmesinde ve finansal karar alma süreçlerinde kritik bir rol oynar. Bu bağlamda, getiri eğrilerinin tahmin edilmesi, yatırımcılar, merkez bankaları ve diğer ekonomik aktörler için değerli bir bilgi kaynağıdır. Bu doktora tezi, Türkiye, Amerika Birleşik Devletleri (ABD) ve Avrupa Merkez Bankası (AMB) tahvil piyasalarında getiri eğrilerinin modellenmesi ve tahmini üzerine odaklanmaktadır. Araştırmada Dinamik Nelson-Siegel Modeli (DL), Fonksiyonel Temel Bileşenler Analizi (FPCA) ve Dinamik Gauss Süreçleri (DGP) olmak üzere üç farklı yöntem incelenmiştir. Modellerin performansı, geniş bir veri seti kullanılarak karşılaştırılmış ve tahmin doğrulukları detaylı bir şekilde analiz edilmiştir. DL modeli, kısa vadeli tahminlerde yüksek doğruluk oranına sahip olmasına rağmen uzun vadeli tahminlerde hata oranlarının arttığı gözlemlenmiştir. FPCA, özellikle AMB verileri üzerinde düşük hata oranları ile öne çıkmış ve karmaşık piyasa yapılarında istikrarlı bir performans sergilemiştir. DGP modeli ise hem Türkiye hem de uluslararası piyasalarda en başarılı sonuçları elde etmiş ve özellikle ABD verileri üzerinde düşük RMSE değerleri ile dikkat çekmiştir. Türkiye piyasasında, yüksek volatilitenin tahmin performansını olumsuz etkilemesine rağmen, DGP modeli diğer yöntemlere kıyasla daha üstün bir performans göstermiştir. Çalışma, yalnızca getiriler ve vadeler arasındaki ilişkiyi modellemekle kalmamış, aynı zamanda bu modellerin ekonomik ve finansal politikalara olan etkilerini de değerlendirmiştir. Bulgular, merkez bankalarının politika yapım süreçlerinde ve yatırımcıların risk yönetiminde önemli katkılar sağlamaktadır. Özellikle, tahvil piyasalarının dinamiklerinin anlaşılmasına yönelik metodolojik öneriler ve piyasa koşullarına uygun model seçimi hakkında pratik rehberlik sunulmuştur. Bu araştırma hem parametrik yaklaşımların hem de makine öğrenimi yöntemlerinin tahmin performansını değerlendirmiş ve gelecekteki ekonomik tahmin çalışmalarını için teorik ve pratik anlamda değerli içgörüler sağlamıştır.

**Anahtar Kelimeler:** Getiri eğrisi modelleme ve tahmin, finansal matematik, gauss süreçleri, Kalman filtresi, fonksiyonel temel bileşenler analizi, veri analizi, zaman serisi analizi, Bayes yöntemleri, makine öğrenmesi

## ABSTRACT

### MODELING AND FORECASTING YIELD CURVES: A COMPARATIVE ANALYSIS OF PARAMETRIC VS. MACHINE LEARNING TECHNIQUES

ÖZTÜRK, Cemal  
Doctor of Philosophy Thesis  
Department of Economics  
Economics Program  
Advisor of Thesis: Prof. Dr. İsmail ÇEVIŞ

January 2025, xiii+221 Pages

**Accurately modeling and forecasting yield curves in financial markets is vital for economic analysis and policymaking. Yield curves, reflecting the term structure of interest rates and market expectations, play a crucial role in predicting economic activities and guiding financial decision-making processes. Yield curve forecasts, therefore, are invaluable resources for investors, central banks, and other economic agents. This doctoral dissertation focuses on the modeling and forecasting of yield curves in the bond markets of Turkey, the United States (US), and the European Central Bank (ECB). The study evaluates three distinct methods: the Dynamic Nelson-Siegel Model (DL), Functional Principal Component Analysis (FPCA), and Dynamic Gaussian Processes (DGP), comparing their performances using a broad dataset and rigorously analyzing their forecasting accuracies. The DL model excelled in short-term predictions but displayed increasing error rates in long-term forecasts. The FPCA model demonstrated stable and low error rates, particularly with ECB data, highlighting its efficacy in complex market structures. The DGP model achieved the best results across all markets, especially excelling with low RMSE values in US datasets. Despite the high volatility in the Turkish market, which generally reduces prediction accuracy, the DGP model outperformed the other methods significantly. Beyond modeling the relationship between yields and maturities, the study also explored the implications of these models on economic and financial policies. The findings contribute to central bank policy formation and investor risk management by offering methodological recommendations and practical guidance on selecting suitable models for different market conditions. This research provides valuable theoretical and practical insights for future economic forecasting studies by evaluating the forecasting performance of both parametric approaches and machine learning techniques.**

**Keywords:** Yield curve modeling and forecasting, financial mathematics, gaussian processes, Kalman filter, functional principal component analysis, data analysis, time series analysis, Bayesian methods, machine learning

## İÇİNDEKİLER

ÖZET.....	ii
ABSTRACT.....	iii
İÇİNDEKİLER.....	iv
ŞEKİLLER DİZİNİ.....	vii
TABLolar DİZİNİ.....	x
SİMGE VE KISALTMALAR DİZİNİ.....	xii

## BİRİNCİ BÖLÜM

### GİRİŞ

1.1 Problem Durumu.....	3
1.2 Araştırmanın Amacı.....	5
1.3 Araştırmanın Önemi.....	6
1.4. Araştırma Metodoloji.....	7
1.4.1 Problem Tanımlama.....	9
1.4.2 Veri Anlama.....	10
1.4.3 Veri Hazırlama.....	10
1.4.4 Modelleme.....	11
1.4.5 Değerlendirme.....	11
1.4.6 Kullanıma Alma.....	12
1.5 Sınırlılıklar.....	12
1.5.1 Veri Kümesi.....	13
1.5.2 Model Seçimi.....	13
1.5.3 Hiperparametre Ayarlama.....	13
1.5.4 Genelleştirilebilirlik.....	14
1.5.4 Verilerin Zaman Boyutu ve Güncellik.....	14

## İKİNCİ BÖLÜM

### VADE YAPISI MODELLERİNİN GENEL TEORİSİ VE STİLİZE OLGULAR

2.1 Tahvil Piyasası Terminolojisi.....	16
2.2 Getiri Eğrisi Şekilleri ve Kullanımı.....	18
2.2.1 Normal Getiri Eğrisi.....	19
2.2.2 Düz Getiri Eğrisi.....	20

2.2.3 Kambur Getiri Eğrisi.....	20
2.2.4 Ters Getiri Eğrisi.....	21
2.3 Getiri Eğrisi Teorileri.....	22
2.3.1 Beklentiler Hipotezi.....	23
2.3.2 Bölünmüş Piyasalar Hipotezi.....	25
2.3.3 Likidite Primi Hipotezi.....	26
2.3.4 Tercih Edilen Habitat Hipotezi.....	26
2.4 Getiri Eğrisinin Tahmin Gücü.....	27
2.5 Getiri Eğrisinin Eğimi ve Ekonomik Çevrim.....	29
2.5.1 Gecikmeli Etki Olasılığı.....	36
2.5.2 Merkez Bankalarının Aktif Müdahaleleri.....	37
2.5.3 Ekonomik Yapıdaki Dönüşümler.....	37
2.5.3.1 Küreselleşme.....	38
2.5.3.2 Teknolojik İlerlemeler.....	38
2.5.3.3 Demografik Değişimler.....	38
2.5.3.4 Finansal Piyasaların Gelişimi.....	39
2.5.4 Diğer Ekonomik Göstergelerin Gücü.....	39
2.5.5 Pandeminin Etkileri ve Olağandışı Ekonomik Ortam.....	40
2.5.5.1 Yapısal Faktörlerin ve Politikaların Etkisi.....	41
2.5.5.2 Belirsizlik ve Gelecek Perspektifi.....	41
2.6 Getiri Eğrisi ve Para Politikası.....	42

## ÜÇÜNCÜ BÖLÜM

### GETİRİ EĞRİSİNİN MODELLEMESİ VE GETİRİ EĞRİLERİNİN TAHMİN EDİLMESİNE YÖNELİK KAVRAMSAL ÇERÇEVE

3.1 Spline Tabanlı Modeller.....	45
3.2 Spline Tabanlı Modellerin Ayrıntıcı Modellerle Karşılaştırılması.....	46
3.3 Ayrıştırılabilir Fonksiyonel Formlar.....	48
3.3.1 Nelson-Siegel Modeli.....	48
3.3.2 Nelson-Siegel-Svensson Modeli.....	52
3.3.3 Diebold-Li Modeli.....	53
3.4 Karşılaştırılan Modeller.....	56
3.4.1 Rassal Yürüyüş (RW) .....	56
3.4.2 Otoregresyon (AR) .....	57
3.4.3 Vektör Otoregresyon (VAR) .....	58



3.4.4 DNS-KF Modelleme.....	58
3.4.4.1 Durum (State) Vektörü ve Gözlem (Observation) Matrisi.....	60
3.4.4.2 Faktör Dinamiği (Geçiş Denklemi) .....	60
3.5 Literatür.....	64
3.6. Veri.....	67
3.7 Çalışma Tasarımı.....	97
3.8 Karşılaştırma Kriteri.....	99
3.9. Sonuçlar.....	101
3.10 Fonksiyonel Veri Analizi.....	144
3.8.1 Fonksiyonel Zaman Serilerinin Tahmini.....	147
3.8.2 Tahmin.....	151
3.8.3 Sonuçlar.....	151
3.11 Makine Öğrenmesi.....	166
3.11.1 Literatür.....	168
3.11.2 Gauss Süreç Modelleri.....	172
3.11.2.1 Bayesyen Tahmin.....	173
3.11.2.2 Kernel (Kovaryans) Yapısı ve Parametreler.....	174
3.11.2.3 Posterior (Artalan) Tahmini.....	175
3.11.2.4 Modelin Öğrenilmesi (Parametre Optimizasyonu).....	176
3.11.2.5 Dinamik Gauss Proses (Dynamic GP) Yöntemi.....	176
3.11.2.6 Kaydırmalı (Rolling) Yaklaşım.....	177
3.11.2.6.1 Rolling Mantığının Temel Prensipleri.....	177
3.11.2.6.2 Gauss Süreç Modelinin Kaydırmalı Yaklaşımınla Bütünleşmesi.....	178
3.11.3 Tahmin.....	180
3.11.4 Sonuçlar.....	183
3.12 Modellerin Karşılaştırılması.....	198
SONUÇ.....	205
KAYNAKLAR .....	208

## ŞEKİLLER DİZİNİ

	Sayfa
Şekil 1.1 CRISP-DM Metodolojisinin Süreç Aşamaları ve İşleyişi.....	9
Şekil 2.1 Getiri Eğrisi Türleri: Normal, Düz, Kambur ve Ters.....	22
Şekil 2.2 Ekonomik Çevrim ve Faiz Oranları (ABD Üç Aylık Hazine Bonoları), 1934-2024.....	31
Şekil 2.3 Türkiye’de Getiri Eğrisinin Eğimi (10 yıl-3 ay farkı, %).....	35
Şekil 2.4 ABD’de Getiri Eğrisinin Eğimi (10 yıl-3 ay farkı, %).....	36
Şekil 3.1 Diebold-Li Modeli Faktör Yükleri Faktör Yükleri.....	56
Şekil 3.2 Ülkeler Arası 10 Yıllık Tahvil Getirilerinin Korelasyon Matrisi.....	77
Şekil 3.3 2014-2022 Yılları Arasında ABD Hazine Tahvili Getiri Eğrilerinin Zamansal ve Vadeye Dayalı Analizi.....	83
Şekil 3.4 ABD’nin 2014’ten 2021’e 11 vadede haftalık getiri eğrileri.....	85
Şekil 3.5 ABD Getiri Eğrilerinin Tarihsel Karşılaştırması ve Fonksiyonel Kutu Grafiği ile İstatistiksel Özet.....	87
Şekil 3.6 Euro Bölgesi’nin 2014 - 2023 Yıllarında 32 Vadede Haftalık Getiri Eğrileri.....	88
Şekil 3.7 2014-2022 Yılları Arasında Euro Bölgesi Tahvil Getiri Eğrilerinin Zamansal ve Vadeye Dayalı Analizi.....	90
Şekil 3.8 Euro Bölgesi Getiri Eğrilerinin Tarihsel Karşılaştırması ve Fonksiyonel Kutu Grafiği ile İstatistiksel Özet.....	92
Şekil 3.9 2014-2022 Yılları Arasında Türkiye Tahvil Getiri Eğrilerinin Zamansal ve Vadeye Dayalı Analizi.....	93
Şekil 3.10 Türkiye’nin 2014 - 2023 Yıllarında 9 Vadede Haftalık Getiri Eğrileri.....	95
Şekil 3.11 Türkiye Getiri Eğrilerinin Tarihsel Karşılaştırması ve Fonksiyonel Kutu Grafiği ile İstatistiksel Özet.....	97
Şekil 3.12 Zaman Serisi İçin Kayan Pencere Yaklaşımı.....	99
Şekil 3.13 Diebold–Li Modeli ile Tahminlerde Eğitim Verisi Pencere Boyutunun Etkisi.....	104
Şekil 3.14 ABD Verileri için DL Modeli ile AR(1) ve AR(p) Modellerinin Tahmin Performansı.....	105

Şekil 3.15 Euro Bölgesi Verileri için DL Modeli ile AR(1) ve AR(p) Modellerinin Tahmin Performansı.....	106
Şekil 3.16 Türkiye Verileri için DL Modeli ile AR(1) ve AR(p) Modellerinin Tahmin Performansı.....	107
Şekil 3.17 ABD Hazine Verilerinin Tahmin Edilen $\beta$ -Vektörünün Haftalık Gecikmelerle %95'lik Güven Aralığında Örneklem Otokorelasyonları.....	108
Şekil 3.18 Farklı Tarihlerde ABD Nelson-Siegel Getiri Eğrilerinin $\lambda$ Parametrelerine Göre Modellenmesi.....	110
Şekil 3.19 Euro Bölgesi Verilerinin Tahmin Edilen $\beta$ -Vektörünün Haftalık Gecikmelerle %95'lik Güven Aralığında Örneklem Otokorelasyonları.....	112
Şekil 3.20 Farklı Tarihlerde Euro Bölgesi Nelson-Siegel Getiri Eğrilerinin $\lambda$ Parametrelerine Göre Modellenmesi.....	114
Şekil 3.21 Türkiye Verilerinin Tahmin Edilen $\beta$ -Vektörünün Haftalık Gecikmelerle %95'lik Güven Aralığında Örneklem Otokorelasyonları.....	116
Şekil 3.22 Farklı Tarihlerde Türkiye Getiri Eğrilerinin $\lambda$ Parametrelerine Göre Modellenmesi.....	118
Şekil 3.23 ABD Tahvil Getiri Eğrisi Tahmin Yöntemleri Karşılaştırması: DNS, VAR ve Kalman Filtresi Yöntemleriyle Tahmin.....	124
Şekil 3.24 Euro Bölgesi Tahvil Getiri Eğrisi Tahmin Yöntemleri Karşılaştırması: DNS, VAR ve Kalman Filtresi Yöntemleriyle Tahmin.....	132
Şekil 3.25 Türkiye Tahvil Getiri Eğrisi Tahmin Yöntemleri Karşılaştırması: DNS, VAR ve Kalman Filtresi Yöntemleriyle Tahmin.....	139
Şekil 3.26 ABD, AMB ve Türkiye için Tahmin Ufuklarına Göre MSE Değerleri.....	140
Şekil 3.27 ABD, AMB ve Türkiye için Tahmin Ufuklarına Göre RMSE Değerleri.....	141
Şekil 3.28 ABD, AMB ve Türkiye için Tahmin Ufuklarına Göre MAE Değerleri.....	142
Şekil 3.29 ABD, AMB ve Türkiye için Tahmin Ufuklarına Göre MAPE Değerleri.....	143
Şekil 3.30 Diebold–Li Modeli ile Çok Adımlı Tahminlerin RMSE Kutu Grafikleri...	144
Şekil 3.31 ABD Verileri İçin İlk Üç Ağırlıklı Fonksiyonel Temel Bileşen ve İlgili Puanlar.....	153
Şekil 3.32 ABD Tahvil Getirileri için FPCA Modelinin Zaman İçinde Vadeye Göre Artık Değerleri.....	155
Şekil 3.33 Euro Bölgesi Verileri İçin İlk Üç Ağırlıklı Fonksiyonel Temel Bileşen ve İlgili Puanlar.....	157
Şekil 3.34 Euro Bölgesi Tahvil Getirileri için FPCA Modelinin Zaman İçinde Vadeye Göre Artık Değerleri.....	159

Şekil 3.35 Türkiye Tahvil Verileri İçin İlk Üç Ağırlıklı Fonksiyonel Temel Bileşen ve İlgili Puanlar.....	161
Şekil 3.36 Türkiye Tahvil Getirileri Modelinin Zaman İçinde Vadeye Göre Artık Değerleri.....	163
Şekil 3.37 FPCA Modeli ile Tahmin: Pencere Boyutunun RMSE Üzerindeki Etkisi...	165
Şekil 3.38 Çoklu Adım İlerisi Tahmin İçin FPCA Modeli Kullanan RMSE Kutu Grafiklerinin Karşılaştırması: $h = 1$ , $h = 3$ ve $h = 6$ için 250 ila 350 Eğitim Periyodu ile Gerçekleştirilen Tahminler.....	166
Şekil 3.39 ABD Dinamik Gauss Süreç (DGP) Modeli için 6 Aylık Tahmin Sonuçlarına Dayalı Getiri Eğrisi.....	185
Şekil 3.40 Euro Bölgesi Dinamik Gauss Süreç (DGP) Modeli için 6 Aylık Tahmin Sonuçlarına Dayalı Getiri Eğrisi.....	189
Şekil 3.41 Türkiye Dinamik Gauss Süreç (DGP) Modeli için 6 Aylık Tahmin Sonuçlarına Dayalı Getiri Eğrisi.....	193
Şekil 3.42 Eğitim Verisi Uzunluğunun DGP Modelleri ile Getiri Tahmin Performansına Etkisi.....	197
Şekil 3.43 RMSE Değerleri ile Ülkelere ve Tahmin Ufuklarına Göre DGP Modelinin Performans Karşılaştırması.....	198
Şekil 3.44 ABD Tahvil Piyasası Vade Yapısı Tahmin Performansı: Farklı Modeller ve Tahmin Ufukları.....	200
Şekil 3.45 Euro Bölgesi Tahvil Piyasası Vade Yapısı Tahmin Performansı: Farklı Modeller ve Tahmin Ufukları.....	201
Şekil 3.46 Türkiye Tahvil Piyasası Vade Yapısı Tahmin Performansı: Farklı Modeller ve Tahmin Ufukları.....	203

## TABLOLAR DİZİNİ

	Sayfa
Tablo 3.1 2014-2023 Dönemi ABD Hazine Sıfır Kuponlu Devlet Tahvillerinin Tanımlayıcı İstatistikleri.....	70
Tablo 3.2 2014-2023 Dönemi AMB Sıfır Kupon Devlet Tahvili Getiri Eğrisi Tanılayıcı İstatistikleri.....	73
Tablo 3.3 2014-2023 Dönemi Türkiye Sıfır Kupon Devlet Tahvili Getiri Eğrisi Tanılayıcı İstatistikleri ve Dağılım Özellikleri .....	76
Tablo 3.4 ABD için Farklı Vadelerde 1 Aylık Getiri Eğrisi Tahmin Yöntemlerinin RMSE Performans Değerleri.....	119
Tablo 3.5 ABD için 1 Aylık Getiri Eğrisi Tahmin Modellerinin Performans Ölçümleri.....	120
Tablo 3.6 ABD için Farklı Vadelerde 3 Aylık Getiri Eğrisi Tahmin Yöntemlerinin RMSE Performans Değerleri .....	120
Tablo 3.7 ABD için 3 Aylık Getiri Eğrisi Tahmin Modellerinin Performans Ölçümleri.....	121
Tablo 3.8 ABD için Farklı Vadelerde 6 Aylık Getiri Eğrisi Tahmin Yöntemlerinin RMSE Performans Değerleri.....	122
Tablo 3.9 ABD için 6 Aylık Getiri Eğrisi Tahmin Modellerinin Performans Ölçümleri.....	122
Tablo 3.10 AMB için Farklı Vadelerde 1 Aylık Getiri Eğrisi Tahmin Yöntemlerinin RMSE Performans Değerleri.....	125
Tablo 3.11 AMB için 1 Aylık Getiri Eğrisi Tahmin Modellerinin Performans Ölçümleri.....	126
Tablo 3.12 AMB için Farklı Vadelerde 3 Aylık Getiri Eğrisi Tahmin Yöntemlerinin RMSE Performans Değerleri.....	127
Tablo 3.13 AMB için 3 Aylık Getiri Eğrisi Tahmin Modellerinin Performans Ölçümleri.....	128
Tablo 3.14 AMB için Farklı Vadelerde 6 Aylık Getiri Eğrisi Tahmin Yöntemlerinin RMSE Performans Değerleri.....	128
Tablo 3.15 AMB için 6 Aylık Getiri Eğrisi Tahmin Modellerinin Performans Ölçümleri.....	129
Tablo 3.16 Türkiye için Farklı Vadelerde 1 Aylık Getiri Eğrisi Tahmin Yöntemlerinin RMSE Performans Değerleri.....	133

Tablo 3.17 Türkiye için 1 Aylık Getiri Eğrisi Tahmin Modellerinin Performans Ölçümleri.....	133
Tablo 3.18 Türkiye için Farklı Vadelerde 3 Aylık Getiri Eğrisi Tahmin Yöntemlerinin RMSE Performans Değerleri.....	134
Tablo 3.19 Türkiye için 3 Aylık Getiri Eğrisi Tahmin Modellerinin Performans Ölçümleri.....	134
Tablo 3.20 Türkiye için Farklı Vadelerde 6 Aylık Getiri Eğrisi Tahmin Yöntemlerinin RMSE Performans Değerleri.....	135
Tablo 3.21 Türkiye için 6 Aylık Getiri Eğrisi Tahmin Modellerinin Performans Ölçümleri.....	135
Tablo 3.22 ABD DGP Modeli: 1 Aylık Tahmin Performansı Değerlendirmesi.....	185
Tablo 3.23 ABD DGP Modeli: 3 Aylık Tahmin Performansı Değerlendirmesi.....	186
Tablo 3.24 ABD DGP Modeli: 6 Aylık Tahmin Performansı Değerlendirmesi.....	187
Tablo 3.25 Euro Bölgesi DGP Modeli: 1 Aylık Tahmin Performansı Değerlendirmesi.....	189
Tablo 3.26 Euro Bölgesi DGP Modeli: 3 Aylık Tahmin Performansı Değerlendirmesi.....	190
Tablo 3.27 Euro Bölgesi DGP Modeli: 6 Aylık Tahmin Performansı Değerlendirmesi.....	191
Tablo 3.28 Türkiye DGP Modeli: 1 Aylık Tahmin Performansı Değerlendirmesi.....	194
Tablo 3.29 Türkiye DGP Modeli: 3 Aylık Tahmin Performansı Değerlendirmesi.....	194
Tablo 3.30 Türkiye DGP Modeli: 6 Aylık Tahmin Performansı Değerlendirmesi.....	195

## SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış bazı simgeler ve kısaltmalar, açıklamaları ile aşağıda sunulmuştur.

<b>Kısaltmalar</b>	<b>Açıklamalar</b>
AB	Avrupa Birliği
ABD	Amerika Birleşik Devletleri
ACF	Autocorrelation Function (Otokorelasyon Fonksiyonu)
AFNS	Arbitrage-Free Nelson-Siegel (Arbitrajsız Nelson-Siegel)
AIC	Akaike Information Criterion (Akaike Bilgi Kriteri)
AMB	Avrupa Merkez Bankası
ANN	Artificial Neural Network (Yapay Sinir Ağı)
AR	AutoRegressive (Oto regresif)
ARMA	AutoRegressive Moving Average (Oto regresif Kayan Ortalama)
ARIMA	Oto regresif Entegre Kayan Ortalama (AutoRegressive Integrated Moving Average)
CRISP-DM	Cross-Industry Standard Process for Data Mining
DİBS	Devlet İç Borçlanma Senetleri
DGP	Dynamic Gaussian Processes (Dinamik Gauss Süreci)
DL	Diebold and Li Modeli
DNSS	Dinamik NS Modeli
DWT	Discrete Wavelet Transforms (Ayrık Dalgacık Dönüşümleri)
ECB	Avrupa Merkez Bankası
EMH	Efficient Market Hypothesis (Etkin Piyasa Hipotezi)
ENS	Extended Nelson Siegel (Genişletilmiş Nelson Siegel)
FDA	Functional Data Analysis (Fonksiyonel Veri Analizi)
FED	Federal Reserve
FNN	Feedforward Neural Network (İleri Beslemeli Sinir Ağı)
FNZ	Fisher- Nychka- Zervos Modeli

FPCA	Functional Principal Component Analysis (Fonksiyonel Temel Bileşen Analizi)
GARCH	Generalized Autoregressive Conditional Heteroskedasticity (Genelleştirilmiş Otoregresif Koşullu Heteroskedastisite)
GP	Gaussian Processes (Gauss Süreçleri)
GOÜ	Gelişmekte Olan Ülkeler
i.i.d.	Independent and identically distributed (bağımsız ve özdeş dağılımlı)
KF	Kalman Filtesi
MAE	Mean Absolute Error (Ortalama Mutlak Hata)
MAPE	Mean Absolute Percentage Error (Ortalama Mutlak Yüzde Hata)
MLP	Multi-Layer Perceptron (Çok Katmanlı Perceptron)
MSE	Mean Square Error (Ortalama Kare Hata)
NBER	National Bureau of Economic Research
NS	Nelson-Siegel Modeli
NSS	Nelson-Siegel-Svensson Modeli
OLS	Ordinary Least Squares (Sıradan En Küçük Kareler)
PC	Principal Components (Temel Bileşenler)
PCA	Principal Components Analysis (Temel Bileşenler Analizi)
RMSE	Root Mean Square Error (Kök Ortalama Kare Hata)
RW	Random Walk (Rassal Yürüyüş)
RWH	Random Walk Hypotesis (Rassal Yürüyüş Hipotezi)
TCMB	Türkiye Cumhuriyet Merkez Bankası
TR	Türkiye
SVM	Support Vector Machines (Destek Vektör Makineleri)
VAR	Vector Auto Regressive (Vektör Otomatik Regresif)
YTM	Vadeye Kadar Getiri
WN	White Noise (Beyaz Gürültü)



## BİRİNCİ BÖLÜM

### GİRİŞ

Finansal piyasalar, para politikası aksiyonlarını reel ekonomiye iletmek için kilit bir kanaldır ve finansal piyasalardaki değişiklikler, birimlerin gelecekteki makroekonomik gelişmeler hakkındaki beklentilerini yansıtabilir. Bu nedenle, finansal piyasa göstergeleri, para politikası ile finansal piyasaların yapısı ve dinamikleri arasındaki ilişkiyi sistematik olarak analiz etmek için yoğun bir şekilde kullanılmakta ve para politikası karar alma süreci ve stratejisinde etkin bir şekilde katkı sağlamaktadır. Para politikası karar alma kalitesi, diğer etkilerin yanı sıra, finansal piyasa göstergelerinin mevcudiyeti ve kalitesine ve bunların açıklayıcı gücüne bağlıdır. Bu nedenle, çeşitli ekonomik ve finansal piyasa göstergeleri mevcuttur ve analiz edilmektedir.

Finansal piyasa göstergeleri, para politikası yapıcılar için değerlidir. Finansal araçların fiyat ve hacimlerindeki hareketler, ekonomik refahı ve ekonomik hissiyatı ve bu kanallar aracılığıyla yurt içi harcama kararlarını etkilemektedir. Finansal varlık fiyat hareketleri de özel sektörün ekonomik görünümüne ilişkin beklentilerindeki değişimin göstergesidir. Daha spesifik olarak, getiri eğrilerinin, herhangi bir zamanda borçlanma senetlerinin getirileri ile vadeye kalan süreleri arasındaki ilişkinin grafiksel bir temsidir. Getiri eğrisinin bilgi içeriği, finansal piyasalardaki varlık fiyatlandırma sürecini yansıtır. Tahvil alım satımı sırasında yatırımcılar, gelecekteki enflasyon ve reel faiz oranlarına ilişkin beklentilerini dikkate alırken, aynı zamanda risk değerlendirmelerini de sürece dahil ederler. Bir yatırımcı, bir tahvilin fiyatını gelecekteki beklenen nakit akışlarını iskonto ederek hesaplar. Genellikle, getiri eğrisi terimi, temerrüt riski olmayan sıfır kuponlu tahvillerin faiz oranlarının vade yapısını ifade eder.

Getiri eğrisini tahmin etmek önemli bir problemdir ve birçok çalışma eğrinin davranışını modellemeye ve tahmin etmeye odaklanmıştır (Diebold & Li, 2006). Bir getiri eğrisinin vadeli yapısı, tahvillerin getirileri ile ilgili vadeleri arasındaki ilişkiyi açıklar. Getiri eğrileri hem farklı vadelere kesitsel bir boyuta hem de zaman içinde dinamik olarak gelişen zamansal bir boyuta sahiptir (Diebold ve Rudebusch, 2013)

Getiri eğrilerinin modellenmesi, piyasa koşulları hakkında bilgi sağlamak için çok değerli bilgiler sunmaktadır. Dolayısıyla böyle bir eğri, ekonomideki borçlanma

maliyetleri için bir taban oluşturmakta ve piyasa faiz oranlarının değerlendirilmesinde faydalı bir ölçüt oluşturmaktadır. Ayrıca getiri eğrileri kısa, orta ve uzun vadeli para politikası, ekonomik aktivite ve enflasyona ilişkin piyasa beklentilerini ölçebilir. Getiri eğrileri, özellikle finansal istikrarın sağlanması, sistemik risklerin izlenmesi, finansal entegrasyonun değerlendirilmesi ve piyasa operasyonlarının analizi gibi alanlarda önemli bir girdi olarak kullanılabilir. Ayrıca, diğer merkez bankacılığı hedeflerine yönelik değerli bilgiler sunarak politika oluşturma süreçlerini destekleyebilir. Bu nedenle, değişikliklerin diğer borçlanma senetlerinin özelliklerinden ziyade vadeye kadar olan getirilerdeki değişiklikleri yansıttığı bir getiri eğrisini tahmin etmek önemlidir. Özellikle, eğriyi yeterli hassasiyetle tahmin etmek için yeterli gözlem mevcut olmalı ve algılanan kredi riskindeki değişikliklerden etkilenmemelidir.

Getiri eğrisi, para politikası amaçları için yararlı bir bilgi seti sunarak ve gelecekteki kısa vadeli oranların beklenen seyri ve ekonomik aktivite ve enflasyon görünümü hakkında önemli bilgiler sağlar. Belirli bir tarihteki kısa ve uzun vadeli faiz oranlarının göreceli seviyesi, piyasa katılımcılarının gelecekteki kısa vadeli faiz oranlarına ilişkin beklentilerine bağlıdır. Bu nedenle, getiri eğrisinin eğimi, gelecekteki ekonomik aktiviteyi tahmin etmek için genellikle yararlı bir gösterge olarak görülmüştür. Eğrinin dikleşmesi genellikle ekonomik aktivitenin hızlanmasını öngörürken, eğrinin düzleşmesi ve özellikle tersine dönmesi genellikle yakın bir yavaşlamayı gösterir. Uzun ve kısa vadeli faiz oranları arasındaki büyük bir pozitif fark, piyasanın kısa vadeli faiz oranlarında bir artış beklediğine ve bunun ekonomik büyüme için daha olumlu bir görünümünden kaynaklanabileceğine işaret edebilir. Büyüme beklentilerine ek olarak, getiri eğrisinin ucunun uzun olması da piyasa katılımcılarının enflasyon trendi hakkındaki görüşlerini ilişkin görüşlerini yansıtabilir.

Sonuç olarak, getiri eğrisinin tahmini çeşitli ekonomik ve finansal uygulamalar için çok önemlidir ve ekonomik tahminler, tahvil fiyatlandırması, portföy yönetimi ve hükümet politikaları için değerli bilgiler sağlar. Getiri eğrisinin reel çıktı ve ekonomik faaliyetler için önemli bir tahmin gücüne sahip olduğu gösterilmiştir, bu da onu finansal ve makroekonomik tahminler için önemli bir araç haline getirmektedir.

Bu çalışmanın Birinci Bölümü yapısal olarak şu şekildedir: İlk olarak, "Problem Durumu" bölümünde, getiri eğrilerinin modellenmesi ve tahmini ile ilgili mevcut durum

ve literatür incelenecektir. Ardından, "Araştırmanın Amacı" bölümünde, çalışmanın genel amacı ve alt hedefleri belirlenecek ve açıklanacaktır. "Araştırmanın Önemi" bölümünde, çalışmanın finansal karar alma süreçlerine ve risk yönetimine olan katkısı vurgulanacaktır. Daha sonra, "Araştırmanın Metodolojisi" bölümünde, kullanılan metodolojik yöntem açıklanacaktır. Son olarak, "Sınırlılıklar" bölümünde, çalışmanın kapsamı ve sınırlılıkları hakkında bilgi verilecektir.

### 1.1. Problem Durumu

Finansal piyasalarda getiri eğrileri, faiz oranlarının vadeye bağlı yapısını modellemek, piyasa beklentilerini analiz etmek ve ekonomik öngörülerde bulunmak açısından kritik bir role sahiptir. Bu eğriler, özellikle tahvil piyasalarının dinamiklerini anlamak ve piyasa katılımcılarının gelecekteki ekonomik faaliyet, enflasyon ve faiz oranlarına ilişkin beklentilerini değerlendirmek için temel bir bilgi kaynağıdır. Ancak, getiri eğrilerinin doğru bir şekilde modellenmesi ve tahmin edilmesi, piyasa koşullarının karmaşıklığı ve belirsizliği nedeniyle önemli zorluklar içermektedir. Özellikle gelişmekte olan piyasalarda, yüksek volatilité, sınırlı veri setleri ve yapısal farklılıklar gibi faktörler, tahmin doğruluğunu olumsuz etkileyebilmektedir. Bu bağlamda, mevcut literatürün getiri eğrilerinin modellenmesine dair sunduğu yöntemlerin hem güçlü yönlerinin hem de sınırlılıklarının ayrıntılı bir şekilde ele alınması büyük önem taşımaktadır.

Finansal piyasalardaki rastgelelik ve öngörülemezlik üzerine önemli teoriler geliştirilmiş ve bu teoriler uzun yıllar boyunca finans camiasında geniş çapta araştırılmıştır. Fama (1965, 1970) ve Malkiel (1999) gibi öncül çalışmalar, finansal piyasaların stokastik bir yapıya sahip olduğunu ve bu yapı nedeniyle tahmin edilemezlik ile karakterize edildiğini öne sürmüştür. Rastal Yürüyüş Hipotezi (RWH) ve Etkin Piyasa Hipotezi (EMH) gibi bu temel hipotezler, hisse senedi fiyatlarının rastgele bir model izlediğini ve tüm mevcut bilgilerin piyasa fiyatlarına yansıdığı için herhangi bir bireyin piyasayı sürekli olarak yenmesinin imkânsız olduğunu savunmuştur. Ancak son dönemde yapılan çalışmalar, özellikle gelişmekte olan piyasalarda bu hipotezlerin tamamen geçerli olmayabileceğini göstermiştir. Zhang ve arkadaşları (2014) ile Chen ve arkadaşlarının (2014) araştırmaları, davranışsal ekonomi ve sosyoekonomik finans teorileri perspektifinden bakıldığında, belirli piyasa koşullarının ve dinamiklerinin varlık fiyatlarının bir dereceye kadar öngörülebilirliğini ortaya koyduğunu göstermektedir. Bu

durum, finansal piyasaların tahmin edilebilirliğinin farklı piyasa yapılarına ve modellerine göre yeniden değerlendirilmesi gerektiğini ortaya koymaktadır.

Bu bağlamda, literatürde hem geleneksel parametrik yöntemlerin hem de modern makine öğrenmesi tekniklerinin getiri eğrilerinin modellenmesi ve tahmin edilmesine yönelik farklı yaklaşımlar sunduğu görülmektedir. Geleneksel parametrik modeller, basitlikleri ve uygulanabilirlikleri nedeniyle yaygın bir şekilde kullanılmaktadır. Ancak bu modeller, karmaşık piyasa koşullarını yeterince yansıtamama ve belirli piyasa yapılarında düşük tahmin performansı gösterme gibi dezavantajlara sahiptir. Buna karşın, makine öğrenmesi gibi modern yöntemler, esneklikleri ve yüksek tahmin doğrulukları ile öne çıkmaktadır. Makine öğrenimi modelleri, veri setlerindeki karmaşıklıkları anlamlandırabilme kabiliyeti sayesinde piyasa koşullarına daha uygun sonuçlar sağlayabilmektedir. Bununla birlikte, bu yöntemlerin uygulanması genellikle yüksek hesaplama maliyetleri, detaylı veri hazırlığı ve uzmanlık gerektirmektedir. Türkiye gibi yüksek volatiliteye sahip piyasalarda, hangi modelin daha iyi performans gösterdiği sorusu ise hâlâ yanıtlanmayı bekleyen önemli bir problem olarak karşımıza çıkmaktadır.

Bu tez, finansal piyasalarda getiri eğrilerinin modellenmesi ve tahmini konusundaki mevcut yöntemleri incelemekte ve üç farklı modelin performansını değerlendirmektedir. İlk olarak, Diebold ve Li (2006) tarafından önerilen Dinamik Nelson-Siegel (DL) Modeli, basitliği ve üç faktör (seviye, eğim ve kamburluk) ile getiri eğrilerini modelleme yeteneği sayesinde geniş bir kullanım alanı bulmuştur. Bu model, kısa vadeli tahminlerde yüksek doğruluk oranına sahipken, uzun vadeli tahminlerde hata oranlarının arttığı gözlemlenmiştir. İkinci olarak, Fonksiyonel Veri Analizi (FDA) yöntemi, özellikle Hyndman ve Shang'ın (2009) FPCA yaklaşımı üzerinden geliştirilmiş ve geniş veri setleri üzerinde başarılı sonuçlar sağlamıştır. FDA yöntemi, getiri eğrilerinin fonksiyonel zaman serisi analizi ile modellenmesini sağlayarak, karmaşık piyasa yapılarına daha iyi uyum göstermektedir. Üçüncü olarak, Gauss Süreçleri (GP), dinamik modelleme kabiliyeti ve bayesyen yapı ile belirsizlik içeren piyasa koşullarında öne çıkmaktadır. GP modelleri, özellikle yüksek volatiliteye sahip piyasalarda tahmin performansını artırmak için güçlü bir araç olarak kabul edilmektedir.

Tezin bu bağlamdaki yeniliklerinden biri, Dinamik Nelson-Siegel Modeli'nin (DNS) Kalman filtreleme teknikleri ile geliştirilerek daha stabil ve optimize bir yapıya

kavuşturulmasıdır. Bu süreçte DNS modeline çeşitli iyileştirmeler eklenmiştir. Özellikle veri tabanlı başlangıç kovaryans seçimi, eigenvalue clipping yöntemi ile aşırı dinamiklerin stabilize edilmesi ve model parametrelerinin optimize edilmesiyle hem yakınsama hızının hem de tahmin performansının artırılması sağlanmıştır. Bu iyileştirmeler, hem geleneksel hem de modern yöntemlerin güçlü yönlerini bir araya getirerek, piyasa koşullarına uygun modelleme yaklaşımlarının geliştirilmesine katkıda bulunmaktadır.

Sonuç olarak, bu tez, farklı piyasa koşullarında kullanılan parametrik ve makine öğrenimi yöntemlerinin getiri eğrisi modelleme ve tahmin performanslarını karşılaştırarak literatüre katkı sağlamayı amaçlamaktadır. Elde edilen bulguların, yalnızca tahmin doğruluğu değil, aynı zamanda ekonomik ve finansal politika yapım süreçlerine yönelik pratik öneriler sunarak yatırımcılar, merkez bankaları ve diğer ekonomik aktörler için değerli bir rehber olması hedeflenmektedir. Bu çalışma, hem teorik hem de pratik açıdan finansal modelleme alanındaki mevcut boşlukları doldurmayı amaçlamakta ve gelecekteki araştırmalar için önemli bir referans noktası oluşturmaktadır.

## 1.2. Araştırmanın Amacı

Bu araştırmanın genel amacı, finansal piyasalarda getiri eğrilerini doğru bir şekilde modellemenin ve tahmin etmenin önündeki zorlukları anlamak ve çeşitli yöntemlerin bu zorlukları ne kadar etkili bir şekilde aştığını belirlemektir. Bu genel amaca ulaşmak için, her bir yöntemin performansını detaylı bir şekilde analiz etmek ve hangi faktörlerin tahmin başarısını etkilediğini incelemek için spesifik alt hedefler belirlenmiştir. Bu araştırma aynı zamanda finansal karar alma süreçlerini geliştirmek için pratik öneriler sağlamayı amaçlamaktadır, böylece yatırımcılar, portföy yöneticileri ve risk analistleri gelecekteki kararlarını daha bilinçli bir şekilde verebilirler.

Araştırmanın bir diğer hedefi, getirilerle vadeler arasındaki ilişkilerin zaman içindeki dinamiklerini incelemek ve bu ilişkilerin tahmin doğruluğu üzerindeki etkilerini anlamaktır. Piyasalar arası karşılaştırmalarla, getiri eğrilerinin şeklinin ve dinamiklerinin ekonomik döngüler üzerindeki etkisi analiz edilecektir. Bu bağlamda, farklı piyasa koşullarında kullanılan veri setlerinin özellikleri, model performansı üzerindeki etkileriyle birlikte analiz edilecektir. Ayrıca, bu modellerin kısa, orta ve uzun vadeli

tahminlerdeki başarıları, ekonomik karar alma süreçlerine yönelik pratik çıkarımlar sunmak amacıyla değerlendirilecektir.

Araştırma, sadece modellerin performansını değerlendirmekle kalmayıp, aynı zamanda getiri eğrilerinin ekonomik görünüm ve para politikası üzerindeki etkilerini de inceleyecektir. Bu kapsamda, elde edilen sonuçlar hem teorik hem de uygulamalı katkılar sunmayı hedeflemektedir.

### 1.3. Araştırmanın Önemi

Getiri eğrisinin tahmini, çeşitli ekonomik ve finansal uygulamalar üzerindeki etkileri nedeniyle ekonomi ve finans alanında büyük önem taşımaktadır. Faiz oranları ile tahvillerin vadeye kalan süresi arasındaki ilişkiyi temsil eden getiri eğrisi, ekonomik ve parasal koşulların değerlendirilmesi, sabit getirili menkul kıymetlerin fiyatlandırılması, ileriye dönük eğrilerin oluşturulması, enflasyon primlerinin hesaplanması ve iş döngülerinin izlenmesi için çok önemli bir göstergedir (Kowal vd., 2017). Ayrıca, getiri eğrisinin tahmin edilmesi, ekonomik tahminlerin oluşturulması, faiz oranı ve kredi türevlerinin fiyatlandırılması, faiz oranı değişikliklerinin finansal araçların temerrüt olasılıkları üzerindeki potansiyel etkisinin değerlendirilmesi, sürenin yönetilmesi ve bir tahvil portföyünün riske maruz değerinin hesaplanması için gereklidir (Rostan vd., 2016). Ayrıca, getiri eğrisi ekonomide çok önemli bir rol oynamakta ve finans ve makroekonomistlerin doğru tahminler yapmasını gerektirmektedir (Alves vd., 2023).

Ampirik kanıtlar, getiri eğrisinin tahvil fiyatlaması, portföy yönetimi ve hükümet politikaları gibi hem akademik hem de pratik konular için değerli bilgiler içerdiğini göstermektedir (Omrane vd., 2017). Ayrıca, diğer ekonomik göstergelerle güçlendirilmiş getiri eğrisinin reel çıktı ve ekonomik faaliyet açısından önemli bir tahmin gücüne sahip olduğu gösterilmiştir (Chionis vd., 2009). Getiri eğrisinin tahmin kabiliyetine ilişkin geniş literatür geleneksel olarak eğrinin eğimine odaklanmıştır, ancak son çalışmalar Federal Fon Oranı gibi kısa vadeli bir faiz oranı ile ölçülen seviyenin önemini vurgulamaya başlamıştır (Bordo ve Haubrich, 2006). Ayrıca, getiri eğrisinin eğrilik parametresinin portföy seçiminde yatırım açısından önemli olduğu gösterilmiştir (Fabozzi vd., 2005).

Bu tezin önemi, finansal piyasalarda getiri eğrilerinin doğru bir şekilde modellenmesi ve tahmin edilmesinin, yatırımcılar, portföy yöneticileri ve risk analistleri için kritik öneme sahip olmasıdır. Hangi modelin daha iyi performans gösterdiğinin belirlenmesi, gelecekteki finansal kararların daha doğru bir şekilde yapılmasına yardımcı olabilir. Ayrıca, bu araştırma, finansal tahmin modellerinin geliştirilmesi ve iyileştirilmesi için bir temel sağlayarak finansal piyasalarda etkili risk yönetimi stratejilerinin oluşturulmasına katkıda bulunabilir.

#### 1.4. Araştırma Metodoloji

Veri bilimi, hızla gelişen ve her geçen gün yeni bir sektöre ve probleme uygulama alanı olan bir çalışma alanıdır. Bu alanda yapılan çalışmalar beraberinde belli bir standartlaşma isteği getirmiştir. Bu sayede bir projeye nasıl başlanması gerektiği, süreç içerisinde atılması gereken adımlar, projenin çıktıları ve beklenen çıktılara ulaşılamaması durumunda yapılması gerekenleri belirleyen farklı metodolojiler zaman içinde geliştirilmiştir. Söz konusu metodolojiler SEMMA, KDD ve CRISP-DM'dir.

Chapman vd. (2000) tarafından tanımlanan CRISP-DM (Cross-Industry Standard Process for Data Mining) metodolojisi, veri bilimi, makine öğrenimi ve bilgi keşfi dahil olmak üzere çeşitli alanlarda temel bir çerçeve haline gelmiştir. Diğer güncel standartlar eklenerek geliştirilmiştir ve veri bilimi uygulamaları için çok yaygın bir metodoloji olmaya devam etmektedir (Mariscal vd., 2010; Martínez-Plumed vd., 2021). CRISP-DM'nin iş anlayışı, veri anlayışı, veri hazırlama, modelleme, değerlendirme ve dağıtım gibi aşamaları farklı araştırma çalışmalarında ve endüstriyel projelerde etkin bir şekilde uygulanmaktadır (Clancy vd., 2021; Imelda ve Kurnianto, 2023; Habyba vd., 2021; Kurniawan ve Sutomo, 2021). Ayrıca, CRISP-DM'nin iş anlayışı ve veri anlayışını ele alarak çeşitli uygulamalarda avantaj sağladığı gözlemlenmiştir (Grzenda ve Legierski, 2019). Ek olarak, CRISP-DM metodolojisi akademik araştırma topluluğunun ihtiyaçlarına göre uyarlanmış ve adımların daha genel, araştırma odaklı bir tanımı sağlamıştır (Marbán vd., 2009).

CRISP-DM metodolojisi, veri madenciliği tahmin modellerinin uygulanması (Wahyudi ve Arroufu, 2022), endüstriyel ortamlarda kalite iyileştirme yaklaşımları (Habyba vd., 2021) ve çeşitli sonuçları tahmin etmek için makine öğrenmesi sistemlerinin

geliştirilmesi (Silva vd., 2020) gibi çeşitli araştırma çalışmalarında kullanılmıştır. Ayrıca, önerilen suç soruşturma metodolojisinin ana aşamalarını desteklediği güvenlik ve suç soruşturmaları bağlamında da kullanılmıştır (Pramanik vd., 2017). CRISP-DM, mühendislik, suç araştırması ve sağlık hizmetleri gibi çeşitli alanlarda CRISP-DM metodolojisine dayalı veri madenciliği projelerinin uygulanmasını açıklayan Wiemer vd. (2019), Pramanik vd. (2017) ve Caetano vd. (2015) gibi çalışmalarda kanıtlandığı gibi pratik uygulamalarda yaygın olarak benimsenmiştir. Bu uygulamalar, CRISP-DM'in gerçek dünya senaryolarındaki pratik uygunluğunu ve etkinliğini göstermektedir. Python ve scikit-learn paketi, belirli araştırma çalışmalarında CRISP-DM metodolojisinin her aşamasını geliştirmek için kullanılmıştır (Moreno-Sanchez, 2021).

#### CRISP-DM'nin Avantajları:

- Sistematik ve tutarlı bir yaklaşım sağlar.
- Projelerin daha verimli ve etkili bir şekilde yürütülmesine yardımcı olur.
- Farklı ekipler arasında iletişimi ve iş birliğini kolaylaştırır.
- Projelerin başarısızlık riskini azaltır.

CRISP-DM, veri odaklı projelerde kullanılan sistematik bir metodolojidir ve özellikle karmaşık veri analizi süreçlerini yapılandırmada kritik rol oynar. Bu çalışmada, tahvil piyasalarındaki getiri eğrilerini modellemek ve analiz etmek amacıyla çeşitli modelleri (Diebold-Li, Fonksiyonel Veri Analizi, Gauss Süreçleri) uygulamaktadır. Bu süreçte CRISP-DM, farklı modellerin karşılaştırılabilir hale gelmesini, verilerin hazırlanmasını ve modellerin piyasa dinamiklerine göre değerlendirilmesini sağlayan bir çerçeve sunmuştur. Metodolojinin altı aşaması, çalışmanın hem teorik hem de pratik bağlamda tutarlı ve sistematik bir şekilde ilerlemesine olanak tanımıştır. Bu yaklaşım, modellerin performansını değerlendirmenin yanı sıra ekonomik analiz ve politika önerileri geliştirme konusunda da güçlü bir temel sağlamaktadır.

Şekil 1.1'de görüldüğü gibi CRISP-DM metodolojisi altı aşamadan oluşmaktadır: Problem Tanımlama, Veri Anlama, Veri Hazırlama, Modelleme, Değerlendirme ve Kullanıma Alma (Shearer, 2000; Clancy vd., 2021). Yaşam döngüsü modeli, aşamalar arasındaki en önemli ve en sık bağımlılıkları gösteren oklara sahip altı aşamadan oluşur.



Aşamaların sırası katı değildir. Aslında, çoğu proje gerektiğinde aşamalar arasında gidip gelir. Söz konusu aşamaların açıklaması aşağıda verilmiştir.



Şekil 1.1 CRISP-DM Metodolojisinin Süreç Aşamaları ve İşleyişi

#### 1.4.1. Problem Tanımlama

Bu aşama, projenin iş amacını, hedeflerini ve gereksinimlerini anlamak için başlar. Projede neyin başarıya ulaşmasının hedeflendiği, sorunun doğası ve çözümün nasıl bir değer yaratacağı belirlenir. Bu aşama, iş paydaşlarıyla etkileşime geçme, ihtiyaçları belirleme ve projenin stratejik hedeflerini saptama sürecini içerir.

Bu çalışmanın temel amacı, farklı piyasa yapılarında tahvil getirilerinin modellenmesi ve bu bağlamda uygun modelleme yaklaşımlarının belirlenmesidir. Bu aşamada, Türkiye, Avrupa ve ABD gibi ülkelerin piyasa dinamiklerinin tahvil getirileri üzerindeki etkileri analiz edilmiştir. Türkiye gibi yüksek volatiliteye sahip bir piyasa ile Avrupa ve ABD gibi daha istikrarlı piyasa yapılarının incelenmesi, araştırmanın temel sorularını oluşturmuştur. Çalışma, piyasalardaki tahvil getirisi eğrilerinin hem kısa vadeli

hem de uzun vadeli dinamiklerini anlamak ve modellemek üzerine odaklanmıştır. Bu adımda, hangi modelleme yöntemlerinin bu piyasa koşullarında anlamlı sonuçlar üretebileceği üzerine stratejik kararlar alınmıştır.

### **1.4.2. Veri Anlama**

Problem anlaşıldıktan sonra kullanılacak verinin kalite, sayı, ulaşılabilirlik gibi özelliklerinin sınanması aşamasıdır. Böylece verilerin analiz için söz konusu özelliklere sahip olup olmadığı belirlenmektedir. Bu sayede verilerde bir problem olup olmadığı belirlenir. Veri gürültülü veya kirli olabileceği gibi eksik olabilir ve yapısal sorunlar barındırabilir. Bunların tespitinin ardından veriye düzeltici işlemler uygulanabilir veya veri yeniden toplanabilir.

Veri anlama aşamasında, kullanılan tahvil getirisi verilerinin kaynağı, yapısı ve özellikleri analiz edilmiştir. Farklı ekonomik koşullara sahip piyasalardan elde edilen veriler, çalışmanın kapsamını genişleterek modellerin bu farklı bağlamlarda test edilmesini mümkün kılmıştır. Bu aşamada veri setinin zaman aralığı ve içerdiği temel değişkenler (tahvil getirileri ve vadeler) incelenmiştir. Ayrıca, Türkiye'nin daha dalgalı bir piyasa yapısına sahip olması nedeniyle eksik veri ve uç değerlerin olup olmadığı kontrol edilmiştir. Verilerin doğru şekilde anlaşılması, modelleme aşamasındaki stratejik kararların alınmasında kilit rol oynamıştır.

### **1.4.3. Veri Hazırlama**

Bu aşama, veri setlerinin analiz için hazırlanmasını içerir. Veri temizleme, veri entegrasyonu, veri dönüşümü ve özellik seçimi gibi işlemler gerçekleştirilir. Veri setleri, analiz için uygun bir formata getirilir. Bu aşama ayrıca veri örnekleme, özellik mühendisliği ve gereksinimlere uygun veri kümesi oluşturma gibi süreçleri de içerir. Veri hazırlığı aşamasında, veri setinin kalitesini artırmak, gürültüyü azaltmak ve uygun veri yapısını elde etmek için çeşitli teknikler kullanılır.

Veri hazırlama sürecinde, veri setlerinin modellerin gereksinimlerine uygun hale getirilmesi hedeflenmiştir. Çalışmada, farklı piyasa verilerinden oluşan geniş bir veri seti işlenmiş ve temizlenmiştir. Bu aşamada yapılan işlemler arasında eksik verilerin

doldurulması, zaman serisi analizi için veri setlerinin yeniden düzenlenmesi ve modellerin gerektirdiği matematiksel formatlara uygun hale getirilmesi yer almıştır. Her bir modelleme yönteminin farklı veri gereksinimleri olduğu için bu süreç çalışmanın kritik bir parçası olmuştur. Özellikle, piyasa dinamiklerini yansıtan önemli özelliklerin korunması ve modellerin karşılaştırılabilir olması adına verilerin dikkatli bir şekilde işlenmesi sağlanmıştır.

#### **1.4.4. Modelleme**

Bu aşamada tanımlanan problem ve elde edilen veri üzerinde makine öğrenmesi veya ekonometrik teknik aracılığıyla model geliştirilir. Söz konusu model, problemin çözümü için özelleştirilmektedir. Yani modelin çalışması için veri üzerinde standartlaştırmak gibi bazı işlemler gerekebilir. Model performansı değerlendirilir ve gerektiğinde iyileştirme yapılır. Bu aşama, farklı modellerin oluşturulması, parametre ayarlanması ve model seçimi gibi süreçleri içerir.

Modelleme aşamasında, tahvil getirilerinin analizinde kullanılan çeşitli yöntemler uygulanmıştır. Her bir modelleme yöntemi, piyasa dinamiklerini farklı açılardan değerlendirebilme kapasitesine sahiptir. Bu süreçte, modellerin parametreleri optimize edilerek piyasa yapısına uygun hale getirilmiş ve farklı piyasa yapılarındaki tahvil getirisi eğrileri analiz edilmiştir. Bu aşama, tez çalışmasının çekirdeğini oluşturan ve veriden anlamlı içgörüler çıkaran en önemli adımlardan biridir.

#### **1.4.5. Değerlendirme**

Bu aşamada, oluşturulan modellerin performansı değerlendirilir. Modellerin doğruluğu, güvenilirliği ve iş amacına uygunluğu değerlendirilir. Gerçek dünya verileri üzerinde test edilerek performansları ölçülür. Modellerin başarısı, iş amacına ulaşım ulaşmadığını belirlemek için ölçütlerle karşılaştırılır. Eğer modeller iş amacını karşılamıyorsa, aşamalar tekrarlanabilir veya yeni stratejiler belirlenerek döngünün başına dönülebilir. Ayrıca, elde edilen sonuçlar paydaşlara sunulur ve projenin ilerlemesi değerlendirilir.

Değerlendirme sürecinde, modellerin performansı karşılaştırılmış ve hangi piyasa yapısında daha uygun sonuçlar verdiği analiz edilmiştir. Çalışmanızda, modellerin tahmin doğruluğu ve uyumu belirli kriterler kullanılarak ölçülmüştür. Özellikle farklı piyasa dinamiklerine uygunluğu değerlendirilerek, modellerin ne ölçüde ekonomik gerçekleri yansıttığı irdelenmiştir. Bu aşama, araştırma sorularınıza verilen yanıtların geçerliliğini ve güvenilirliğini sağlamış, aynı zamanda modellerin güçlü ve zayıf yönlerini ortaya koymuştur.

#### **1.4.6. Kullanıma Alma**

Seçilen model karar verme sistemlerine, gerçek dünya uygulamalarına veya raporlama altyapısına entegre edilir. Modelin performansı zaman içinde izlenir ve gerektiğinde bakım planlanır. Son olarak, çalışmanızın bulguları, ekonomik analizlerde ve piyasa tahminlerinde kullanılabilir hale getirilmiştir. Bu aşamada, modellerin piyasalarda nasıl uygulanabileceği ve ekonomik politikalarla ilişkili çıkarımlar geliştirilmiştir. Özellikle, piyasa dinamiklerinin analiz edilmesi ve gelecekteki araştırmalara ışık tutacak sonuçların sunulması bu sürecin önemli bir çıktısıdır. Dağıtım aşaması, çalışmanızın hem akademik hem de uygulamalı bağlamda fayda sağlamasına olanak tanımaktadır.

CRISP-DM metodolojisi, bu çalışmanın tüm aşamalarını yapılandırmak için güçlü bir çerçeve sunmuştur. İş süreçlerinin anlaşılmasından veri hazırlığına, modelleme ve değerlendirme süreçlerinden bulguların uygulanabilirliğine kadar her aşama, bu araştırmanın sistematik bir şekilde ilerlemesini sağlamıştır. Metodolojinin uygulanması, farklı piyasa yapılarının incelenmesini kolaylaştırmış ve tahvil getirisi eğrilerinin dinamiklerini anlamada tutarlı bir yapı oluşturmuştur. Bu yaklaşım, çalışmanın metodolojik sağlamlığını güçlendirmiş ve farklı piyasa yapılarında modelleme yaklaşımlarının uygulanabilirliğini test etmiştir.

#### **1.5. Sınırlılıklar**

Bu çalışmada ele alınan sınırlılıklar, araştırmanın kapsamını ve sonuçlarının genelleştirilebilirliğini etkileyebilecek bazı temel faktörleri içermektedir. Aşağıda bu sınırlılıklar detaylı bir şekilde açıklanmaktadır.

### 1.5.1 Veri Kümesi

Bu çalışmada kullanılan veri seti, hazine tahvili verileri evreninden seçilmiş olup mevcut piyasa getirilerinin göstergesi olarak değerlendirilmiştir. Bunun temel nedeni, her bir getiri eğrisi modelinin sonuçlarının önemli ölçüde kullanılan veri setinin büyüklüğü, kalitesi ve temsil yeteneği ile ilişkili olmasıdır. Bolder ve Streliski (1999) tarafından da belirtildiği gibi, modelleme sürecinin başarısı, verilerin niteliklerine sıkı sıkıya bağlıdır. Bu bağlamda, kullanılan veri setinin hem geniş kapsamlı hem de tutarlı bir şekilde hazırlanması gereklidir. Ancak, özellikle gelişmekte olan piyasalarda veri eksiklikleri, sınırlı geçmiş veri setleri ve eksik gözlemler, modellerin tahmin performansını olumsuz yönde etkileyebilmektedir. Zhang vd. (2017) bu durumu, tahmin doğruluğunu artırmak için daha geniş veri setlerine ve yüksek kaliteli verilere duyulan ihtiyaç bağlamında ele almıştır. Veri kümesinin yetersizliği veya veri hazırlama aşamasında yapılan hatalar, özellikle dinamik piyasa koşullarında tahmin modellerinin etkinliğini azaltabilmektedir.

### 1.5.2. Model Seçimi

Bu araştırmanın bir diğer önemli sınırlılığı, kullanılan modellerin seçimi ve bu seçimin araştırma sonuçlarına olan etkisidir. Her bir model, kendine özgü avantajlara ve dezavantajlara sahiptir. Parametrik modeller, basit yapıları nedeniyle kullanım kolaylığı sağlarken, karmaşık piyasa dinamiklerini tam olarak yansıtamayabilir. Öte yandan, makine öğrenmesi yöntemleri daha yüksek tahmin doğruluğu sunabilse de, bu yöntemlerin uygulanması yüksek hesaplama maliyetleri ve uzmanlık gerektirir. Seçilen modellerin performansı, belirli piyasa koşullarında optimize edilebilirken, diğer piyasa yapılarında bu modellerin aynı başarıyı göstermesi garanti değildir. Örneğin, Türkiye gibi yüksek volatilitelere sahip piyasalarda, kullanılan modellerin ne ölçüde uygun sonuçlar vereceği hâlâ araştırılmayı bekleyen bir konudur. Bu durum, model seçiminin yalnızca mevcut piyasa koşulları için değil, aynı zamanda farklı piyasalara uygulanabilirliğini de içermesi gerektiğini göstermektedir.

### 1.5.3. Hiperparametre Ayarlama

Hiperparametre, makine öğrenmesi ve derin öğrenme modellerinde, modelin eğitimi sırasında doğrudan öğrenilmeyen, bunun yerine önceden belirlenip ayarlanan

öğrenme oranı, epoch sayısı, batch boyutu gibi parametrelerdir. Bu parametreler, modelin performansını optimize etmek ve uygun bir şekilde çalışmasını sağlamak için önemlidir. Araştırmada kullanılan birçok model, performanslarını optimize etmek için hiperparametrelerin hassas bir şekilde ayarlanmasını gerektirmektedir. Hiperparametrelerin seçimi ve ayarlanması, özellikle makine öğrenimi yöntemlerinde önemli bir rol oynamaktadır. Ancak bu süreç, genellikle karmaşık ve zaman alıcıdır. Bergstra ve Bengio (2012) tarafından belirtildiği üzere, hiperparametre optimizasyonunun etkili bir şekilde yapılması, model performansı üzerinde belirleyici bir etkiye sahiptir. Bu bağlamda, hiperparametrelerin belirli bir veri seti veya zaman dilimi için optimize edilmesi mümkün olmakla birlikte, bu parametrelerin farklı piyasa koşullarında aynı etkiyi göstereceği garanti edilemez. Ayrıca, hiperparametre ayarlarında yapılan hatalar veya yetersiz optimizasyon, modellerin tahmin doğruluğunu ve geliştirilebilirliğini olumsuz yönde etkileyebilir. Bu nedenle, hiperparametrelerin seçim süreci titizlikle ele alınmalıdır.

#### **1.5.4. Genelleştirilebilirlik**

Bu çalışmanın bir diğer önemli sınırlılığı, elde edilen sonuçların farklı piyasa koşullarına ve veri setlerine genelleştirilebilirliğidir. Araştırmada kullanılan veri setleri ve modeller, belirli piyasa dinamiklerine göre tasarlanmış ve uygulanmıştır. Ancak, bu sonuçların farklı finansal piyasalara veya değişen ekonomik koşullara uygulanabilirliği belirsizdir. Örneğin, Avrupa ve ABD gibi daha istikrarlı piyasalardan elde edilen bulguların, Türkiye gibi yüksek volatiliteye sahip piyasalarda aynı başarıyı göstermesi beklenmeyebilir. Ayrıca, bu araştırmada kullanılan modellerin belirli bir finansal varlık sınıfı veya piyasa koşulları için optimize edilmiş olması, diğer durumlarda başarısız olma riskini de beraberinde getirmektedir. Bu nedenle, elde edilen sonuçların genelleştirilmesi ve daha geniş bir bağlama uygulanması için daha fazla araştırmaya ihtiyaç duyulmaktadır.

#### **1.5.5. Verilerin Zaman Boyutu ve Güncellik**

Araştırmada kullanılan veri setlerinin güncelliği ve zaman içindeki kapsamı, tahmin performansı açısından kritik bir rol oynamaktadır. Finansal piyasalarda koşullar hızla değişebilir ve bu değişimler tahmin modellerinin doğruluğunu etkileyebilir. Özellikle geçmiş verilere dayanan modeller, ekonomik krizler, politika değişiklikleri

veya piyasa şokları gibi dışsal faktörler nedeniyle gelecekteki koşulları yansıtmakta yetersiz kalabilir. Bu durum, model performansını değerlendirmek için verilerin zaman boyutunun ve güncelliğinin dikkatli bir şekilde ele alınmasını gerektirmektedir.

Sonuç olarak, bu araştırmanın sınırlılıkları, sadece kullanılan modellerin performansı ile sınırlı kalmamakta, aynı zamanda veri setlerinin kalitesi, hiperparametre optimizasyonu ve sonuçların genelleştirilebilirliği gibi daha geniş bir çerçeveyi kapsamaktadır. Bu sınırlılıklar, çalışmanın bulgularını değerlendirirken dikkatle ele alınmalı ve gelecekteki araştırmalar için bir rehber olarak kullanılmalıdır. Bu çalışmanın İkinci Bölümünde, vadeye kadar getiri eğrilerinin modellenmesine ilişkin teorik altyapı detaylandırılmış, Üçüncü Bölümde ise kullanılan modellerin tahmin performansları analiz edilmiştir. Son olarak, Dördüncü Bölümde genel sonuçlar tartışılmış ve bu sonuçlara dayalı olarak politika yapıcılar ve yatırımcılar için öneriler sunulmuştur.

## İKİNCİ BÖLÜM

### VADE YAPISI MODELLERİNİN GENEL TEORİSİ VE STİLİZE OLGULAR

Sabit getirili enstrümanların analizi için, faiz oranı tahminlerinin elde edilmesi, finansal modelleme ve risk modellemesi için hayati bir öneme sahiptir. Analistler, piyasaları değerlendirirken kararlarını ve sonuçlarını getiri eğrilerinin modellenmesine dayandırır. Ekonomistler içinse getiri eğrisi, yatırımcıların risk alma istekliliği ve piyasa katılımcılarının geleceğe dair beklentileri hakkında kritik bilgiler sunar.

Bu bölümde, tahvil fiyatlarının dinamiklerini tanımlayan vade yapısı modelleri için geniş kapsamlı bir çerçeve sunulmaktadır. Bu çerçeve, finansal analizin dayanağını oluşturur ve ardışık bölümlerde ayrıntılı olarak ele alınacak farklı modellerin temelini sağlar. Getiri eğrisi analizi, iskonto eğrisi (discount curve), ileri oran eğrisi (forward rate curve) ve getiri eğrisi (yield curve) gibi üç temel teorik tahvil piyasası yapısını içerir. Bu yapılar, finansal piyasa katılımcılarının geleceğe dair beklentilerini ve risk algılarını anlamak için vazgeçilmez araçlardır. Bu bölüm, bu yapıların genel teorisini ayrıntılı bir şekilde açıklarken, sonraki kısımlarda bu teorik çerçevenin pratik uygulamalarını ele alınacaktır. Bu sayede, vade yapısı modellerinin gerçek dünya finansal kararlarında nasıl kullanılabileceğine dair bir anlayış geliştirilmesi amaçlanmaktadır.

#### 2.1 Tahvil Piyasası Terminolojisi

İlk olarak teknik olarak vadeye kadar getiri olarak adlandırılan getiri kavramı tanımlanacaktır. Getiri, vade sonunda nakit akışının bugünkü değerinin cari fiyatına eşit olduğu faiz oranıdır. Literatürde yaygın olarak iki tür getiri kullanılmaktadır. Bunlar basit getiri ve sürekli bileşik getiridir.

**Tanım 1.** Vadesi  $\tau$  dönem sonra dolacak 1 ₺ nominal değerli kuponsuz bir tahvil için cari fiyat  $P(t, T)$  ve basit getiri  $R$  ise fiyat ve getiri arasındaki ilişki şu şekilde tanımlanır:



$$P(t, T) = \frac{1}{(1 + R)^\tau} \quad (2.1)$$

$T$  zamanında vadesi gelen temerrütsüz kuponuz bir tahvil,  $T$  zamanında 1 ₺ ödeyecek ve diđer zamanlarda ödeme yapmayacak olan bir menkul kıymettir. Bu tahvilin  $t$  zamanındaki fiyatı  $0 \leq t \leq T$  olmak üzere  $P(t, T)$  ise  $T$  vade tarihinde  $P(T, T) = 1$  olur. Getiri (vadeye kadar), tahvil fiyatının  $T$  vade tarihinde bire yükseldiđi sürekli bileşik getiri oranı olarak tanımlanır.  $t$  zamanındaki getiri  $y(t, T)$  olarak gösterilmektedir.

**Tanım 2.** Nominal deđeri 1 ₺ olan kuponuz bir tahvil için sürekli bileşik getiri,  $y(t, T)$  ařađıdaki eřitliđi sađlar.

$$P(t, T) = \exp(-\tau y(t, T)), \quad (2.2)$$

veya

$$y(t, T) = -\frac{\ln P(t, T)}{\tau}, \quad (2.3)$$

burada  $\tau = T - t$ 'dir.  $\tau$ 'nin bir fonksiyonu olarak,  $y(t, T)$  genellikle  $t$  zamanında (sıfır kuponlu) getiri eđrisi olarak adlandırılır. Getiri eđrisi, belirli bir vadenin faiz oranını belirterek faiz oranlarının vade yapısını tanımlamaktadır.

Burada kullanılan bir diđer kavram da vadeli faiz oranıdır. (Anlık) forward oranı, tahvil sahibinin yatırımını  $T$  'den sonraki bir an için uzatarak kazanabileceđi anlık getiri oranıdır.  $t$  zamanındaki forward oranını  $f(t, T)$  için iskonto fonksiyonu ve anlık forward oranı arasındaki iliřki:

$$f(t, T) = -\frac{\partial}{\partial T} \ln P(t, T). \quad (2.4)$$

Denklem (2.4)'ün integralinden ařađıdaki sonu çıkarmaktadır:

$$P(t, T) = \exp \left\{ - \int_t^T f(t, \mu) d\mu \right\}. \quad (2.5)$$

Denklem (2.3) ve (2.5)'ten, getiri ile vadeli faiz oranı arasındaki ilişkiyi elde ederiz:

$$y(t, T) = \frac{1}{\tau} \int_t^T f(t, \mu) d(\mu). \quad (2.6)$$

$\tau$ 'nın fonksiyonları olarak  $P(t, T)$  fiyatı,  $y(t, T)$  getirisi ve  $f(t, T)$  forward oranı,  $T$  vadesinden önceki  $t$  zamanında faiz oranlarının vade yapısının eşdeğer tanımları olarak görülebilir. Bu tanımlar, fonksiyonlardan herhangi birinin bilinmesinin diğer ikisini çözmek için yeterli olduğunu göstermektedir<sup>1</sup>.

Getiri eğrileri hakkında stilize olgular aşağıdadır:

1. Ortalama getiri eğrisi vade ile artar ve içbükeydir,
2. Getirilerin volatiliteleri vadelerle birlikte azalır,
3. Getiriler, bir ila 12 ay arasında otokorelasyon ile gösterilebilecek güçlü bir sürekliliğe sahiptir,
4. Farklı vadelerdeki getiriler arasındaki yatay kesit farkı olan getiri farkları, gerçek getirilere göre daha az oynaklık ve süreklilik göstermektedir.

## 2.2 Getiri Eğrisi Şekilleri ve Kullanımı

Sabit getirili bir menkul kıymetin getirisi ile vadeye kalan süre arasındaki ilişkiyi temsil eden getiri eğrisi, ekonomi ve finans alanında çok önemli bir göstergedir. Genellikle ekonominin gelecekteki durumu hakkında fikir verebilecek şekli açısından analiz edilir. Getiri eğrisinin şekli tipik olarak üç faktör açısından tanımlanır: seviye, eğim ve eğrilik (Wright, 2011). Örneğin, yukarı doğru eğimli bir getiri eğrisi genellikle uzun vadelerin riskliliği ile ilişkilendirilir (Holmström & Tirole, 2001). Öte yandan, düz veya ters bir getiri eğrisi yaklaşan bir resesyon olasılığının daha yüksek olduğuna işaret edebilirken, dik bir getiri eğrisi yaklaşan bir resesyon olasılığının düşük olduğuna işaret eder (Faulkender,

---

<sup>1</sup> Daha fazla ayrıntı için Anderson vd. (1996) bakınız.

2005). Aslında, tarihsel veriler 1960'ların ortalarından sonraki her resesyona, yaklaşan resesyona 6 çeyreği içinde negatif eğimli, ters bir getiri eğrisi tarafından öngörüldüğünü göstermiştir (Ang vd., 2003).

Getiri eğrisi, eğri üzerinde seviye, eğim ve eğrilik etkilerine sahip olabilen piyasa hareketlerine (şoklara) doğrudan bir yanıt olarak kayar ve şekil değiştirir. Seviye etkisi, faiz oranının tüm vade seviyeleri için aynı miktarda nasıl değiştiğini açıklarken, eğim değişiklikleri kısa vadeli veya uzun vadeli oran değişikliklerinin nispeten birbiriyle orantısız olduğu durumu yansıtır. Eğriliğin ana etkisi, getiri eğrisinin öncekinden daha kambur şekilli hale geldiği orta vadeli faiz oranları ile ilgilidir (Nyman-Andersen, 2018). Getiri eğrileri yukarı doğru eğimli, aşağı doğru eğimli, kambur ve ters kambur gibi şekillerde görülebilir (Diebold ve Rudebusch, 2013; Diebold ve Li, 2006).

### 2.2.1 Normal Getiri Eğrisi

Normal getiri eğrisi, genellikle ekonominin sağlıklı bir şekilde büyüdüğünü ve enflasyon oranında ciddi bir dalgalanma beklenmediğini ifade eden bir göstergedir. Normal bir getiri eğrisi, kısa vadeli faiz oranlarının düşük, uzun vadeli faiz oranlarının ise daha yüksek olduğu pozitif eğimli bir yapıya sahiptir (Şekil 2.1). Bu yapı, piyasa katılımcılarının gelecekte ekonomik büyüme ve istikrar beklediğini gösterir. Ekonominin toparlanma evresinde, merkez bankalarının düşük faiz oranları politikasıyla desteklenen yatırımlar ve tüketim artışı uzun vadeli faiz oranlarının yükselmesine neden olabilir.

Örneğin, ABD ve Avrupa gibi ekonomik istikrarın ve düşük volatilitenin hâkim olduğu piyasalarda normal getiri eğrisi genellikle sıkça gözlenir. Bu tür piyasalarda, merkez bankalarının düşük enflasyon ve büyüme beklentilerini destekleyen para politikaları normal getiri eğrisinin sürekliliğini sağlar. Türkiye gibi gelişmekte olan ülkelerde ise bu eğri, yüksek faiz oranlarının uzun vadede daha az risk algısı yaratması durumunda ortaya çıkabilir.

Dik bir normal getiri eğrisi ise, genellikle ekonomik döngünün dip noktasında ortaya çıkar. Bu durumda merkez bankaları, ekonomiyi canlandırmak için agresif faiz indirimlerine gitmiş olabilir. Bu politikaların etkisiyle kısa vadeli faiz oranları hızla düşerken, uzun vadeli faiz oranları gelecekteki büyüme beklentileri nedeniyle daha yüksek

seviyelerde kalır (Nawalkha vd., 2005). Çalışmanız bağlamında, Türkiye, Avrupa ve ABD piyasalarında normal getiri eğrisi durumlarının tarihsel analizleri, farklı piyasa yapılarında ekonomik beklentilerin nasıl şekillendiğini anlamak için önemli bir temel sunabilir.

### 2.2.2 Düz Getiri Eğrisi

Düz getiri eğrisi, genellikle ekonomik belirsizliklerin yüksek olduğu veya ekonomik döngünün dönüş noktasına yaklaştığı durumlarda gözlemlenir. Kısa ve uzun vadeli faiz oranları arasındaki farkın azalmasıyla eğri yatay bir forma dönüşür. Bu durum, piyasa katılımcılarının gelecekte faiz oranlarında veya ekonomik büyümede büyük bir değişim beklemediğini gösterebilir. Bununla birlikte, düz getiri eğrisi aynı zamanda piyasalarda "bekle-gör" modunda bir yaklaşımı da temsil eder; çünkü yatırımcılar, belirsizlik nedeniyle uzun vadeli kararlar almaktan kaçınabilir.

Düz getiri eğrisi, genellikle durgunluk veya toparlanma öncesi geçiş dönemlerinde ortaya çıkar. Örneğin, Avrupa'da ekonomik büyümenin durgunlaştığı ve merkez bankasının gelecekte faiz oranlarını düşürebileceğine dair işaretler verdiği dönemlerde bu tür bir eğri gözlemlenebilir. ABD'de düz getiri eğrisi, genellikle FED'in faiz oranlarında değişiklik yapmadan önceki bekleme dönemlerinde sıkça görülür. Türkiye gibi daha oynak piyasalarda ise düz getiri eğrisi nadir görülür, çünkü yüksek faiz oranları ve değişken piyasa beklentileri eğrinin bu formunu oluşturmasını zorlaştırır.

### 2.2.3 Kambur Getiri Eğrisi

Kambur getiri eğrisi, kısa vadeli ve uzun vadeli faiz oranlarının birbirine yakın olduğu, ancak orta vadeli faiz oranlarının yükseldiği bir yapı sergiler. Bu durum, piyasa katılımcılarının kısa vadede ekonomik iyileşme beklediği, ancak uzun vadede belirsizliklerin devam edebileceği algısına işaret eder. Kambur getiri eğrisi, genellikle ekonomik toparlanma dönemlerinde ortaya çıkar ve kısa sürelidir.

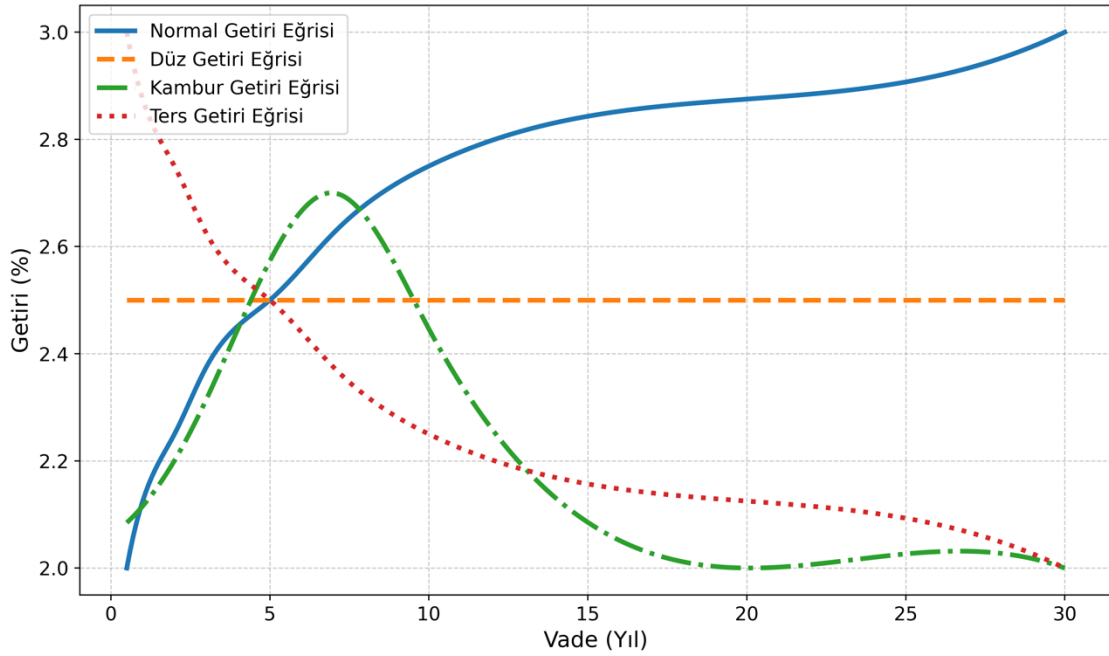
Bu eğri, genellikle gelişmiş piyasalarda, özellikle de orta vadeli tahvillerin yoğun olarak alınıp satıldığı Avrupa piyasasında görülebilir. Türkiye gibi piyasalarda kambur getiri eğrisi, yatırımcıların orta vadede daha fazla getiri talep ettiği yüksek oynaklık dönemlerinde ortaya çıkabilir.

### 2.2.4 Ters Getiri Eğrisi

Ters getiri eğrisi, genellikle ekonomik döngünün zirve noktasında, yani aşırı ısınma dönemlerinde ortaya çıkar. Kısa vadeli faiz oranlarının uzun vadeli faiz oranlarından daha yüksek olması, piyasa katılımcılarının gelecekte ekonomik daralma, durgunluk veya resesyona beklediğini gösterir. Merkez bankaları, enflasyonu kontrol altına almak için faiz oranlarını artırırken, uzun vadeli faiz oranları ekonomik büyüme beklentilerinin düşmesi nedeniyle daha düşük seviyelerde kalabilir. Bu durum, genellikle finansal piyasalarda risk iştahının azalmasına ve güvenli liman varlıklarına yönelime neden olur (Şekil 2.1).

ABD’de ters getiri eğrisi genellikle bir resesyona habercisi olarak görülür ve tarihsel olarak bu durum birçok ekonomik krizden önce gözlenmiştir. Avrupa’da da benzer şekilde, ekonomik daralma dönemlerinden önce ters getiri eğrisi oluşabilir. Türkiye’de ise bu eğri, daha çok ekonomik kriz dönemlerinde, yüksek kısa vadeli faiz oranları ve belirsiz uzun vadeli beklentilerle ilişkilendirilir.

Getiri eğrisi şekilleri, ülkelerin ekonomik yapıları ve piyasa dinamiklerine göre değişiklik gösterebilir. ABD ve Avrupa gibi gelişmiş ülkelerde, normal ve düz getiri eğrileri ekonomik istikrar ve düşük volatilité koşullarını yansıtırken, ters getiri eğrisi genellikle krizlerin habercisidir. Türkiye gibi gelişmekte olan ülkelere ise, ekonomik dalgalanmalar ve yüksek faiz oranları nedeniyle eğrilerin şekilleri daha oynak ve kısa süreli olabilir. Bu nedenle, getiri eğrilerinin şekilleri ve bunların yorumlanması, ülke ekonomisinin yapısal dinamiklerini anlamak için kritik bir araçtır.



**Şekil 2.1** Getiri Eğrisi Türleri: Normal, Düz, Kambur ve Ters

Getiri eğrisi, Şekil 2.1'de gösterildiği gibi kalan vadeleri farklı olan faiz oranlarını göstermektedir. Getiri eğrisi, piyasa hareketlerine (şoklara) doğrudan bir tepki olarak kayar ve şekil değiştirir, bu da eğri üzerinde seviye, eğim ve eğrilik etkilerine sahip olabilir. Seviye etkisi, faiz oranının tüm vade seviyeleri için aynı miktarda değişmesini tanımlarken, eğim değişiklikleri kısa vadeli veya uzun vadeli faiz değişikliklerinin birbirine göre nispeten orantısız olduğu durumu yansıtır. Eğriliğin ana etkisi, getiri eğrisinin öncekinden daha kambur şekilli hale geldiği orta vadeli faiz oranları ile ilgilidir.

Ekonomik beklentilerin faizin vade yapısının şekilleriyle ilişkilendiren tartışmalar, bu şekillerin gelecekteki faiz oranlarına ilişkin beklentiler hakkında bilgi içerdiğini göstermektedir. Ancak beklentiler, getiri eğrisinin neden farklı zamanlarda farklı şekillere sahip olduğunu tam olarak açıklamamaktadır. Buna ek olarak yatırımcılar farklı vadelerde tahvillere yatırım yapmak için diğer önemli değişkenler olan risk ve likidite primlerini dikkate almaktadırlar. Birçok değişken getiri eğrisinin şeklini etkilediğinden, bu değişkenlerin etkilerini vurgulayan alternatif hipotezler geliştirilmiştir.

### 2.3 Getiri Eğrisi Teorileri

Faiz oranları birçok tahvil için farklılık göstermektedir. Faiz oranlarının tahvilden tahvile farklılık göstermesi; firmaların, sigorta şirketlerinin, bankaların ve yatırımcıların

tahvillerin alınması veya satılması hususunda belirleyici etmen olmaktadır. Faiz oranlarının farklılaşmasına neden olarak iki temel ayrım söz konusudur: Bunlardan ilki, vadeye kadarki süreleri aynı olan fakat risk, likidite ve gelir vergisi açısından farklılaşan tahvillerin sahip olduğu faiz oranlarının risk yapısıdır. İkinci olarak risk, likidite ve vergi oranları aynı ancak farklı vade yapısına sahip tahviller arasındaki ilişkiye faiz oranlarının vade yapısı denilmektedir.

Dört temel vade yapısı hipotezi aşağıda verilmiştir.

- Beklentiler hipotezi
- Likidite primi hipotezi
- Bölünmüş piyasalar hipotezi
- Tercih edilen habitat hipotezi

Teoriler gelecekte kısa vadeli faiz oranlarının hareketini tahmin etmemize yardımcı olmaktadır. Getiri eğrisinin yukarı doğru dik bir eğime sahip olması kısa vadeli faiz oranlarının yükselmesinin beklendiği, yukarı doğru hafif bir eğime sahip olması kısa vadeli faiz oranlarının aynı kalmasının beklendiği, düz bir eğime sahip olması kısa vadeli faiz oranlarının ılımlı bir şekilde düşmesinin beklendiği ve ters bir getiri eğrisine sahip olması ise kısa vadeli faiz oranlarının keskin bir şekilde düşmesinin beklendiği anlamına gelmektedir.

### **2.3.1 Beklentiler Hipotezi**

Faiz oranlarının vade yapısına ilişkin beklentiler teorisi, uzun vadeli faiz oranlarının piyasanın gelecekteki kısa vadeli faiz oranlarına ilişkin beklentileri tarafından belirlendiğini öne sürer (Taylor, 1991). Bu teori, farklı vadelerdeki borçlanma senetlerinin getirilerini karşılaştırarak beklentileri çıkarmak için yaygın olarak kullanılmaktadır (Friedman, 1980). Vadeli faiz oranlarının gösterdiği vade yapısı, doğal faiz oranındaki düşük frekanslı hareketleri tahmin etmek için kullanılır (Laubach & Williams, 2003). Ancak, gelecekteki kısa vadeli faiz oranlarının tahmininde vade yapısının öngörü gücüne ilişkin tartışmalar olmuştur (Mishkin, 1990). Bazı çalışmalar, beklentiler hipotezinin geçerliliğini sorgulamış ve bu hipotezin geçerli olmadığını öne sürmüştür (Froot, 1989). Buna ek olarak, ampirik çalışmalar getiri eğrisinin eğimindeki değişikliklerin spot faiz oranlarında gelecekte

meydana gelecek deęişikliklerin yönünü tahmin edebildiğini doğrulamıştır (Estrella & Hardouvelis, 1991).

Fisher (1930) tarafından ortaya konan Beklentiler hipotezine göre farklı vadelerde tahvillerin faiz oranlarının farklılaşmasının nedeni, faiz oranlarının gelecekte gerçekleşmesi beklenen değerlerinin deęişmesidir. Bu teorinin arkasındaki temel varsayım, tahvil alıcılarının bir vadedeki tahvili diğerine tercih etmedikleri, dolayısıyla beklenen getirisi farklı vadedeki başka bir tahvilden daha az olan herhangi bir tahvil miktarını ellerinde tutmayacaklarıdır. Bu özelliğe sahip tahvillerin mükemmel ikame olduğu söylenir. Bu durum farklı vadelerdeki tahvillerin tam ikame olması durumunda, bu tahvillerin beklenen getirilerinin eşit olması gerektiği anlamına gelir (Mishkin, 2019).

Beklentiler hipotezi, getiri eğrisi pozitif eğimli olduğunda, kısa vadeli faiz oranlarının gelecekte yükselmesinin beklendiğini öne sürer. Bu durumda, uzun vadeli faiz oranının şu anda kısa vadeli faiz oranından daha yüksek olması, gelecekteki kısa vadeli faiz oranlarının ortalamasının mevcut kısa vadeli faiz oranından daha yüksek olacağını işaret eder. Bu durum, ancak kısa vadeli faiz oranlarının gelecekte yükselmesi bekleniyorsa gerçekleşebilir. Getiri eğrisi ters olduğunda (negatif eğimli), gelecekteki kısa vadeli faiz oranlarının ortalamasının mevcut kısa vadeli faiz oranından daha düşük olması beklenir. Bu da kısa vadeli faiz oranlarının gelecekte ortalama olarak düşmesinin beklendiği anlamına gelir. Getiri eğrisi düz olduğunda ise, beklentiler teorisi kısa vadeli faiz oranlarının gelecekte ortalama olarak deęişmesinin beklenmediğini öne sürer.

Faiz oranlarının vade yapısı, dinamiklerini anlamak ve tahmin etmek için önerilen çeşitli model ve yaklaşımlarla kapsamlı bir araştırma konusu olmuştur. Örneğin, bazı modeller stokastik dizi şokları ile ileri faiz oranı eğrisinin dinamiklerine odaklanmıştır (Santa-Clara ve Sornette, 2001). Diğer çalışmalar, faiz oranlarını yönlendiren stokastik süreci modellemek için üstel splineler kullanarak vade yapısını incelemiştir (Vasicek & Fong, 1982). Ayrıca, vadeli faiz oranlarını gelecekteki faiz oranları, enflasyon oranları ve para birimi değer kaybı oranlarına ilişkin piyasa beklentilerinin göstergeleri olarak tahmin etme ve yorumlama çabaları olmuştur (Svensson, 1994). Özetle, faiz oranlarının vade yapısına ilişkin beklentiler hipotezi, kısa vadeli ve uzun vadeli faiz oranları arasındaki ilişkinin anlaşılmasında merkezi bir kavram olmuştur. Beklentilerin çıkarımında yaygın olarak kullanılmasına rağmen, tahmin gücü ve ampirik geçerliliği konusunda tartışmalar



devam etmektedir. Vadeli yapının dinamiklerini incelemek için, bu araştırma alanının karmaşıklığını ve önemini yansıtan çeşitli modeller ve yaklaşımlar geliştirilmiştir.

### 2.3.2 Bölünmüş Piyasalar Hipotezi

Culbertson (1957) tarafından önerilen bölünmüş piyasalar hipotezi, farklı piyasa katılımcılarının farklı vade bölümlerinde vadeleri olan tahvilleri tercih ettiğini belirtmektedir. Bölünmüş piyasalar hipotezine göre, bononun getirisi diğer vadelerdeki bonoların beklenen getirilerinden etkilenmez. Farklı vadelerdeki bonolar birbirinin ikamesi olmadığından, farklı bir vadedeki bonoyu elde tutmanın beklenen getirisi diğer vadedeki bononun beklenen getirisini etkilememelidir. Bu hipotez beklentiler hipotezinin farklı vadelerdeki bonoların tam ikame olduğunun varsayımının tam tersidir. Çünkü yatırımcıların kendi vade tercihleri vardır, o vadedeki beklenen getiri ile ilgilenirler.

Bu teori, kurumsal yatırımcıların belirli vade türleri için tercihlerine dayanmaktadır ve bu daha sonra menkul kıymetlerin arz ve talebi yoluyla getiri eğrisini belirleyecektir. Örneğin, hayat sigortası şirketleri genellikle daha uzun vadeli tahvillere yatırım yaparken, bankalar kısa ve orta vadeli vadelere bağlı kalmaktadır. Piyasa riski düşük olan yatırımcılar, anapara istikrarını sağlayan kısa vadeli vadeleri tercih etmektedir (Faerber, 2001).

Faiz oranlarının vade yapısına ilişkin bölünmüş piyasalar hipotezi, özellikle finansal krizler sırasında faiz oranlarının dinamiklerini anlamada ilgi çeken bir konu olmuştur (Gürkaynak & Wright, 2012). Bu hipotez "tercih edilen habitat teorisi" şemsiyesi altında yer almakta ve faiz oranlarının vade yapısının şekillenmesinde piyasa bölümlenmesinin önemini vurgulamaktadır (Williamson, 2015; Vayanos ve Vila, 2009). Piyasa segmentasyonunun reel faiz oranının para politikası şoklarına tepkisi üzerinde, özellikle de toplam çıktı büyüme oranının kalıcı olarak düşmesi ve bu tür şokları takiben reel faiz oranının kalıcı olarak artması açısından etkileri olduğu gösterilmiştir (Occhino, 2008). Ayrıca, düopolistik fiyat belirleme piyasasındaki denge özellikleri faiz oranlarının vade yapısının belirleyicileri olarak ele alınmış ve oyun teorisi ışığında faiz oranlarının vade yapısına alternatif bir bakış açısı getirilmiştir.

### 2.3.3 Likidite Primi Hipotezi

Hicks (1939), uzun vadeli tahvillerin getirisinin, yatırımcıları uzun vadeli tahvillerin daha yüksek fiyat oynaklığına karşı telafi etmek için kısa vadeli tahvillerin getirilerinin beklenen getiriye aşması gerektiğini öngören likidite primi hipotezini ortaya koymuştur. Sonuç olarak, piyasa gelecekteki kısa oranların mevcut seviyelerde kalmasını beklese bile, vade yapısı, vadenin artan bir fonksiyonu olmalıdır. Likidite primi hipotezi, normal ve dik şekilli getiri eğrilerini açıklayabilmektedir.

Bu hipotez, gelecekteki faiz oranlarının beklentilerine risk unsurunu ekler. Yatırımcılar genellikle kısa vadeli vadeleri tercih ediyor. Uzun vadeli faizleri, ancak uzun vadeli faiz oranlarının, gelecekteki faiz oranlarında beklenen dalgalanmaların risklerini karşılayacak kadar yükselmesini beklerlerse tercih ederler. Diğer bir deyişle, yatırımcılar, kendilerini uzun vadeli faiz oranlarının gelecekteki belirsizliklerine maruz bırakmamak için risk primi adı verilen ek bir getiri talep ederler. Bu ek risk primini almayı beklemiyorlarsa, kısa vadeli yatırımlara devam edecekler ve bunları vade sonunda yeni kısa vadeli menkul kıymetlere devredecekler (Faerber, 2001)

### 2.3.4 Tercih Edilen Habitat Hipotezi

Modigliani ve Sutch (1966)'nın ortaya attığı tercih edilen habitat hipotezi olarak bilinen başka bir teori, vade yapısının, gelecekteki faiz oranları beklentisi ile bir risk primini yansıttığı görüşünü benimser. Bununla birlikte, tercih edilen habitat teorisi, risk priminin vadeye eşit olarak yükselmesi gerektiği iddiasını reddetmektedir.

Likidite primi teorisiyle yakından ilişkili olan tercih edilen habitat teorisi, yatırımcıların bir vadedeki tahvilleri başka bir vadedeki tahvillere tercih ettiklerini varsayar. Bir vadedeki tahvilleri başka bir vadedeki tahvillere tercih ettikleri için, tercih edilen vadeye (habitat) sahip olmayan tahvilleri ancak bu tahviller biraz daha yüksek beklenen getiri sağlıyorsa satın almaya isteklidirler. Riskten kaçınan yatırımcıların kısa vadeli tahvillerin yaşam alanını uzun vadeli tahvillerin yaşam alanına tercih etmesi muhtemel olduğundan, uzun vadeli tahvilleri ancak daha yüksek beklenen getirileri varsa ellerinde tutmaya isteklidirler (Mishkin, 2019).

Likidite primi ve tercih edilen habitat teorileri vade yapısına ilişkin temel ampirik gerçekleri çok iyi açıkladıkları için faiz oranlarının vade yapısına ilişkin en yaygın kabul gören teorilerdir. Bu teoriler, uzun vadeli faiz oranının likidite (vade) primi ve tahvilin ömrü boyunca gerçekleşmesi beklenen kısa vadeli faiz oranlarının ortalamasının toplamı olacağını ileri sürerek hem beklentiler teorisinin hem de bölünmüş piyasalar teorisinin özelliklerini birleştirmektedir.

Likidite primi ve tercih edilen habitat teorileri aşağıdaki gerçekleri açıklamaktadır:

- Farklı vadelerdeki tahvillerin faiz oranları zaman içinde birlikte hareket etme eğilimindedir.
- Kısa vadeli faiz oranları düşük olduğunda, getiri eğrilerinin yukarı doğru dik bir eğime sahip olma olasılığı daha yüksektir.
- Getiri eğrileri genellikle yukarı doğru eğimlidir, ancak kısa vadeli faiz oranları yüksek olduğunda, getiri eğrilerinin ters olma olasılığı daha yüksektir.

#### **2.4 Getiri Eğrisinin Tahmin Gücü**

Getiri eğrisinin tahmin gücü ekonomi alanında kapsamlı araştırmalara konu olmuştur. Getiri eğrisinin tahmin gücüne ilişkin ampirik kanıtlar 1980'lerin sonlarına kadar uzanmaktadır (Estrella, 2005). Getiri eğrisinin tahmin gücü, özellikle para politikasının yürütülmesinde merkez bankaları için ilgi çekici bir konu olmuştur (Estrella & Hardouvelis, 1991). Getiri eğrisinin durgunlukların öngörülmesi ve çıktı büyümesinin tahmin edilmesi gibi reel ekonomik faaliyetler için öngörü gücü içerdiği tespit edilmiştir (Hännikäinen, 2017; Tawose vd., 2021). Ancak son yıllarda getiri eğrisinin tahmin gücünün kötüleştiğine dair gözlemler bulunmaktadır (Chinn & Kucko, 2015; Pace, 2012).

Çalışmalar, getiri eğrisinin tahmin gücünün zaman içinde dalgalandığını göstermiştir (Hännikäinen, 2017). Örneğin, getiri eğrisinin uzun ucunun (2 yılın ötesinde) Amerika Birleşik Devletleri için en güçlü tahmin gücüne sahip olduğu ve tahminlerin daha kısa ufuklar için en doğru olduğu gözlemlenmiştir (Estrella vd., 2001). Buna ek olarak, getiri eğrisinin çıktı büyümesini öngörme gücünün istikrarsız olduğu tespit edilmiştir (Giacomini & Rossi, 2006). Ayrıca, getiri eğrisinin şeklini tahmin etme yeteneği, ekonomik koşullara ilişkin tahmin yeteneği ile ilişkilendirilmiştir (Dolan, 1999).

Getiri eğrisinin tahmin gücünü etkileyen faktörler:

- Ekonomik belirsizlik: Ekonomik belirsizlik arttıkça, getiri eğrisinin tahmin gücü azalır. Yatırımcılar, riskten kaçınmak için kısa vadeli yatırımlara yönelebilir ve bu da eğrinin ters eğimli olmasına neden olabilir.
- Likidite riski: Uzun vadeli yatırımlar, kısa vadeli yatırımlara göre daha fazla likidite riski taşır. Bu nedenle, yatırımcılar uzun vadeli yatırımlar için daha yüksek getiri talep edebilir ve bu da eğrinin yukarı eğimli olmasına neden olabilir.
- Döviz kuru riski: Açık ekonomilerde, döviz kuru riskleri de getiri eğrisini etkileyebilir. Döviz kuru dalgalanmalarından endişe duyan yatırımcılar, yurt dışı yatırımlardan kaçınabilir ve bu da eğrinin ters eğimli olmasına neden olabilir.

Metodoloji açısından, getiri eğrisinin tahmin gücünü analiz etmek için dalga sinir ağı modelleri (Shah & Debnath, 2017), faktör analizi yaklaşımları (Alper vd., 2004) ve tahmin kombinasyon teknikleri (Pauwels ve Vasnev, 2012) dahil olmak üzere çeşitli yaklaşımlar kullanılmıştır. Bu çalışmalar, getiri eğrisinin öngörü gücünü etkileyen faktörlerin daha iyi anlaşılmasına katkıda bulunmuştur.

Sonuç olarak, getiri eğrisinin öngörü gücü, resesyonlar ve çıktı büyümesi gibi ekonomik koşulları tahmin etme kabiliyetine dair kanıtlarla birlikte kapsamlı bir araştırma konusu olmuştur. Bununla birlikte, zaman içinde öngörü gücünde dalgalanmalar ve ülkeler arasında öngörü gücünde farklılıklar olduğu gözlemlenmiştir. Getiri eğrisinin dinamiklerini ve öngörü gücünü anlamak, politika yapıcılar ve yatırımcılar için bilgiye dayalı kararlar almada büyük önem taşımaktadır. Literatürde getiri eğrisinin tahmin edici gücüne ilişkin getiri eğrisinin para politikasının durumunu yansıttığı, getiri eğrisindeki hareketin kredi piyasası, gelecek enflasyon beklentisi, arz şokları, bütçe açığı ve tüketim kararları ile ilişkili olduğu gibi farklı hipotezler ortaya atılmıştır. Ters eğimli bir getiri eğrisi genellikle ekonomik durgunluğun habercisi olarak kabul edilir. Yatırımcılar, kısa vadeli yatırımlardan daha fazla getiri elde edebileceklerini düşünerek uzun vadeli faiz oranlarını aşağı çeker. Bu durum, yatırım ve harcamaları azaltarak ekonomik büyümeyi yavaşlatabilir. Eğrinin eğimi, enflasyon beklentilerini de yansıtır. Eğrinin yukarı eğimli olması, yatırımcıların gelecekte enflasyonun artacağını ve faiz oranlarının yükseleceğini beklediklerini gösterir. Merkez

bankaları, para politikası kararlarını verirken getiri eğrisini dikkate alır. Ters eğimli bir getiri eğrisi, merkez bankasının faiz oranlarını düşürmesi gerektiğine dair bir işaret olarak yorumlanabilir.

## 2.5 Getiri Eğrisinin Eğimi ve Ekonomik Çevrim

Kessel (1965) ve Fama (1986) gibi öncü araştırmalar, ABD'nin getiri eğrisinin durgunluk veya yavaşlama öncesi düzleştiği fenomenini belirtmiştir. Ancak, 1980'lerin sonlarında ABD'nin getiri eğrisinin yeniden yataylaşmaya başladığını gösteren ampirik kanıtlar ortaya çıkmıştır. Harvey (1988, 1989) ve Laurent (1988, 1989), getiri eğrisinin resesyonları diğer ekonomik göstergelerden daha iyi tahmin ettiğini göstermiştir. Stock ve Watson (1989), ABD Ticaret Bakanlığı'nın öncü göstergeler listesine getiri eğrisinin eğimine dayalı bir ölçü eklenmesini önermiştir. Son olarak, Estrella ve Hardouvelis (1991) ile Chen (1991)'in çalışmaları, daha düz bir getiri eğrisi ile gelecekteki daha düşük ekonomik büyüme arasındaki ilişkiyi stilize bir gerçek olarak ele almıştır. Estrella & Mishkin (1996) getiri eğrisinin ABD resesyonlarının güçlü bir tahmincisi olduğunu ve resesyonları iki ila altı çeyrek öncesinden tahmin etmede diğer finansal ve makroekonomik göstergelerden daha iyi performans gösterdiğini bulmuştur. Rudebusch & Williams (2007) getiri eğrisinin resesyonları öngörmedeki tahmin gücüne ilişkin süregelen bulmacanın altını çizmiş ve getiri eğrisinin tahmin gücünün resesyonlarda ve genişlemelerde farklılık gösterebileceğini, bunun da tahmin yeteneğinin dinamik doğasına işaret ettiğini vurgulamıştır.


Getiri eğrisinin eğimi genellikle resesyonların önemli bir öngörücüsü olarak görülmektedir (Estrella ve Hardouvelis, 1991; Stock ve Watson, 2003; Rudebusch ve Williams, 2009; De Backer vd., 2019). Finansal krizler ve resesyonlar düzenli olarak birlikte meydana gelen korelasyonlu olaylardır (Bluwstein vd., 2023). Şekil 2.2, 1965'ten 2024'e kadar üç aylık ABD Hazine tahvilinin piyasa getirisinin günlük hareketini göstermekte ve ekonomik çevrimlerin ne zaman durgunluğa girdiğini göstermektedir. Grafik, faiz oranlarının zaman içindeki değişimini yüzde cinsinden kırmızı bir çizgi ile ifade ederken, gri dikey bantlar ABD ekonomisindeki resesyon (durgunluk) dönemlerini göstermektedir.

Ekonomik genişleme dönemlerinde, genellikle talebin artması ve ekonomik aktivitenin hızlanması ile enflasyon baskıları da artar. Bu durum, merkez bankalarının faiz oranlarını artırmasına yol açar. Faiz oranlarının yükseltilmesi, enflasyonun kontrol altına alınması ve ekonominin aşırı ısınmasının önlenmesi amacı taşır. Grafikte bu eğilim, 1950'lerden 1970'lere kadar olan dönemde net bir şekilde gözlemlenmektedir. Ekonomik genişleme dönemlerinde faiz oranları istikrarlı bir şekilde yükselmiş ve 1980'lerde zirve yapmıştır.

Durgunluk dönemlerinde ise ekonomik aktivite yavaşlar, talep düşer ve işsizlik artar. Bu koşullar altında, merkez bankaları genellikle faiz oranlarını düşürerek ekonomiyi canlandırmaya çalışır. Faiz oranlarının düşürülmesi, borçlanma maliyetlerini azaltarak tüketim ve yatırım harcamalarını teşvik eder. Grafikte bu eğilim, özellikle 1980'lerin sonlarından itibaren gözlemlenmektedir. 1980'lerin sonlarında başlayan ve 1990'larda devam eden ekonomik durgunluk dönemlerinde faiz oranlarında belirgin bir düşüş yaşanmıştır.

2000'li yılların başında faiz oranlarının düşük seviyelerde seyretmesi, 2001 resesyonu ve 2008 finansal krizi gibi ekonomik durgunluk dönemlerinin bir sonucudur. Bu dönemde genişlemeci para politikaları uygulanmış ve faiz oranları düşürülmüştür. 2010'dan sonra ekonomik toparlanma sürecine girildiğinde ise faiz oranlarında yeniden bir artış eğilimi gözlemlenmiştir. Ancak bu artış, 1980'lerdeki gibi keskin değil, daha ılımlı olmuştur.

Sonuç olarak, Şekil 2.2, ABD Hazine faiz oranlarının ekonomik çevrimlerle nasıl bir ilişki içinde olduğunu ve faiz oranlarının ekonomik genişleme dönemlerinde yükselme, durgunluk dönemlerinde ise düşme eğiliminde olduğunu açıkça göstermektedir. Buna göre, ekonomik döngülerin faiz oranları üzerindeki etkilerini anlamak ve gelecekteki para politikası kararlarını değerlendirmek için önemli bilgiler sunmaktadır.



**Şekil 2.2** Ekonomik Çevrim ve Faiz Oranları (ABD Üç Aylık Hazine Bonoları), 1934-2024<sup>2</sup> (Gri alanlar NBER tarafından belirlenen durgunluk dönemini göstermektedir)

Harvey (1991, 1997), Plosser ve Rouwenhorst (1994), Bonser-Neal ve Morley (1997), Estrella ve Mishkin (1997), Bernard ve Gerlach (1998), Ivanova ve diğerleri (2000) ve Moneta (2005) tarafından yapılan çalışmalarda getiri eğrisi ile ekonomik faaliyet arasındaki bağlantı birçok ülkede kurulmuştur. Ancak, getiri eğrisinin tahmin kabiliyeti bir ülkeden diğerine farklılık göstermektedir. En güçlü korelasyon Amerika Birleşik Devletleri, Almanya ve Kanada'da gözlemlenirken, ilişki Belçika, İrlanda, İtalya, Hollanda ve İspanya'da daha az belirgindir. Bu üç ülkedeki en güçlü korelasyonun nedeni, büyük ekonomiler olmaları, yani bireysel şoklara daha az eğilimli olmalarıdır. Ayrıca, kamu borçları son birkaç on yıldır risksiz olarak kabul edilmektedir (De Backer vd., 2019). Bu durum devlet tahvili getirilerinin kredi risk priminden etkilenmediği ve dolayısıyla getiri eğrisi sinyallerinin daha doğru olmasını sağladığı anlamına gelmektedir.

10 yıllık ve 3 aylık Hazine faiz oranı farkı, finans literatüründe kapsamlı olarak incelenen önemli bir göstergedir. Genellikle vade farkı olarak adlandırılan bu fark, başta GSYH büyümesi ve iş çevrimleri olmak üzere ekonomik faaliyetlerin öngörülmesinde önemlidir (Edirisuriya, 2015; Hamilton & Kim, 2001; Zabczyk & Estrella, 2008). Araştırmalar, bu farktaki değişikliklerin çeşitli ekonomik değişkenler üzerinde önemli etkileri olabileceğini göstermiştir. 10 yıllık Hazine bonoları ile 90 günlük banka bonoları

<sup>2</sup> St. Louis Federal Rezerv Bankası (FRED): <https://fred.stlouisfed.org/graph/?g=1ldER>.

arasındaki faiz farkındaki %10'luk bir artış, takip eden 7 ila 9 çeyrek boyunca GSYH büyümesinde yaklaşık %4'lük bir artışa neden olmaktadır (Edirisuriya, 2015). Ayrıca, 10 yıllık Hazine tahvil faizi ile 3 aylık Hazine bonusu faizi arasındaki fark, ekonomik faaliyetin değerli bir öngörücüsü olarak tanımlanmıştır (Hamilton ve Kim, 2001).

Çalışmalar ayrıca faiz oranı farklarının para politikası ve finansal piyasalar üzerindeki etkisini de araştırmıştır. Örneğin, federal fon oranı ile Hazine getirileri arasındaki fark, piyasa likiditesi ve para politikasının etkinliği üzerindeki etkilerini anlamak için analiz edilmiştir (Alquist vd., 2022). Ayrıca, Hazine nakit yönetimi ile para politikaları arasındaki ilişki araştırılmış ve hazine fonlarının para piyasasına yatırım ölçeğinin faiz oranlarını ve likiditeyi nasıl etkileyebileceği vurgulanmıştır (Tang, 2019).

Faiz oranı farklarının dinamikleri, kredi farkları ve şirket tahvil getirileri ile ilişkileri de dahil olmak üzere çeşitli bağlamlarda araştırılmıştır. Araştırmalar, uzun ve kısa vadeli spot Hazine getirileri arasındaki farkların temerrüt primleri içerdiğini ve reel tüketim ve üretim büyümesini tahmin etmede önemli olduğunu göstermiştir (Kamara, 1997). Ayrıca, Hazine faizleri ile şirket tahvil faizleri arasındaki fark, Hazine faizleri ile şirket borçlanma maliyetleri arasındaki etkileşimi anlamak için incelenmiştir (Duffee, 1998; Duffee, 1996).

Bu bağlamda, gelişmekte olan ülkelerde (GOÜ) risk primi ve enflasyonun gelişmiş ülkelere kıyasla daha oynak olması, faiz oranları ve ekonomik aktivite üzerindeki etkileşimlerin farklı bir dinamik oluşturduğunu göstermektedir. GOÜ'lerde sıkı para politikası uygulamalarının ekonomik aktivite üzerindeki etkileri, bu ülkelerin ekonomik yapılarındaki özgünlükler nedeniyle farklılık gösterebilir.

GOÜ'de, risk primi ve enflasyonun gelişmiş ülkelere kıyasla daha oynak olması nedeniyle, sıkı para politikası uygulamaları ekonomik aktivite üzerinde olumlu etkiler yaratabilir. Küçük ve açık ekonomilerde enflasyon üzerinde döviz kuru ve ithal fiyatlar gibi dışsal faktörlerin de belirleyici olabilmesi ve beklentilerin tam olarak çıpalanmamış olması, kısa dönemli sıkı para politikasının ekonomik aktivitede yavaşlamaya yol açmadan döviz kuru ve enflasyon beklentilerini düşürerek ters eğimli bir getiri eğrisine neden olabileceğini göstermektedir (TCMB, 2019).



Parasal sıkılaştırma, kısa vadeli faizleri yükseltirken, bu hamlenin güvenilirliğine bağlı olarak gelecekteki enflasyon beklentilerini düşürebilir ve uzun vadeli faizlerin gerilemesine yol açabilir. GOÜ üzerine yapılan ampirik çalışmalar da bu ilişkiyi desteklemektedir (Barroso vd., 2014; Moreno, 2008)

Şekil 2.4, Türkiye’de 10 yıllık tahvil faiz oranı ile 3 aylık tahvil faiz oranı arasındaki farkı (spread) zaman içinde göstermektedir. Gri alanlar, genellikle Türkiye ekonomisinde durgunluk veya kriz dönemlerini işaret eder. Bu spread, yalnızca farklı vadelerdeki faiz oranlarının basit bir farkı olmaktan öte, piyasanın Türkiye ekonomisine ilişkin beklenti, risk iştahı ve güven düzeyinin bir göstergesi niteliğindedir. Özellikle kısa vadeli faizler para politikası kararları ve piyasa volatilitesinden hızla etkilenirken, uzun vadeli faizler ise enflasyon beklentileri, siyasi ve jeopolitik riskler ile küresel gelişmelere daha duyarlı olabilmektedir.

2012’den 2017’ye kadar olan dönemde, grafikte spread’in genel olarak düşük seyrettiği veya zaman zaman negatif değerlere gerilediği görülmektedir. Bu görece istikrarlı tablonun arkasında, Türkiye ekonomisinin o tarihlerde büyüme performansını koruması, enflasyonun göreceli olarak kontrol altında tutulabilmesi ve bütçe açıklarının sınırlı kalması gibi unsurlar öne çıkmıştır. Ayrıca, küresel ölçekte uygulanan genişlemeci para politikaları (örneğin ABD Merkez Bankası’nın uzun süreli düşük faiz politikası), gelişmekte olan ülkelere sermaye girişini desteklemiş ve Türkiye de bu durumdan olumlu etkilenmiştir. Bu süreçte yatırımların artması ve yabancı yatırımcı güveninin yüksek kalması, uzun vadeli faiz oranlarını baskı altında tutarken kısa vadeli faizlerde de önemli dalgalanmaların önüne geçilmiştir.

Grafikteki gri alanlar arasında, 15 Temmuz 2016 darbe girişimi dönemine de dikkat çekilmektedir. Bu olağanüstü durum, Türkiye’de politik ve ekonomik belirsizliği arttırmış, bu da kısa vadede faiz oranlarında yukarı yönlü riskler yaratmıştır. Ancak, küresel piyasalardaki likidite koşullarının o dönemde hâlâ destekleyici olması ve siyasi istikrarın hızlıca sağlanmasıyla, darbe girişimi sonrası süreçteki dalgalanma nispeten sınırlı kalmıştır. Buna rağmen, yatırımcıların risk iştahı ve güven algısı geçici olarak bozulmuş, bu da spread’in belirli bir süre dalgalanmasına yol açmıştır.

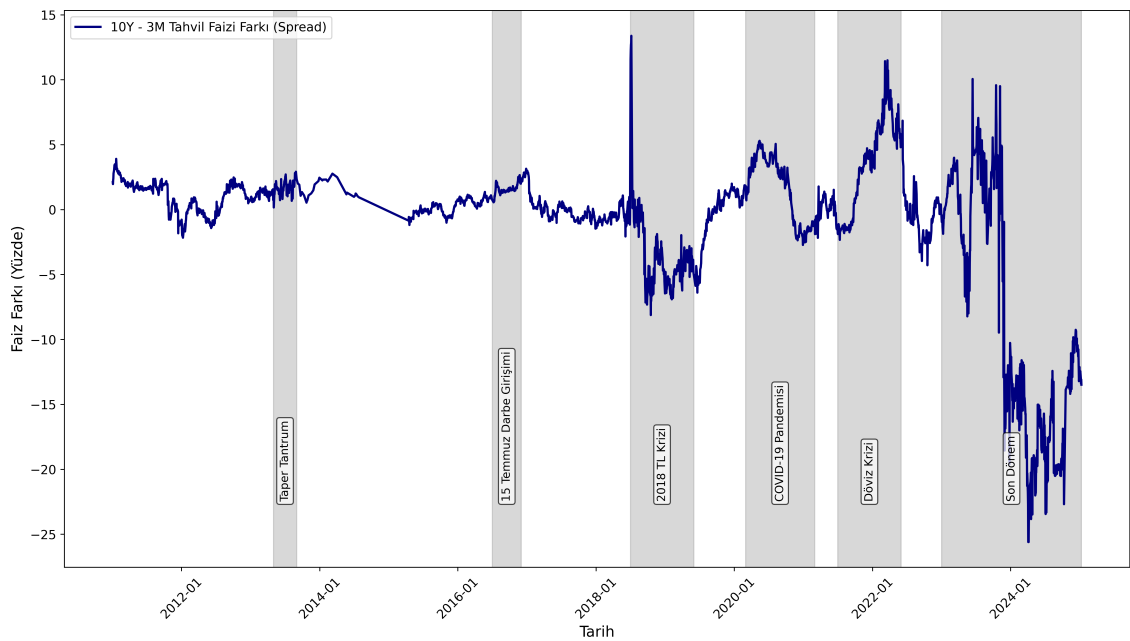
Ancak 2018 yılında yaşanan kur krizi, spread'i hızla yükseltmiştir. Bu krizin nedenleri arasında, aşırı kredi büyümesi, dış borç yükü, cari açık, yanlış ekonomi politikaları (faiz indirimleri, döviz rezervlerinin erimesi) ve jeopolitik gerginlikler (ABD ile yaşanan Brunson krizi) sayılabilir. Kur krizi, ekonomide derin bir daralmaya, enflasyonun hızla yükselmesine ve yatırımcı güveninin zedelenmesine yol açmıştır. Türkiye'de, 2018 yılının ikinci ve üçüncü çeyreklerinde enflasyon beklentilerindeki hızlı artışın ardından, Türkiye Cumhuriyet Merkez Bankası'nın (TCMB) uyguladığı sıkı para politikası önlemleri, getiri eğrisinin eğimini daha da negatife çevirmiştir. Bu dönemde, enflasyon beklentilerinde de hızlı bir düşüş gözlemlenmiştir.

2019 sonrası dönemde spread'te dalgalı bir görünüm öne çıkmaktadır. 2018'deki kur krizinin etkileri tam atlatılamamışken, COVID-19 pandemisinin 2020 itibarıyla küresel ekonomide yarattığı şok, Türkiye'de de hem arz hem talep yönlü sorunlar doğurmuştur. Bu süreçte uygulanan genişlemeci politikalar (örneğin düşük faiz, kredi teşvikleri) kısa vadeli faizleri bir miktar baskılarken, uzun vadeli faizler artan enflasyon beklentileri ve dış finansman riskleri nedeniyle yüksek seviyesini korumuş veya yükseltmiştir. Jeopolitik riskler ve küresel belirsizlikler de yatırımcı güvenini sürekli test ettiği için spread zaman zaman oldukça yüksek değerlere çıkmıştır.

2022 yılında yaşanan “dolar krizi” ve TL'nin değer kaybının hızlanması, spread üzerinde yeni dalgalanmalara neden olmuştur. Yüksek enflasyon ve dış finansman ihtiyacı, para ve kur politikalarında sık dönüşümlerin yaşanmasıyla birleşince, özellikle kısa vadede faiz kararları sık sık gözden geçirilmiştir. Buna karşılık uzun vadede, jeopolitik gerginlikler (Rusya-Ukrayna savaşı), artan enerji ve emtia fiyatları gibi küresel faktörler devreye girerek risk algısını artırmıştır. Bu durum, grafik üzerinde sıkça aşağı ve yukarı yönlü hareketler şeklinde kendini göstermiştir.

2023 yılı başından itibaren Türkiye'de spread'in yükseliş trendine girdiği görülmektedir. Bu durum, çeşitli faktörlerin bir araya gelmesiyle açıklanabilir. Öncelikle, 2023 yılında enflasyonun hedeflenen seviyenin oldukça üzerinde seyretmesi, yatırımcıların enflasyon beklentilerini olumsuz etkilemiş ve risk primini artırmıştır. İkinci olarak, Rusya-Ukrayna savaşının devam etmesi ve küresel tedarik zincirlerindeki aksamalar, enerji ve emtia fiyatlarında artışa neden olmuş ve Türkiye ekonomisi üzerindeki baskıyı artırarak spread'in yükselmesine katkıda bulunmuştur.

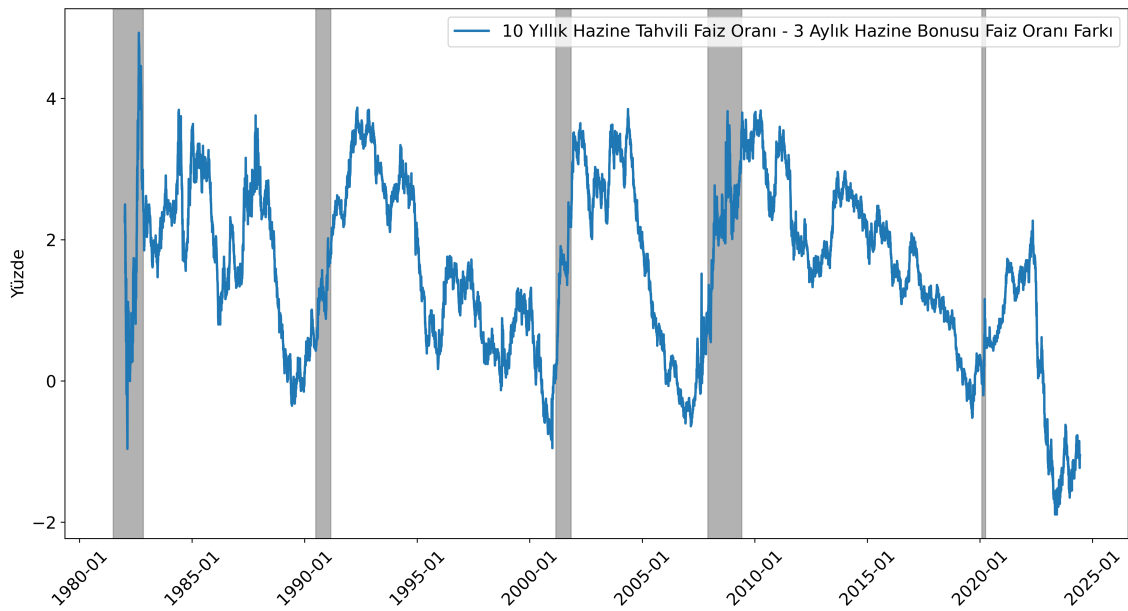
Merkez Bankası'nın 2023'te sıkı para politikalarına yönelmiş, faiz oranları artırılmış, kredi büyümesi kontrol altına alınmaya çalışılmış ve enflasyonla mücadele öncelik haline getirilmiştir. Bu dönemde Merkez Bankası'nın faiz artırım döngüsüne başlamasıyla kısa vadeli faiz oranları yükselmiştir. Ancak, uzun vadeli faiz oranları, enflasyon beklentileri, jeopolitik riskler ve yatırımcı güveni gibi çeşitli faktörlerden etkilenmeye devam ettiği için spread genişlemiştir. Ekonomik belirsizlikler ve jeopolitik risklerin yanı sıra, iç politikadaki gelişmeler de yatırımcı güvenini olumsuz etkilemiştir. Bu durum, yabancı yatırımcıların Türkiye'den çıkışını hızlandırarak spread'in yükselmesine katkıda bulunmuştur.



**Şekil 2.3** Türkiye’de Getiri Eğrisinin Eğimi (10 yıl-3 ay farkı, %) (Gri alanlar durgunluk dönemini göstermektedir)

ABD ekonomisi üzerine yapılan araştırmalar, getiri eğrisi eğimi ile ekonomik aktivite arasında ters yönlü bir ilişki olduğunu doğrulamaktadır. Bu araştırmalarda, genellikle 10 yıl ve 3 ay vadeli Hazine kıymetlerinin getiri farkı olarak ölçülen eğimin, 4 ila 6 çeyrek öncesinden ekonomideki yavaşlamaya dair sinyaller verdiği tespit edilmiştir. 1950’den bu yana ABD’de yaşanan her resesyonu (NBER) 1967 yılındaki yanlış sinyal hariç, başarılı bir şekilde öngören getiri eğrisi, diğer bazı gelişmiş ülke ekonomileri için de benzer sonuçlar vermiştir. Almanya, Kanada ve İngiltere gibi ülkeler üzerinde yapılan çalışmalar da bu ilişkiyi desteklemektedir (Estrella ve Mishkin, 1997; Bernard ve Gerlach, 1998). Şekil 2.3’ten görüleceği gibi, son 45 yılda getir eğrisi eğimi negatife geçtiğinde (kısa vadeli faiz oranları uzun vadeli faiz oranlarından yüksek olduğunda), genellikle bir süre

sonra ekonomik durgunluk yaşanmıştır. Bunun nedeni, negatif eğimin yatırımcıların gelecekteki ekonomik büyüme ve enflasyon beklentilerinin zayıf olduğunu göstermesi ve bu beklentinin ekonomik aktiviteyi yavaşlatmasıdır. Kısa vadeli faiz oranlarının uzun vadeli faiz oranlarını aştığı ters bir getiri eğrisinin yaklaşan bir resesyonu güvenilir bir şekilde öngördüğüne dair geleneksel inanç son yıllarda sorgulanmaktadır. Tersine dönmüş bir getiri eğrisini ekonomik gerilemelere bağlayan tarihsel kanıtlara rağmen, getiri eğrisinin tersine döndüğü son örneklerin ardından bir durgunluk yaşanmaması, bu göstergenin güvenilirliği konusunda soru işaretleri yaratmıştır (Wright, 2006; Benzoni vd., 2018). Bu farklılaşmanın olası kaynakları ve etkileri detaylı bir şekilde aşağıda incelenmiştir.



**Şekil 2.4** ABD’de Getiri Eğrisinin Eğimi (10 yıl-3 ay farkı, %) (Gri alanlar NBER tarafından belirlenen durgunluk dönemini göstermektedir)<sup>3</sup>

### 2.5.1 Gecikmeli Etki Olasılığı

Getiri eğrisi eğiminin negatife dönmesi ile durgunluk arasında zaman gecikmesi olabileceği ihtimali göz ardı edilmemelidir. Ekonomik sistemin karmaşık yapısı ve çeşitli faktörlerin etkileşimi nedeniyle, negatif eğimin etkileri hemen görülmeyebilir. Yatırımcıların ve işletmelerin kararlarını gözden geçirmeleri, harcamalarını kısmaları ve ekonomik aktiviteyi yavaşlatmaları zaman alabilir.

<sup>3</sup> St. Louis Federal Rezerv Bankası (FRED): <https://fred.stlouisfed.org/graph/?g=1oRIy>.

### 2.5.2 Merkez bankalarının aktif müdahaleleri

Olası açıklamalardan biri, getiri eğrisi ile resesyona arasındaki geleneksel ilişkiyi bozmuş olabilecek niceliksel genişleme gibi geleneksel olmayan para politikaları da dahil olmak üzere küresel ekonominin değişen dinamikleridir (Rudebusch ve Williams, 2007; King ve Perli, 2007). Merkez bankaları, ekonomik istikrarı sağlamak ve durgunlukları önlemek için faiz oranlarını ve para arzını yönetir. Pandemi sonrası dönemde, Fed, eşi benzeri görülmemiş bir parasal genişleme politikası izledi. Bu politika, faiz oranlarını sıfıra yakın seviyelere indirmeyi, varlık alım programlarıyla piyasalara likidite sağlamayı ve hükümetin ekonomik destek programlarını finanse etmeyi içeriyordu. Bu agresif müdahaleler, negatif getiri eğrisi eğimine rağmen ekonominin durgunluğa girmesini önlemiş olabilir.

ABD'de kriz sonrası dönemde uygulanan para politikalarının, özellikle tahvil alım programları ve sözlü yönlendirme politikaları aracılığıyla, vade primi üzerinde kayda değer etkileri olmuştur. Bu etkiler, uzun vadeli faizlerin düşürülmesi ve gelecekteki politika adımlarına ilişkin belirsizliklerin azaltılması yoluyla vade priminin düşmesine yol açmıştır. Hatta bazı araştırmalar, vade priminin önemli ölçüde azaldığını ve bazı dönemlerde negatif değerlere ulaştığını ortaya koymaktadır. Bu bağlamda, getiri eğrisinin ters eğimi sadece kısa vadeli faiz beklentilerini değil, aynı zamanda negatif vade primini de kısmen yansıtabilir (Adrian vd., 2013; Hördahl ve Tristani, 2014; Kim ve Wright, 2005).

### 2.5.3 Ekonomik yapıdaki dönüşümler

Küresel ekonomi, finansal piyasaların yapısal değişimleri, artan küreselleşme, teknolojik ilerlemeler ve demografik dönüşümlerden etkilenmektedir. Bu değişimler, geleneksel ekonomik göstergelerin ve tarihsel modellerin geçerliliğini sınırlayarak, yeni dinamiklerin ve faktörlerin ortaya çıkmasına yol açmıştır. Ekonomik dönüşümler, merkez bankalarının politikalarını, piyasa beklentilerini ve yatırımcı davranışlarını önemli ölçüde etkileyebilir (Moneta, 2005; Christiansen, 2013).

### 2.5.3.1 Küreselleşme

Küreselleşme, mal, hizmet ve sermaye akışlarının hızlanmasıyla dünya ekonomisinin entegre bir yapı kazanmasını sağlamıştır. Bu süreç, ticari engellerin azalması, uluslararası rekabetin artması ve üretim maliyetlerinin düşmesi ile birlikte fiyatların genel seviyesinde düşüşe yol açmıştır. Küreselleşmenin etkisiyle düşük enflasyon dönemleri ortaya çıkmış ve merkez bankalarının uzun vadede düşük faiz oranları politikalarını sürdürmelerine olanak tanımıştır (Taylor, 2001; Bernanke, 2005). Özellikle gelişmiş ülkelerdeki merkez bankaları, küresel piyasa koşullarına uyum sağlamak için faiz politikalarını küresel ticaret dengeleriyle uyumlu hale getirmiştir.

### 2.5.3.2 Teknolojik ilerlemeler

Teknolojik yenilikler, verimliliği artırarak ekonomik büyümenin en önemli itici güçlerinden biri haline gelmiştir. Dijitalleşme, yapay zeka ve otomasyon gibi teknolojiler, üretim süreçlerini hızlandırmış ve maliyetleri düşürerek ekonomilerin daha esnek hale gelmesini sağlamıştır (Brynjolfsson & McAfee, 2014). Bunun yanı sıra, yeni endüstrilerin ortaya çıkışı istihdamı artırırken, durgunluk risklerini azaltarak ekonomik istikrarı güçlendirmiştir. Özellikle bilgi teknolojileri ve finansal teknolojiler (fintech), finansal piyasaların daha etkin çalışmasını sağlayarak ekonomik döngüler üzerindeki belirsizlikleri azaltmaktadır.

### 2.5.3.3 Demografik değişimler

Demografik faktörler, özellikle yaşlanan nüfus ve düşük doğum oranları, ekonomik büyüme ve yatırım dinamiklerini önemli ölçüde etkilemektedir. Yaşlanan nüfus, tasarruf oranlarını artırırken tüketim ve yatırımları azaltabilir, bu da uzun vadede faiz oranlarının düşmesine yol açabilir (Bloom & Canning, 2008). Avrupa ve Japonya gibi düşük doğurganlık oranlarına sahip ülkelerde bu etkiler daha belirgin şekilde görülmektedir. Ayrıca, demografik değişimler, sağlık ve sosyal güvenlik harcamalarının artmasına neden olarak devletlerin bütçe politikalarını yeniden şekillendirmesine yol açmaktadır.

### 2.5.3.4 Finansal piyasaların gelişimi

Finansal piyasalardaki gelişmeler, yeni araçların ve risk yönetimi tekniklerinin ortaya çıkmasıyla birlikte finansal sistemin dayanıklılığını artırmıştır. Türev ürünler, varlığa dayalı menkul kıymetler ve ileri düzey algoritmalar, risklerin daha etkili bir şekilde yönetilmesine olanak tanımaktadır (Gorton & Metrick, 2012). Ayrıca, finansal inovasyonlar sayesinde, kriz dönemlerinde piyasa likiditesinin korunması ve sermaye akışlarının yönlendirilmesi kolaylaşmıştır. Bu gelişmeler, finansal sistemin dış şoklara karşı daha dirençli olmasını sağlayarak ekonomik istikrarı güçlendirmiştir.

### 2.5.4 Diğer Ekonomik Göstergelerin Gücü

Getiri eğrisi eğimi, ekonomik döngülerin ve gelecekteki ekonomik koşulların öngörülmesinde güçlü bir araç olarak kabul edilse de, tek başına ekonominin geleceği hakkında kesin bir yargıya varmak yeterli olmayabilir. Getiri eğrisinin negatif eğimli olduğu durumlarda bile diğer ekonomik göstergelerin güçlü olması, ekonominin durgunluğa girmesini engelleyebilir veya bu riski azaltabilir.

Özellikle işsizlik oranı, tüketici güveni, iş yatırımları, Gayri Safi Yurtiçi Hasıla (GSYH) büyüme oranı ve enflasyon gibi göstergeler, ekonomik koşulların daha geniş bir perspektiften değerlendirilmesini sağlar. Örneğin:

- **İşsizlik Oranı:** İşsizlik oranındaki düşüşler, ekonomik aktivitenin güçlü olduğunu ve istihdam artışının devam ettiğini gösterebilir.
- **Tüketici Güveni:** Tüketici güven endeksi yükselse, bireylerin ekonomiye olan güveni artar ve bu da tüketim harcamalarını destekleyerek ekonomik büyümeyi güçlendirebilir.
- **GSYH Büyümesi:** GSYH'nin pozitif bir şekilde büyümesi, ekonomik üretimin ve talebin sürdüğünü gösterir, bu da durgunluk riskini azaltabilir.
- **Enflasyon:** Düşük ve istikrarlı enflasyon, tüketici harcamalarını ve yatırımları destekleyerek sağlıklı bir ekonomik ortam yaratabilir.

Diğer ekonomik göstergeler, getiri eğrisindeki olumsuz sinyallere rağmen ekonominin temel yapısının sağlam kalmasını sağlayabilir. Örneğin, ABD ekonomisi geçmişte bazı dönemlerde negatif getiri eğrisi sinyali almasına rağmen güçlü istihdam verileri ve tüketim talebi sayesinde durgunluktan kaçınmıştır. Benzer şekilde, Avrupa ve Asya gibi bölgelerde de ekonomik büyüme göstergeleri, tek bir göstergenin öngördüğü durumu dengeleyebilir.

Bu nedenle, getiri eğrisi analizleri yapılırken, diğer ekonomik göstergelerin bir arada değerlendirilmesi, daha kapsamlı ve doğru bir ekonomik tahmin yapılmasına olanak sağlar. Ekonomik göstergelerin güçlü olduğu dönemlerde negatif getiri eğrisi yanıltıcı olabileceği gibi, zayıf göstergelerin olduğu durumlarda pozitif bir getiri eğrisi de ekonomik iyimserliği garanti edemez. Bu nedenle, çoklu ekonomik veriler arasında dengeli bir analiz yapılması kritik önem taşır.

### **2.5.5 Pandeminin Etkileri ve Olağandışı Ekonomik Ortam**

COVID-19 pandemisi, dünya ekonomisinde daha önce benzeri görülmemiş bir etki yaratarak ekonomik aktivitenin ani bir şekilde düşmesine ve ardından hükümetlerin aldığı önlemler ve geniş çaplı aşılama çalışmalarının etkisiyle hızlı bir toparlanmaya yol açmıştır. Pandemi döneminde yaşanan bu olağandışı süreç, ekonomik göstergelerde ciddi dalgalanmalara, tedarik zinciri problemlerine ve enflasyon oranlarındaki artışa neden olmuştur. Bu bağlamda, getiri eğrisi eğimi ile ekonomik durgunluk arasındaki geleneksel ilişki, pandeminin kendine has etkilerinden dolayı geçici olarak bozulmuş olabilir.

Getiri eğrisi eğimi, ekonomik görünüm hakkında değerli bilgiler sunmaya devam etse de, pandemi gibi olağandışı dönemlerde bu göstergenin yorumlanması daha karmaşık bir hale gelmiştir. Pandeminin etkisi, küresel ticaret ağlarını, tüketici davranışlarını ve üretim dinamiklerini yeniden şekillendirerek getiri eğrisi analizi üzerinde önemli etkiler yaratmıştır. Ekonominin bu olağanüstü döneminde, merkez bankaları ve hükümetler, genişletici para ve maliye politikalarını uygulayarak ekonomik çöküşü önlemeye çalışmışlardır. Ancak bu politikaların getiri eğrisi üzerindeki etkisi, uzun vadede daha farklı sonuçlara yol açabilir.



### 2.5.5.1 Yapısal faktörlerin ve politikaların etkisi

Pandemi sonrası ekonomik ortamda, küreselleşme, teknolojik ilerlemeler ve demografik değişimler gibi yapısal faktörlerin ekonomiye etkisi daha belirgin hale gelmiştir. Özellikle merkez bankalarının faiz oranlarını düşük seviyelerde tutarak ekonomiyi destekleme çabaları ve hükümetlerin genişletici maliye politikaları, ekonomik görünüm üzerindeki etkilerini artırmıştır. Bununla birlikte, bu tür politikaların getiri eğrisinin eğimi ve durgunluk ilişkisi üzerindeki etkileri, geçmiş dönemlerden farklı bir dinamik oluşturabilir.

Bu durum, politika yapıcılar ve ekonomistler için daha fazla dikkat ve esneklik gerektiren bir ortam yaratmaktadır. Ekonomik göstergelerin daha karmaşık bir şekilde yorumlanmasını, farklı teorik yaklaşımların değerlendirilmesini ve esnek ekonomik politikaların benimsenmesini gerektirir. Pandemi sonrası dönemde, ekonomilerin toparlanması sürecinde getiri eğrisi eğiminin anlamını çözümlmek, ekonomik risklerin doğru yönetilmesi için kritik önem taşımaktadır.

### 2.5.5.2 Belirsizlik ve gelecek perspektifi

Getiri eğrisi eğimi ile durgunluk arasındaki geleneksel ilişkinin gelecekte nasıl şekilleneceği halen belirsizliğini korumaktadır. Ancak, pandeminin getirdiği yeni ekonomik gerçeklikler ışığında bu ilişkinin daha önce olduğu kadar basit ve doğrudan olmayacağı açıktır. Ekonomik aktörlerin ve politika yapıcılarının, bu yeni dinamikleri anlamak ve bilinçli kararlar almak için daha fazla bilgiye, analize ve derinlemesine araştırmaya ihtiyaç duyacağı açıktır. Bu süreçte, ekonomik göstergelerin etkileşimlerini daha geniş bir bağlamda ele almak, ekonomik politika kararlarının başarısı açısından kritik olacaktır.

Pandemi sonrası dönemde, getiri eğrisi analizi, sadece faiz oranlarındaki değişimlerle değil, aynı zamanda tedarik zincirindeki iyileşmeler, tüketici güveni, enflasyon ve iş gücü piyasalarındaki değişimlerle birlikte değerlendirilmelidir. Bu çok boyutlu yaklaşım, hem ekonomik belirsizliklerin yönetilmesine hem de olası krizlerin önlenmesine katkı sağlayacaktır.

## 2.6 Getiri Eğrisi ve Para Politikası

Merkez bankaları uyguladıkları para politikaları ile işsizlik, üretim, yatırım gibi reel ekonomik hedeflere ulaşmayı, fiyat istikrarını sağlamayı ve enflasyonun hedeflenen düzeylerde tutulmasını amaçlarlar. Bu hedeflere ulaşılabilmesi için, ekonomik konjoktüre uygun, etkin ve istikrarlı para politikaları uygulanması gerekmektedir. Kısa vadeli faiz oranlarını aktif para politikası aracı olarak kullanan merkez bankalarının reel ekonomiyi etkileyen uzun vadeli faiz oranlarına etkisi piyasa faizleri kanalıyla olmaktadır. Yani parasal aktarım mekanizmasında en önemli ve birinci kanal piyasa faiz oranlarıdır (Akıncı, 2006). Bu nedenle para politikası ile tahvil faizleri arasındaki ilişkiyi anlamak aktarım mekanizmasının iyi çalışması açısından önemlidir. Para politikasının hem reel sektör hem de enflasyon için önemli bir öngörü gücü vardır. Bu nedenle getiri eğrisi, diğer bilgilerle birlikte, para politikasını yönlendirmeye yardımcı olmak için kullanılabilir yararlı bilgilerin bir parçası olarak görülmesi gereken basit ve doğru bir ölçüdür (Estrella ve Mishkin, 1997).

Uzun vadeli faiz oranlarının, kısa vadeli faiz oranı beklentileri hakkında bilgi içermesi nedeniyle, getiri eğrisinin eğimi, merkez bankaları tarafından yakından izlenmesi gereken bir göstergedir. Düzleşen veya tersine çevrilmiş (negatif eğimli) getiri eğrisi, gelecekte kısa vadeli faiz oranlarının düşeceğine ve dolayısıyla ekonomik aktivitenin yavaşlayacağına ve enflasyonun azalacağına işaret edebilir (Mishkin, 1990). Estrella (2005) ve Estrella ve Mishkin (1997) bunun genellikle böyle olduğunu ve para politikasının, özellikle sıkılaştırma inandırıcı olduğunda, getiri eğrisinin eğiminin önemli bir belirleyicisi olduğunu göstermiştir. Ekonomik döngüleri ve enflasyonu tahmin etmede kullanışlı bir araç olan getiri eğrisi, aynı zamanda para politikası duruşunun sıklığına dair bir gösterge olarak görülür. Buna göre, olumlu eğimli bir getiri eğrisi, vade göstergesi olarak para politikası duruşunun nötr veya gevşek olduğuna işaret ederken, düz veya tersine çevrilmiş getiri eğrisi sıkı bir para politikası duruşunu gösterir (Bernanke, 1990). Adrian ve Estrella (2008)'e göre, para politikası duruşunun faiz oranlarının seviyesinden ziyade getiri eğrisinin eğimi tarafından daha iyi yakalandığını göstermektedir. Ayrıca, getiri eğrisi modeli, gizil faktörler (getiri eğrisinin seviyesi, eğimi ve eğrilik faktörleri) ile kapasite kullanımı, politika faizi ve enflasyon gibi makroekonomik değişkenlerin bir kombinasyonudur (Tam ve Yu, 2007).

## ÜÇÜNCÜ BÖLÜM

### GETİRİ EĞRİSİNİN MODELLEMESİ VE GETİRİ EĞRİLERİNİN TAHMİN EDİLMESİNE YÖNELİK KAVRAMSAL ÇERÇEVE

Getiri eğrisi tahmini, hazineler, merkez bankaları ve piyasa katılımcıları tarafından finansal varlık fiyatlandırması ve tahvil portföy yönetimi gibi çok çeşitli uygulamalarda kullanılan önemli bir araçtır. Getiri eğrisini etkin bir şekilde tahmin etmek ve öngörmek için çeşitli modeller önerilmiştir. Nelson-Siegel modeli, basitliği ve getiri eğrisini doğru tahmin etme kabiliyeti nedeniyle yaygın olarak kullanılmaktadır (Nelson ve Siegel, 1987; Christensen vd., 2009). Ayrıca, Dinamik Nelson-Siegel modelinin tahmin edilmesinin kolay olduğu ve getiri eğrisinin doğru tahminlerini sağladığı gösterilmiştir (Christensen vd., 2009). Diğer çalışmalar, getiri eğrisindeki varyansı yakalamak için rejim değiştirme modellerinin kullanımını araştırmış ve getiri eğrisinin yüksek varyanslı rejimlerde daha dik hale geldiğini ve düşük varyanslı rejimlerde faiz oranı varyansından bağımsız olduğunu göstermiştir (Christiansen, 2004).

Getiri eğrisi tahmin modelleri, arbitrajsız (Hull ve White 1990; Heath vd. 1992) ve denge yaklaşımlarına (Vasicek 1977; Cox vd. 2005; Duffie ve Kan 1996) dayanan önceki çalışmaların aksine, örneklem dışı tahmin performansına odaklanan istatistiksel modellerin kullanılmasını öneren Diebold ve Li'nin (2006) çalışmasından bu yana tahmin yeteneklerini artırmıştır (Kauffmann vd., 2022).

Finansal araçların fiyat ve hacimlerdeki hareketler ekonomik refahı, ekonomik duyarlılığı ve bu kanallar vasıtasıyla yurtiçi harcama kararlarını etkiler. Finansal araç fiyat hareketleri, özel sektörün ekonomik beklentilerindeki değişikliklerin de göstergesidir. Daha spesifik olarak, getiri eğrilerinin, herhangi bir zamanda borçlanma senetlerinin getirileri ve vadeye kalan süreleri arasındaki ilişkinin grafiksel bir temsilini sağlamaktadır. Bir getiri eğrisinin bilgi içeriği, finansal piyasalardaki varlık fiyatlandırma sürecini yansıtır. Yatırımcılar tahvil alıp satarken, gelecekteki enflasyon ve reel faiz oranlarına ilişkin beklentilerini ve risk değerlendirmelerini de dahil ederler. Bir yatırımcı, gelecekte beklenen nakit akışlarını iskonto ederek bir tahvilin fiyatını hesaplar. Genellikle "getiri eğrisi"

terimi, temerrüt riski olmayan sıfır kuponlu tahvillerin faiz oranlarının vade yapısını ifade eder.

Getiri eğrisi, para politikası amaçları için faydalı bir bilgi seti sunar ve gelecekteki kısa vadeli oranların beklenen patikası ve ekonomik faaliyet ve enflasyonun görünümü hakkında bilgi ölçer. Kısa ve uzun vadeli faiz oranlarının belirli bir tarihteki göreceli seviyesi, piyasa katılımcılarının gelecekteki kısa vadeli faiz oranlarına ilişkin beklentilerine bağlıdır. Bu nedenle, getiri eğrisinin eğimi genellikle gelecekteki ekonomik faaliyeti tahmin etmek için yararlı bir gösterge olarak ortaya çıkmıştır. Eğrinin dikleşmesi genellikle ekonomik faaliyetin hızlanacağını öngörürken, eğrinin düzleşmesi ve özellikle de tersine dönmesi genellikle yakın bir yavaşlamaya işaret etmiştir. Bunun açıklaması, uzun ve kısa vadeli faiz oranları arasındaki büyük pozitif farkın, piyasanın ekonomik büyüme için daha olumlu bir görünüm nedeniyle kısa vadeli faiz oranlarında bir artış beklediğini gösterebileceğidir. Büyüme beklentilerine ek olarak, getiri eğrisinin ucu piyasa katılımcılarının enflasyondaki trend gelişmeleri hakkındaki görüşlerini de yansıtabilir.

Gözlemlenen (tahvil fiyatı) verilerden kuponsuz ve vadeli faiz eğrilerinin türetilebileceği, bazıları diğerlerinden daha karmaşık olan bir dizi tahmin metodolojisi mevcuttur. Anderson vd. (1996), bunları iki farklı gruba ayırmaktadır: Birincisi, denge veya arbitraj argümanlarını kullanan durum değişkenleri ve varlık fiyatlandırma yöntemlerindeki değişiklikler hakkında belirli varsayımlarda bulunan modeller; ikincisi, mevcut getiri eğrisinin varlık fiyatlarından elde edilen verilerin "yumuşatılması" yoluyla tanımlandığı istatistiksel tekniklere dayalı modeller.

Anderson vd. (1996) ile Bolder ve Gusba (2002) farklı yöntemler sunmuşlardır. Bu yöntemler şunlardır:

1. McCulloch yöntemi (1971, 1975) iskonto fonksiyonunu uydurmak için bir kübik spline kullanır. Bu amaçla örtük bir düzgünlük cezası kullanılır.

2. Fisher, Nychka ve Zervos (1995) (FNZ) ileri oran fonksiyonunu uydurmak için bir kübik spline kullanır. Ancak bu yöntem, sabit bir pürüzlülük cezası uygulayarak pürüzsüzlük cezasını açık hale getirmektedir.

3. Waggoner (1997) yaklaşımı FNZ yöntemine benzetmekle birlikte değişken bir pürüzlülük cezası getirmesi bakımından farklılık göstermektedir.

4. Anderson ve Sleath (2001), Waggoner (1997) modelinin farklı bir pürüzlülük cezası fonksiyonel formuna sahip bir varyantını geliştirmiştir. Anderson ve Sleath (2001), vadeler boyunca sürekli olarak değişen ve Waggoner'in beş yumuşatma parametresine kıyasla sadece üç parametrenin tahmin edilmesini gerektiren daha karmaşık bir ceza fonksiyonu kullanmıştır.

5. Nelson ve Siegel (1987) tarafından geliştirilen ve Svensson (1994) tarafından genişletilen parametrik yaklaşım, iskonto oranı fonksiyonunun üstel bir yaklaşımını doğrudan tahvil fiyatlarına uyarlar.

İlk dört yöntem spline tabanlı teknikler iken, beşinci yaklaşım cimri bir parametrik yaklaşımdır. Farklı yaklaşımlar, vade yapısındaki gerçek bükülmeleri karşılayacak esneklik ile "pürüzsüzlük" arasında bir değiş tokuş içermektedir. Bu iki yaklaşımın bir özeti ve karşılaştırması aşağıdaki üç bölümde sunulmaktadır.

### **3.1 Spline tabanlı modeller**

McCulloch (1971, 1975) öncülük ettiği spline tabanlı modeller, düğüm noktalarında çeşitli segmentleri birleştirerek bir araya getirilen bir eğri oluşturmak için parçalı kübik polinom kullanmaktadır (McCulloch, 1971). Bu yöntemler, parçaların düzgün ve sorunsuz bir şekilde bağlanmasını sağlamak için daha da geliştirilmiştir (Fisher vd., 1995; Waggoner, 1997). McCulloch'un yönteminde iskonto fonksiyonu bir regresyon spline kullanılarak tahmin edilmektedir. Bu teknikteki en önemli yenilik temel spline kavramıdır. Parçalı polinomların hesaplanması ve tahmin edilmesi, eğrinin ayrı bölgelerinin yakın bölgelerdeki hareketlerden daha az etkilenmesi için ayrı eğri parçalarının birbirinden neredeyse

bağımsız olarak hareket etmesine izin verir. Sonuç olarak, yakın bölgelerdeki hareketler eğrinin ayrı bölümleri üzerinde daha az etkiye sahiptir.

Fisher, Nychka ve Zervos (1995) (FNZ), aşırı "pürüzlülük" için bir ceza ile yumuşatma spline'ları kullanarak ileri oran eğrisini çıkarmak için bir teknik geliştirmiştir. Önerilen düğüm sayısı, tahminde kullanılan tahvil sayısının yaklaşık üçte biridir ve düğümler, bitişik düğümler arasında kabaca eşit sayıda tahvil olgunlaşacak şekilde aralıklı olmalıdır. Ceza, kısa vadeli menkul kıymetlerin yanlış fiyatlandırılmasına yol açan salınım davranışını ve uyumu azaltır (Bliss, 1996). Yöntemin sabit pürüzlülük cezası, vade yapısının daha gerçek eğriliğe sahip olduğu kısa uçta gerekli olan daha fazla esnekliğe izin vermez.

Vasicek ve Fong (1982) da iskonto fonksiyonunu türetmek için spline tabanlı bir model kullanmıştır. İskonto fonksiyonunun üstel formunu, getirilerin türetildiği tahvil fiyatı verilerine uyacak şekilde değiştirmişlerdir. Ancak bu modelin dezavantajı aynı vade tarihine sahip tahvillerin aynı oranda iskonto edilmesine izin vermemesidir (Mastronikola, 1991). Bu modeller, teorik ortalama getiri eğrisi ile gözlemlenen eğriler arasındaki uyumsuzluğun üstesinden gelememektedirler. Böylece gözlemlenen eğriler teorinin ima ettiğiinden önemli ölçüde daha içbükey olmaktadır (Nyman-Andersen, 2018). Bu durum, tahvil getirilerini çeşitli makroekonomik ve finansal değişkenlerin bir fonksiyonu olarak gören çok faktörlü afin modeller kullanılarak çözülebilmektedir (Backus vd., 1998; Cassola ve Barros, 2001).

### **3.2 Spline Tabanlı Modellerin Ayrıntıcı Modellerle Karşılaştırılması**

Anderson vd. (1996) karşılaştırmalı çalışmalarında İngiltere için sıfır kupon getirisini hesaplamak için dört farklı yöntemi ele almaktadır. Tahmin edilen getiri eğrisinin ortaya çıkan dört şekli çok farklı değildir. Ancak, her modelin vadeli faiz eğrileri oldukça farklıdır. Örneğin, hem N&S hem de Svensson modellerinde, vadeli faiz oranlarının düzleştirilmiş bir uzun uca doğru düzgün bir şekilde yöneldiği ima edilmektedir. McCulloch modelinde ise vadeli faizler vadeye göre dalgalanmakta, vadeye kalan süre uzadıkça dik bir şekilde yükselmektedir. Son olarak, Mastronikola (1991) modelindeki vadeli faiz eğrisi incelendiğinde, eğrinin

uzun uçta düzleştiği ve NS ve Svensson modellerinden daha fazla eğrilik sergilediği görülmektedir.

Yukarıdaki karşılaştırmalı çalışmaların gösterdiği gibi, hangi modelin kullanıldığına bağlı olarak, getiri eğrisi tahminlerinde pürüzsüzlük ve uyum faktörü arasında sürekli bir değiş tokuş vardır. O halde, bir yandan çok esnek olan, verilere aşırı uyan veya aykırı değerleri norm olarak kabul eden modeller ile diğer yandan çok ayrıntıcı olan modeller arasında bir denge kurmak gerekir. Herhangi bir seçim sürecinin bir parçası olarak, getiri eğrisi tahminlerinde pürüzsüzlük ve uyum faktörü arasındaki denge, getiri eğrisinin nihai kullanım amacına bağlıdır. Bu bağlamda tahmin edilen bir getiri eğrisi, her veri noktasına (ve aykırı değere) uymamalı, ancak piyasa beklentilerinin bir göstergesi olarak düzgün bir eğriyi temsil etmelidir. Bununla birlikte, eğri gerçek beklentileri yansıtmalı ve altta yatan vade yapısındaki hareketleri yakalayacak kadar esnek olmalıdır.

Avrupa Birliği içinde, birçok üye devletin ulusal merkez bankaları getiri eğrilerini tahmin etmekte ve bazı durumlarda bu ulusal getiri eğrileri kamuoyuna da açıklanmaktadır. Bazı ulusal merkez bankaları hem spline tabanlı hem de cimri modeller kullanmaktadır. Nelson & Siegel ve Svensson modelleri Euro bölgesinde hâkim modellerdir (BIS, 2005). Seçilen araçlar çoğunlukla para piyasası araçları ve devlet tahvilleridir ve bazı durumlarda bu araçlar birleştirilerek aynı eğri içinde kullanılmaktadır.

Finansal piyasalardaki dalgalanmaların ve risklerin doğru bir şekilde değerlendirilmesi için getiri eğrisinin hem düzgün bir şekilde temsil edilmesi hem de piyasa beklentilerini yansıtmaları önemlidir. Nelson & Siegel ve Svensson modelleri, çeşitli vade yapısındaki faiz oranlarını uygun bir şekilde yakalayabilen ve aynı zamanda gelecekteki faiz oranı hareketlerini tahmin etmede esneklik sağlayan sofistike matematiksel yapılarıyla bu gereksinimleri karşılamaktadır. Bu modeller, finansal karar alıcılara, getiri eğrisinin altında yatan ekonomik dinamikleri daha iyi anlama ve gelecekteki piyasa koşullarını daha doğru bir şekilde değerlendirme imkânı sunar. Bu nedenle, ulusal merkez bankaları gibi önemli kuruluşlar, bu ayrıntılı modelleri tercih ederek daha güvenilir ve kapsamlı getiri eğrisi tahminleri elde etmeyi amaçlarlar. Bu nedenle bu çalışmada getiri

eğrisinin hassas bir şekilde tahmin edilmesi gerekliliği nedeniyle ayrıntıcı modeller tercih edilmiştir.

### 3.3 Ayrıştırılabilir Fonksiyonel Formlar

#### 3.3.1 Nelson-Siegel Modeli

Nelson-Siegel (1987) modeli, faiz oranlarının vade yapısını modellemek ve tahmin etmek için yaygın olarak kullanılan bir parametrik eğri uydurma modelidir. İlk olarak 1987 yılında Nelson ve Siegel tarafından önerilen model, getiri eğrisinin seviye, eğim ve eğrilik faktörlerini yakalamak için bir dizi getiriye parametrik bir eğri uydurur (Diebold ve Li, 2006). Model yıllar içinde çeşitli yönlerini ve sınırlamalarını ele almak için genişletilmiş ve rafine edilmiştir.

Nelson-Siegel (NS) forward faiz eğrisi, bir sabit eklenmiş polinom zamanları üstel bir bozunma terimi ve popüler bir matematiksel yaklaşma fonksiyonu olan bir Laguerre fonksiyonu olarak görülebilir (Bolder ve Gusba, 2002; Diebold ve Li, 2006). Böylece anlık forward oranı için aşağıdaki çözümü verirler:

$$f(\theta) = \beta_0 + \beta_1 e^{-\frac{\theta}{\tau_1}} + \beta_2 e^{-\frac{\theta}{\tau_2}} \quad (3.1)$$

burada  $\tau_1$  ve  $\tau_2$  diferansiyel denklemin reel kökleridir. Ancak NS, modelin aşırı parametrelili olduğu sonucuna varmış ve eşit kök çözümü kullanmaya karar vermiştir. Dolayısıyla anlık forward oran fonksiyonu:

$$f(\theta) = \beta_0 + \beta_1 e^{-\frac{\theta}{\tau}} + \beta_2 \left[ \frac{\theta}{\tau} e^{-\frac{\theta}{\tau}} \right], \quad (3.2)$$

burada  $\theta = T - t$  dir.  $[t, T]$  periyodundaki getiri,  $[t, t + dt]$  periyodunda aktif olan oranların toplamının ortalaması olduğundan, bu basit sezgi ile getiri  $R(\theta)$  Denklem (3.1)'in integrali olarak tanımlanabilir. Yani,

$$R(t, T) = \frac{1}{T - t} \int_t^T f(s, T) ds \quad (3.3)$$



Burada  $R(t, T)$ ,  $t$  ile  $T$  arasındaki getiri olarak tanımlanır. İleri (forward) faiz oranı  $f(s, T)$ ,  $s \in [t, T]$  aralığında geçerli olan anlık faiz oranıdır. Denklem (3.3), getiri  $R(t, T)$  nin,  $f(s, T)$  nin ortalaması olduğunu ifade eder. Ekonomik bakış açısıyla, dönem boyunca uygulanacak “anlık faizlerin” yıllıklaştırılmış ortalamasına eşittir.

$$R(t, T) = \frac{1}{T-t} \int_t^T \left( \beta_0 + \beta_1 e^{-\frac{(T-s)}{\tau}} + \beta_2 \left[ \frac{(T-s)}{\tau} e^{-\frac{(T-s)}{\tau}} \right] \right) ds \quad (3.4)$$

Burada,  $f(s, T)$  yerine Nelson-Siegel modelinin özel formu yazılmıştır.  $\beta_0$ ,  $\beta_1$  ve  $\beta_2$ , sırasıyla *seviye*, *eğim* ve *eğrilik* parametreleridir.  $\tau$ , getiri eğrisindeki üstel çürümenin “zaman ölçeği”ni belirler.  $(T - s)$ , vadeye kalan süreyi yansıtır. Bu integrali çözerek kapalı formda bir getiri fonksiyonuna ulaşmak mümkündür.

$$R(t, T) = \beta_0 + (\beta_1 + \beta_2) \frac{1 - e^{-\frac{(T-s)}{\tau}}}{\frac{(T-s)}{\tau}} - \beta_2 e^{-\frac{(T-s)}{\tau}} \quad (3.5)$$

Denklem (3.5), (3.4)’teki integrali *kapalı formda* çözmeyi sonucudur. Kısa vadede ( $T - s$  küçükken)  $\beta_1$  ve  $\beta_2$  terimleri daha baskın olurken, uzun vadede ( $T - s$  büyükken) üstel terimler sönümlenerek  $\beta_0$  hâkim duruma gelir.

$$\begin{aligned} R(t, T) &= \frac{1}{\theta} \int_t^T \left( \beta_0 + \beta_1 e^{-\frac{s}{\tau}} + \beta_2 \left[ \frac{s}{\tau} e^{-\frac{s}{\tau}} \right] \right) ds \\ &= \frac{1}{\theta} \int_0^\theta f(s) ds \\ &= R(\theta) \end{aligned} \quad (3.6)$$

Burada  $\theta = T - t$  alınarak, integral sınırları  $t$  den  $T$  ye yerine  $0$  dan  $\theta$  ya dönüştürülmüştür.  $R(\theta)$  ifadesi, artık getiri fonksiyonunun yalnızca vade uzunluğuna ( $\theta$ ) bağlı olduğunu vurgular. Matematiksel olarak,  $\theta$  kadar süre boyunca geçerli olacak anlık faiz  $f(s)$  nin ortalamasını temsil eder.

$$\begin{aligned}
R(t, T) &= \frac{1}{\theta} \int_0^\theta f(s) ds \\
&= R(\theta)
\end{aligned}
\tag{3.7}$$

Böylece  $t$  zamanı yerine “ $\theta$  kadar ileriye” bakılan, daha sade bir gösterim elde edilir.

$$R(t, T) = \frac{1}{\theta} = R(\theta) \tag{3.8}$$

NS parametrik ailesi, teknik olarak faktör yüklenme eğrileri olarak adlandırılan ve genellikle getirilerin cimri bir şekilde enterpolasyonu için kullanılan 3 fonksiyon içerir. Yani Nelson-Siegel forward oran eğrisi, üstel bir çürüme terimi olan ve popüler bir matematiksel yaklaşma fonksiyonu olan bir polinom olan bir sabit artı bir Laguerre fonksiyonu olarak görülebilir. Karşılık gelen getiri eğrisi,

$$\begin{aligned}
y_t(\tau) &= \beta_{1t} + \beta_{2t} \left( \frac{1 - \exp(-\lambda_t \tau)}{\lambda_t \tau} \right) \\
&+ \beta_{3t} \left( \frac{1 - \exp(-\lambda_t \tau)}{\lambda_t \tau} - \exp(-\lambda_t \tau) \right) + \epsilon_t(\tau)
\end{aligned}
\tag{3.9}$$

Burada  $\epsilon_t(\tau) \sim N(0, \sigma_\epsilon^2)$  ve  $y_t(\tau)$ ,  $t$  zamanında vadesi  $\tau$  olan getiri eğrisini göstermektedir. Üç faktör,  $\beta_{1t}$ ,  $\beta_{2t}$  ve  $\beta_{3t}$  sırasıyla seviye, eğim ve eğrilik olarak belirtilmektedir.  $\tau$  parametresi, eğim ve eğrilik faktörleri için yüklerin üstel olarak azalan oranını kontrol etmektedir ve daha küçük bir değer daha yavaş bir bozulmaya neden olurken, büyük değerler hızlı bozulmaya yol açmaktadır. Geniş bir değerler aralığında, NS getiri eğrisinin uyum iyiliğinin  $\tau$  'nun spesifik değerine çok duyarlı değildir (Chen ve Niu, 2014).

NS modelin avantajı, parametrelerinin yorumlanabileceği kolaylıktır. Yalnızca dört parametresi vardır ve bu nedenle, anlaşılması kolaydır. Ayrıca fazla

uydurmaya daha az eğilimlidir ve daha pürüzsüzdür. Ayrıca diğer modellerin aksine vade sayısı arttıkça parametre sayısı da artmamaktadır.  $\tau$  sıfıra ve sonsuza yaklaştıkça spot oran eğrisinin sınırlarını alarak Nelson ve Siegel (1987), uzun vadeli bileşenin katkısının  $\beta_{1t}$  olduğunu ve kısa vadeli bileşenin katkısının  $\beta_{1t} + \beta_{2t}$  olduğunu bulmuştur. Ayrıca  $\beta_{2t}$ , uzun vadeli ve kısa vadeli getiriler arasındaki fark olduğu için vadeli prim olarak yorumlanabilir (Alper vd., 2004).

Bu form iktisadi olarak, getiri eğrisinin kısa vadeli para politikası beklentilerinden kaynaklanan değişik vadelerdeki fiyatlandırmaları yakalayan bir bileşen, orta vadeli konjonktür dalgalanması beklentilerinden kaynaklanan fiyatlandırma davranışını yakalayan, böylece getiri eğrisinde bir kıvrım olmasına izin veren bir bileşen ve uzun vadede, ekonominin durağan düzeyindeki faiz beklentisini yakalayan bir bileşen olarak yorumlanabilir (Özge vd., 2006).

$\beta_1$ , vadeye kalan gün sonsuza yakınsarken getirilerin limit değerini vermektedir yani  $\lim_{t \rightarrow \infty} y_t(\tau) = \beta_1$ . Bu parametre piyasa katılımcılarının ekonominin durağan düzeyindeki faiz beklentisini (bir vade primi ile) vermektedir. Vadeye kalan gün sıfıra giderken yani  $\lim_{t \rightarrow 0} y_t(\tau) = \beta_1 + \beta_2$  anlık faiz oranını vermektedir.

Dolayısıyla  $\beta_2$  uzun vadeli getiri ile kısa vadeli getiri arasındaki farka eşittir. Diğer bir ifadeyle  $\beta_2$  getiri eğrisinin eğiminin negatif işaretli değeridir.  $\tau$ , getiri eğrisinde meydana gelecek kıvrımın hangi vadede yer alacağını belirlemektedir.  $\beta_3$  getiri eğrisindeki kıvrımının büyüklüğünü ve yönünü belirler.  $\beta_3$  negatif ise, vadenin  $\tau$ 'ya eşit olduğu noktada getiri eğrisi çukur şeklini alırken  $\beta_3$  pozitif ise, vadenin  $\tau$ 'ya eşit olduğu noktada getiri eğrisi tümsek şeklini almaktadır. Bu parametre,  $\tau$  ile, konjonktür dalgalanmasına bağlı olarak beklenen faiz patikasını getiri eğrisine dahil etmektedir (Ayliffe, 2020).

Ekonomik teoriye, yani iki önemli kısıtlamaya uymaktadır:

1. 0 vadeli tahvilin fiyatı 1 TL olmalıdır.
2.  $\lim_{\tau \rightarrow \infty} P(\tau) = 0$ : vade sonsuz yaklaştıkça fiyat sıfır olmalıdır.

Nelson-Siegel modeli, tahmin yeteneklerini geliştirmek ve belirli zorlukları ele almak için yıllar içinde genişletilmiş ve değiştirilmiştir. Christensen vd. (2011) tahmin edilmesi kolay olan ve doğru getiri eğrisi tahminleri sağlayan dinamik Nelson-Siegel (DNS) modelini tanıtmıştır. Bu dinamik versiyon, zaman içinde parametrelerde değişiklik yapılmasına izin vererek modelin esnekliğini ve tahmin gücünü artırmaktadır. Ayrıca, Nelson-Siegel modelini arbitraj yokluğu ile uzlaştırmak için afin arbitrajsız Nelson-Siegel (AFNS) modeli geliştirilerek daha sağlam ve güvenilir vade yapısı modellenmesi sağlanmıştır.

Araştırmacılar Nelson-Siegel modelinin, daha iyi bir uyum için ek parametreler içerecek şekilde orijinal modeli genişleten Nelson-Siegel-Svensson (NSS) modeli gibi çeşitli uyarlamalarını araştırmışlardır (Svensson, 1994). Svensson, daha karmaşık getiri eğrisi dinamiklerini yakalamak için modeli dört faktörlü bir versiyona genişletmiştir (Ishii, 2019). Bu genişletmeler, daha geniş bir yelpazedeki getiri eğrisi şekillerini ve davranışlarını yakalamayı amaçlamaktadır.

Sonuç olarak, Nelson-Siegel modeli, esnekliğini, doğruluğunu ve zaman içinde getiri eğrisinin dinamiklerini yakalama yeteneğini artırmayı amaçlayan çeşitli uzantılar ve iyileştirmelerle faiz oranı modellenmesinde temel bir araç olmaya devam etmektedir.

### **3.3.2 Nelson–Siegel–Svensson Modeli**

Nelson-Siegel-Svensson (NSS) modeli, getiri eğrisini tanımlamak için esnek ve basit bir yol sağlayan, finans alanında yaygın olarak kullanılan bir vade yapısı modelidir. İlk olarak Nelson ve Siegel (1987) tarafından tanıtılan ve Svensson (1997) tarafından genişletilen bu model, getirilerin kesitine etkin bir şekilde uyma kabiliyeti nedeniyle finansal piyasa uygulayıcıları, merkez bankaları ve araştırmacılar arasında popülerdir (Christensen vd., 2009; Christensen vd., 2011).

Model, getiri eğrisinin seviyesini, eğimini ve eğriliğini yakalayan üç faktöre dayanmaktadır ve Svensson (1997)'nin uzantısı modelin esnekliğini artırmak için ikinci bir eğrilik faktörü eklemiştir (Christensen vd., 2009). NSS modeli daha da geliştirilmiş ve getiri eğrilerinin tahmin edilmesi, faiz oranı dinamiklerinin tahmin edilmesi ve opsiyon zımni oynaklığının analiz edilmesi gibi çeşitli bağlamlarda uygulanmıştır (Chen ve Niu,

2014; Guo vd., 2014; Kim vd., 2020). Ayrıca, tahmin yeteneklerini geliştirmek için zamanla değişen parametreleri, stokastik oynaklığı ve rejim değiştirme özelliklerini içerecek şekilde genişletilmiştir (Koopman vd., 2010; Hautsch ve Yang, 2012; Eo ve Kang, 2020). Ayrıca NSS modelinin tahmin ve fiyatlandırma uygulamalarındaki performansını artırmak için Dinamik Nelson-Siegel modeli, afin arbitrajsız modeller ve derin öğrenme yaklaşımları gibi farklı varyasyonları geliştirilmiştir (Chen ve Niu, 2014; Kratsios ve Hyndman, 2020; Eo ve Kang, 2016). Bu gelişmeler, modelin arbitrajsız kısıtlamaların olmaması ve örneklem dışı tahmin doğruluğunun daha iyi olması gibi sınırlamalarını ele almaktadır (Ullah, 2015; Kawakatsu, 2020).

Modelin faiz oranlarının vade yapısını doğru bir şekilde yakalama kabiliyeti, onu para politikası analizi, risk yönetimi ve finansal piyasa tahmini için değerli bir araç haline getirmiştir (Gilli vd., 2010; Ullah vd., 2013; Dziwok ve Karaş, 2021).

Genel olarak Nelson-Siegel-Svensson modeli, faiz oranlarının vade yapısını modellemek, getiri eğrisi dinamikleri hakkında içgörü sağlamak ve hem akademik hem de pratik ortamlarda çeşitli finansal analizleri ve karar alma süreçlerini desteklemek için temel bir çerçeve olmaya devam etmektedir. Uyarlanabilirliği, basitliği ve getiri eğrisinin kritik özelliklerini yakalamadaki etkinliği, finansal modelleme ve ekonometrik araştırmalarda bir köşe taşı olarak konumunu sağlamıştır.

### 3.3.3 Diebold-Li Modeli

Nelson-Siegel modelinin parametrelerinin bir başka yorumu Diebold ve Li (2003) tarafından önerilmektedir. Diebold ve Li'ye (2003) göre,  $\beta_0$ ,  $\beta_1$  ve  $\beta_2$  getiri eğrisinin üç gizli faktörü olarak yorumlanabilir.  $\beta_0$  üzerindeki yük birdir ve limitte sifıra düşer; dolayısıyla getiri eğrisi seviyesi olarak yorumlanabilir. Ayrıca,  $\beta_0$ 'daki bir artış tüm getirileri eşit oranda artırır. Belirttiğimiz gibi,  $\beta_1$  kısa vadeli getiridir ve getiri eğrisinin eğimi olarak yorumlanabilir.  $\beta_1$ 'deki bir artışın kısa getirileri uzun getirilerden daha fazla artırdığına ve böylece getiri eğrisinin eğimini değiştirdiğine dikkat edin. Son olarak,  $\beta_2$  getiri eğrisinin eğriliği olarak yorumlanabilir.  $\beta_2$ 'deki bir artışın kısa ve uzun getiriler üzerinde çok az etkisi vardır, ancak orta vadeli getirileri artırır.

Nelson-Siegel fonksiyonu statik bir modelken, Diebold-Li modeli bu fonksiyonun dinamik bir versiyonudur. Zaman boyunca değişen dinamik faktörler ( $\beta_{1,t}, \beta_{2,t}, \beta_{3,t}$ ) otoregresif bir süreçle modellenir:

$$\beta_{i,t} = \phi_i \beta_{i,t-1} + \epsilon_{i,t} \quad (3.10)$$

Bu yaklaşım, modelin hem geçmiş verilere dayanarak mevcut tahminler yapmasını hem de ileriye dönük öngörülerde bulunmasını sağlar.

Diebold-Li modeli, getiri eğrisini üç temel faktörle açıklayarak ekonomik anlamlar çıkarılmasını kolaylaştırır. Seviye, eğim ve eğrilik faktörleri, getiri eğrisinin temel dinamiklerini temsil eder ve makroekonomik değişkenlerle doğrudan ilişkilidir. Örneğin, seviye faktörü uzun vadeli büyüme ve enflasyon beklentilerini yansıtırken, eğim faktörü kısa vadeli faiz oranları ve likidite koşullarını açıklamaktadır (Diebold & Li, 2006). Bu model, hem kısa vadeli hem de uzun vadeli getiriler üzerinde etkili sonuçlar sunarak farklı piyasa yapıları ve ekonomik koşullara kolayca uyarlanabilir. Türkiye gibi volatil piyasalarda kısa vadeli dalgalanmaları yakalarken, ABD ve Avrupa gibi daha istikrarlı piyasalarda uzun vadeli tahvil dinamiklerini başarıyla açıklamaktadır (BIS, 2008).


Dinamik faktörlerin zaman serisi doğası, getiri eğrisinin zaman içindeki değişimlerini yakalamada güçlü bir araçtır. Otoregresif süreçlerle modellendiği için hem geçmiş verilerle analiz yapılabilir hem de ileriye dönük tahminler oluşturulabilir (Diebold vd., 2006). Ayrıca, literatürde sıklıkla diğer modellerle karşılaştırılmış ve genellikle daha iyi tahmin performansı gösterdiği ortaya konmuştur. Özellikle kısa vadeli tahvil getirilerindeki oynaklık ve uzun vadeli eğilimlerin tahmin edilmesinde üstün bir performans sergilemiştir (Christensen vd., 2011). Basit yapısı ve optimize edilebilir parametreleri, modelin uygulamalı finans çalışmalarında geniş bir kullanım alanı bulmasını sağlamaktadır (Diebold ve Rudebusch, 2013). Ayrıca, para politikası ve ekonomik beklentilerin getiri eğrisi üzerindeki etkilerini analiz etmek için de güçlü bir araçtır, bu da merkez bankalarının politika etkilerini tahmin etme ve piyasa tepkilerini değerlendirme konusunda modelin önemini artırmaktadır.

Şekil 3.1, modelin temel parametreleri olan seviye  $\beta_1$ , eğim  $\beta_2$  ve eğrilik  $\beta_3$  faktörlerinin vadeye bağlı etkilerini görselleştirmektedir. Grafik, her bir faktörün farklı

vadelerde tahvil getirileri üzerindeki etkisini ayrıştırarak modelin yapısal dinamiklerini daha anlaşılır hale getirmektedir. Seviye faktörü  $\beta_1$ , vadeden bağımsız olarak sabit bir etki gösterir ve uzun vadeli faiz oranlarının genel seviyesini temsil eder. Bu durum, modelin tahvil piyasasındaki uzun vadeli beklentileri anlamada sağlam bir temel sunduğunu göstermektedir.

Eğim faktörü  $\beta_2$ , özellikle kısa vadelerde güçlü bir etkiye sahiptir ve vadeler uzadıkça etkisi azalarak sifıra yaklaşır. Bu durum, kısa vadeli tahvil getirilerinin uzun vadeli tahvillerle karşılaştırıldığında daha fazla dalgalandığını ve para politikası değişikliklerine daha duyarlı olduğunu göstermektedir. Eğrilik faktörü  $\beta_3$  ise, kısa vadelerde sıfırdan başlayarak orta vadelerde (5-10 yıl) zirve yapar ve ardından uzun vadelerde etkisi giderek azalır. Bu durum, eğrilik faktörünün getiri eğrisinin orta vadeli dinamiklerini yansıttığını ve piyasanın orta vadede nasıl fiyatlandığını açıklamada kritik bir rol oynadığını ortaya koymaktadır.

Genel olarak, bu grafik, Diebold-Li modelinin tahvil piyasasındaki farklı vadelerdeki dinamikleri ayrıştırmada ne kadar etkili olduğunu göstermektedir. Faktörlerin vadelere göre ayrışması, piyasa oyuncularının kısa, orta ve uzun vadeli risk ve getiri beklentilerini anlamada güçlü bir araç sunar. Model, özellikle ekonomik analizlerde farklı vade segmentlerindeki değişkenliklerin ayrıştırılmasına ve yorumlanmasına olanak tanıyarak, hem akademik hem de uygulamalı finans çalışmalarında değerli bir katkı sağlar.



Şekil 3.1 Diebold-Li Modeli Faktör Yükleri

### 3.4. Karşılaştırılan Modeller

Bu bölümde, getiri eğrisini tahmin etmek için kullanılan modeller tanıtılmakta ve performansları karşılaştırılmaktadır. Çalışmada, hem standart kıyaslama modelleri hem de getiri eğrisinin farklı vadeler arasındaki dinamiklerini ele alan gelişmiş modeller değerlendirilmiştir. Seçilen yöntemler, literatürdeki Brechtken (2008) ve Caldeira ve ark. (2019) gibi çalışmalara dayanmaktadır. Kullanılan başlıca modeller arasında Rastgele Yürüyüş (RW), Otokorelasyon (AR), Vektör Otokorelasyon (VAR) ve gelişmiş bir model olan Dinamik Nelson-Siegel Kalman Filtresi (DNS-KF) bulunmaktadır.

#### 3.4.1. Rastgele Yürüyüş (RW)

Rastgele Yürüyüş modeli, incelenen en basit yöntemdir ve diğer modellerin performansını değerlendirmek için bir kıyaslama standardı olarak kullanılır. Bu model,



getiri eğrisindeki değişimlerin tamamen rastgele ve zamandan bağımsız olduğunu varsayar.

Vadesi  $\tau$  olan bir getiriyi ( $y(\tau)$ ) ele alırsak model şu şekilde ifade edilir:

$$y_{t+1}(\tau) = y_t(\tau) + \varepsilon_t(\tau), \quad i = 1, \dots, T \quad (3.11)$$

burada  $y_t(\tau)$ ,  $t$  zamanındaki  $\tau$  vadeli getiri,  $\varepsilon_t(\tau) \sim \mathcal{N}(0, \sigma^2(\tau))$  normal dağılıma sahip hata terimidir. Herhangi bir  $T + h$  dönemdeki tahmin ise şu şekilde ifade edilir:

$$\hat{y}_{T+h}(\tau) = y_T(\tau) \quad (3.12)$$

Bu yaklaşım, yarının getirisini tahmin etmenin en iyi yolunun bugünkü getiri olduğunu varsayar. Basitliği nedeniyle sıkça kullanılır; ancak piyasaların etkin olduğu durumlarda bu modelin aşılması genellikle zordur.

### 3.4.2 Otoregresyon (AR)

Otokorelasyon (AR) modeli, tek bir vadede geçmiş değerlerin mevcut ve gelecekteki getiriler üzerindeki etkisini modellemeye yönelik bir yöntemdir. AR modelleri, her vadeyi ayrı ayrı ele alır ve bu vadeler arasındaki etkileşimleri göz ardı eder.

AR(1) modeli şu şekilde ifade edilir:

$$y_t(\tau) = \alpha + \phi y_{t-1}(\tau) + \varepsilon_t(\tau), \quad i = 1, \dots, T \quad (3.13)$$

burada  $\alpha$  sabit terim,  $\phi$  otokorelasyon katsayısı, bir önceki dönemin getirisinin mevcut getiri üzerindeki etkisini temsil ederken,  $\varepsilon_t(\tau) \sim \mathcal{N}(0, \sigma^2(\tau))$  normal dağılıma sahip hata terimidir. Herhangi bir  $T + h$  dönemdeki tahmin ise şu şekilde ifade edilir:

$$\hat{y}_{T+h}(\tau) = \hat{\alpha} + \hat{\phi} y_{T+h-1}(\tau) \quad (3.14)$$

AR modelleri kısa vadeli bağımlılıkları anlamada başarılıdır; ancak vadeler arasındaki dinamikleri ele almadığı için çok değişkenli bir yapıyı temsil etmekte yetersizdir.

### 3.4.3. Vektör Otoregresyon (VAR)

Vektör Otokorelasyon (VAR) modeli, birden fazla vadeyi aynı anda ele alarak vadeler arasındaki dinamik etkileşimleri modellemesine olanak tanır. VAR modelleri, getiri eğrisini etkileyen ortak şokları ve vadeler arasındaki karşılıklı ilişkileri yakalayabilir.

VAR(1) modeli şu şekilde tanımlanır:

$$\mathbf{y}_t = \mathbf{A}_0 + \mathbf{A}_1 \mathbf{y}_{t-1} + \varepsilon_t, \quad i = 1, \dots, T \quad (3.15)$$

Burada  $\mathbf{y}_t = [y_t(\tau_1), y_t(\tau_2), \dots, y_t(\tau_n)]^T$  vektör halinde birden fazla vadenin getirileri,  $\mathbf{A}_0$  sabit terim vektörü,  $\mathbf{A}_1$  vadeler arası ilişkileri temsil eden katsayı matrisi iken  $\varepsilon_t \sim \mathcal{N}(\mathbf{0}, \Sigma)$  çok değişkenli normal dağılıma sahip hata terimidir.

VAR modelleri, vadeler arası bağımlılıkları anlamada güçlüdür; ancak çok sayıda parametre gereksinimi nedeniyle aşırı öğrenme (overfitting) riski taşır. Ayrıca, modelin tahmin performansı, seçilen gecikme sayısına ( $p$ ) bağlıdır. Bu nedenle, VAR modellerinin uygulanabilirliği, veri setinin büyüklüğüne ve kalitesine bağlıdır.

### 3.4.4. DNS-KF Modelleme

Faiz oranı dinamiklerini modellemekte kullanılan Nelson–Siegel (NS) yaklaşımı, getiri eğrisini üç temel faktör ( $L$ ,  $S$ ,  $C$ ) yardımıyla özetler. Zaman içinde bu faktörleri tahmin etmek ve geleceğe yönelik projeksiyonlar elde etmek adına Kalman filtre temelli yöntemler sıklıkla tercih edilir. Diebold ve Li (2006) ile başlayan DNS yaklaşımı, hem iki adımlı (önce NS faktörlerini OLS ile bulup ardından bir VAR(1) tahmini) hem de tek adımlı Kalman filtre (DNS-KF) biçiminde literatürde yer almıştır.

Diebold ve Li (2006) ile popülerlik kazanan bu yöntemde, zaman içinde faktörleri ( $L$ ,  $S$ ,  $C$ ) tahmin etmek ve çok adımlı öngörüler (multi-step forecast) elde etmek amacıyla bir Kalman filtre (KF) çerçevesine başvurulabilir. Böylelikle, hem faktörlerin ( $L$ ,  $S$ ,  $C$ ) hem de parametrelerin eşanlı biçimde tahmini mümkün olur.

Ancak standart DNS-KF formülasyonlarında,

- ilk kovaryans (hem gözlem hem durum kovaryansları)
- offset parametreleri (durum geçişinde sabit terim vb.)
- özdeğer büyüklüğünün (eigenvalue) 1’i aşması halinde oluşan “eksplozif” dinamik sorunları gibi zorluklar söz konusu olabilir. Bu çalışma, söz konusu sorunlara bir dizi iyileştirme önermektedir.

Bu iyileştirmeler;

1. Veri-tabanlı başlangıç kovaryans seçimleri,
2. Offset (kayma) parametrelerinin EM algoritmasıyla öğrenilmesi,
3. Eigenvalue clipping ile patlayıcı VAR(1) sürecinin yumuşak biçimde stabilize edilmesi ve
4. Manuel EM döngüsüyle log-likelihood yakınsamasının izlenmesi olarak özetlenebilir. Bu eklemeler sayesinde DNS-KF’nin hem yakınsama hızı hem de tahmin performansı artış gösterecektir.

Standart DNS-KF formülasyonlarında, başlangıç kovaryanslarının veya offset parametrelerinin yeterince veri-tabanlı ayarlanmaması, yakınsama zorlukları, “eksplozif” VAR(1) durumu gibi sorunlarla karşılaşılabilir. Bu çalışmada, söz konusu DNS-KF yapısına eklenen basit ama etkili iyileştirmelerin (özellikle veri-tabanlı başlangıç kovaryansı, offset öğrenimi ve eigenvalue clipping) modeli daha stabil hâle getirdiği gösterilmektedir.

Nelson–Siegel modeli,  $\tau$  vadesi için getiri  $y_t(\tau)$  değerini şu üç faktör yardımıyla açıklamaktadır:

$$y_t(\tau) = L_t + S_t \left( \frac{1 - \exp(-\lambda_t \tau)}{\lambda_t \tau} \right) + C_t \left( \frac{1 - \exp(-\lambda_t \tau)}{\lambda_t \tau} - \exp(-\lambda_t \tau) \right) + \epsilon_t(\tau) \quad (3.16)$$

burada  $L_t$ ,  $S_t$  ve  $C_t$  sırasıyla uzun vadeli seviye, eğim ve kamburluk faktörlerini temsil eder;  $\lambda$  sabit parametre (exponential decay) olarak alınır. Bu formülasyon, yüksek boyutlu “maturity” (vade) uzayını yalnızca 3 faktörle açıklayarak büyük basitlik sağlar.

#### 3.4.4.1 Durum (State) Vektörü ve Gözlem (Observation) Matrisi

Zaman serisi boyunca  $t = 1, \dots, T$  anlarında gözlemlenen  $\mathbf{y}_t \in \mathbb{R}^M$  olsun; burada  $M$  farklı vade (ör. 3 ay, 6 ay, 1 yıl, ...) yer alıyor. Nelson–Siegel, getiri vektörünü şu şekilde temsil eder:

$$\mathbf{y}_t = \mathbf{H}\beta_t + \mathbf{u}_t, \quad (3.17)$$

burada  $\beta_t = [L_t, S_t, C_t]^T \in \mathbb{R}^3$ ,  $\mathbf{H} \in \mathbb{R}^{M \times 3}$  “tasarım matrisi” (design matrix),  $\mathbf{u}_t$  gürültü (gözlem hatası),  $\mathbf{u}_t \sim \mathcal{N}(\mathbf{0}, \mathbf{R})$ .

Tasarım matrisi  $\mathbf{H}$ ,  $\tau_i$  vadeleri için:

$$\mathbf{H} = \begin{bmatrix} 1 & \frac{1 - e^{-\lambda\tau_1}}{\lambda\tau_1} & \frac{1 - e^{-\lambda\tau_1}}{\lambda\tau_1} - e^{-\lambda\tau_1} \\ 1 & \frac{1 - e^{-\lambda\tau_2}}{\lambda\tau_2} & \frac{1 - e^{-\lambda\tau_2}}{\lambda\tau_2} - e^{-\lambda\tau_2} \\ \vdots & \vdots & \vdots \\ 1 & \frac{1 - e^{-\lambda\tau_M}}{\lambda\tau_M} & \frac{1 - e^{-\lambda\tau_M}}{\lambda\tau_M} - \lambda\tau_M \end{bmatrix}, \quad (3.18)$$

#### 3.4.4.2 Faktör Dinamiği (Geçiş Denklemi)

NS faktörlerinin zaman içindeki evrimi çoğunlukla bir **VAR(1)** veya **AR(1)** tipi süreçle modellenir:

$$\beta_{t+1} = \mathbf{A}\beta_t + \mathbf{d} + \boldsymbol{\eta}_t, \quad (3.19)$$

burada  $\mathbf{A} \in \mathbb{R}^{3 \times 3}$  geçiş matrisi,  $\mathbf{d}$  sabit bir ofset (drift) vektörü,  $\mathbf{Q}$  durum gürültüsü kovaryansı olmak üzere  $\boldsymbol{\eta}_{t+1} \sim \mathcal{N}(\mathbf{0}, \mathbf{Q})$ .

Bu iki denklem birlikte durum uzayı (state-space) formülasyonunu oluşturur ve bir Kalman filtre yardımıyla ( $\beta_t$ ) hem tahmin ( $\hat{\beta}_{t|t-1}$ ) hem de güncel kestirim ( $\hat{\beta}_{t|t}$ ) yapılabilir.

DNS-KF (tek adımda) yaklaşımında, A,d,Q,H,R gibi parametreler E-steps / M-steps (EM algoritması) ile veri üzerinden öğrenilir. Pykalman veya benzeri paketler, Kalman filtreyi “beklenen tam log-likelihood” fonksiyonunu maksimize edecek şekilde iteratif günceller.

Ancak pratikte:

1. Başlangıç Kovaryans Seçimi:  $\mathbf{Q}$  ve  $\mathbf{R}$  genelde sabit bir  $\alpha \mathbf{I}$  ile başlatılır (ör.  $\alpha = 0.1$ ). Veri seti büyükse ya da getiri oynaklığı farklıysa,  $\alpha$  küçük veya büyük seçildiğinde EM yakınsaması tutarsız olabilir.
2. Offset (d) Varsayımı:  $\mathbf{d} = 0$  alındığında, reel veride ortalama drift varsa model onu yakalayamaz.
3. Eksplozif VAR(1):  $\rho(\mathbf{A}) > 1$  (matrisin en büyük özdeğeri 1’i aştığında), faktörler “patlayıcı” şekilde büyüyebilir. Birçok ampirik çalışmada bu durum “ekonomik mantık dışı” görülür.
4. EM Yakınsama: Sabit iterasyon sayısı (ör. 50) her zaman ideal olmayabilir; bazen 10 iterasyonda yakınsarken bazen 100 iterasyon bile yetmeyebilir.

Bu tezde, DNS-KF’yi daha kararlı kılmak ve performansı artırmak adına şu 4 iyileştirme uygulanmaktadır:

### i) Veri-Tabanlı Başlangıç Kovaryansı

$\mathbf{Q}$  ve  $\mathbf{R}$  matrislerini, tamamen  $\alpha \mathbf{I}$  sabit varsaymak yerine:

- Eğer elimizde kısa bir faktör serisi (VAR(1) ile kestirilmiş  $\hat{\beta}_t$ ) varsa, bu serinin kalıntıları kullanarak  $\hat{\mathbf{Q}}$  tahmini yapılabilir.

- Gözlem kovaryansı  $\mathbf{R}$  için, veride NS tahmini ile gerçek arasındaki farkları inceleyip kabaca bir tahmin almak mümkündür.

Başlangıçta bu değerlere yakın bir matrisle EM'e girildiğinde, ilk adımlarda daha düşük varyans veya daha mantıklı varyans tahminiyle başlamak, yakınsama performansını iyileştirir.

## ii) Offset Parametrelerinin EM'de Öğrenilmesi

$\mathbf{d} \neq \mathbf{0}$ : Finansal verilerde faktörlerin ortalama bir "drift" içermesi sık rastlanır. Eğer  $\mathbf{d}$  sabit olarak 0 alınrsa, model  $\mathbf{A}$ 'ya bu drift'i yüklemek zorunda kalabilir; bu da gereksiz şekilde özdeğerlerin 1'e yaklaşmasına sebebiyet verebilir.

Benzer şekilde, observation offset ( $\mathbf{o}$ ) ekleyerek  $\beta_{t+1} = \mathbf{A}\beta_t + \mathbf{o} + \boldsymbol{\eta}_t$  formuna geçilebilir. EM aşamasında  $\mathbf{d}$  ve  $\mathbf{o}$  da parametre olarak işlenirse model "sabit sapmaları" veri içinden öğrenir.

## iii) Eigenvalue Clipping (Eksplozif VAR Önleme)

Eksploziflik kontrolünde " $\mathbf{A} = \mathbf{I}$  ile değiştirme" oldukça agresif bir düzeltmedir. Bunun yerine:

1.  $\mathbf{A}$ 'nın özdeğerlerini ( $\lambda_i$ ) bulunur.
2.  $\max|\lambda_i| > 1$  ise  $\alpha = \frac{0.999}{\max|\lambda_i|}$  gibi bir ölçek (scale) hesaplanır.
3. Tüm özdeğerleri  $\lambda_i = \lambda_i \times \alpha$  yaparak,  $\rho(\mathbf{A}^*) \approx 0.999$ .

Bu sayede, patlayıcı olmayacak kadar küçük ancak orijinal VAR(1) yapısına çok yakın bir geçiş matrisi elde edilir.

## iv) Manuel EM Döngüsü ve Log-Likelihood Takibi

Standart kullanımda, 50 adım iterasyondan sonra durdurulmaktadır. Ancak:

- Bazı veri setlerinde 50 adım fazla, bazılarında az gelebilir.
- Yakınsama tam 10. adımda olabilecekken 50 adım beklenmesi zaman kaybıdır veya 50 adım bile yetmeyip 100 adımda konverjans sağlanabilir.

Bu tezde, EM adımının “log-likelihood” değişimini  $\Delta = |\log L_{yeni} - \log L_{eski}|$  takibe alınmakta  $\Delta < 10^{-5}$  şeklinde bir koşulla EM döngüsünü durduruyoruz. Böylece hem hesaplama verimliliği artar hem de yakınsamayı sürekli takip etme olanağımız olur.

---

### Algoritma 1. DNS Kalman Filtreleme Algoritması

---

1	Girdi verilerinin hazırlanması	Veri seti hazırlanır ve tahvil vadeleri ( $\tau$ ) belirlenir.
2	Kalman filtresi için başlangıç parametrelerinin belirlenmesi	Durum, offset ve geçiş matrisleri gibi başlangıç parametreleri ( $state_{init}, offset_{init}, trans_{init}$ ) ayarlanır.
3	Geçiş ve gözlem matrislerinin tanımlanması	Dinamik Nelson-Siegel (DNS) modeline göre $\lambda$ parametresiyle geçiş ve gözlem matrisleri oluşturulur.
4	Kalman filtresinin em algoritmasıyla eğitilmesi	EM algoritması kullanılarak Kalman filtresi, veri setine uyacak şekilde optimize edilir.
5	Sistem stabilitesi kontrolü	Geçiş matrisinin normu kontrol edilir. Eğer patlama (explosivity) tespit edilirse, geçiş matrisi yeniden normalize edilir.
6	Tahmin aşaması	Eğitilen Kalman filtresi ile ileri dönük tahminler yapılır ( $t + 1, t + 2, \dots, t + n$ ).

### 3.5 Literatür

Getiri eğrisi, sabit getirili menkul kıymetler (özellikle devlet tahvilleri ve tahvil piyasaları) için temel bir gösterge olarak hem kurumsal hem de bireysel yatırımcılar, hem de politika yapımcılar tarafından yakından takip edilmektedir. Yıllar içinde yapılan akademik çalışmalar, getiri eğrisinin eğiminin (özellikle kısa ve uzun vadeli faiz oranları arasındaki farkın) gelecekteki makroekonomik koşulları, enflasyonu, resesyonları veya genel ekonomik büyümeyi tahmin etmede anlamlı sinyaller taşıyabileceğini göstermiştir. Aşağıda, bu alanda yapılan çalışmalardan oluşan kapsamlı bir literatür derlemesi sunulmuş; hem kuramsal hem de ampirik açıdan öne çıkan bulgular özetlenmiştir.

Yapılan ilk çalışmalar (Anderson, 2006; Campbell, 1995) getiri eğrisinin, piyasanın gelecekteki faiz oranı beklentilerini ve enflasyon görünümünü yansıttığını belirtir. Bu çerçevede, uzun vadeli faizlerin kısa vadeli faizlerden yüksek olmasının (normal veya pozitif eğimli eğri) piyasalarda daha yüksek enflasyon veya daha yüksek reel faiz beklentisi olduğunu; buna karşılık eğrinin tersine dönmesinin (inversion) ise gelecekte ekonomik yavaşlama beklentisini işaret ettiği sıkça vurgulanmıştır. Özellikle Campbell ve Shiller (1991); Diebold ve Rudebusch (2013); Nelson ve Siegel (1987) ile başlayan teorik modeller, getiri eğrisini tek faktörlü veya çok faktörlü yapılar altında incelemiş, dinamik modelleme (Diebold ve Li, 2006; dinamik Nelson–Siegel modeli) ve AFNS (arbitraj-olmayan Nelson–Siegel) modelleri de sıklıkla uygulanmıştır (bk. Diebold ve Rudebusch, 2013).

Özellikle ABD ekonomisi örneğinde, getiri eğrisinin terse dönmesiyle resesyon arasındaki ilişkiye vurgu yapan çalışmalar (Estrella ve Mishkin, 1996; Chinn ve Kucko, 2015; Ozturk ve Pereira, 2013) bu yöntemin güçlü bir öncü gösterge olduğunu ileri sürmüştür. Doh (2011) ise DSGE çerçevesinde nominal katılıklar (fiyat yapışkanlığı) ile getiri eğrisi arasındaki etkileşimi vurgulamış, esnek fiyat varsayımları altında Merkez Bankası enflasyon hedefinin getiri eğrisini şekillendirdiğini iddia etmiştir. Anderson (2006) ve Ahmed ve Khan (2022) ise ters eğrinin resesyonları tahminde “hatalı pozitif”



sonuçlar da doğurabileceğini, bu yüzden sadece eğriyi değil para politikası yaklaşımı, küresel risk algısı gibi unsurları da hesaba katmanın gerekli olduğunu göstermiştir.

Estrella ve Mishkin (1998) ile başlayan uzun soluklu çalışmalar, ABD, Kanada, Almanya, Fransa, İtalya, Japonya ve Birleşik Krallık'ta getiri eğrisinin büyüme ve enflasyonu tahmin etmedeki performansını incelemiştir. Buna göre 10 yıllık ve 3 aylık faiz oranları (Hvozdenská, 2013, 2015; Chinn ve Kucko, 2010, 2015) arasında hesaplanan farkın (yield spread) bir sonraki 4-5 çeyrek içerisinde reel faaliyet düzeyini öngörebildiği sıklıkla teyit edilmiştir. Mehl (2009) getiri eğrisinin gelişmekte olan piyasalarda da enflasyon ve büyüme öngörüsünde anlamlı olduğunu göstermiş, ancak bu ülkelerde ABD ve Euro Bölgesi getiri eğrilerinin de yerel koşulları etkilediğine dikkat çekmiştir.

Farklı çalışmalarda (Demary, 2017; Nymand-Andersen, 2018; Horváth vd., 2014), para politikası rejiminin (Fed, ECB ve diğer merkez bankalarının faiz kararları), getiri eğrisinin kısa vadesini güçlü biçimde etkilediği; uzun vadede ise enflasyon beklentileri ve risk primlerinin belirleyici olduğu ifade edilmektedir. Özellikle ABD'de 2019'daki eğri tersine dönmesi veya 2020 pandemi dönemi, para otoritelerinin "tahvil alım programları" (QE) gibi araçlarla uzun vadeli faiz oranlarını aşağı çekmesi yoluyla getiri eğrisinin şekillendiğini göstermiştir (Choudhry, 2006; Burgess, 2019).

Bazı çalışmalar, getiri eğrisinin yalnızca makroekonomik öngörü değil, aynı zamanda tahvil portföylerinde "hedging" stratejileri, getiri eğrisi risk yönetimi (Fabozzi & Mann, 2012; Reitano, 2012) ve ihraç borçlanma vade yapısına karar verme (Wickström & Smith, 2012) gibi alanlarda kullanıldığını vurgulamıştır. Slope faktörünün yanı sıra "curvature" (eğrilik) ve "level" (seviye) bileşenlerini de göz önünde bulunduran faktör modelleri (İlmanen & Iwanowski, 1997; Piazzesi ve Cochrane, 2009) portföy optimizasyonu ve vade seçimlerinde yaygınlaşmıştır.

Toplamda, literatürün büyük bölümü, getiri eğrisinin özellikle 10 yıllık ve 3 aylık tahvil faizleri arasındaki fark kullanılarak makroekonomik aktiviteyi öngörmede anlamlı sinyaller sunduğunu ortaya koymuştur. Ancak bu ilişkiyi yorumlarken para politikası rejimleri, küresel risk iştahı, piyasa likiditesi gibi faktörlerin dönemsel olarak etkili olduğu vurgulanmaktadır. Modelleme tarafında da tek faktörlü veya sabit varsayımli modeller yerine, rejim değişimli, dinamik Nelson-Siegel, semiparametrik faktör veya

makine öğrenimi yöntemleri giderek daha fazla tercih edilmektedir. Getiri eğrisinden alınan sinyallerin hem finansal piyasalar (portföy stratejileri, risk yönetimi) hem de makroekonomik kararlar (para politikası, kamu borçlanma stratejisi) açısından önemli olduğu genel kabul görmektedir.

Literatürde Türkiye Hazine tahvillerinin getiri eğrisini modelleyen birçok çalışma bulunmaktadır. Alper vd. (2004), Mc-Culloch ve Nelson-Siegel yöntemleriyle tahmin edilen getiri eğrilerine faktör analizi uygulayarak getiri eğrisini tahmin etmişlerdir. Çalışma, her bir aylık getiri eğrisini üç faktörle- seviye, eğim ve eğrilik - karakterize etmeyi ve her bir faktörün zaman serisi özelliklerini kullanarak getiri eğrilerini tahmin etmeyi amaçlamaktadır. Yazarlar ayrıca farklı alt örneklerde üç faktörlü modelin açıklayıcı gücünü araştırmakta ve faktörler için AR-GARCH ve rassal yürüyüş süreçlerinin tahmin performansını karşılaştırmakta ve AR-GARCH spesifikasyonunun açıklayıcı ve tahmin gücüne ilişkin cesaret verici sonuçlar bulmaktadır. Bu araştırma, getiri eğrilerinin tahmininde faktör analizinin uygulanmasına ilişkin değerli bilgiler sunmakta ve getiri eğrisi tahmini alanına metodolojik bir katkı sağlamaktadır.

Akıncı vd. (2006), Türkiye'nin devlet iç borçlanma senetleri için getiri eğrisi tahminlerini sunmakta ve bu tahminlerin piyasa katılımcılarının faiz beklentilerini ölçmek için uygun bir araç olduğunu vurgulamaktadır. Bu çalışma, Türkiye'nin devlet iç borçlanma senetleri için yüksek frekansta ve uzun vadeli sabit kuponlu bonoları da tahmine dahil eden Extended Nelson Siegel (ENS) yöntemi ile getiri eğrisi tahminleri sunarak, bu tahminlerin piyasa katılımcılarının faiz beklentilerini ölçmek için uygun bir araç olduğunu vurgulamaktadır. Ayrıca, makale ENS yönteminin kullanımı, veri setinin özellikleri ve tahminlerde kullanılan parametreler hakkında detaylı bilgi sunmaktadır. Bu çalışmanın, Türkiye'nin ekonomik analizleri ve para politikalarının oluşturulmasında önemli bir araç olarak kullanılabileceği sonucuna varılabilir.

Artam (2006) getiri eğrisinin zaman serisi özelliklerini modellemek için makro değişkenleri dahil etmiştir. Ang-Piazessi (AP), Diabold-Rudebusch-Aruoba (DRA) modellerini ve kendi makro-finans modelini analiz etmiştir. Kendi modelinde makro değişkenler olarak TÜFE ve Kapasite Kullanımı ile iki gizli değişken kullanmıştır. Bu makro-finans yaklaşımları, tahvil getirileri ve makroekonomik değişkenlerin ortak dinamiklerini afin dönem yapısı modelleri ile tahmin etmektedir. Kendi makro-finans

modelinin getiri eğrisini tahmin etmede AP ve DRA yaklaşımlarından daha iyi olduğunu, çünkü bu modellerde makroekonomik değişkenlerin gizli faktörlerden daha küçük bir etkiye sahip olduğunu bulmuştur. Bu makale, tahvil getirileri ve makroekonomik değişkenlerin ortak dinamiklerini tahmin eden makro-finans modellerini sunarak ve tartışarak yeni bilgilere katkıda bulunmaktadır. Çalışma ayrıca, faiz oranlarının vade yapısı ile makroekonomik temeller arasındaki çift yönlü karakterizasyonu vurgulamakta ve bu iki alan arasındaki ilişkiye dair içgörü sağlamaktadır. Ayrıca, makroekonomik değişkenlerin faiz oranlarının vade yapısı üzerindeki etkisinin anlaşılmasına ve makro faktörler ile tahvil getirisi faktörlerinin ortak dinamiklerini yakalayan modellerin geliştirilmesine katkıda bulunmaktadır. Genel olarak makalenin katkısı, makroekonomik değişkenler ve tahvil getirileri arasındaki etkileşimin anlaşılması ve modellenmesini ilerleterek finansal ve ekonomik analizler için değerli bilgiler sağlamaktır.

Baki (2006), aylık getiri eğrilerini tahmin etmek için Türkiye'nin 1992-2004 yılları arasındaki devlet tahvili verilerini kullanmışlardır. Veri setini, fiyat ve vadenin aylık hacim ağırlıklı ortalamasını hesaplayarak oluşturmuşlardır. McCulloch ve Nelson-Siegel yöntemlerinin performansını karşılaştırmak için hem örneklem içi hem de örneklem dışı analizler uygulamışlardır. Sonuçlar McCulloch yönteminin üstün örneklem içi özelliklere sahip olduğunu, Nelson-Siegel yönteminin ise üstün örneklem dışı özelliklere sahip olduğunu göstermiştir. Ayrıca, faiz oranlarının vade yapısını tahmin etmek için B-spline eğri uydurma tekniğini kullanmışlar ve McCulloch ve Nelson-Siegel modellerinin örneklem içi analiz performansını verilerine göre karşılaştırmışlardır. Bulgular, farklı modellerin göreceli performansları ve kupon ödeme verilerini kullanarak daha fazla araştırma yapma potansiyeli hakkında fikir vermektedir. Genel olarak bu çalışma, faiz oranı modellemesi ve bunun devlet tahvili getirilerine uygulanmasına ilişkin anlayışa katkıda bulunmaktadır.

### 3.6. Veri

Bu tezde, Türkiye, Avrupa Merkez Bankası ve ABD'nin dönemsel faiz ödemeyen, iskontolu olarak ihraç edilen ve nominal değeri üzerinden vadesi gelen hazine bonoları getirileri kümesi üzerinde modellerin performansı değerlendirilmiştir. Türkiye verileri Refinitiv Eikon veri tabanından alınmıştır (Refinitiv, 2023). Avrupa Merkez Bankası verileri, Euro Bölgesi'nde AAA kredi notuna sahip hükümet tahvillerinin spot getiri

oranlarını içermektedir (Avrupa Merkez Bankası, 2023). Amerika Birleşik Devletleri verileri ise ABD Hazine Bakanlığı Kaynak Merkezi'nden elde edilmiştir (ABD Hazine Bakanlığı, 2023). Bu çalışma, farklı piyasa koşullarında kullanılan modellerin getiri eğrilerini tahmin etme performansını karşılaştırmayı amaçlamakta ve ekonomik analizlerde bu modellerin sunduğu avantaj ve sınırlamaları değerlendirmektedir.

Getiri eğrisinin piyasadaki değerlerine bakılmak istendiğinde, her vade için risksiz, kuponsuz bir tahvilin listelenmesi gerekecektir. Ancak, bu tür tahvillerin sayısı çok az olduğundan, getiri eğrisi verilerinin mevcut tahvil verilerinden tahmin edilmesi gerekmektedir. Bu tez çalışmasında, finansal kriz sonrasındaki dönemi kapsayan 2014-01 ile 2023-05 arasındaki zaman aralığı seçilmiştir. Bu dönem, getiri eğrilerinin zamansal dinamiklerini anlamak için oldukça uygun bir veri seti sağlamaktadır.

Veri ön işleme aşamasında, tatiller ve ticari olmayan günler nedeniyle uygun olmayan (NA) gözlemler veri setinden çıkarılmıştır. Bu adım, analizlerde yalnızca aktif ticaretin gerçekleştiği günlerin kullanılması ve dolayısıyla daha doğru bir modelleme yapılabilmesi açısından önemlidir. Ayrıca, ABD ve Türkiye getirileri söz konusu olduğunda, seçilen tüm zaman aralığı için mevcut olmayan vade süreleri de veri setinden kaldırılmıştır. Bu adım, analizlerde eksik ya da düzensiz verilerin yol açabileceği hataları önlemek amacıyla gerçekleştirilmiştir.

Her ülke için günlük getiriler, haftalık frekansa örneklenmiş ve bu süreçte piyasa verilerinde eksik olan vade uzunlukları analizden çıkarılmıştır. Türkiye için vade uzunlukları 1 ay ila 10 yıl arasında değişirken, ABD'de vade uzunlukları 1 ay ila 30 yıl, ECB için ise 3 ay ile 30 yıl arasında belirlenmiştir. Elde edilen haftalık veriler hem zamansal hem de vadeye dayalı eğilimleri değerlendirmek üzere fonksiyonel zaman serisi (fts) objelerine dönüştürülmüştür. Fonksiyonel zaman serisi analizi, getiri eğrisinin zamana ve vadeye dayalı değişimlerini modellemek için ftsa R paketi (Hyndman ve Shang, 2024) kullanılarak gerçekleştirilmiştir. Bu süreç, tahvil getirilerindeki zamansal değişimlerin ve ekonomik politika etkilerinin daha derinlemesine anlaşılmasına olanak sağlamıştır. Ayrıca, günlük ve haftalık veri örneklemelerinin fts modellerine entegrasyonu, getiri eğrilerinin zamansal ve vadeye dayalı olarak modellenmesi için önemli bir altyapı sunmuştur.

Bu ön işleme adımlarının ardından, her ülke için veri seti haftalık OHLC (Açılış, En Yüksek, En Düşük, Kapanış) formatında örneklenmiş ve vadeler yıl bazında standardize edilmiştir. Bu yaklaşım, farklı ülkelerden elde edilen verilerin karşılaştırılabilir olmasını ve modelleme sürecinde tutarlı sonuçlar elde edilmesini sağlamıştır.

Tablo 3.1 ABD Hazine sıfır kuponlu devlet tahvillerine ilişkin veri setinin tanımlayıcı istatistikleri, farklı vadeler için ortalama getiriler, standart sapmalar, çarpıklık ve basıklık değerlerini içermektedir. Kısa vadeli tahvillerin ortalama getirileri, uzun vadeli tahvillere göre daha düşüktür. Örneğin, 1 ay vadeli tahvillerin ortalama getirisi %0,69 iken, 30 yıl vadeli tahvillerin ortalama getirisi %2,62'dir. Bu durum, yatırımcıların uzun vadeli yatırımlar için daha yüksek getiri talep etmeleriyle açıklanabilir. Ayrıca, standart sapmalar, kısa vadeli tahvillerin getirilerinde daha fazla dalgalanma olduğunu göstermektedir. Kısa vadeli tahvillerin standart sapması 0,8318 iken, 30 yıl vadeli tahvillerin standart sapması 0.5930'dur. Bu, kısa vadeli piyasa koşullarının daha volatil olduğunu göstermektedir.

Çarpıklık değerleri, getirilerin dağılımındaki asimetrinin yönünü ve derecesini göstermektedir. Kısa vadeli tahvillerde (örneğin, 1 ay vadeli tahvil) pozitif çarpıklık (0.9197) görülmektedir. Bu, getirilerin sağa doğru uzun kuyruklu olduğunu, yani yüksek getirilerin nadir ama daha aşırı olduğunu göstermektedir. Uzun vadeli tahvillerde ise (örneğin, 30 yıl vadeli tahvil) negatif çarpıklık (-0.5701) görülmektedir. Bu, getirilerin sola doğru uzun kuyruklu olduğunu, yani düşük getirilerin nadir ama daha aşırı olduğunu göstermektedir. Bu durum, yatırımcıların kısa vadeli tahvillerde daha fazla risk aldıklarını, uzun vadeli tahvillerde ise daha temkinli olduklarını göstermektedir.

Basıklık değerleri, getirilerin dağılımındaki uç değerlerin yoğunluğunu göstermektedir. Tüm vadeler için basıklık değerlerinin negatif olması, getirilerin dağılımının normal dağılıma göre daha basık olduğunu ve aşırı değerlerin daha az olduğunu göstermektedir. Örneğin, 1 ay vadeli tahvillerin basıklık değeri -0.7257, 30 yıl vadeli tahvillerin basıklık değeri ise -0.3857'dir. Bu, piyasaların nispeten istikrarlı olduğunu ve ekstrem getiri değişimlerinin nadir olduğunu göstermektedir.

Kısa vadeli tahvillerdeki pozitif çarpıklık ve yüksek standart sapma, piyasanın kısa vadeli ekonomik belirsizliklere daha duyarlı olduğunu göstermektedir. Yatırımcılar, kısa vadeli risklere karşı daha hassastır ve bu nedenle kısa vadeli tahvillerde daha fazla getiri

dalgalanması yaşanır. Uzun vadeli tahvillerdeki negatif çarpıklık ve daha düşük dalgalanma, uzun vadeli ekonomik görünümün daha istikrarlı olduğuna dair bir güveni yansıtmaktadır. Bu durum, yatırımcıların uzun vadede daha güvenli ve öngörülebilir bir getiri beklediklerini göstermektedir.

ABD Merkez Bankası'nın faiz oranlarını belirlemesi ve ekonomik büyüme beklentileri, tahvil getirilerini doğrudan etkilemektedir. Düşük kısa vadeli tahvil getirileri, düşük faiz oranları ve genişlemeci para politikalarının bir yansıması olabilirken, uzun vadeli tahvil getirilerinin nispeten daha yüksek olması, yatırımcıların gelecekteki enflasyon ve faiz artış beklentilerini yansıtabilir. Bu durum, ekonomik büyüme ve enflasyon beklentilerinin yatırımcı kararları üzerindeki etkisini göstermektedir.

**Tablo 3.1.** 2014-2023 Dönemi ABD Hazine Sıfır Kuponlu Devlet Tahvillerinin Tanımlayıcı İstatistikleri ve Dağılım Özellikleri

Vade	Gözlem Sayısı	Ortalama	Standart Sapma	Minimum	1. Çeyrek	Medyan	3. Çeyrek	Maksimum	Çarpıklık	Basıklık
1 Ay	2002	0.6891	0.8318	0.00	0.0400	0.20	1.48	2.51	0.9197	-0.7257
3 Ay	2002	0.7280	0.8477	0.00	0.0400	0.26	1.54	2.49	0.8599	-0.8436
6 Ay	2002	0.8050	0.8611	0.02	0.0800	0.41	1.57	2.58	0.8084	-0.8940
1 Yıl	2002	0.8881	0.8631	0.04	0.1300	0.54	1.57	2.74	0.7834	-0.8449
2 Yıl	2002	1.0649	0.8113	0.09	0.4300	0.75	1.60	2.98	0.7403	-0.6489
3 Yıl	2002	1.2423	0.7556	0.10	0.7900	1.04	1.61	3.05	0.5781	-0.4915
5 Yıl	2002	1.5626	0.6901	0.19	1.1800	1.60	1.89	3.09	0.0316	-0.3875
7 Yıl	2002	1.8294	0.6582	0.36	1.4225	1.93	2.23	3.18	-0.3354	-0.3717
10 Yıl	2002	2.0279	0.6454	0.52	1.6000	2.15	2.49	3.24	-0.4990	-0.4455
20 Yıl	2002	2.4041	0.5845	0.87	2.0325	2.52	2.84	3.69	-0.5197	-0.3127
30 Yıl	2002	2.6205	0.5930	0.99	2.2400	2.79	3.04	3.93	-0.5701	-0.3857

Bu tanımlayıcı istatistikler, getiri eğrilerinin risk ve getiri profilini daha iyi anlamak için kritik öneme sahiptir. Kısa vadeli getirilere ilişkin yüksek varyans ve pozitif çarpıklık, kısa vadede yüksek getiri fırsatlarının mevcut olduğunu, ancak bu getirilerin yüksek oynaklıkla birlikte geldiğini göstermektedir. Uzun vadeli getiriler ise genellikle daha yüksek olmasına rağmen, negatif çarpıklık ve belirli bir düzeyde varyans içermektedir. Bu, uzun vadeli yatırımcılar için potansiyel getiri fırsatları sunarken, aynı zamanda beklenmedik büyük kayıplar riskini de beraberinde getirebileceğini ifade etmektedir. Bu analizler, yatırımcıların portföy stratejilerini belirlerken dikkate almaları gereken önemli bilgiler sunar.

Tablo 3.2, 2014 yılı Ocak ayından 2023 yılı Eylül ayına kadar olan dönemde, AMB tarafından piyasaya sunulan sıfır kupon devlet tahvillerinin getiri eğrisine ilişkin tanılayıcı istatistikleri ve dağılım özelliklerini içermektedir. Veriler, her hafta başındaki gözlemleri temsil etmektedir ve tatil günleri ile işlem yapılmayan günlerdeki eksik gözlemler çıkarılmıştır. Her vadede 2358 gözlem bulunmaktadır, bu da haftalık olarak yaklaşık 9 yıllık bir süreye tekabül etmektedir. Getirilerin ortalama değerleri, kısa vadelerden uzun vadeler boyunca genellikle artan bir eğilim göstermektedir. Bu durum, normal bir getiri eğrisi yapısını yansıtır; yani, daha uzun vadeli tahviller genellikle daha yüksek getiri sağlar. Bu dönem, Avrupa bölgesinin finansal kriz sonrası toparlanma sürecini ve ardından gelen ekonomik belirsizlik dönemlerini kapsamaktadır.

Getirilerdeki dalgalanmaların boyutu, yaklaşık olarak 0,61 ile 0,80 arasında değişmektedir ve bu, getiri volatilitésinin zamanla değişimini göstermektedir. Getiri oranlarının minimum ve maksimum değerleri, her vadede geniş bir aralık göstermekte olup, piyasa koşullarının ve ekonomik durumların etkisiyle getirilerin zaman içinde nasıl değiştiğini yansıtmaktadır. Avrupa bölgesinde, özellikle 2014 sonrasında uygulanan genişlemeci para politikaları, düşük faiz oranları ve varlık alım programları, tahvil getirilerini önemli ölçüde etkilemiştir.

Getirilerin dağılımını ve ortalama etrafındaki yayılımını gösteren 1. Çeyrek (Q1) ve 3. Çeyrek (Q3) değerleri, getirilerin %25'lik ve %75'lik dilimlerde nasıl bir dağılım gösterdiğini belirtmektedir. Medyan değerler, ortalama etrafında getirilerin yarısının bu değer altında, yarısının ise üstünde olduğunu göstermekte olup, genellikle ortalamaya yakındır. Çarpıklık, verinin asimetrisini gösterir ve pozitif çarpıklık değerleri, dağılımın sağa eğimli olduğunu ve getirilerin çoğunun ortalamadan altında olduğunu belirtir. Tablodaki çarpıklık değerleri genellikle pozitif ve yüksek olup, piyasanın zaman zaman aşırı pozitif getiri dönemleri yaşadığını göstermektedir. Bu, Avrupa Merkez Bankası'nın politika kararlarının piyasa üzerindeki etkilerini yansıtmaktadır. Basıklık ise dağılımın tepe noktasının sivriliğini gösterir ve pozitif basıklık, daha sivri ve dar tepeye sahip bir dağılımı ifade eder, bu da verinin normal dağılıma göre daha fazla uç değer içerdiğini gösterir. Tablodaki yüksek basıklık değerleri, piyasanın ekstrem getiri değerlerine sahip olduğunu göstermektedir.

Kısa vadeli tahviller (3 ay - 2 yıl) genellikle negatif ve düşük getiriler sunmaktadır. 2014-2023 yılları arasında Avrupa Merkez Bankası (AMB) tarafından ihraç edilen sıfır kuponlu devlet tahvillerinin negatif getiri sağlamasının ardında çeşitli ekonomik ve finansal faktörler bulunmaktadır. Bu durum, Merkez bankalarının ekonomiyi canlandırmak amacıyla faiz oranlarını sıfırın altına indirmesi, tahvil gibi sabit getirili enstrümanların negatif getiri sağlamasına neden olmuştur. Örneğin, Avrupa Merkez Bankası'nın negatif faiz politikası, bazı devlet tahvillerinin negatif getiriyle işlem görmesine yol açmıştır (Alper, 2017). Gelecekte faiz oranlarının daha da düşeceği beklentisi, mevcut düşük getirili veya negatif getirili tahvillere olan talebi artırabilir. Yatırımcılar, ileride daha düşük getiri elde etme riskine karşı mevcut düşük getirili enstrümanları tercih edebilirler (TCMB, 2020).

Kısa vadeli tahvillerin negatif getiri sergilemesinin bir diğer nedeni AMB, 2014 yılında enflasyonu canlandırmak ve ekonomik büyümeyi desteklemek amacıyla politika faiz oranlarını sıfırın altına indirmiştir. Bu strateji, piyasa faiz oranlarının da negatif seviyelere inmesine yol açarak tahvil getirilerinin düşmesine neden olmuştur. Örneğin, AMB'nin mevduat faiz oranını negatif seviyelere çekmesi, bankaların ellerindeki fazla likiditeyi merkez bankasında tutmak yerine tahvillere yönlendirmesine sebep olmuştur (Bloomberg HT, 2022). Bu program uyarınca AMB'nin uyguladığı varlık alım programları kapsamında büyük miktarlarda tahvil alımları, tahvil fiyatlarını artırırken getirilerini düşürmüş ve negatif getirilere katkıda bulunmuştur. Özellikle 2015 yılında başlatılan parasal genişleme programı, tahvil piyasasında arz-talep dengesini etkileyerek getirilerin düşmesine neden olmuştur (Bloomberg HT, 2024).

Buna ek olarak ekonomik belirsizlik dönemlerinde yatırımcılar, güvenli liman olarak görülen devlet tahvillerine yönelmişlerdir. Artan talep, tahvil fiyatlarını yükseltirken getirilerini düşürmüş ve bazı durumlarda negatif getirilere yol açmıştır. Özellikle Avrupa'daki borç krizleri ve küresel ekonomik dalgalanmalar, yatırımcıların güvenli varlıklara yönelmesine neden olmuştur

Orta vadeli tahviller (3 yıl - 10 yıl) genellikle pozitif getiriler sunmakta ve daha fazla stabilite göstermektedir. Bu, ekonominin toparlanma sürecinde nispeten daha az belirsizlikle karşılaşıldığını göstermektedir. Uzun vadeli tahvillerde (10 yıl ve üzeri) getiriler daha yüksek ve pozitif olup, uzun vadeli ekonomik beklentileri ve enflasyon



beklentilerini yansıtmaktadır. Uzun vadeli getiriler, yatırımcıların ekonomik istikrar ve büyüme beklentilerini ifade ederken, Avrupa bölgesinde uzun vadeli enflasyon hedeflerine duyulan güveni de yansıtmaktadır.

Genel olarak, bu analiz, Avrupa Merkez Bankası'nın sıfır kupon devlet tahvillerinin getirilerinin zaman içindeki davranışını ve dağılımını anlamak için kapsamlı bir bilgi sunmaktadır. Bu istatistikler, yatırımcıların getiri eğrisini değerlendirmelerine ve gelecekteki tahvil getirileri hakkında bilgi sahibi olmalarına yardımcı olabilir. Avrupa bölgesinin ekonomik durumu, uygulanan para politikaları ve finansal piyasaların dinamikleri, bu getiri eğrisinin şekillenmesinde önemli rol oynamıştır.

**Tablo 3.2** 2014-2023 Dönemi AMB Sıfır Kupon Devlet Tahvili Getiri Eğrisi Tanılayıcı İstatistikleri ve Dağılım Özellikleri

Vade	Gözlem Sayısı	Ortalama	Standart Sapma	Minimum	1. Çeyrek	Medyan	3. Çeyrek	Maksimum	Çarpıklık	Basıklık
3 ay	2358	-0.3856	0.6108	-0.9300	-0.6841	-0.6096	-0.2694	2.8182	3.1857	11.2492
6 ay	2358	-0.3666	0.6801	-0.9147	-0.6934	-0.6273	-0.2692	3.0784	3.1565	10.4196
1 yıl	2358	-0.3479	0.7342	-0.9130	-0.7045	-0.6362	-0.2617	3.3035	3.0386	9.3098
2 yıl	2358	-0.3174	0.7368	-0.9706	-0.7040	-0.6151	-0.2063	3.2126	2.7377	7.4517
3 yıl	2358	-0.2564	0.7269	-1.0021	-0.6724	-0.5258	-0.1433	3.0546	2.4447	5.8893
4 yıl	2358	-0.1670	0.7231	-1.0091	-0.6164	-0.4227	-0.0332	2.9454	2.1619	4.5825
5 yıl	2358	-0.0616	0.7238	-0.9962	-0.5474	-0.2799	0.0958	2.8817	1.8843	3.4617
6 yıl	2358	0.0491	0.7278	-0.9703	-0.4746	-0.1282	0.2402	2.8459	1.6213	2.5092
7 yıl	2358	0.1582	0.7342	-0.9363	-0.3980	0.0205	0.3837	2.8261	1.3867	1.7312
8 yıl	2358	0.2615	0.7423	-0.8976	-0.3235	0.1475	0.5112	2.8152	1.1897	1.1257
9 yıl	2358	0.3568	0.7513	-0.8567	-0.2502	0.2668	0.6296	2.8091	1.0321	0.6747
10 yıl	2358	0.4431	0.7606	-0.8152	-0.1828	0.3736	0.7405	2.8054	0.9103	0.3501
11 yıl	2358	0.5205	0.7695	-0.7743	-0.1212	0.4703	0.8405	2.8026	0.8182	0.1220
12 yıl	2358	0.5892	0.7777	-0.7348	-0.0654	0.5531	0.9277	2.7999	0.7486	-0.0363
13 yıl	2358	0.6499	0.7848	-0.6971	-0.0141	0.6231	1.0012	2.7968	0.6956	-0.1463
14 yıl	2358	0.7034	0.7908	-0.6614	0.0277	0.6854	1.0623	2.7929	0.6539	-0.2242
15 yıl	2358	0.7503	0.7954	-0.6279	0.0622	0.7406	1.1173	2.7881	0.6198	-0.2814
16 yıl	2358	0.7914	0.7987	-0.5965	0.0976	0.7902	1.1661	2.8385	0.5904	-0.3257
17 yıl	2358	0.8275	0.8007	-0.5673	0.1267	0.8340	1.2045	2.8816	0.5637	-0.3625
18 yıl	2358	0.8590	0.8015	-0.5431	0.1503	0.8743	1.2379	2.9143	0.5385	-0.3950
19 yıl	2358	0.8866	0.8012	-0.5282	0.1719	0.9104	1.2766	2.9383	0.5137	-0.4254
20 yıl	2358	0.9107	0.8000	-0.5148	0.1928	0.9401	1.3061	2.9552	0.4890	-0.4549
21 yıl	2358	0.9318	0.7979	-0.5027	0.2112	0.9666	1.3357	2.9663	0.4640	-0.4841
22 yıl	2358	0.9503	0.7952	-0.4918	0.2256	0.9888	1.3601	2.9727	0.4387	-0.5133
23 yıl	2358	0.9664	0.7918	-0.4819	0.2400	1.0121	1.3829	2.9752	0.4129	-0.5424

24 yıl	2358	0.9806	0.7879	-0.4729	0.2549	1.0316	1.4012	2.9748	0.3867	-0.5716
25 yıl	2358	0.9930	0.7837	-0.4647	0.2663	1.0499	1.4099	2.9719	0.3603	-0.6005
26 yıl	2358	1.0039	0.7791	-0.4571	0.2761	1.0671	1.4265	2.9673	0.3337	-0.6289
27 yıl	2358	1.0135	0.7744	-0.4502	0.2863	1.0831	1.4404	2.9612	0.3072	-0.6568
28 yıl	2358	1.0219	0.7695	-0.4438	0.2928	1.0974	1.4478	2.9542	0.2807	-0.6838
29 yıl	2358	1.0293	0.7645	-0.4379	0.2979	1.1120	1.4575	2.9463	0.2546	-0.7099
30 yıl	2358	1.0358	0.7596	-0.4324	0.3035	1.1267	1.4668	2.9380	0.2288	-0.7349

Tablo 3.3, 2014 yılı Ocak ayından 2023 yılı Haziran ayına kadar olan dönemde, Türkiye tarafından piyasaya sunulan sıfır kupon devlet tahvillerinin getiri eğrisine ilişkin tanılayıcı istatistikleri ve dağılım özelliklerini içermektedir. Gözlem sayıları her vade için oldukça yüksektir, bu da analizlerin güvenilirliğini artırmaktadır. Ortalama faiz oranları vadeye göre farklılık göstermektedir; kısa vadeli faiz oranları genellikle daha düşük iken, uzun vadeli faiz oranları daha yüksek seviyelerde bulunmaktadır. Bu, yatırımcıların uzun vadeli ekonomik riskleri telafi etmek için daha yüksek getiri talep ettiğini göstermektedir.

Standart sapma değerleri, faiz oranlarının volatilitelerini yansıtmaktadır. Özellikle 3 Yıl vadeli faiz oranlarının standart sapması oldukça yüksektir (43.4878), bu da bu vadede önemli dalgalanmalar yaşandığını göstermektedir. Minimum ve maksimum değerler arasındaki büyük farklar, belirli dönemlerde piyasa koşullarının oldukça değişken olduğunu ve faiz oranlarının geniş bir aralıkta hareket ettiğini ortaya koymaktadır.

25. yüzdellik, medyan ve 75. yüzdellik değerler, faiz oranlarının dağılımı hakkında daha detaylı bilgi vermektedir. Özellikle medyan değerler, piyasanın genel eğilimini yansıtarak yatırımcılar için önemli bir referans noktası oluşturmaktadır.

Türkiye, ABD ve AMB sıfır kupon devlet tahvillerinin kısa ve uzun vadeli getirileri karşılaştırıldığında, Türkiye'nin kısa ve uzun vadeli tahviller arasındaki yüzdellik farkının diğer iki ekonomiye göre oldukça düşük olduğu gözlemlenmektedir. Türkiye'de 1 aylık tahvil getirisi 12.5997, 10 yıllık tahvil getirisi ise 12.8810 olarak kaydedilmiştir. Bu değerler arasındaki yüzdellik fark yaklaşık %2.23'tür. ABD'de ise 1 aylık tahvil getirisi 0.6891, 10 yıllık tahvil getirisi ise 2.0279 olup, yüzdellik fark %194.25 olarak hesaplanmıştır. Benzer şekilde, AMB verilerinde 3 aylık tahvil getirisi -0.3856, 10 yıllık tahvil getirisi ise 0.4431 olarak kaydedilmiş ve yüzdellik fark %214.91 olarak

bulunmuştur. Bu sonuçlar, Türkiye’de kısa ve uzun vadeli tahvil getirileri arasındaki farkın, ABD ve AMB ile kıyaslandığında çok daha küçük olduğunu ortaya koymaktadır. Türkiye’deki bu durum, faiz oranlarının kısa ve uzun vadeler arasında daha dengeli bir yapıya sahip olduğunu ve uzun vadeli ekonomik beklentilerin kısa vadelerle benzer seviyelerde olduğunu göstermektedir. Buna karşılık, ABD ve AMB’de uzun vadeli tahvillerin getirileri, kısa vadeli tahvillere kıyasla çok daha yüksek olup, yatırımcıların uzun vadeli riskleri telafi etmek için daha büyük getiriler talep ettiğini yansıtmaktadır. Bu analiz, Türkiye’nin faiz yapısının, gelişmiş ekonomilerle kıyaslandığında daha homojen bir risk-getiri dengesi sunduğunu göstermektedir.

Tablo 3.3'te görüldüğü üzere, çarpıklık değerleri veri dağılımının simetrik olup olmadığını gösterir. Pozitif çarpıklık, dağılımın sağa eğimli olduğunu ve uzun bir sağ kuyruk olduğunu ifade ederken, negatif çarpıklık sol eğimli bir dağılımı ve uzun bir sol kuyruk olduğunu gösterir. Kısa vadeli (1 Ay, 3 Ay) faiz oranları genelde pozitif çarpıklığa sahiptir, bu da daha yüksek oranların nadiren fakat önemli miktarda görüldüğünü gösterir. Özellikle 6 Ay vadeli faiz oranında oldukça yüksek bir çarpıklık gözlenmektedir (1.1265), bu da veri setinde uç değerlerin bulunduğunu işaret eder. 3 Yıl vadeli oranlar ise, çok yüksek pozitif çarpıklık ve basıklık gösteriyor. Bu, veride belirli bir dönemde anormal derecede yüksek oranların bulunduğuna işaret etmektedir.

Basıklık değeri, dağılımın sivriliğini gösterir. Pozitif basıklık, dağılımın sivri ve yüksek uç değerlerin sık olduğunu gösterirken, negatif basıklık, dağılımın düz ve düşük uç değerlerin nadir olduğunu gösterir. 3 Ay, 9 Ay ve 1 Yıl vadeli oranlar negatif basıklık gösteriyor, bu da daha düz ve geniş bir dağılım olduğunu ifade eder. 6 Ay ve 3 Yıl vadeli oranlar ise yüksek pozitif basıklık göstermektedir, bu da veri setinde çok sivri ve belirgin uç değerlerin olduğunu işaret eder. Bu durum, belirli dönemlerde faiz oranlarının oldukça volatil olduğunu ve ani değişiklikler yaşandığını gösterir.


Merkez Bankası'nın faiz politikaları, piyasa beklentileri ve global ekonomik koşullar, bu dalgalanmaları önemli ölçüde etkilemiştir. Türkiye Cumhuriyeti Merkez Bankası'nın enflasyonu kontrol altına almak ve ekonomik istikrarı sağlamak amacıyla uyguladığı sıkı para politikaları, faiz oranlarının yüksek seyretmesine neden olmuştur. Aynı zamanda, dış ticaret dengesi, cari açık ve dış borç dinamikleri de faiz oranlarını etkileyen önemli faktörler arasında yer almaktadır. Bu durum, yatırımcıların Türkiye'deki

uzun vadeli ekonomik risklere karşılık daha yüksek getiri talep etmeleriyle sonuçlanmıştır.

**Tablo 3.3** 2014-2023 Dönemi Türkiye Sıfır Kupon Devlet Tahvili Getiri Eğrisi Tanılayıcı İstatistikleri ve Dağılım Özellikleri

Vade	Gözlem Sayısı	Ortalama	Std. Sapma	Min	25. Yüzdelerik	Medyan	75. Yüzdelerik	Max	Çarpıklık	Basıklık
1 Ay	2452	12.5997	4.2777	4.6590	9.7000	10.6780	15.4365	29.3170	0.9536	0.0582
3 Ay	2452	12.5298	4.4706	3.3450	8.9017	10.7540	15.8475	25.4850	0.7757	-0.3807
6 Ay	2452	12.7027	5.2821	0.0000	9.1360	11.1880	17.0340	79.3620	1.1265	9.4758
9 Ay	2452	12.9842	5.2800	4.4600	9.4558	11.4895	17.5555	26.1780	0.3518	-0.6640
1 Yıl	2452	13.8153	4.7748	6.3200	9.9500	12.2200	17.7000	28.0000	0.8170	-0.3658
2 Yıl	2452	13.6028	4.7221	6.6200	9.9000	11.6500	17.5325	30.7900	0.8656	-0.2944
3 Yıl	2452	14.3767	43.4878	6.6700	9.8200	11.5700	17.4500	2153.8300	48.6207	2392.8515
5 Yıl	2452	13.2544	4.5184	6.6700	9.8875	11.4450	16.4300	27.2500	1.0393	0.1689
10 Yıl	2452	12.8810	3.8997	6.8200	10.0100	11.6100	15.7200	26.4700	1.0178	0.3107

Ülkeler arası tahvil getirilerinin korelasyon matrisi, finansal piyasaların analizinde, portföy yönetiminde ve küresel ekonomik etkileşimlerin anlaşılmasında kritik bir rol oynamaktadır. Bu matris, farklı ülkelerin devlet tahvillerinin getirileri arasındaki ilişkileri ölçerek yatırımcıların risk yönetimi, çeşitlendirme stratejileri ve ekonomik dinamiklerin takibi gibi çeşitli alanlarda bilgi sağlar. Şekil 3.2, ABD, Avrupa Merkez Bankası (AMB) ve Türkiye'nin 10 yıllık tahvil getirileri arasındaki korelasyonu görselleştirerek, ülkeler arasındaki ekonomik ilişkiler ve piyasa dinamiklerine dair önemli sonuçlar ortaya koymaktadır.



**Şekil 3.2** Ülkeler Arası 10 Yıllık Tahvil Getirilerinin Korelasyon Matrisi

### 1. Portföy Çeşitlendirmesi ve Risk Yönetimi

Korelasyon matrisi, portföy yönetiminde çeşitlendirme stratejileri oluşturmak için temel bir araçtır. Farklı ülkelerin tahvil getirileri arasındaki düşük veya negatif korelasyonlar, portföy riskini azaltabilir ve beklenmeyen piyasa dalgalanmalarına karşı koruma sağlar (Markowitz, 1952). Markowitz'in portföy teorisine göre, düşük korelasyon gösteren varlıklar bir araya getirilerek toplam portföy riskinin azaltılması sağlanabilir. Çeşitlendirilmiş portföylerde, düşük korelasyona sahip tahvillerin bir arada bulunması, küresel piyasa oynaklığını dengeleyerek daha istikrarlı getirilere ulaşılmasını sağlar (Bekaert & Harvey, 1995).

- **ABD ve AMB Arasındaki Yüksek Korelasyon (0.73):** ABD ve Euro bölgesi arasındaki 0.73 gibi yüksek bir korelasyon, bu iki bölgenin finansal piyasalarının birbirine yakın hareket ettiğini göstermektedir. Bu durum, iki bölgenin makroekonomik politikalarının benzerlik gösterdiğini ve küresel piyasa entegrasyonunun yüksek olduğunu gösterir. Bu tür yüksek korelasyon,

yatırımcıların portföy çeşitlendirmesinde bu iki ekonomiye yatırım yaparken risklerinin daha az dağıtıldığını ve piyasa şoklarına daha duyarlı olabileceklerini gösterir.

- **Türkiye ile Gelişmiş Ekonomiler Arasındaki Düşük veya Negatif Korelasyon:** Türkiye ile ABD (-0.04) ve Türkiye ile AMB (-0.46) arasındaki düşük veya negatif korelasyon, yatırımcıların risk yönetimi açısından Türkiye'ye yatırım yaparak portföylerini çeşitlendirme imkanına sahip olduklarını gösterir. Türkiye'nin tahvil piyasasının gelişmiş ekonomilere göre daha bağımsız hareket etmesi, yatırımcıların farklı risk faktörlerine maruz kalmasını engelleyebilir ve portföyde risklerin dengelenmesine yardımcı olabilir.

## 2. Ekonomik ve Finansal Şokların Yayılması

Ekonomik veya finansal şokların ülkeler arası tahvil getirileri üzerindeki etkisini anlamak için korelasyon matrisi kullanılır. Jeopolitik olaylar, doğal afetler veya finansal krizler gibi dış şokların, ülkelerin tahvil getirileri üzerindeki etkisini değerlendirmede korelasyon önemli bir ölçüdür. Forbes ve Rigobon (2002), kriz dönemlerinde artan korelasyonun finansal bulaşma olgusunu yansıttığını ifade etmektedir. Bu tür analizler, yatırımcılara kriz durumlarında risk yönetim stratejileri geliştirme fırsatı sunar.

Tahvil getirileri arasındaki korelasyon, ülkelerin ekonomik döngülerinin uyumluluğu ve küresel ekonomik entegrasyon seviyesini anlamak için bir gösterge olarak kabul edilmektedir. Gürkaynak ve Wright (2012), tahvil getirilerinin küresel ekonomik belirsizlik dönemlerinde yüksek korelasyon eğiliminde olduğunu ve bunun merkez bankası politikaları ya da küresel ekonomik gelişmelerden kaynaklanabileceğini vurgulamaktadır. Yüksek korelasyon, ülkeler arası ekonomik senkronizasyonun göstergesi olabilir ve ülkelerin birbirine bağımlı bir şekilde hareket ettiğini gösterebilir.

- **ABD ve AMB'nin Korelasyonu ve Şok Yayılması:** Yüksek korelasyon, ekonomik veya finansal şokların bir bölgeden diğerine hızlıca yayılabileceğini gösterir. ABD ve Euro bölgesi arasındaki korelasyonun yüksek olması, bu bölgeler arasında finansal entegrasyonun güçlü olduğunu ve şokların birbirine

geçiş yapma olasılığını artırdığını ortaya koymaktadır. Örneğin, 2008 Küresel Finansal Krizi sırasında ABD’de başlayan şokların hızla Euro bölgesine yayılması bu yüksek korelasyon ile açıklanabilir.

- **Türkiye’nin Ayrışması:** Türkiye’nin gelişmiş ülkelerden bağımsız hareket ettiğini gösteren düşük korelasyon, ekonomik ve finansal şokların bu ülkelerden Türkiye’ye geçişinin daha sınırlı olabileceğini işaret etmektedir. Ancak bu aynı zamanda, Türkiye’nin kendi içsel ekonomik dinamiklerine daha duyarlı olduğunu ve dışsal şoklardan daha bağımsız hareket ettiğini gösterir. Bu durum, gelişmekte olan bir ekonomi olarak Türkiye’nin daha spesifik riskler barındırdığı anlamına gelir.

### 3. Para Politikası ve Faiz Oranı Kararları

Korelasyon matrisi, merkez bankalarının para politikalarının küresel etkilerini analiz etmede önemli bir rol oynar. ABD Merkez Bankası’nın faiz politikaları gibi büyük ekonomilerin kararları, diğer ülkelerin tahvil piyasalarını da etkileyebilir. Mishkin (2008), ABD para politikasının diğer ülke tahvil getirilerini etkileyebileceğini ve bunun, piyasa katılımcılarının diğer ülke tahvillerine olan taleplerini de yönlendirdiğini ifade etmektedir. Korelasyon matrisi, bu tür etkileri analiz ederek yatırımcılara küresel piyasa hareketlerini önceden tahmin etme olanağı sağlar.

- **Para Politikalarının Senkronizasyonu:** ABD ve AMB arasındaki yüksek korelasyon, bu iki bölgenin para politikası senkronizasyonunun güçlü olduğunu göstermektedir. Küresel sermaye akımları açısından bu durum, yatırımcıların bu iki piyasa arasındaki faiz oranı hareketlerini yakından takip etmesine ve uyumlu kararlar almasına yol açar.
- **Türkiye’nin Para Politikası Bağımsızlığı:** Türkiye’nin ABD ve AMB ile olan korelasyonunun düşük olması, Türkiye’nin kendi ekonomik gerçeklerine dayalı daha bağımsız bir para politikası uyguladığını gösterir. Türkiye, gelişmekte olan bir piyasa olarak enflasyon, döviz kuru ve siyasi risk gibi faktörlerin daha fazla etkisi altında olduğu için, bu farklılık daha belirgin hale gelir. Bu durum,

para politikalarının diğer gelişmiş ekonomilerden farklı zamanlamalarla yürütülmesine neden olabilir.

#### 4. Finansal İstikrar ve Küresel Risk Algısı

- **ABD ve AMB'nin Yüksek Korelasyonu:** ABD ve Euro bölgesi arasındaki yüksek korelasyon, küresel finansal istikrar açısından önemli bir gösterge olarak değerlendirilir. Bu tür yüksek ilişki, piyasaların aynı şoklara benzer şekilde tepki verdiğini ve küresel risk algısının benzer olduğunu gösterir. Bu durum, büyük finansal krizlerde riskin geniş bir coğrafyaya yayılma potansiyelini artırabilir.
- **Türkiye'nin Farklı Korelasyon Profili:** Türkiye'nin düşük veya negatif korelasyonu, gelişmiş ülkelerle finansal entegrasyonunun daha sınırlı olduğunu ve bu nedenle küresel risk algısının farklı bir yönünü yansıttığını gösterir. Türkiye'nin içsel makroekonomik dengesizlikleri ve siyasi belirsizlikleri, bu farklılığın temel nedenlerindedir. Bu durum, Türkiye'nin belirli dönemlerde küresel sermaye çıkışlarına daha duyarlı hale gelmesine neden olabilir.

#### 5. Küresel Likidite ve Sermaye Akımları

- **ABD ve AMB'nin Korelasyonunun Likidite Etkileri:** Yüksek korelasyon, küresel likidite koşullarının ABD ve Euro bölgesine benzer etkiler yarattığını gösterir. Merkez bankalarının parasal genişleme veya sıkılaştırma dönemlerinde bu iki bölge benzer tepkiler vermekte, bu da sermaye akımlarının iki bölge arasında benzer şekilde hareket etmesine neden olmaktadır.
- **Türkiye'nin Ayrışması ve Sermaye Akışları:** Türkiye'nin düşük korelasyonu, küresel sermaye akımlarından bağımsız hareket edebilme potansiyeline işaret eder. Ancak bu aynı zamanda, Türkiye ekonomisinin içsel dengesizliklere ve risklere karşı daha fazla duyarlılık göstermesine ve küresel likidite değişimlerinden farklı şekilde etkilenmesine de yol açar. Türkiye'nin gelişmekte olan bir piyasa olarak yüksek risk primi talep edilmesi, sermaye akışlarının dalgalanmasına neden olabilir.



Şekil 3.2, ABD, AMB ve Türkiye tahvil piyasaları arasındaki korelasyonu özetleyerek, bu ülkeler arasındaki ekonomik ve finansal ilişkilerin karmaşıklığını ortaya koymaktadır. ABD ve AMB arasındaki yüksek korelasyon, bu iki ekonominin makroekonomik politikalarının ve finansal piyasalarının uyumlu hareket ettiğini ve küresel entegrasyonun güçlü olduğunu göstermektedir. Diğer yandan, Türkiye'nin ABD ve AMB ile düşük veya negatif korelasyonu, bu piyasanın gelişmiş piyasalardan ayrıştığını ve farklı ekonomik dinamiklere sahip olduğunu göstermektedir. Bu analiz, ülkeler arasındaki korelasyonların yatırım stratejileri, risk yönetimi ve küresel ekonomik ilişkiler açısından neden bu kadar önemli olduğunu bir kez daha vurgulamaktadır.

ABD'nin 2014–2023 yılları arasındaki getiri eğrileri bu Şekil 3.3'te üç boyutlu olarak gösterilmektedir. Grafikte x eksenini vade, y eksenini yıllar ve z eksenini getiriyi temsil etmektedir. ABD'nin getiri eğrileri, 2016 ile 2020 yılları arasında önemli ölçüde dalgalanmalar göstermektedir. FED'in faiz oranlarını artırması ve küresel ekonomik belirsizlikler, ABD ekonomisinin bu dönemdeki yoğun dalgalanmaların ana nedenleridir. 2016-2018 yılları arasında getiri eğrisi yükseldiği ve daha sonra 2020'de COVID-19 salgını nedeniyle önemli dalgalanmalar yaşandığı görülmektedir.


Düşük vadelerde (0-5 yıl) getiri oranları daha yüksektir ve vadeler arttıkça getiri oranları düşmektedir. Bu, kısa vadeli faiz oranlarının yüksek olduğu ve uzun vadeli tahvillere yatırımcıların ilgisinin azaldığı bir ekonomik yapıyı göstermektedir. Özellikle 2018 yılından itibaren kısa vadeli faiz oranları önemli ölçüde arttı, bu da FED'in faiz artırımları ile bağlantılıdır. 2020'de pandemi nedeniyle kısa vadeli faiz oranları önemli ölçüde düşüş gözlemlenmiştir.

2014-2016 döneminde, düşük faiz oranlarının hâkim olduğu genişlemeci para politikalarının etkisiyle, mavi ve yeşil renklerin ağırlıkta olduğu görülmüştür. Bu durum, küresel finansal kriz sonrası ekonomiyi desteklemek amacıyla FED'in düşük faiz politikalarını sürdürdüğünü yansıtmaktadır. 2018 yılı ve sonrasında, kırmızı tonların artmasıyla faiz oranlarında belirgin bir yükselme gözlenmiştir. Bu, FED'in enflasyon ve büyüme baskılarına karşı faiz oranlarını artırdığı sıkı para politikası dönemine işaret etmektedir. 2020'de COVID-19 pandemisiyle birlikte, mavi ve yeşil tonlar yeniden baskın hale gelmiştir. Bu renk geçişi, FED'in ekonomiyi desteklemek amacıyla faiz oranlarını düşürdüğünü ve genişlemeci para politikalarına geri döndüğünü açıkça göstermektedir.

Kısa vadeli tahvillerde düşük faiz oranları, mavi ve yeşil tonlarla ifade edilirken, uzun vadeli tahvillerde kırmızı tonların daha baskın olduğu görülmektedir. Bu durum, yatırımcıların uzun vadeli ekonomik riskleri telafi etmek için daha yüksek getiri talep ettiklerini göstermektedir.

ABD tahvillerindeki faiz oranlarının zamansal ve vadeye dayalı analizi, merkez bankası politikalarının piyasa getirileri üzerindeki etkisini açıkça ortaya koymaktadır. 2018 sonrası sıkılaştırılan para politikası ve 2020’de başlayan pandemiyle birlikte uygulanan genişlemeci politikalar, tahvil getirilerinde önemli değişimlere yol açmıştır. Bu analiz, ekonomik dalgalanmaların ve merkez bankası müdahalelerinin tahvil getirileri üzerindeki etkilerini görsel olarak anlamaya olanak tanımaktadır.

ABD Hazine tahvillerinin 2014-2022 dönemindeki getirileri, FED’in politika değişikliklerine duyarlı bir yapı sergilemiştir. Renk bazlı görselleştirme, faiz oranlarındaki dönemsel ve vadeye dayalı değişimleri ortaya koymak için etkili bir yöntemdir. Elde edilen bulgular, ekonomik karar vericilerin ve yatırımcıların piyasa dinamiklerini daha iyi anlamasına katkı sağlamaktadır.




**Şekil 3.3** 2014-2022 Yılları Arasında ABD Hazine Tahvili Getiri Eğrilerinin Zamansal ve Vadeye Dayalı Analizi

Şekil 3.4, Amerika Birleşik Devletleri'nin 2014'ten 2021'e kadar olan dönemde 11 farklı vade için haftalık getiri eğrilerini üç boyutlu bir grafik olarak göstermektedir. Bu grafik, yatay eksenlerde vade ve tarih değişkenlerini, dikey ekseninde ise getiri oranlarını temsil etmektedir. Getiri eğrileri, belirli bir zaman diliminde farklı vadelerdeki getirilerin değişimini ve genel eğilimleri görselleştirmektedir. Renk skalası, getiri oranlarını vurgulamakta olup, daha yüksek getiriler sarı ve yeşil tonlarında, daha düşük getiriler ise mavi ve mor tonlarında gösterilmiştir. Bu görselleştirme, belirli dönemlerdeki faiz oranlarının nasıl değiştiğini ve piyasaların nasıl tepki verdiğini analiz etmek için kullanışlı bir araçtır. Özellikle, finansal koşullar ve para politikası çalışmaları açısından, bu getiri eğrilerinin zaman içindeki hareketleri önemli ipuçları sunmaktadır.

Grafikte, kısa vadeli faiz oranlarının zamanla dalgalandığı, uzun vadeli oranların ise daha sabit bir yapıya sahip olduğu dikkat çekmektedir. Özellikle 2020'de faiz oranlarının sıfıra yakın seviyelere inmesi, COVID-19 pandemisi sırasında uygulanan genişlemeci para politikalarını yansıtmaktadır. Pandemi sonrasında, özellikle 2022'den itibaren faiz oranlarında keskin bir artış görülmekte olup, bu durum enflasyonu kontrol altına almak amacıyla gerçekleştirilen para politikası sıkılaştırmalarına işaret eder.

Uzun vadeli tahvillerde, piyasanın uzun dönemli büyüme ve enflasyon beklentilerinin yansıdığı daha istikrarlı bir eğri gözlemlenirken, kısa vadeli faiz oranlarındaki oynaklık, para politikasının hızlı etkilerine işaret etmektedir. Ayrıca, 2019-2020 arasında getiri eğrisinde meydana gelen yataylaşma ve potansiyel ters eğim, ekonomik yavaşlama veya resesyona beklentilerini yansıtabilir. Genel olarak, grafikteki veriler ekonomik dalgalanmalar, merkez bankası politikaları ve piyasa beklentilerinin tahvil getirileri üzerindeki etkisini net bir şekilde ortaya koymaktadır.

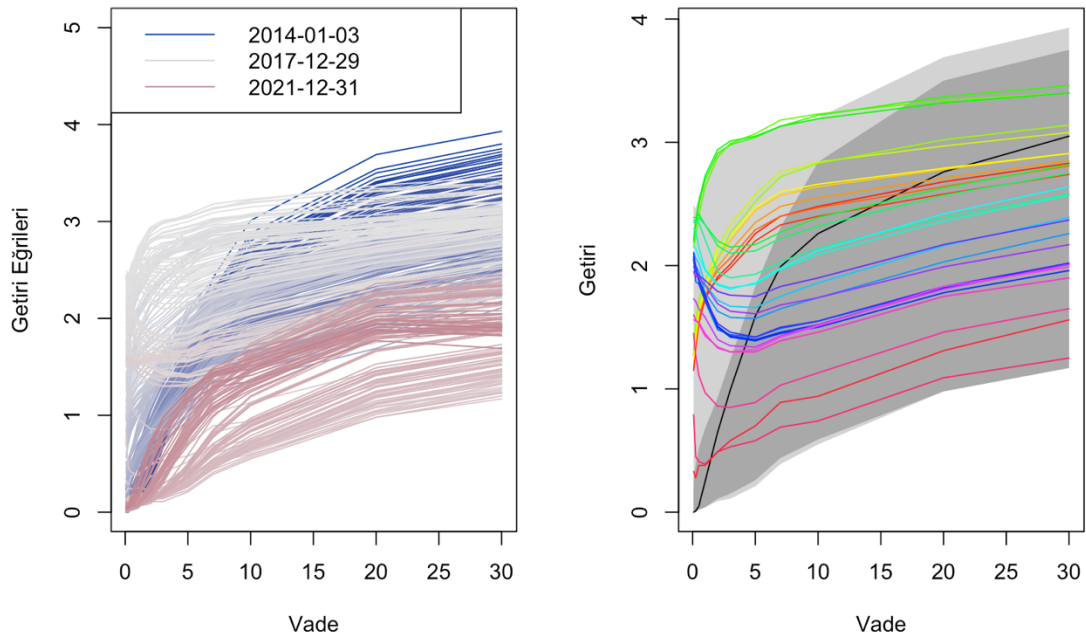


**Şekil 3.4** ABD'nin 2014'ten 2021'e 11 Vadede Haftalık Getiri Eğrileri

Şekil 3.5, ABD getiri eğrilerine ait grafikler, faiz oranlarının vade yapısındaki zamansal dinamiklerini anlamak için fonksiyonel zaman serisi analizine dayalı olarak üretilmiştir. Soldaki grafik, 2014, 2017 ve 2021 yıllarına ait getiri eğrilerinin karşılaştırmasını sunmaktadır. Bu eğriler, kısa vadeden uzun vadeye kadar faiz oranlarındaki değişimlerin piyasa koşulları üzerindeki etkilerini görselleştirmektedir. Özellikle kısa vadeli faiz oranlarının (0-5 yıl) zaman içinde daha fazla dalgalanma gösterdiği ve uzun vadede (10-30 yıl) daha istikrarlı bir yapıya ulaştığı gözlemlenmektedir. 2014 yılında eğrilerin daha yüksek seviyelerde yer alması, sıkı para politikalarının bir etkisi olarak yorumlanabilirken, 2021 yılında görülen düşük seviyeler, pandemi sonrası dönemde benimsenen genişleyici para politikalarının ve düşük faiz ortamının bir yansımasıdır. 2017 yılı eğrileri ise bu iki dönem arasında orta seviyede bir denge durumunu işaret etmektedir ve bu dönem, ekonomik istikrarın sağlandığı bir geçiş yılı olarak değerlendirilebilir.

Sağdaki grafik, fonksiyonel kutu grafiği yöntemiyle getiri eğrilerinin istatistiksel özetini sunmaktadır. Fonksiyonel kutu grafiği, verilerin yoğun olduğu merkezi eğilimleri ve uç noktaları görselleştirmek için oldukça etkili bir araçtır. Gri tonlarla gösterilen alanlar, eğrilerin çoğunlukla yoğunlaştığı bölgeleri ifade ederken, renkli eğriler piyasa anomalilerini ve uç noktaları temsil etmektedir. Analizde kullanılan PCAproj yöntemi (Principal Component Analysis Projection), getiri eğrilerinin temel bileşenlerini çıkararak yüksek boyutlu veriyi indirger ve varyasyonun en büyük olduğu boyutlara odaklanır. Bu yaklaşım, veri setindeki temel yapıyı ve varyasyonları anlamak için güçlü bir matematiksel çerçeve sunar. PCAproj, grafikte kullanılan farklı projeksiyonlar aracılığıyla, kısa vadeli faiz oranlarının (0-5 yıl) ekonomik şoklara daha duyarlı olduğunu, uzun vadeli faiz oranlarının ise daha istikrarlı piyasa beklentileriyle şekillendiğini göstermektedir. Ayrıca, uç noktaların (outliers) belirginleşmesi, piyasa anormalliklerinin ve ekonomik şokların etkilerinin analizine olanak tanır.

Bu grafikler, ABD getiri eğrilerinin zamansal yapısını ve ekonomik koşullardaki değişimlerin piyasa dinamiklerine etkisini anlamak için önemli bir araçtır. PCAproj yöntemi sayesinde, eğriler arasındaki temel varyasyon kaynakları açıkça ortaya çıkarılmakta ve kısa vadeli faiz oranlarındaki oynaklığın uzun vadeli oranlara kıyasla daha fazla olduğu anlaşılmaktadır. Bu tür bir analiz, makroekonomik politika, piyasa istikrarı ve risk yönetimi stratejileri açısından değerli bilgiler sunmaktadır. Ayrıca, ABD getiri eğrilerinin Avrupa Merkez Bankası (ECB) eğrileri ile karşılaştırılması, küresel ekonomik dinamiklerin değerlendirilmesine yönelik daha kapsamlı bir perspektif sunabilir. PCAproj yöntemiyle sağlanan bu detaylı analiz, özellikle finansal modelleme ve tahvil piyasası çalışmalarında ileri düzey bir analitik yaklaşım sunmaktadır.



**Şekil 3.5** ABD Getiri Eğrilerinin Tarihsel Karşılaştırması ve Fonksiyonel Kutu Grafiği ile İstatistiksel Özet


Şekil 3.6, 2014-2023 yılları arasında Avrupa Merkez Bankası'nın (AMB) haftalık bazda 32 farklı vadeye ait getiri eğrisi dinamiklerini göstermektedir. Grafik, bu dönemdeki ekonomik olaylar ve para politikası kararlarının tahvil getirileri üzerindeki etkisini açıkça ortaya koymaktadır. Özellikle kısa vadeli getirilerin oldukça oynak bir yapıya sahip olduğu, uzun vadeli getirilerin ise görece daha istikrarlı olduğu gözlenmektedir. Bu durum, kısa vadeli getirilerin doğrudan AMB'nin para politikası kararlarından etkilendiğini, uzun vadeli getirilerin ise piyasanın uzun vadeli beklentilerini yansıttığını göstermektedir.

2016-2020 döneminde kısa vadeli getirilerin ağırlıklı olarak negatif bölgede seyrettiği dikkat çekmektedir. Bu durum, düşük büyüme ve düşük enflasyon ortamında ekonomik aktiviteyi teşvik etmek için uygulanan negatif faiz politikasının bir sonucudur. 2019-2020 yıllarında gözlemlenen yatay veya ters getiri eğrisi ise ekonomik durgunluk endişelerinin arttığını işaret etmektedir. COVID-19 pandemisinin 2020'deki etkisiyle birlikte, AMB'nin likiditeyi artırmak ve ekonomik toparlanmayı desteklemek amacıyla uyguladığı genişlemeci para politikaları sonucunda getiriler daha da gerilemiştir.

Pandemi sonrası dönemde, özellikle 2022 itibarıyla, kısa vadeli faiz oranlarında keskin bir artış yaşanmıştır. Bu artış, enflasyonla mücadele kapsamında uygulanan sıkı para

politikalarının bir yansımasıdır ve getiri eğrisinin eğimini artırmıştır. Uzun vadeli getirilerde ise nispeten daha az değişim görülmüş, bu da uzun vadeli ekonomik büyüme ve enflasyon beklentilerinin daha istikrarlı olduğunu göstermektedir.

Genel olarak, AMB'nin getiri eğrisi dinamikleri, düşük enflasyon ve büyüme ortamından pandemi şoklarına ve ardından enflasyonist baskılarla mücadeleye kadar uzanan ekonomik koşullara adaptasyonunu yansıtmaktadır. Grafik, AMB para politikalarının tahvil piyasası üzerindeki etkisini ve bu etkilerin Euro Bölgesi ekonomisinin istikrarı ve yatırım kararları üzerindeki önemini vurgulamaktadır.



**Şekil 3.6** Euro Bölgesi'nin 2014 - 2023 Yıllarında 32 Vadede Haftalık Getiri Eğrileri


Şekil 3.7, 2016–2020 yılları arasındaki getiri eğrileri üç boyutlu bir grafikte gösterilmektedir. Grafikte x eksenini olgunluğu, y eksenini yılları ve z eksenini getiriyi temsil etmektedir. 2016 yılından itibaren getiri eğrilerinin genel olarak yukarı doğru bir eğilim gösterdiği ve 2020 yılına kadar daha az değişken hale geldiği görülmektedir. Bu, faiz



oranlarının zaman içindeki seyrini anlamamıza yardımcı olmak için ekonomik koşulların ve piyasa dinamiklerinin yıllar içinde nasıl değiştiğini göstermektedir.

Faiz oranlarındaki çeşitli yıllardaki değişiklikler ve volatilité, eğrilerdeki renk değişimleriyle görsel olarak gösterilebilir. Vadeler arttıkça getiri oranlarının nasıl değiştiği dikkat çekicidir. Bununla birlikte, düşük vadelerde (0-5 yıl) daha düşük getiriler tipik olarak görülmektedir. Grafikte kullanılan renkler, getiri oranlarının seviyelerini temsil eder. Mavi renkler tipik olarak daha düşük getiri oranlarına, kırmızı renkler ise daha yüksek getiri oranlarına atıfta bulunur. Zaman içinde getiri eğrilerindeki değişikliklerin daha iyi anlaşılması için renk geçişleri kullanılmaktadır. Bu grafik, özellikle ekonomik dalgalanmalar ve politika değişiklikleri sırasında meydana gelen ani dönüşümleri göstermektedir.

Getiri eğrilerinin değişkenliği ve yoğunluğu, ekonomik koşulların ve piyasaların zaman içinde nasıl değiştiğini göstermektedir. Yıl içindeki keskin yükselişler ve düşüşler, politika değişikliklerinin veya belirli ekonomik gelişmelerin etkilerini gösterebilir. Örneğin, COVID-19 pandemisinin 2020 yılında ekonomi üzerindeki etkisinin bir sonucu olarak getiri eğrilerinde önemli değişiklikler gözlemlenmektedir.

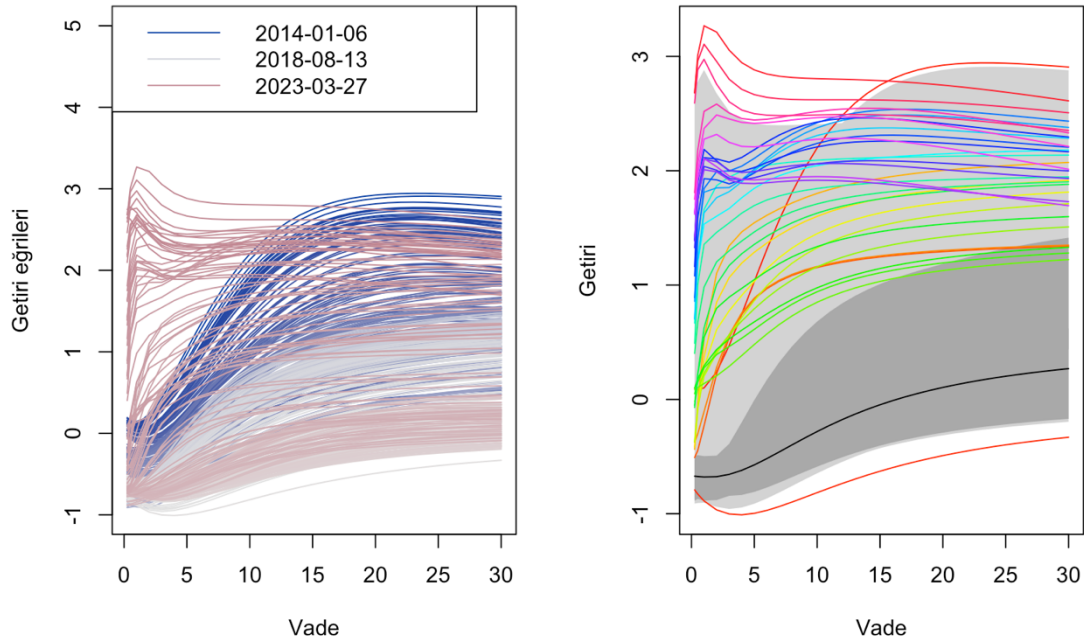


**Şekil 3.7** 2014-2022 Yılları Arasında Euro Bölgesi Tahvil Getiri Eğrilerinin Zamansal ve Vadeye Dayalı Analizi

Şekil 3.8, Avrupa Merkez Bankası (AMB) verilerine dayanarak getiri eğrilerinin zamansal dinamiklerini incelemeye yönelik önemli içgörüler sunmaktadır. Soldaki grafik, 2014, 2018 ve 2023 yıllarına ait getiri eğrilerinin zamana bağlı olarak nasıl şekillendiğini göstermektedir. Grafik, faiz oranlarının ve ekonomik koşulların zamanla değişimini görselleştirirken, kısa vadeli getiri eğrilerinin (0.25 ila 1 yıl) uzun vadeli eğrilere (10 ila 30 yıl) kıyasla daha yüksek volatilité sergilediği dikkat çekmektedir. Bu eğilim, genellikle kısa vadeli finansal ürünlerin ekonomik belirsizliklere daha duyarlı olmasıyla ilişkilendirilebilir. Özellikle 2014 yılında daha düşük seviyelerde yer alan eğriler, 2023'te genel olarak daha yüksek seviyelere ulaşmış ve bu durum faiz oranlarındaki artışlarla tutarlılık göstermiştir. Eğrilerin yukarı doğru hareketi, ekonomik büyüme, enflasyon beklentileri ve merkez bankası politikalarındaki sıkılaştırma ile ilişkilendirilebilir.

Sağdaki grafik, fonksiyonel kutu grafiği olarak, getiri eğrilerinin istatistiksel özetini sunmaktadır. Grafik, fonksiyonel veri analizindeki projeksiyon yöntemleri (PCAproj) kullanılarak merkezi eğilimleri ve uç değerleri görselleştirmiştir. Koyu gri alanlar, getiri eğrilerinin büyük bir kısmının yoğunlaştığı bölgeleri temsil ederken, açık gri ve renkli alanlar, veri setindeki uç değerleri ve daha az rastlanan eğrileri göstermektedir. Kısa vadede (0 ila 10 yıl arası) daha büyük dalgalanmalar gözlemlenirken, uzun vadede (10 ila 30 yıl) eğrilerin daha öngörülebilir bir yapıya sahip olduğu görülmektedir. Bu durum, kısa vadeli faiz oranlarının ekonomik şoklara daha duyarlı olmasının yanı sıra, uzun vadeli oranların piyasa katılımcıları arasında geleceğe yönelik daha stabil beklentilerle şekillenmesiyle açıklanabilir. Ayrıca, grafikteki uç noktalar, olası ekonomik şokları veya piyasa anomalilerini işaret ederek, makroekonomik analizler ve risk modellemeleri için değerli bir zemin oluşturmaktadır.

Genel olarak, her iki grafik de getiri eğrilerinin zaman içerisindeki değişimlerini ve bu değişimlerin altında yatan dinamikleri anlamak için değerli görsel araçlardır. Bu analiz, ekonomik dalgalanmaların merkez bankası politikaları üzerindeki etkilerini ve piyasa katılımcılarının faiz oranlarına yönelik beklentilerini daha iyi anlamak için önemli bilgiler sunmaktadır. Özellikle, verilerin getiri eğrileri üzerindeki tarihsel ve yapısal etkilerini daha ayrıntılı inceleyerek, hem akademik hem de uygulamalı ekonomi alanlarında katkılar sağlanabilir.




**Şekil 3.8** Euro Bölgesi Getiri Eğrilerinin Tarihsel Karşılaştırması ve Fonksiyonel Kutu Grafiği ile İstatistiksel Özet

Şekil 3.9, 2016 ile 2020 yılları arasındaki Türkiye getiri eğrileri bu grafikte üç boyutlu olarak gösterilmektedir. Grafikte x eksenini vade, y eksenini yıllar ve z eksenini getiriyi temsil etmektedir. Bu grafik, Türkiye'nin ekonomik ve finansal durumu hakkında önemli bilgiler sunmaktadır. 2018–2020 yılları arasında Türkiye'nin getiri eğrileri önemli ölçüde dalgalanmalar göstermiştir. Politika belirsizliği, yüksek enflasyon oranları ve para birimindeki değer kaybı, bu dalgalanmaların başlıca nedenleridir.

Düşük vadelerde (0-5 yıl) getiri oranlarının daha yüksek olduğu ve vadeler arttıkça getiri oranlarının kademeli olarak düştüğü gözlemlenmektedir. Bu durum, kısa vadeli faiz oranlarının yüksek olduğu ve yatırımcıların uzun vadeli tahvillere daha az talep gösterdiği bir ekonomik yapıyı yansıtmaktadır. Özellikle 2018 yılından itibaren kısa vadeli faiz oranlarının belirgin şekilde arttığı görülmektedir; bu, o dönemdeki ekonomik kriz ve yüksek enflasyon oranları ile ilişkilidir.

Renk geçişleri, Türkiye ekonomisinin ve finansal durumunun zaman içinde nasıl değiştiğini daha iyi anlamamıza yardımcı olmaktadır. Kırmızı bölgelerin artması, özellikle 2018 ve sonrasında, faiz oranlarının yüksek seviyelerde seyrettiği bir dönemi temsil ediyor.

Getiri eğrilerinin dalgalanma yoğunluğu ve değişkenliği, Türkiye piyasalarının ve ekonomik durumlarının zaman içinde nasıl değiştiğini göstermektedir. Yıl içindeki keskin yükselişler ve düşüşler, belirli ekonomik olaylar veya politika değişikliklerinin etkilerini yansıtabilir. Örneğin, 2018 yılındaki döviz krizi, getiri eğrilerinde belirgin dalgalanmalara yol açmıştır. Bu tür dalgalanmalar, piyasa oyuncuları için önemli bilgi kaynaklarıdır ve gelecekteki ekonomik kararlar için temel oluşturabilir.



**Şekil 3.9** 2014-2022 Yılları Arasında Türkiye Tahvil Getiri Eğrilerinin Zamansal ve Vadeye Dayalı Analizi


Şekil 3.10, Türkiye'nin 2014-2023 yılları arasında haftalık bazda tahvil getiri eğrilerindeki değişimleri göstermektedir ve özellikle kısa vadeli faiz oranlarındaki yüksek volatilité dikkat çekmektedir. Kısa vadelerdeki keskin dalgalanmalar, Türkiye ekonomisinin yüksek enflasyonist baskılar, döviz kuru oynaklıkları ve sık sık değişen para

politikaları ile karakterize edilen makroekonomik istikrarsızlıklarını yansıtmaktadır. Özellikle 2021 ve 2022 yıllarında kısa vadeli getirilerdeki ani yükselişler, enflasyon oranlarının hızla artışı ve Türk Lirası'nın değer kaybı ile bağlantılıdır. Bu durum, yatırımcıların yüksek risk algısıyla kısa vadeli tahvillere yönelmesinden kaynaklanmış olabilir.

Uzun vadeli tahvil getirilerinin daha stabil bir yapı sergilemesine rağmen, bu getirilerin yüksek seviyelerde seyretmesi, Türkiye ekonomisinde uzun vadeli borçlanma maliyetlerinin arttığını ve ülkenin genel olarak yüksek risk primi taşıdığını göstermektedir. Ayrıca, Türkiye'nin ulusal ekonomik politikalarının belirsizliği ve döviz rezervlerindeki zayıflık, uluslararası yatırımcılar tarafından risk algısını artırmış ve piyasa oynaklığını derinleştirmiştir.

2020 sonrası dönemde, pandemi etkisinin hafiflemesiyle birlikte faiz oranlarının artırılması ve sıkılaştırıcı para politikalarının benimsenmesi, getiri eğrilerindeki dikleşmeyi ve özellikle kısa vadeli tahvil getirilerindeki yükselişi tetiklemiştir. Ancak, bu durum ekonomik büyüme üzerinde sınırlayıcı etkiler yaratmış olabilir. Grafikte gözlemlenen yüksek dalgalanma ve volatilité, Türkiye ekonomisindeki makroekonomik belirsizliklerin ve politika uyumsuzluklarının tahvil piyasası üzerindeki baskısını açıkça ortaya koymaktadır.

Sonuç olarak, Türkiye'nin getiri eğrisi dinamikleri, enflasyon, kur oynaklığı ve para politikası belirsizliklerinin tahvil piyasası üzerindeki güçlü etkisini vurgulamaktadır. Bu bulgular, Türkiye tahvil piyasasının uluslararası yatırımcılar için yüksek risk ve getiri sunan bir profil çizdiğini ortaya koymakta ve ekonomik istikrarın sağlanmasının piyasa oynaklığını azaltmada kritik bir rol oynayacağını göstermektedir.




**Şekil 3.10** Türkiye'nin 2014 - 2023 Yıllarında 9 Vadede Haftalık Getiri Eğrileri

Şekil 3.11, faiz oranlarının vade yapısı üzerindeki zamansal değişimleri anlamak için fonksiyonel zaman serisi analizi çerçevesinde ele alınmıştır. Soldaki grafik, 2014, 2018 ve 2023 yıllarına ait getiri eğrilerinin tarihsel karşılaştırmasını sunmaktadır. Grafik, kısa vadeden uzun vadeye (0 ila 10 yıl) kadar faiz oranlarının dinamiklerini ve piyasa koşullarındaki değişiklikleri göz önüne sermektedir. 2014 yılında eğrilerin düşük seviyelerde olması, o dönemin görece daha istikrarlı ekonomik koşullarını ve kontrollü faiz politikalarını yansıtmaktadır. Buna karşın, 2023 yılı eğrilerinde kısa vadeden itibaren belirgin bir yükseliş gözlemlenmekte, bu durum yüksek enflasyonist baskılar ve ekonomik belirsizliklerin piyasa faiz oranlarına yansımaları olarak değerlendirilmektedir. 2018 yılı eğrileri ise bu iki dönem arasında bir geçiş dinamiği sunmakta ve o dönemdeki piyasa oynaklığını göstermektedir. Özellikle kısa vadeli faiz oranlarındaki değişkenliğin, ekonomik şoklara ve para politikalarındaki dalgalanmalara olan duyarlılığın bir yansıması olduğu söylenebilir.

Sağdaki grafik ise fonksiyonel kutu grafiği yardımıyla, getiri eğrilerinin yoğunlaştığı alanları ve piyasa anomalilerini istatistiksel olarak özetlemektedir. Koyu gri alanlar, faiz oranlarının büyük bir kısmının yoğunlaştığı merkezi eğilimleri temsil ederken, renkli eğriler piyasanın uç noktalarını ve aykırı durumlarını görselleştirmektedir. Bu grafik, analizin projeksiyon kısmında PCAproj yöntemini kullanarak, getiri eğrilerindeki varyasyon kaynaklarını ve temel yapıları öne çıkarmaktadır. PCAproj yöntemi, özellikle kısa vadeli oranların ekonomik belirsizliklere karşı hassasiyetini ortaya koyarken, uzun vadeli faiz oranlarının daha stabil bir yapıda olduğunu göstermektedir. 2023 yılında kısa vadeli faiz oranlarındaki dalgalanma, piyasa katılımcılarının yüksek enflasyon ve makroekonomik belirsizliklerden kaynaklanan risk algısını net bir şekilde yansıtmaktadır.

Bu analiz, Türkiye'deki ekonomik dalgalanmaların ve politika değişikliklerinin getiri eğrileri üzerindeki etkilerini anlamak için önemli bir görselleştirme sunmaktadır. Özellikle, kısa vadeli faiz oranlarında gözlemlenen oynaklık, piyasa katılımcılarının beklentileri ve risk algılarındaki ani değişimlerle ilişkilidir. Diğer yandan, uzun vadeli faiz oranlarının daha istikrarlı bir yapı göstermesi, yatırımcıların uzun vadede ekonomik istikrar beklentilerine olan güvenini yansıtmaktadır. Türkiye'nin getiri eğrileri üzerindeki bu detaylı analiz, makroekonomik politika kararları, piyasa risk değerlendirmeleri ve küresel piyasa dinamiklerinin daha geniş bir bağlamda değerlendirilmesine katkı sağlamaktadır. Bu bağlamda, Türkiye getiri eğrilerinin Avrupa ve ABD gibi diğer ekonomilerle karşılaştırılması, küresel piyasa trendleri ve bölgesel farklılıkların analizinde yeni bakış açıları sunabilir.





**Şekil 3.11** Türkiye Getiri Eğrilerinin Tarihsel Karşılaştırması ve Fonksiyonel Kutu Grafiği ile İstatistiksel Özet

### 3.7. Çalışma Tasarımı

Bu bölüm, sonraki bölümde açıklanan her modelleme yöntemine uygulanan genel bir çalışma tasarımını sunmaktadır. Tüm ampirik analizler, R versiyon 3.6.3 (R Core Team, 2023) ve Python 3.9 programlama dili (Python Software Foundation, 2020) kullanılarak gerçekleştirilmiştir. Python ve R, bu çalışmada birbirini tamamlayan önemli araçlar olarak kullanılmıştır. Python'un esnek programlama altyapısı ve R'nin istatistiksel analiz kabiliyetleri, çalışmanın veri işleme ve modelleme süreçlerinde etkili bir şekilde birleştirilmiştir.

Örnekleme Dışı Test ve K-Kat Çapraz Doğrulama, model performansını değerlendirmek için kullanılan iki temel yöntemdir. Örnekleme Dışı Test, modelin gerçek dünya verilerinde nasıl performans göstereceğini belirlemek amacıyla kullanılır. Bu yöntemde, mevcut veri seti eğitim ve test olmak üzere ikiye ayrılır. Eğitim verisi, modelin öğrenmesi için kullanılırken, test verisi modelin performansını değerlendirmek için kullanılır. Bu süreçte model, test verisindeki sonuçları tahmin eder ve bu tahminlerin doğruluğu ölçülür. Bu yöntem, modelin yeni ve görülmemiş verilerdeki genelleme


yeteneğini değerlendirmemize olanak tanır ve yanlış performans değerlendirmesini önler (Bergmeir vd., 2018).

K-Kat Çapraz Doğrulama ise, model performansını daha sağlam ve genelleştirilebilir bir şekilde değerlendirmek amacıyla kullanılır. Bu yöntem, veri setini  $k$  adet alt küme (fold) olarak böler ve her bir alt küme, sırayla test seti olarak kullanılırken, diğer  $k-1$  alt küme eğitim için kullanılır. Bu süreç  $k$  kez tekrarlanır ve her seferinde farklı bir alt küme test seti olarak kullanılır. Sonuç olarak, her bir döngüyle elde edilen performans ölçüleri ortalanarak genel bir performans ölçütü elde edilir. K-Kat Çapraz Doğrulama, tek bir eğitim ve test bölmesi yerine modelin farklı veri bölmelerindeki performansını değerlendirdiği için daha güvenilir bir performans tahmini sağlar ve tüm veri setinin hem eğitim hem de test için kullanılmasına olanak tanır (Zhang, 2021).

Üçüncü bir yöntem olarak Kayan Pencere Yöntemi, zaman serisi analizlerinde kullanılan bir tekniktir ve diğer iki yönteme kıyasla zaman bağımlılığı içeren verilerde model performansını değerlendirmek için özelleşmiş bir yaklaşımdır. Bu yöntem, zaman serisi boyunca belirli bir pencerenin adım adım kaydırılması ile verilerin eğitim ve test setlerine ayrılmasını sağlar. Birden fazla tahmin modeli üretmek için belirli bir pencere uzunluğu  $l$  olan eğitim verilerinin yuvarlanan bir penceresi kullanılmıştır. Mevcut veri penceresine dayanarak, sonraki  $h$  dönemleri için tahminler yapılır ve tüm eğri üzerindeki ortalama tahmin hatası kaydedilir. Tüm veri seti boyunca adım adım ilerleyerek bu tahmin sürecinin tekrarlanması, sırasıyla set boyutuna ve seçilen yuvarlanan pencerenin hafta sayısına bağlı olarak bu yöntem için bir tahmin doğruluğu ölçüsü verir. Şekil 3.12, pencerenin kademeli olarak kaydırılmasıyla bu yaklaşımı göstermektedir.

Şekil 3.12’de, yeşil bloklar eğitim verilerini temsil ederken, mor-sarı bloklar test verilerini göstermektedir. Beyaz bloklar ise kullanılmayan veya henüz işlem görmemiş veri noktalarını belirtir. İlk adımda, belirli sayıda veri noktaları eğitim seti olarak seçilir (yeşil bloklar) ve hemen ardından gelen veri noktaları test seti olarak kullanılır (mor-sarı bloklar). Bu pencere, belirli bir adım boyutu ile kaydırılarak yeni eğitim ve test veri setleri oluşturulur. Bu işlem, zaman serisinin tamamı boyunca tekrarlanır. Her yeni adımda pencere, eğitim ve test verilerini kapsayacak şekilde kaydırılır, böylece modelin farklı dönemlerdeki performansı karşılaştırılabilir. Örnek tahmin ufku 4 dönemdir. Kayan pencere yöntemi, modelin zaman içindeki değişimlere nasıl tepki verdiğini anlamak ve

zamansal bağımlılıkları değerlendirmek için etkili bir yaklaşımdır. Bu yöntem, özellikle zaman serisi verilerinde modelin genel performansını ve doğruluğunu artırmak amacıyla kullanılmaktadır.



Şekil 3.12 Zaman Serisi İçin Kayan Pencere Yaklaşımı

### 3.8. Karşılaştırma Kriteri

Finansal modellerin performansını değerlendirmek için bir dizi istatistiksel yöntem kullanılmaktadır. Model performanslarını karşılaştırmak ve değerlendirmek, finansal modelleme süreçlerinde kritik bir adımdır. Etkili bir model değerlendirme süreci, tahmin edilen değerlerin gözlemlenen gerçek verilerle olan uyumunu ölçmekle başlar. Bu doğrultuda, modellerin tahmin doğruluğunu ve genelleme kapasitesini analiz etmek için yaygın olarak kullanılan istatistiksel ölçütlerden biri olan kök-ortalama-kare hatası (RMSE) bu çalışmada temel kriter olarak benimsenmiştir.

Bu çalışmada, modellerin tahmin performansını değerlendirmek için kök-ortalama-kare hatası kullanılmıştır. RMSE, tahmin edilen değerler ile gerçek değerler arasındaki farkın karesini hesaplayan, bu farkların ortalamasını alan ve son olarak karekökünü alan bir ölçüttür. Aşağıda RMSE formülü tanımlanmıştır:

$$RMSE_i = \sqrt{\frac{\sum_{\tau=1}^m (\hat{y}[\tau, i] - y[\tau, i])^2}{m}} \quad (3.20)$$

$\hat{y}[\tau, i]$ ,  $i$  dönemi ve  $\tau$  vadeli tahmin edilen getiriyi,  $y[\tau, i]$  ilgili  $i$  dönemi ve  $\tau$  vadeli gözlemlenen gerçek getiriyi,  $\tau$  belirli bir vade noktasını,  $m$  ise her bir  $i$  dönemindeki toplam vade sayısını ifade etmektedir. RMSE değeri, bir tahmin modelinin tüm getiri eğrilerini kapsayan tahmin hatalarının ortalama karesel hatasının bir ölçüsüdür.

RMSE, Diebold ve Li (2006) tarafından faiz oranı modellerinin değerlendirilmesinde kullanılmış ve bu alandaki literatürde standart bir karşılaştırma kriteri olarak benimsenmiştir. Bu yöntem, model hatalarının ölçülmesi ve farklı modeller arasında doğruluk kıyaslaması yapılmasına olanak tanır. RMSE'nin kullanımı, tahmin edilen tahvil fiyatlarının gerçek piyasa fiyatlarına yakınlığını ölçmek amacıyla özellikle uygundur. Chinn ve Kucko (2010), Molenaars vd. (2015), Arbia ve Di Marcantonio (2015), Sambasivan ve Das (2017) ile Castello ve Resta (2022) gibi çalışmalar RMSE'yi finansal tahmin modellerinin genelleştirilebilirliğini test etmek için kullanmıştır.

Buna ek olarak, bu çalışmada RMSE yanında MSE, MAE ve MAPE gibi diğer istatistiksel ölçütler de kullanılmıştır. Bu metrikler, tahmin performansını farklı boyutlarıyla değerlendirme imkânı sağlamaktadır:

- **MSE (Mean Squared Error):** RMSE'nin karekök alınmamış hâli olarak düşünülebilir. Tahmin ve gerçek değerler arasındaki hataların karesinin ortalamasını alarak, büyük hataları daha baskın şekilde yansıtır.

$$MSE_i = \frac{1}{m} \sum_{\tau=1}^m (\hat{y}[\tau, i] - y[\tau, i])^2 \quad (3.21)$$

Burada  $m$  her bir  $i$  dönemindeki toplam vade sayısını,  $y[\tau, i]$  gerçek getiriyi ve  $\hat{y}[\tau, i]$  tahmin edilen getiriyi ifade etmektedir.

- **MAE (Mean Absolute Error):** Tahmin edilen değer ile gerçek değer arasındaki mutlak farkların ortalamasını hesaplar. Modellerin ortalama mutlak sapmasını ölçmekte etkilidir ve yorumlaması kolaydır.

$$MAE_i = \frac{1}{m} \sum_{\tau=1}^m |\hat{y}[\tau, i] - y[\tau, i]| \quad (3.22)$$

Bu ölçüt, hataların mutlak değerlerinin ortalamasını alarak tahmin sapmasının düzeyini doğrudan yansıtmaktadır.

- **MAPE (Mean Absolute Percentage Error):** Hataları yüzdesel olarak ifade eder. Gerçek değerlerin sifira yakın olmadığı durumlarda, tahmin performansını oransal farklılık üzerinden değerlendirerek, farklı büyüklükteki serilerin kıyaslanmasında pratik bir ölçüt sunar.

$$MAPE_i = \frac{100}{m} \sum_{\tau=1}^m \left| \frac{\hat{y}[\tau, i] - y[\tau, i]}{y[\tau, i]} \right| \quad (3.23)$$

Gerçek değer  $y[\tau, i]$  sifira yakın olmadığı sürece, tahmin hatalarını yüzdesel olarak ifade ederek farklı büyüklükteki serileri kıyaslamada kolaylık sağlar.

Bu ek ölçütler, tahmin hatalarına farklı açılardan bakarak modellerin doğruluk performansını derinlemesine analiz etme olanağı verir. Dolayısıyla, RMSE'nin yanı sıra MSE, MAE ve MAPE kullanımı, model performansının çok boyutlu bir değerlendirmesini yaparak daha kapsamlı sonuçlar elde etmeyi amaçlamaktadır.

### 3.9. Sonuçlar

Dinamik Nelson-Siegel (DNS) modelinin VAR(1) ve Kalman Filtreleme (KF) versiyonları, modelin temel bir bileşeni olan  $\lambda$  parametresinin belirlenmesini gerektirir. Bu parametre, getiri eğrisinin eğim ve şekil faktörlerini kontrol ederek modelin vadeler arasında daha iyi bir uyum sağlamasına olanak tanır.  $\lambda$ , DNS modelinde vade yapılarını belirleyen anahtar bir parametredir. Modeldeki yükseklik ( $L$ ), eğim ( $S$ ), ve şekil ( $C$ ) faktörlerinin fonksiyonel formu doğrudan  $\lambda$ 'nın değerine bağlıdır. Bu parametre:

- Daha düşük vadelerde eğriye keskin dönüşler sağlar,
- Daha uzun vadelerde eğrinin yataylaşmasını kontrol eder.

Modelin başarısı,  $\lambda$ 'nın doğru seçilmesine bağlıdır. Yanlış bir  $\lambda$  değeri, tahmin doğruluğunu ve model uyumunu ciddi şekilde etkileyebilir. Bu nedenle,  $\lambda$ 'nın veri setine özgü bir optimizasyon prosedürü ile belirlenmesi gerekir.

DNS-VAR(1) ve DNS-KF yöntemleri,  $\lambda$  parametresini belirlemek için grid search tabanlı bir optimizasyon yöntemi uygular. Aşağıda bu yöntem açıklanmıştır:

$\lambda$  'nın seçimi, verilerden en iyi uyumu sağlayacak parametreyi bulmak için şu şekilde gerçekleştirilir:

Amaç Fonksiyonu:

$$\hat{\lambda}_t = \underset{\lambda \in \mathbb{R}}{\operatorname{argmin}} OLS_t^{NS}(\lambda) \quad (3.24)$$

Burada,  $OLS_t^{NS}(\lambda)$ , gözlemlenen getiri eğrisi  $(y_t(\tau))$  ile modelin tahmini  $(\hat{y}_t(\tau, \lambda))$  arasındaki karesel hata toplamını (OLS) ifade eder:

$$OLS_t^{NS}(\lambda) = \sum_{\tau} (y_t(\tau) - \hat{y}_t(\tau, \lambda))^2 \quad (3.25)$$

Grid Search Yöntemi:  $\lambda$ ,  $[0.001, 2]$  aralığında belirli bir adım büyüklüğü (0.001) ile taranır. Her bir  $\lambda$  değeri için OLS fonksiyonu hesaplanır ve minimum OLS değeri veren  $\lambda$ , model için optimal parametre olarak seçilir.

Bu prosedür, modelin vadeler arasında daha doğru ve esnek bir uyum sağlamasına olanak tanır. Özellikle:

- **DNS-VAR(1):** Vadeler arasındaki ilişkiyi vektör otoregresif bir yapı içinde modellemek için optimize edilmiş bir  $\lambda$  sağlar.
- **DNS-KF:** Kalman filtreleme aşamasında kullanılan gözlem ve geçiş matrislerinin  $\lambda$  'ya bağlı olarak doğru tanımlanmasını mümkün kılar.

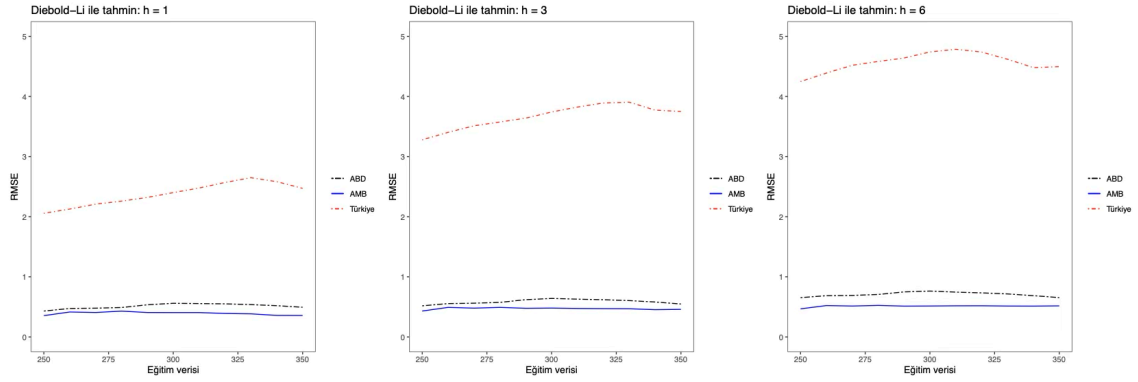
Bu süreç, DNS modelinin dinamik yapısını ve veri setine olan duyarlılığını artırır. Grid search, hesaplama açısından maliyetli olsa da, özellikle getiri eğrisi tahmini gibi hassas modellerde yüksek doğruluk sağlar.

Bu tezde incelenecek olan DL modelini temsil eden standart model,  $AR(1)$  süreci ile  $\beta$ -vektörünü tahmin etmektedir. DL modelinin tahmin performansı, modelin faktörlerini tahmin etmek için kullanılan AR sürecinin gecikmesi açısından ayrıca değerlendirilmiştir. Tahmin,  $h = 1$ ,  $h = 3$  ve  $h = 6$  aylık tahmin ufuklarıyla gerçekleştirilmiştir.

DL tarafından öngörüldüğü gibi tahmin için sabit bir  $\lambda_t$  belirlemek için, tahmin edilen tüm  $\lambda_t$  lerin ortalaması hesaplanır (Arbia ve Marcantonio, 2015). Tahminler, gözlenen zaman serisinin eğitim örneğinin sonundan itibaren 1 adımdan  $h$  adıma kadar özyinelemeli olarak yapılır. Böylece farklı tahmin ufukları için tahminler gerçekleştirilmektedir.

Eğitim verilerinin pencere uzunluğu,  $h = 1$ ,  $h = 3$  ve  $h = 6$  için eğitim verisinde 250 ila 350 dönemlik modelleme ile ayarlanmıştır. Şekil 3.13 farklı modellerin tahmin performansını göstermek için kutu grafikleri, yuvarlanan pencerelerle yapılan tahminlerin ortalama RMSE değerlerini göstermektedir. Buna göre, ABD ve AMB verileri için pencere boyutunun artması, RMSE değerlerinde önemli bir değişiklik yaratmamaktadır. Bu veri setleri için modelin tahmin performansı oldukça tutarlı ve güvenilirdir. Ancak, Türkiye verileri için pencere boyutunun artması, RMSE değerlerinde belirgin bir artışa neden olmaktadır. Bu, Türkiye verilerinin daha değişken ve öngörülemez olduğunu ve modelin bu veriler üzerinde daha az başarılı olduğunu göstermektedir.

Bu analizler, pencere boyutunun seçiminin tahmin performansı üzerindeki etkisini vurgulamakta ve farklı veri setlerinin bu seçime nasıl tepki verdiğini göstermektedir. Özellikle, daha değişken ve dalgalanmalara açık verilerde (Türkiye gibi), uygun pencere boyutunun belirlenmesi tahmin performansı için kritik öneme sahiptir. Bu bulgular, Diebold–Li modelinin farklı ekonomik bağlamlarda nasıl performans gösterdiğini anlamak için değerli bilgiler sunmaktadır.




**Şekil 3.13** Diebold–Li Modeli ile Tahminlerde Eğitim Verisi Pencere Boyutunun Etkisi

DL, getiri eğrilerini tahmin etmek için  $\beta_{1t}, \beta_{2t}, \beta_{3t}$  faktörleri  $AR(1)$  modeli uygulanarak tahmin etmektedir. Bu tezde,  $\beta$  – vektörünün tek değişkenli zaman serisini tahmin eden  $AR$  sürecinin gecikmesi, daha ayrıntılı olarak incelenmiş ve farklı gecikmeler dikkate alınmıştır (Diebold ve Rudebusch, 2013). Bu amaçla sunulan modeller,  $AR(p)$  sürecini 4 gecikmeye kadar optimize ederek, AIC tarafından en uygun modeli seçerek değerlendirilmiştir (Reinicke, 2019).

Şekil 3.14, ABD verileri kullanılarak, Diebold–Li modeli ile getiri eğrilerini tahmin etmek için  $AR(1)$  ve  $AR(p)$  modelleri uygulanarak elde edilen RMSE değerlerinin karşılaştırmasını göstermektedir. Grafikler, tahmin adımları  $h = 1$ ,  $h = 3$  ve  $h = 6$  için ayrı ayrı sunulmuştur.

ABD verileri üzerinde yapılan analizler,  $AR(1)$  ve  $AR(p)$  modellerinin kısa, orta ve uzun vadeli tahminlerde benzer performans sergilediğini göstermektedir.  $AR(1)$  modelinin basit yapısına rağmen,  $AR(p)$  modeli ile karşılaştırıldığında performansında belirgin bir fark bulunmamaktadır. Bu,  $AR(1)$  modelinin ABD verileri üzerinde etkili bir tahmin modeli olduğunu ortaya koymaktadır.  $AR(p)$  modeli ise, farklı gecikmeler dikkate alınarak optimize edilmesine rağmen, ek bir avantaj sağlamamaktadır. Bu bulgular,  $\beta$  – vektörünün tek değişkenli zaman serisi tahmininde  $AR(1)$  modelinin yeterli ve etkili bir çözüm olduğunu göstermektedir.



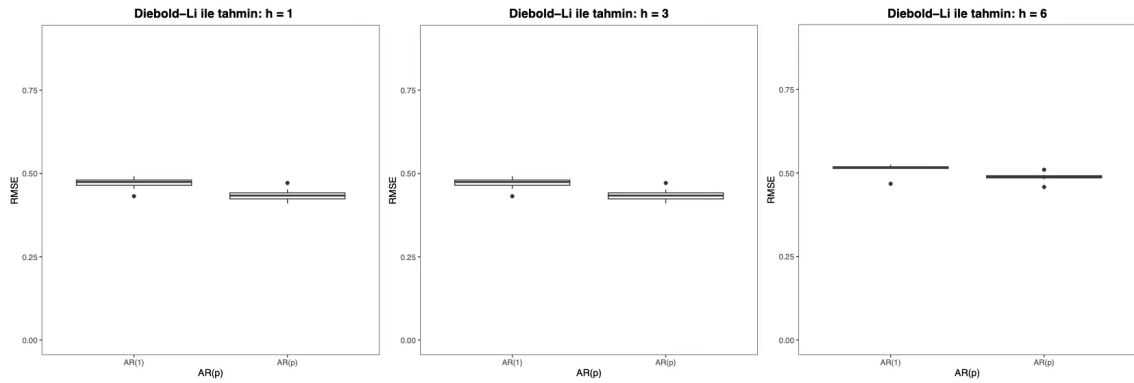


**Şekil 3.14** ABD Verileri için DL Modeli ile  $AR(1)$  ve  $AR(p)$  Modellerinin Tahmin Performansı

Şekil 3.15 AMB verileri üzerinde yapılan analizler,  $AR(1)$  ve  $AR(p)$  modellerinin kısa, orta ve uzun vadeli tahminlerde benzer performans sergilediğini göstermektedir. Her iki modelin de düşük RMSE değerleri sunması, modelin AMB verileri üzerindeki genel performansının güçlü olduğunu göstermektedir.  $AR(1)$  modelinin basit yapısı, özellikle kısa vadeli tahminlerde etkili bir performans sunarken,  $AR(p)$  modeli de bu performansı desteklemektedir.

AMB verilerinin istikrarlı yapısı,  $AR(1)$  ve  $AR(p)$  modellerinin tutarlı tahminler yapmasını kolaylaştırmaktadır. Ancak,  $AR(p)$  modelinin farklı gecikmeler dikkate alınarak optimize edilmesine rağmen,  $AR(1)$  modeline kıyasla belirgin bir avantaj sağlamadığı gözlemlenmiştir. Bu bulgular, AMB verileri üzerinde yapılan tahminlerde  $AR(1)$  modelinin güvenilir ve etkili bir seçenek olduğunu doğrulamaktadır.

Sonuç olarak, AMB verilerinde hem  $AR(1)$  hem de  $AR(p)$  modelleri, çeşitli tahmin adımları için tutarlı ve düşük hata oranları ile güçlü bir performans sergilemektedir. Bu, AMB verilerinin öngörülebilirliğinin yüksek olduğu ve model seçiminde  $AR(1)$  modelinin genellikle yeterli olduğu sonucuna varmamızı sağlar.  $AR(p)$  modeli ise, optimize edilmiş yapısıyla ek bir doğruluk sağlama potansiyeline sahip olsa da, genel performans üzerinde belirgin bir fark yaratmamaktadır.



**Şekil 3.15** Euro Bölgesi Verileri için DL Modeli ile  $AR(1)$  ve  $AR(p)$  Modellerinin Tahmin Performansı

Şekil 3.16, Türkiye devlet tahvili verileri kullanılarak, Diebold–Li modeli ile getiri eğrilerini tahmin etmek için  $\beta_{1t}, \beta_{2t}, \beta_{3t}$  faktörlerinin  $AR(1)$  ve  $AR(p)$  modelleri uygulanarak elde edilen RMSE değerlerinin karşılaştırılması gösterilmektedir. Grafikler, tahmin adımları  $h = 1, h = 3$  ve  $h = 6$  için ayrı ayrı sunulmuştur.


Türkiye devlet tahvili verileri üzerinde yapılan analizlerde,  $AR(p)$  modelinin  $AR(1)$  modeline göre daha düşük RMSE değerleri ile tutarlı ve başarılı tahminler sunduğu gözlemlenmektedir. Kısa, orta ve uzun vadeli tahminlerde  $AR(p)$  modelinin performansının  $AR(1)$  modeline kıyasla belirgin şekilde daha iyi olduğu anlaşılmaktadır. Bu, Türkiye verilerinin daha karmaşık ve değişken yapısının, daha yüksek gecikmeli  $AR(p)$  modelinin optimize edilmesi ile daha iyi yakalanabildiğini göstermektedir.

Türkiye ekonomisi, son yıllarda ekonomik ve finansal dalgalanmalarla karşı karşıya kalmıştır. Özellikle enflasyon oranlarındaki dalgalanmalar, döviz kuru hareketleri ve makroekonomik belirsizlikler, devlet tahvili getirilerini tahmin etmeyi zorlaştıran faktörler arasında yer almaktadır. Bu bağlamda,  $AR(p)$  modelinin daha yüksek gecikmeleri dikkate alarak tahmin performansını artırması, Türkiye ekonomisinin karmaşık dinamiklerini daha iyi yansıtabilmesine bağlanabilir.

Türkiye verilerinde  $AR(1)$  modelinin performansının nispeten düşük olması, bu verilerin yüksek değişkenlik ve öngörülemezlik içermesinden kaynaklandığı düşünülmektedir.  $AR(p)$  modeli ise, daha fazla gecikmeyi dikkate alarak bu değişkenliği daha iyi modelleyebilmekte ve bu sayede daha düşük RMSE değerleri sunmaktadır. Bu

bulgular, Türkiye devlet tahvili verileri için tahmin yaparken,  $AR(p)$  modelinin  $AR(1)$  modeline göre daha uygun ve etkili bir seçenek olduğunu ortaya koymaktadır.

Sonuç olarak, Türkiye verileri üzerinde yapılan analizler,  $AR(p)$  modelinin yüksek performansını vurgularken,  $AR(1)$  modelinin daha basit yapısının bu karmaşık veriler üzerinde yeterli olmadığını göstermektedir. Bu durum, tahmin modellerinin seçiminde verinin yapısına uygun optimizasyonların yapılmasının önemini bir kez daha ortaya koymaktadır. Özellikle Türkiye gibi ekonomik belirsizliklerin ve dalgalanmaların yüksek olduğu ülkelerde, daha karmaşık modellerin kullanılması, tahmin doğruluğunu artırabilir ve ekonomik karar alma süreçlerine daha güvenilir bilgi sağlayabilir.




**Şekil 3.16** Türkiye Verileri için DL Modeli ile  $AR(1)$  ve  $AR(p)$  Modellerinin Tahmin Performansı

Şekil 3.17, ABD Hazine verilerinin tahmin edilen  $\beta$ -vektörüne ait otokorelasyon fonksiyonlarını (ACF) haftalık gecikmelerle %95'lik güven aralığında göstermektedir. Grafikler, her bir  $\beta$ -tahmininin ( $\hat{\beta}_{t1}$ ,  $\hat{\beta}_{t2}$ ,  $\hat{\beta}_{t3}$ ) gecikme değerlerine göre otokorelasyonlarını ayrıntılı olarak sunmaktadır. Siyah çubuklar, her bir gecikme için otokorelasyon katsayılarını temsil ederken, mavi kesik çizgiler %95'lik güven aralığını göstermektedir.

Bu grafiklerde görüldüğü gibi, otokorelasyon başlangıçta yüksek olup zamanla azalmaktadır. Sol üst grafik ( $\hat{\beta}_{t1}$ ) ve sağ üst grafik ( $\hat{\beta}_{t2}$ ) ile alt grafik ( $\hat{\beta}_{t3}$ ) arasında benzer bir desen gözlemlenmektedir. Başlangıçta yüksek olan otokorelasyon değerleri, gecikmeler arttıkça azalarak %95'lik güven aralığının içine düşmektedir. Bu durum, modelin başlangıçta güçlü bir bağımlılık gösterdiğini, ancak zamanla bu bağımlılığın azaldığını ve daha kararlı hale geldiğini göstermektedir.

Bu otokorelasyon analizleri, zaman serisi verilerinin model performansını değerlendirmek açısından büyük önem taşır. Modelin tahmin edilen  $\beta$ -tahminlerinin zaman içindeki otokorelasyon yapısını anlamak, modelin güvenilirliği ve doğruluğu hakkında önemli bilgiler sunar. Otokorelasyonların düşük seviyelere inmesi, modelin tahmin hatalarının azaldığını ve daha güvenilir tahminler üretebileceğini göstermektedir.



**Şekil 3.17** ABD Hazine Verilerinin Tahmin Edilen  $\beta$ -Vektörünün Haftalık Gecikmelerle %95'lik Güven Aralığında Örneklem Otokorelasyonları

Şekil 3.18, ABD tahvil piyasasına ait belirli dönemlerdeki tahvil getirilerinin Nelson-Siegel modeli ile tahmin edilen eğrilerini göstermektedir. İki farklı lambda değeri ( $\lambda^{grid} = 0.496$  ve  $\lambda^{DL} = 0.0609$ ) ile yapılan tahminler karşılaştırılmaktadır.  $\lambda$  parametresi, tahvil eğrilerinin kısa, orta ve uzun vadeli segmentlerini nasıl etkilediğini modelleyen önemli bir değişkendir.

$\lambda$  parametresi, getiri eğrisinin eğimini ve dinamiklerini etkileyen bir ölçüttür. Bu analizde kullanılan  $\lambda^{grid}$ , kullanıcı tarafından belirlenen ve tahmin hatalarını minimize etmek için optimize edilmiş bir değerdir. Buna karşılık,  $\lambda^{DL}$ , Diebold ve Li (2006) tarafından önerilen standart bir parametre değeridir. Görselde, bu iki parametre değerinin farklı dönemlerdeki getiri eğrileri üzerindeki etkisi açıkça görülmektedir.


2018-06-19 dönemi, ABD Merkez Bankası'nın (FED) faiz oranlarını kademeli olarak artırdığı bir sürece denk gelmektedir. Bu dönemde tahvil getirilerinde kısa vadede (3–5 yıl) yükselme gözlenmiş, ancak uzun vadede eğri yatay bir seyir izlemiştir. Şekil 3.18'de  $\lambda^{grid}$ , hem kısa hem de orta vadeli tahvil getirilerinde daha uyumlu bir tahmin sunarken,  $\lambda^{DL}$  uzun vadeli tahminlerde düz bir eğilim sergileyerek piyasa beklentilerinden sapmıştır.

2019 yılı, küresel ticaret savaşları ve ABD-Çin arasındaki gerilimlerin arttığı bir dönemi ifade etmektedir. Şekil 3.18'de bu döneme ait getiri eğrisi, tahvil piyasasında dalgalanmaların etkisini göstermektedir. Özellikle  $\lambda^{grid}$ , uzun vadeli tahvil getirilerinde (15–30 yıl) gözlemlenen artışı daha iyi tahmin etmiştir. Buna karşılık  $\lambda^{DL}$ 'nin tahminleri, uzun vadede piyasa verilerinden sapma göstermiştir. Bu durum, ticari belirsizliklerin uzun vadeli faiz oranlarına olan etkisini yansıtmaktadır.

Pandemi sonrası toparlanmanın hızlandığı 2021-08-02 dönemi, ekonomik teşvik paketlerinin etkisiyle ABD tahvil piyasasında hareketliliğin devam ettiği bir süreçtir. Şekil 3.18'de  $\lambda^{grid}$ 'nin kısa ve orta vadeli tahvil getirilerinde daha uyumlu tahminler sunduğu görülmektedir. Uzun vadede ise  $\lambda^{DL}$ , düz bir eğri çizerek piyasanın artan belirsizliklerine yeterince uyum sağlayamamıştır.

ABD tahvil piyasasında tahvil getirileri, FED'in faiz kararları, enflasyon beklentileri ve küresel ekonomik belirsizlikler gibi faktörlerden etkilenmektedir. 2018-2019 yıllarında gözlenen faiz artışları ve ticaret savaşlarının etkileri, tahvil eğrilerinin hem eğimini hem de seviyesini şekillendirmiştir. 2021 yılında ise pandeminin ekonomik etkileri ve genişleyici politikalar, kısa ve orta vadeli tahvil getirilerinin eğrisini yukarı yönlü şekillendirmiştir.

Şekil 3.18,  $\lambda^{grid}$ 'nin ABD tahvil piyasasında Nelson-Siegel modelini optimize etmek için daha uygun bir parametre olduğunu göstermektedir. Bu analiz, ABD tahvil piyasasındaki farklı dönemlerdeki ekonomik gelişmelerin, tahvil eğrisinin kısa, orta ve uzun vadeli segmentleri üzerindeki etkilerini başarılı bir şekilde ortaya koymaktadır. Özellikle piyasa beklentilerinin modellenmesi açısından  $\lambda^{grid}$ 'nin daha esnek bir yapı sunduğu gözlemlenmiştir.




**Şekil 3.18** Farklı Tarihlerde ABD Nelson-Siegel Getiri Eğrilerinin  $\lambda$  Parametrelerine Göre Modellenmesi

Şekil 3.19, Avrupa Merkez Bankası (AMB) verilerinin tahmin edilen  $\beta$ -vektörüne ait otokorelasyon fonksiyonlarını (ACF) haftalık gecikmelerle %95'lik güven aralığında göstermektedir. Grafiklerde, her bir  $\beta$ -tahmininin ( $\hat{\beta}_{t1}, \hat{\beta}_{t2}, \hat{\beta}_{t3}$ ) farklı gecikme değerlerine göre otokorelasyonları detaylandırılmıştır. Siyah çubuklar, her bir gecikme

için otokorelasyon katsayılarını, mavi kesik çizgiler ise %95'lik güven aralığını temsil etmektedir.

İlk olarak, sol üst grafikte ( $\hat{\beta}_{t1}$ ), başlangıçta yüksek otokorelasyon değerleri görülmekte ve gecikme arttıkça bu değerler azalmaktadır. Sağ üst grafikte ( $\hat{\beta}_{t2}$ ) de benzer bir desen izlenmektedir; otokorelasyon değerleri başlangıçta yüksek olup, zamanla azalarak %95'lik güven aralığına düşmektedir. Alt grafikte ( $\hat{\beta}_{t3}$ ) de aynı şekilde, otokorelasyon başlangıçta yüksek olup, gecikmeler arttıkça azalmaktadır.

Bu grafikler, AMB verilerinin tahmin edilen  $\beta$ -tahminlerinin zaman içindeki otokorelasyon yapısını anlamak için kritik öneme sahiptir. Başlangıçtaki yüksek otokorelasyon değerleri, modelin belirli gecikmelerde güçlü bir bağımlılık gösterdiğini, ancak zamanla bu bağımlılığın azalarak modelin daha kararlı hale geldiğini işaret eder. Otokorelasyonların azalması, modelin tahmin doğruluğunu ve güvenilirliğini artırmaktadır.



**Şekil 3.19** Euro Bölgesi Verilerinin Tahmin Edilen  $\beta$ -Vektörünün Haftalık Gecikmelerle %95'lik Güven Aralığında Örneklem Otokorelasyonları

Şekil 3.20, Euro Bölgesi'ndeki farklı dönemlere ait getiri eğrilerinin tahminlerini ve bunların iki farklı lambda parametresi ( $\lambda^{grid} = 0.5092$  ve  $\lambda^{DL} = 0.0609$ ) kullanılarak nasıl modellendiğini göstermektedir. Nelson-Siegel modeli, getiri eğrisini analiz etmek için yaygın olarak kullanılan bir yöntemdir ve lambda parametresi, modelin kısa, orta ve uzun vadeli faiz oranlarını nasıl şekillendirdiğini belirleyen kilit bir değişkendir.

2015-07-09 dönemi, Euro Bölgesi'nde düşük faiz politikalarının etkilerinin gözlemlendiği bir süreçtir. Avrupa Merkez Bankası'nın (AMB) genişleyici parasal politikalarının etkisiyle, tahvil getirileri oldukça düşük seviyelerde seyretmiştir. Şekil 3.20'de görüldüğü gibi,  $\lambda^{grid}$ , değeri kısa vadeli (3–5 yıl) tahvil getirilerinde daha iyi bir




uyum sağlarken,  $\lambda^{DL}$ , daha düz bir eğri çizerek piyasanın dinamiklerini tam olarak yansıtamamıştır. Bu,  $\lambda^{grid}$ 'in daha optimize bir parametre değeri olduğunu göstermektedir.

2019 yılı, Euro Bölgesi'nin enflasyon hedeflerini tutturmakta zorlandığı bir döneme işaret etmektedir. Bu tarihte de genişleyici para politikalarının devam ettiği ve düşük faizlerin tahvil piyasasına yön verdiği görülmektedir.  $\lambda^{grid}$ , özellikle orta vadeli tahvil getirilerinde daha yüksek bir uyum sergilemiştir. Şekil 3.20'de, bu dönemde piyasanın istikrar arayışı nedeniyle tahvil eğrisinin daha düzgün bir seyir izlediği anlaşılmaktadır.

Pandemi sonrası toparlanma sürecini yansıtan 2021-01-18 dönemi, tahvil getirilerinde daha dalgalı bir yapıyı ortaya koymaktadır. Bu dönemde AMB'nin genişleyici politikalarının etkileri sürerken, piyasalardaki belirsizlikler tahvil eğrisine yansımıştır. Özellikle  $\lambda^{grid}$ , kısa ve orta vadeli tahvil getirilerinde (2–7 yıl arası) gözlemlenen oynaklıkları daha iyi yakalamıştır.  $\lambda^{DL}$ 'nin uzun vadeli tahminlerdeki zayıf performansı, bu dönemdeki ekonomik belirsizliklerin modellenmesinde sınırlı kalmıştır.

Bu tarih, Euro Bölgesi'nde enflasyon baskılarının artmaya başladığı ve AMB'nin faiz oranlarını artırma kararı aldığı bir dönemi temsil etmektedir. Şekil 3.20, uzun vadeli tahvil getirilerinin (10–30 yıl arası) eğiminde belirgin bir değişiklik olduğunu ortaya koymaktadır.  $\lambda^{grid}$ , uzun vadeli tahminlerde gözlemlenen veriye daha iyi uyum sağlarken,  $\lambda^{DL}$  bu eğilimleri yansıtmada yetersiz kalmıştır. Bu durum, politika değişikliklerinin piyasa beklentilerini nasıl şekillendirdiğini açıkça göstermektedir.



**Şekil 3.20** Farklı Tarihlerde Türkiye Nelson-Siegel Getiri Eğrilerinin  $\lambda$  Parametrelerine Göre Modellenmesi

Şekil 3.20’de yer alan her dönem, Euro Bölgesi’ndeki farklı makroekonomik gelişmeleri yansıtmaktadır. 2015-2019 yılları arasındaki düşük faiz ortamı, pandeminin ekonomik etkileriyle şekillenen 2021 yılı ve 2023 yılında artan enflasyonla birlikte uygulanan sıkılaştırıcı para politikaları, model tahminlerini doğrudan etkilemiştir. AMB’nin tahvil alım programları ve faiz kararları, getirilerin vade boyunca nasıl değiştiğini anlamak için kritik bir zemin hazırlamaktadır.


Şekil 3.20,  $\lambda^{grid}$ ’nin Euro Bölgesi’nde Nelson-Siegel modelini optimize etmek için daha uygun bir parametre olduğunu göstermektedir. Bu analiz, farklı dönemlerdeki tahvil getirilerinin AMB’nin politikalarına nasıl yanıt verdiğini ve bu yanıtların getiri eğrisi üzerinde oluşturduğu dinamikleri başarılı bir şekilde ortaya koymaktadır. Özellikle

ekonomik gelişmelerle şekillenen piyasa beklentileri, politika yapıcılar ve yatırımcılar için önemli içgörüler sunmaktadır.

Şekil 3.21, Türkiye verilerinin tahmin edilen  $\beta$ -vektörüne ait otokorelasyon fonksiyonlarını (ACF) haftalık gecikmelerle %95'lik güven aralığında göstermektedir. Bu grafikler, her bir  $\beta$ -tahmininin  $(\hat{\beta}_{t1}, \hat{\beta}_{t2}, \hat{\beta}_{t3})$  farklı gecikme değerlerine göre otokorelasyonlarını ayrıntılı bir şekilde sunmaktadır. Siyah çubuklar her bir gecikme için otokorelasyon katsayılarını, mavi kesik çizgiler ise %95'lik güven aralığını temsil etmektedir.

Grafiklerin detaylı incelenmesi, modelin zaman içindeki performansını anlamak için önemli ipuçları sunmaktadır. Sol üst grafik  $(\hat{\beta}_{t1})$  incelendiğinde, başlangıçta yüksek olan otokorelasyon değerlerinin zamanla azaldığı görülmektedir. Sağ üst grafikte  $(\hat{\beta}_{t2})$  de benzer bir desen izlenmektedir; başlangıçta yüksek olan otokorelasyon değerleri, gecikmeler arttıkça azalmaktadır ve belirli bir noktadan sonra %95'lik güven aralığına düşmektedir. Alt grafikte  $(\hat{\beta}_{t3})$  de aynı şekilde, başlangıçta yüksek olan otokorelasyon değerlerinin zamanla azaldığı izlenmektedir.

Bu otokorelasyon analizleri, Türkiye verilerinin tahmin edilen  $\beta$ -tahminlerinin zaman içindeki otokorelasyon yapısını anlamak açısından kritiktir. Yüksek otokorelasyon değerleri, modelin belirli gecikmelerde güçlü bir bağımlılık gösterdiğini işaret ederken, otokorelasyonun azalması, modelin daha kararlı hale geldiğini ve bağımlılığın azaldığını göstermektedir. Bu durum, modelin tahmin doğruluğunu ve güvenilirliğini artırmaktadır.



**Şekil 3.21** Türkiye Verilerinin Tahmin Edilen  $\beta$ -Vektörünün Haftalık Gecikmelerle %95'lik Güven Aralığında Örneklem Otokorelasyonları

Şekil 3.22, Türkiye'nin tahvil piyasasına ait seçili dönemlerdeki tahvil getirilerinin Nelson-Siegel modeli ile tahmin edilen eğrilerini ve farklı lambda ( $\lambda$ ) değerleri ile oluşturulan tahminleri göstermektedir. Görsel,  $\lambda^{grid} = 1.2538$  ve  $\lambda^{DL} = 0.0609$  değerleri üzerinden bir karşılaştırma sunmaktadır. Lambda parametresi, tahvil getirilerinin farklı vade segmentlerindeki (kısa, orta ve uzun vadeli) davranışını etkileyen kritik bir parametredir.

2014 dönemi, Türkiye'nin ekonomik büyüme oranlarında yavaşlamanın başladığı ve küresel piyasalarda belirsizliğin arttığı bir süreçtir. Şekil 3.22'de  $\lambda^{grid}$ , özellikle kısa vadeli (0–5 yıl) tahvil getirilerini başarılı bir şekilde yakalarken,  $\lambda^{DL} = 0.0609$ 'nin tahminleri uzun vadede (15–30 yıl) getirilerde belirgin bir sapma göstermiştir. Küresel

sermaye akışlarının daraldığı ve Türkiye'nin ekonomik kırılganlıklarının arttığı bu dönem, getirilerde dalgalanmalar yaratmıştır.


2014 yılının ikinci yarısı, Türkiye'nin cari açığın yüksek olduğu, ancak büyümenin görece ivmelendiği bir dönemi temsil etmektedir. Bu tarih için oluşturulan tahvil eğrisi, tahvil piyasasının kısa vadede yüksek getiri beklentisine işaret etmektedir.  $\lambda^{grid}$ , hem kısa hem de orta vadeli tahvil getirilerinde (5–15 yıl) piyasa gerçeklerini yansıtırken,  $\lambda^{DL} = 0.0609$  'nin tahminleri bu segmentte piyasa verilerinden ciddi şekilde ayrılmıştır.

2015 yılı, Türkiye'de artan siyasi belirsizliklerin ve küresel faiz artırımını beklentilerinin tahvil piyasalarını etkilediği bir dönemdir. 2015-09-14 tarihinde,  $\lambda^{grid}$ 'in tahvil getirilerini daha uyumlu bir şekilde tahmin ettiği, özellikle orta vadede (5–10 yıl) dikkat çekmektedir. Buna karşılık  $\lambda^{DL}$ , uzun vadeli tahvillerde (20–30 yıl) piyasadaki düşüş eğilimini yansıtamamaktadır. Bu, piyasa oyuncularının uzun vadeli risklere karşı temkinli olduğunu göstermektedir.

2018 yılı, Türkiye'nin ciddi ekonomik dalgalanmalar yaşadığı, yüksek enflasyon ve döviz krizinin damga vurduğu bir süreçtir. 2018-09-05 tarihli tahvil eğrisi, kısa vadeli tahvil getirilerinin ani bir şekilde yükseldiğini ve uzun vadeli getirilerin negatif değerlere yaklaştığını göstermektedir. Bu durum, piyasa aktörlerinin uzun vadede ciddi bir güven eksikliği yaşadığına işaret etmektedir.  $\lambda^{grid}$ , kısa ve orta vadeli getirilerde daha uyumlu tahminler sunarken,  $\lambda^{DL}$ 'nin tahminleri bu eğilimleri yeterince yakalayamamıştır.

Türkiye tahvil piyasasında getiriler, ekonomik büyüme, cari açık, enflasyon oranları ve döviz kuru dalgalanmaları gibi faktörlerden büyük ölçüde etkilenmektedir. 2014-2018 yılları arasında, Türkiye ekonomisi hem içsel kırılganlıklar hem de küresel ekonomik değişimlerle mücadele etmiştir. 2018 yılında zirve yapan döviz krizi ve buna bağlı olarak artan faiz oranları, tahvil eğrilerinde belirgin sarpmalara yol açmıştır.

Şekil 3.22, Türkiye tahvil piyasasında  $\lambda^{grid}$ 'in tahvil getirilerini modellemek için daha uygun bir parametre olduğunu göstermektedir. Özellikle ekonomik belirsizliklerin arttığı dönemlerde,  $\lambda^{grid}$ 'in tahmin performansı  $\lambda^{DL}$ 'ye kıyasla daha üstündür. Bu durum, Türkiye'nin tahvil piyasasındaki kısa ve orta vadeli beklentilerin daha doğru bir şekilde modellenmesini sağlamaktadır.



**Şekil 3.22** Farklı Tarihlerde Türkiye Nelson-Siegel Getiri Eğrilerinin  $\lambda$  Parametrelerine Göre Modellenmesi

Bu çalışmada, Türkiye, Avrupa Merkez Bankası (AMB) ve ABD veri setlerini kullanarak farklı vadelerde getiri eğrisi tahmin modellerinin performansları karşılaştırılmıştır. Tahmin modellerinin performansı, farklı vadelerdeki getiri eğrisi tahminleri için önemli bir analiz alanıdır. Bu performans analizleri, model seçiminde rehberlik etmek ve en uygun tahmin yöntemini belirlemek amacıyla RMSE, MSE, MAE ve MAPE gibi istatistiksel kriterlerle değerlendirilir. Özellikle farklı vadelerdeki (1 Ay, 3 Ay, 6 Ay, 1 Yıl, vb.) tahmin performansı detaylandırılmış ve modellerin güçlü ve zayıf yönleri analiz edilmiştir.

Bu kapsamda, her ülkenin veri seti ayrı ayrı ele alınmış, model sonuçları tablo halinde sunulmuş ve sonuçlar üzerine detaylı yorumlar yapılmıştır. İlk olarak ABD veri setiyle yapılan analizler sunulmuş, ardından diğer veri setlerine geçilmiştir.

ABD veri seti üzerinde yapılan 1 aylık tahmin çalışmasında, farklı vadeler için RW, AR(1), VAR(1), DNS-VAR(1) ve DNS-KF modelleri karşılaştırılmıştır. Tablo 3.4, bu modellerin farklı vadelerdeki RMSE değerlerini sunmaktadır. 1 aylık vadelerde RW modeli genellikle düşük RMSE değerleri ile temel bir benchmark olarak öne çıkmaktadır. AR(1) modeli, özellikle kısa vadelerde oldukça etkili olup DNS-VAR(1) ile benzer sonuçlar üretmiştir. Ancak DNS-KF modeli, uzun vadelerde daha yüksek RMSE değerleriyle dikkat çekmekte ve bu durum, bu modelin karmaşık yapısının kısa vadelerde dezavantaj yarattığını göstermektedir.

**Tablo 3.4** ABD için Farklı Vadelerde 1 Aylık Getiri Eğrisi Tahmin Yöntemlerinin RMSE Performans Değerleri

Vade	RW	DNS-VAR(1)	DNS-KF	AR(1)	VAR(1)
1 Ay	0.0000	0.0362	0.0323	0.0051	0.0259
3 Ay	0.0100	0.0404	0.0323	0.0079	0.0240
6 Ay	0.0000	0.0153	0.0105	0.0023	0.0139
1 Yıl	0.0100	0.0233	0.0468	0.0124	0.0040
2 Yıl	0.0500	0.0725	0.1057	0.0554	0.0474
3 Yıl	0.1000	0.1130	0.1498	0.1068	0.1024
5 Yıl	0.1700	0.1589	0.1949	0.1772	0.1730
7 Yıl	0.1900	0.1587	0.1905	0.1987	0.2029
10 Yıl	0.2000	0.2421	0.2676	0.2087	0.2241
20 Yıl	0.1700	0.1361	0.1513	0.1799	0.1825
30 Yıl	0.1600	0.2184	0.2298	0.1751	0.1865

ABD veri seti üzerinde 1 aylık tahmin modellerinin genel performansı Tablo 3.5'te sunulmuştur. RW modeli, düşük hata değerleri ile temel bir benchmark olarak yer alırken, DNS-VAR(1) ve DNS-KF modelleri daha karmaşık yapılarıyla farklı sonuçlar vermiştir. Ancak, DNS-KF modeli en yüksek MAPE değerini sunarak düşük performans göstermiştir.

**Tablo 3.5** ABD için 1 Aylık Getiri Eğrisi Tahmin Modellerinin Performans Ölçümleri

Model	MSE	RMSE	MAE	MAPE
RW	0.0157	0.1251	0.0964	14.8604
VAR(1)	0.0185	0.1360	0.1072	22.9662
AR(1)	0.0175	0.1322	0.1025	16.7831
DNS-VAR	0.0179	0.1338	0.1099	30.9816
DNS-KF	0.0236	0.1536	0.1275	34.5770

Bu tabloda özellikle RW modelinin basitliği ile güçlü bir benchmark sunduğu görülmektedir. DNS-KF, karmaşık yapısına rağmen uzun vadede zayıf kalmıştır.

Tablo 3.6, 3 aylık vadelerde yapılan tahmin analizinde RMSE değerlerini sunmaktadır. Buna göre, RW modeli, düşük vadelerde rekabetçi bir performans gösterirken, DNS-VAR(1) modelinin genel olarak daha kararlı olduğu görülmüştür. DNS+KF modeli, özellikle uzun vadelerde hata oranlarını artırmıştır. RW modeli düşük vadelerde temel performans sunarken, DNS-VAR(1) modelinin genel anlamda daha stabil olduğu görülmektedir.

**Tablo 3.6.** ABD için Farklı Vadelerde 3 Aylık Getiri Eğrisi Tahmin Yöntemlerinin RMSE Performans Değerleri

Vade	RW	DNS-VAR(1)	DNS-KF	AR(1)	VAR(1)
1 Ay	0.0200	0.0916	0.0797	0.0102	0.0722
3 Ay	0.0100	0.0532	0.0472	0.0170	0.0319
6 Ay	0.0000	0.0398	0.0499	0.0067	0.0304
1 Yıl	0.0100	0.0132	0.0752	0.0050	0.0271
2 Yıl	0.0400	0.0153	0.2295	0.0261	0.0397
3 Yıl	0.0800	0.0567	0.4349	0.0614	0.0690
5 Yıl	0.1200	0.1127	0.8033	0.1001	0.0978
7 Yıl	0.1300	0.1400	1.0809	0.1062	0.0899
10 Yıl	0.0800	0.0253	1.2411	0.0572	0.0393
20 Yıl	0.0400	0.0540	1.6494	0.0196	0.0377
30 Yıl	0.0300	0.0570	1.6990	0.0256	0.0787



ABD veri seti üzerinde 3 aylık tahminlerin genel performansı Tablo 3.7'de verilmiştir. DNS-VAR(1) modeli, daha kararlı performans sunarak RW modelini birkaç durumda geride bırakmıştır. Tabloya göre DNS-VAR(1) modeli uzun vadelerde daha dengeli bir performans sunmuşken, DNS-KF modeli yüksek hata oranları nedeniyle rekabet gücünü kaybetmiştir.

**Tablo 3.7** ABD için 3 Aylık Getiri Eğrisi Tahmin Modellerinin Performans Ölçümleri

<b>Model</b>	<b>MSE</b>	<b>RMSE</b>	<b>MAE</b>	<b>MAPE</b>
RW	0.0044	0.0666	0.0509	11.3492
VAR(1)	0.0037	0.0611	0.0518	27.4195
AR(1)	0.0028	0.0527	0.0380	10.2884
DNS-VAR	0.0050	0.0710	0.0569	33.7371
DNS-KF	0.8381	0.9155	0.5661	80.8461

ABD veri seti üzerinde 6 aylık tahmin analizlerinde, farklı vadeler ve modeller için elde edilen sonuçlar Tablo 3.8'de verilmiştir. Bu sonuçlar, RW modelinin özellikle kısa vadelerde temel bir benchmark olarak etkili olduğunu, ancak daha uzun vadelerde DNS-VAR(1) ve VAR(1) modellerinin rekabetçi performans sergilediğini göstermektedir. DNS-KF modeli, yine uzun vadelerdeki karmaşık yapısı nedeniyle yüksek RMSE değerleri ile diğer modellere kıyasla daha düşük performans göstermiştir.

**Tablo 3.8** ABD için Farklı Vadelerde 6 Aylık Getiri Eğrisi Tahmin Yöntemlerinin RMSE Performans Değerleri

Vade	RW	DNS-VAR(1)	DNS-KF	AR(1)	VAR(1)
1 Ay	0.0400	0.0719	0.0114	0.0672	0.0422
3 Ay	0.0000	0.0907	0.0464	0.0150	0.0609
6 Ay	0.1400	0.1959	0.1828	0.1287	0.1780
1 Yıl	0.3000	0.3053	0.3642	0.2866	0.3166
2 Yıl	0.5100	0.4732	0.7105	0.4800	0.4962
3 Yıl	0.5400	0.4935	0.9264	0.5023	0.5059
5 Yıl	0.4300	0.3897	1.1891	0.3910	0.3694
7 Yıl	0.2800	0.2548	1.3463	0.2344	0.1945
10 Yıl	0.1100	0.0451	1.4150	0.0686	0.0676
20 Yıl	0.0200	0.0460	1.8258	0.0405	0.1086
30 Yıl	0.0900	0.2164	1.7914	0.1716	0.2749

ABD veri seti için 6 aylık tahmin modellerinin genel performans ölçümleri Tablo 3.9'da sunulmaktadır. RW modeli, düşük MSE ve RMSE değerleri ile temel bir benchmark olmaya devam ederken, AR(1) modeli kısa vadelerdeki güçlü performansını sürdürmüştür. Bununla birlikte, DNS-KF modeli hem MSE hem de RMSE değerlerinde oldukça yüksek hata oranları sunarak diğer modellerden belirgin şekilde ayrılmıştır. DNS-VAR(1) ise uzun vadelerde daha kararlı sonuçlar sunarak dikkat çekmiştir.

**Tablo 3.9** ABD için 6 Aylık Getiri Eğrisi Tahmin Modellerinin Performans Ölçümleri

Model	MSE	RMSE	MAE	MAPE
RW	0.0861	0.2934	0.2236	67.2951
VAR(1)	0.0823	0.2869	0.2318	76.3697
AR(1)	0.0754	0.2747	0.2148	90.9495
DNS-VAR	0.0800	0.2829	0.2311	105.2301
DNS-KF	1.2094	1.0997	0.8418	91.0801

Şekil 3.23, ABD ekonomisi için 6 aylık tahmin sonuçlarına dayalı olarak beş farklı modelin getiri eğrilerini sunmaktadır. Grafik, tahvil vadeleri boyunca (1 yıl ila 30 yıl)

tahmin edilen getiri oranlarının karşılaştırılmasını sağlar ve piyasanın faiz oranlarına ilişkin beklentilerini değerlendirmek için önemli bir araçtır. Tahmin modellerinin farklı vadelerdeki davranışları, kullanılan yöntemlerin avantajlarını ve sınırlılıklarını ortaya koymaktadır.

ABD'nin tahvil piyasası, küresel ekonomik koşullara duyarlı bir yapıya sahiptir ve bu nedenle, özellikle uzun vadelerde model tahminlerinde çeşitlilik gözlenmektedir. Random Walk (RW) modeli, tahminlerin doğruluğu açısından bir temel oluştururken, diğer modellerle kıyaslandığında oldukça basit bir yaklaşım sergiler. Kısa vadelerde RW modeli diğer yöntemlerle benzer sonuçlar üretmekle birlikte, uzun vadelerde daha düz bir eğri sunmaktadır. Bu, RW'nin ekonomik belirsizliklere yanıt verme kapasitesinin sınırlı olduğunu ve piyasadaki karmaşık dinamikleri yakalamakta yetersiz kalabileceğini göstermektedir.


Dinamik Nelson-Siegel (DNS) modelleri olan DNS-VAR ve DNS-KF, uzun vadelerde daha yüksek getiri tahminleri sunmaktadır. Özellikle DNS-KF modeli, uzun vadelerde belirgin bir şekilde artış göstermektedir. Bu, DNS-KF'nin piyasa oynaklığına ve ekonomik belirsizliklere daha duyarlı olduğunu ortaya koyar. DNS-KF'nin uzun vadeli tahminlerdeki bu yükselişi, yatırımcıların enflasyon beklentilerindeki artış ve büyüme potansiyeline dair pozitif sinyallerle ilişkilendirilebilir. Bununla birlikte, DNS-KF modelinin yüksek belirsizlik dönemlerinde performans kayıpları yaşayabileceği, stabilize kontrolünün ve parametre optimizasyonunun önemini vurgular.

AR(1) ve VAR(1) modelleri ise daha dengeli bir görünüm sunmaktadır. Bu modeller, kısa ve orta vadelerde DNS modellerine göre daha tutarlı sonuçlar verirken, uzun vadelerde DNS modellerinin öngördüğü yüksek getirilerin gerisinde kalmaktadır. AR(1) ve VAR(1)'in bu davranışı, ABD'nin kısa ve orta vadeli faiz oranlarındaki stabilizeyi yansıtır ve Federal Rezerv'in para politikalarının bu zaman aralığında etkili olduğunu gösterir. Ancak, uzun vadeli tahminlerde bu modellerin performansı sınırlı kalabilir, çünkü getiri eğrisindeki eğim değişikliklerini yeterince yakalayamayabilirler.

Getiri eğrisinin genel olarak "pozitif eğimli" bir yapıya sahip olması, ABD ekonomisinde uzun vadeli beklentilerin pozitif olduğunu göstermektedir. Bu durum, yatırımcıların uzun vadeli tahvillere olan güvenini ve daha yüksek getiriler talep etme

eğilimlerini yansıtır. Ayrıca, uzun vadeli faiz oranlarının artacağına dair piyasa beklentilerini de desteklemektedir. Bu tür bir yapı, genellikle ekonomik büyümenin süreceğine ve enflasyonist baskıların belirginleşeceğine dair bir işaret olarak değerlendirilir.

Sonuç olarak, Şekil 3.23'te sunulan modellerin tahmin sonuçları, ABD'nin tahvil piyasasındaki dinamiklerin ve ekonomik beklentilerin anlaşılmasına önemli katkılar sunmaktadır. Özellikle DNS modellerinin uzun vadeli öngörülerdeki başarısı, bu yöntemlerin daha karmaşık piyasa koşullarında kullanılabilirliğini vurgulamaktadır. Bununla birlikte, RW ve VAR gibi modellerin daha dengeli tahminler sunması, kısa ve orta vadeli analizlerde tercih edilebilirliklerini artırmaktadır. Bu analizler, yatırım kararları ve makroekonomik politika belirleme süreçleri için yol gösterici niteliktedir.



**Şekil 3.23** ABD Tahvil Getiri Eğrisi Tahmin Yöntemleri Karşılaştırması: DNS, VAR ve Kalman Filtresi Yöntemleriyle Tahmin

Aşağıdaki analizler, Euro Bölgesi için farklı vadelerde ve modellerde yapılan tahminlerin performans ölçümlerini içermektedir. Çalışma boyunca tahmin modellerinin başarısı, MSE, RMSE, MAE ve MAPE gibi performans ölçütleri üzerinden değerlendirilmiştir.

**Tablo 3.10** Euro Bölgesi için Farklı Vadelerde 1 Aylık Getiri Eğrisi Tahmin Yöntemlerinin RMSE Performans Değerleri

Vade	RW	DNS-VAR(1)	DNS-KF	AR(1)	VAR(1)
3 Ay	0.0064	0.0297	0.0586	0.0047	0.0206
6 Ay	0.0074	0.0105	0.0722	0.0058	0.0146
1 Yıl	0.0108	0.0168	0.0855	0.0095	0.0049
2 Yıl	0.0200	0.0215	0.0727	0.0215	0.0274
3 Yıl	0.0297	0.0033	0.0360	0.0362	0.0442
4 Yıl	0.0387	0.0268	0.0056	0.0504	0.0566
5 Yıl	0.0467	0.0516	0.0430	0.0625	0.0661
6 Yıl	0.0536	0.0716	0.0743	0.0723	0.0737
7 Yıl	0.0598	0.0865	0.0991	0.0802	0.0801
8 Yıl	0.0652	0.0970	0.1183	0.0865	0.0856
9 Yıl	0.0701	0.1040	0.1330	0.0918	0.0905
10 Yıl	0.0746	0.1085	0.1442	0.0963	0.0948
11 Yıl	0.0786	0.1112	0.1528	0.1001	0.0988
12 Yıl	0.0823	0.1127	0.1596	0.1035	0.1024
13 Yıl	0.0858	0.1134	0.1649	0.1065	0.1057
14 Yıl	0.0889	0.1137	0.1692	0.1092	0.1087
15 Yıl	0.0917	0.1137	0.1728	0.1117	0.1115
16 Yıl	0.0944	0.1135	0.1759	0.1140	0.1140
17 Yıl	0.0968	0.1132	0.1785	0.1161	0.1163
18 Yıl	0.0990	0.1129	0.1808	0.1181	0.1185
19 Yıl	0.1010	0.1125	0.1828	0.1200	0.1204
20 Yıl	0.1028	0.1122	0.1846	0.1218	0.1222
21 Yıl	0.1045	0.1120	0.1863	0.1235	0.1239
22 Yıl	0.1061	0.1117	0.1878	0.1252	0.1254
23 Yıl	0.1075	0.1115	0.1891	0.1268	0.1268
24 Yıl	0.1089	0.1112	0.1904	0.1284	0.1281
25 Yıl	0.1101	0.1110	0.1916	0.1299	0.1293
26 Yıl	0.1113	0.1109	0.1927	0.1314	0.1305
27 Yıl	0.1123	0.1107	0.1937	0.1329	0.1316
28 Yıl	0.1133	0.1105	0.1946	0.1344	0.1326
29 Yıl	0.1142	0.1104	0.1955	0.1359	0.1335
30 Yıl	0.1151	0.1103	0.1963	0.1374	0.1344

Tablo 3.10, Euro Bölgesi için farklı vadelerde bir aylık getiri eğrisi tahmin yöntemlerinin RMSE performans değerlerini karşılaştırmaktadır. Sonuçlar, RW modelinin kısa vadelerde (özellikle 3 ay ve 6 ay) diğer yöntemlere kıyasla üstün performans sergilediğini göstermektedir. Ancak vadeler uzadıkça RW modelinin

performansı düşmekte ve özellikle 10 yıl ve sonrasında DNS-KF modelinin performansı daha öne çıkmaktadır. DNS-VAR(1) yöntemi ise genel olarak tutarlı sonuçlar verse de kısa vadelerdeki performansı, RW ve AR(1) modellerine göre zayıf kalmaktadır. AR(1) modeli kısa vadelerde etkili olsa da vadeler uzadıkça hata oranı önemli ölçüde artmaktadır. Bu sonuçlar, her bir modelin spesifik vadelerdeki başarısını değerlendirmek için kapsamlı bir analiz sağlamaktadır.

Tablo 3.11, AMB için bir aylık getiri eğrisi tahmin modellerinin genel performans ölçümlerini sunmaktadır. AR(1) modeli, düşük MSE, RMSE ve MAE değerleriyle en başarılı model olarak dikkat çekmektedir. Bu model, tahmin doğruluğunda RW modelini az bir farkla geride bırakmaktadır. Öte yandan, DNS-KF modeli yüksek hata oranları ile en düşük performansı göstermektedir. DNS-VAR modeli, orta düzeyde bir doğruluk sağlayarak AR(1) ve RW'nin gerisinde kalırken, DNS-KF'nin belirgin zayıflıklarına göre daha iyi bir sonuç sunmaktadır. Genel olarak, RW ve AR(1) modelleri bu zaman dilimi için öne çıkan yöntemlerdir.

**Tablo 3.11** AMB için 1 Aylık Getiri Eğrisi Tahmin Modellerinin Performans Ölçümleri

Model	MSE	RMSE	MAE	MAPE
RW	0.0176	0.1328	0.0849	4.9450
VAR(1)	0.1720	0.4148	0.3686	17.7662
AR(1)	0.0141	0.1186	0.0804	4.6684
DNS-VAR	0.0537	0.2317	0.2062	10.1189
DNS-KF	0.2886	0.5372	0.3422	19.3779

Tablo 3.12, üç aylık getiri eğrisi tahmin yöntemlerinin RMSE performans değerlerini göstermektedir. RW modeli kısa vadelerde etkili bir performans sergilerken, DNS+VAR(1) modeli uzun vadelerde öne çıkmaktadır. Örneğin, 3 ay ve 6 ay vadelerinde RW modeli düşük hata oranlarıyla öne çıksa da 10 yıl ve sonrasında DNS+VAR(1) modelinin üstünlüğü dikkat çekmektedir. Bununla birlikte, DNS-KF yöntemi genel olarak yüksek hata oranları ile diğer yöntemlere kıyasla daha düşük bir performans sergilemektedir. AR(1) modeli, kısa vadelerde tatmin edici sonuçlar verirken vadeler uzadıkça etkinliğini kaybetmektedir.

**Tablo 3.12** AMB için Farklı Vadelerde 3 Aylık Getiri Eğrisi Tahmin Yöntemlerinin RMSE Performans Değerleri

Vade	RW	DNS-VAR(1)	DNS-KF	AR(1)	VAR(1)
3 Ay	1.1888	0.4230	1.6332	1.1761	0.6693
6 Ay	0.9308	0.5467	1.8770	0.6680	0.8917
1 Yıl	0.7864	0.6262	2.1011	0.4128	1.1193
2 Yıl	0.7136	0.4772	2.1305	0.3991	1.0814
3 Yıl	0.5842	0.3266	2.0586	0.3627	0.9887
4 Yıl	0.4685	0.2840	2.0127	0.3243	0.9260
5 Yıl	0.3935	0.2949	1.9966	0.3204	0.8841
6 Yıl	0.3509	0.3102	1.9981	0.3403	0.8556
7 Yıl	0.3282	0.3177	2.0078	0.3669	0.8367
8 Yıl	0.3165	0.3186	2.0203	0.3904	0.8251
9 Yıl	0.3100	0.3154	2.0326	0.4077	0.8192
10 Yıl	0.3057	0.3106	2.0433	0.4186	0.8175
11 Yıl	0.3016	0.3055	2.0517	0.4238	0.8188
12 Yıl	0.2967	0.3011	2.0576	0.4242	0.8224
13 Yıl	0.2905	0.2977	2.0609	0.4207	0.8275
14 Yıl	0.2827	0.2957	2.0618	0.4140	0.8337
15 Yıl	0.2733	0.2951	2.0604	0.4046	0.8406
16 Yıl	0.2623	0.2959	2.0569	0.3930	0.8480
17 Yıl	0.2498	0.2981	2.0516	0.3796	0.8559
18 Yıl	0.2360	0.3017	2.0448	0.3647	0.8641
19 Yıl	0.2209	0.3066	2.0365	0.3486	0.8725
20 Yıl	0.2047	0.3128	2.0271	0.3315	0.8812
21 Yıl	0.1876	0.3203	2.0166	0.3136	0.8902
22 Yıl	0.1698	0.3288	2.0054	0.2952	0.8995
23 Yıl	0.1513	0.3385	1.9934	0.2763	0.9090
24 Yıl	0.1323	0.3491	1.9809	0.2572	0.9187
25 Yıl	0.1129	0.3606	1.9680	0.2380	0.9287
26 Yıl	0.0933	0.3728	1.9548	0.2188	0.9389
27 Yıl	0.0735	0.3857	1.9414	0.1998	0.9493
28 Yıl	0.0535	0.3992	1.9278	0.1810	0.9600
29 Yıl	0.0336	0.4132	1.9142	0.1626	0.9708
30 Yıl	0.0137	0.4275	1.9007	0.1448	0.9818

Tablo 3.13, üç aylık getiri eğrisi tahmin modellerinin genel performans ölçümlerini içermektedir. RW modeli, düşük MSE ve RMSE değerleri ile yine başarılı bir performans göstermektedir. Ancak AR(1) modeli, özellikle düşük MAE ve MAPE değerleriyle dikkate değer bir rekabet sunmaktadır. DNS-KF yöntemi, özellikle yüksek

RMSE ve MAPE değerleriyle, diğer yöntemlere göre oldukça düşük bir performans sergilemektedir. Bu durum, DNS-KF'nin üç aylık zaman dilimlerinde etkili bir tahmin yöntemi olmadığını göstermektedir.

**Tablo 3.13** AMB için 3 Aylık Getiri Eğrisi Tahmin Modellerinin Performans Ölçümleri

Model	MSE	RMSE	MAE	MAPE
RW	0.1711	0.4136	0.3224	13.8428
VAR(1)	0.8015	0.8953	0.7363	30.5000
AR(1)	0.1666	0.4081	0.3565	15.1470
DNS-VAR	0.1297	0.3602	0.2923	12.2147
DNS-KF	4.0106	2.0026	1.7252	71.4903

Tablo 3.14, AMB için farklı vadelerde altı aylık getiri eğrisi tahmin yöntemlerinin RMSE performans değerlerini göstermektedir. RW modeli kısa vadelerde en düşük hata oranlarına sahip olmakla birlikte, vadeler uzadıkça DNS-VAR(1) modelinin üstünlüğü açıkça görülmektedir. DNS-KF yöntemi ise genel olarak yüksek hata oranlarına sahiptir ve uzun vadelerdeki tahmin başarısı düşüktür. AR(1) modeli kısa vadelerde RW ile rekabet edebilir durumda olsa da vadeler uzadıkça etkinliği azalmakta, DNS+VAR(1) ve VAR(1) yöntemlerinin gerisinde kalmaktadır.

**Tablo 3.14** AMB için Farklı Vadelerde 6 Aylık Getiri Eğrisi Tahmin Yöntemlerinin RMSE Performans Değerleri

Vade	RW	DNS-VAR(1)	DNS-KF	AR(1)	VAR(1)
3 Ay	2.1312	0.9320	2.6483	2.1057	1.8427
6 Ay	1.6193	0.8844	2.6578	1.0679	2.5986
1 Yıl	1.1155	0.7619	2.5566	0.8528	3.3097
2 Yıl	0.6994	0.7362	2.2941	0.5710	3.3672
3 Yıl	0.4559	0.8716	2.1399	0.3409	3.1197
4 Yıl	0.3038	0.9736	2.0759	0.1960	2.8953
5 Yıl	0.2185	1.0238	2.0598	0.1107	2.7211
6 Yıl	0.1751	1.0383	2.0666	0.1544	2.5918
7 Yıl	0.1557	1.0317	2.0833	0.2341	2.4988
8 Yıl	0.1494	1.0135	2.1038	0.2991	2.4338
9 Yıl	0.1499	0.9900	2.1246	0.3463	2.3895
10 Yıl	0.1535	0.9646	2.1442	0.3789	2.3600
11 Yıl	0.1580	0.9397	2.1618	0.4005	2.3405



12 Yıl	0.1622	0.9165	2.1768	0.4141	2.3274
13 Yıl	0.1654	0.8958	2.1891	0.4217	2.3181
14 Yıl	0.1670	0.8778	2.1988	0.4247	2.3108
15 Yıl	0.1671	0.8626	2.2059	0.4243	2.3042
16 Yıl	0.1654	0.8501	2.2105	0.4210	2.2976
17 Yıl	0.1620	0.8403	2.2129	0.4155	2.2905
18 Yıl	0.1571	0.8329	2.2132	0.4083	2.2828
19 Yıl	0.1506	0.8278	2.2116	0.3995	2.2744
20 Yıl	0.1427	0.8247	2.2083	0.3895	2.2654
21 Yıl	0.1335	0.8235	2.2034	0.3786	2.2558
22 Yıl	0.1232	0.8240	2.1972	0.3669	2.2459
23 Yıl	0.1119	0.8260	2.1897	0.3545	2.2357
24 Yıl	0.0997	0.8293	2.1812	0.3417	2.2255
25 Yıl	0.0867	0.8339	2.1717	0.3284	2.2153
26 Yıl	0.0730	0.8396	2.1614	0.3150	2.2052
27 Yıl	0.0588	0.8462	2.1505	0.3014	2.1955
28 Yıl	0.0441	0.8536	2.1389	0.2878	2.1861
29 Yıl	0.0289	0.8618	2.1269	0.2742	2.1771
30 Yıl	0.0135	0.8707	2.1144	0.2607	2.1687

Tablo 3.15, altı aylık getiri eğrisi tahmin modellerinin genel performans ölçümlerini içermektedir. RW modeli, düşük MSE ve RMSE değerleriyle öne çıkarken, AR(1) modeli de oldukça rekabetçi bir performans sergilemektedir. DNS-VAR yöntemi, özellikle düşük MAE ve MAPE değerleriyle etkili bir tahmin aracı olarak dikkat çekmektedir. Bununla birlikte, DNS-KF yöntemi, özellikle yüksek MAPE değeri ile en düşük performansa sahip modeldir. Bu durum, DNS-KF'nin bu zaman diliminde etkili bir yöntem olmadığını göstermektedir.

**Tablo 3.15** AMB için 6 Aylık Getiri Eğrisi Tahmin Modellerinin Performans Ölçümleri

Model	MSE	RMSE	MAE	MAPE
RW	0.3742	0.6117	0.4813	20.9274
VAR(1)	0.9420	0.9706	0.8294	34.3518
AR(1)	0.3567	0.5972	0.5058	22.6459
DNS-VAR	0.3193	0.5652	0.4456	18.5603
DNS-KF	5.0475	2.2478	1.8709	77.9821

Şekil 3.24, Euro Bölgesi tahvil getirilerinin farklı vadelerdeki tahminlerini DNS-VAR, DNS-KF, AR, VAR ve RW modelleri üzerinden karşılaştırmaktadır. Grafik, Euro Bölgesi'nde tahvil piyasalarının dinamiklerini anlamak için önemli bir perspektif sunar. Getiri eğrisi tahminlerinin ekonomik gelişmeler ve getiri eğrisi teorisi bağlamında ele alınması, bu modellerin farklı piyasa koşullarında nasıl performans gösterdiğini değerlendirmeye olanak tanır.

Euro Bölgesi'nde 2008 Küresel Finansal Krizi, ardından gelen Avrupa Borç Krizi ve yakın dönemde pandemi sonrası toparlanma dönemi gibi ekonomik gelişmeler, tahvil piyasalarında dalgalanmalara yol açmıştır. Bu bağlamda, getiri eğrileri genellikle piyasa beklentilerini, merkez bankası politikalarını ve risk primlerini yansıtır. Getiri eğrisi teorisine göre, kısa vadeli getiriler genellikle likidite tercihlerini ve piyasa oynaklığını yansıtırken, uzun vadeli getiriler piyasa katılımcılarının enflasyon beklentileri ve ekonomik büyüme öngörülerine dayanır.

DNS-VAR modeli, özellikle uzun vadede tahvil getirilerinin stabil bir şekilde tahmin edilmesi açısından güçlü bir performans göstermektedir. Grafik, DNS-VAR'ın vadeler ilerledikçe eğrinin yataylaştığını ve piyasa beklentilerini başarıyla yansıttığını göstermektedir. Bu durum, Euro Bölgesi'nde uzun vadeli tahvil piyasasının genellikle risk primiyile uyumlu bir yapıya sahip olduğunu ve merkez bankası politikalarının uzun dönem getiri eğrisine etkisinin başarılı bir şekilde modellenebildiğini ortaya koymaktadır. DNS-VAR modeli, getiri eğrisi teorisinde tanımlanan "seviye", "eğim" ve "bombelik" unsurlarını açıklama kapasitesiyle bilinir ve bu özellik, Euro Bölgesi gibi karmaşık ekonomik dinamiklere sahip bir bölgede modelin başarısını pekiştirmektedir.


DNS-KF yöntemi ise kısa vadelerde oynak bir yapı sergilemektedir. Bu durum, özellikle kriz dönemlerinde kısa vadeli tahvil piyasalarındaki dalgalanmayı açıklayabilecek bir hassasiyet sunmaktadır. Ancak uzun vadede DNS-KF'nin tahmin eğrisi diğer modellere kıyasla daha yukarıda konumlanmakta, bu da modelin uzun vadeli risk primlerini abartabileceğini göstermektedir. Euro Bölgesi'nde kısa vadeli tahvil piyasalarındaki dalgalanmalar, özellikle piyasa belirsizliğinin ve merkez bankası müdahalelerinin etkisini yansıtır. DNS-KF'nin kısa vadeli dalgalanmalara duyarlılığı, piyasa şoklarının modellenmesinde avantaj sunabilir.

AR modeli, kısa vadelerde başarılı bir tahmin performansı sergilerken uzun vadelerde etkisini kaybetmektedir. Bu model, Euro Bölgesi'nde kısa vadeli merkez bankası politika oranlarının tahvil getirileri üzerindeki etkisini değerlendirmede faydalı olabilir. Ancak AR modelinin, getiri eğrisi teorisinin bombelik gibi uzun vadeli özelliklerini açıklamada yeterli bir performans sergilemediği görülmektedir.

VAR modeli, hem kısa hem de orta vadelerde nispeten iyi bir performans sergilemektedir. Euro Bölgesi'nde tahvil piyasalarındaki oynaklıklar ve risk primleri, özellikle kriz dönemlerinde VAR modeliyle başarılı bir şekilde modellenenbilir. Ancak modelin uzun vadeli tahminlerinde DNS-VAR'a kıyasla daha düşük bir tahmin seviyesi sunduğu dikkat çekmektedir. Bu durum, VAR modelinin ekonomik büyüme ve enflasyon beklentilerini yansıtmakta sınırlı kalabileceğini göstermektedir.

RW modeli ise sabit bir eğri sunmasıyla dikkat çekmektedir. Bu model, geçmiş değerlerin geleceği belirleyeceği varsayımına dayandığından, özellikle kısa vadeli tahvil tahminlerinde düşük hata oranı sunmaktadır. Ancak uzun vadeli getiri eğrisinde ekonomik beklentileri ve piyasa dinamiklerini modelleme açısından oldukça sınırlıdır. Bu durum, Euro Bölgesi gibi merkez bankası politikalarının ve piyasa şoklarının belirgin bir etkisinin olduğu bir bölgede RW modelinin etkisiz kalabileceğini göstermektedir.

Grafiğin genel yapısı, Euro Bölgesi tahvil piyasalarının kriz dönemlerinde kısa vadeli tahvillerde oynaklığa, uzun vadede ise daha istikrarlı ve piyasa beklentilerine dayalı bir yapıya sahip olduğunu ortaya koymaktadır. Getiri eğrisinin kısa vadede yükselen ve ardından uzun vadede yataylaşan şekli, piyasa katılımcılarının uzun vadede daha düşük belirsizlik öngördüğünü ve risk priminin daha sabit olduğunu göstermektedir. DNS-VAR modeli, Euro Bölgesi'nde uzun vadeli tahvil getirilerinin piyasa beklentilerini yansıtmada en güçlü model olarak öne çıkmaktadır. DNS-KF ve VAR yöntemleri ise kısa vadeli ekonomik oynaklıkların modellenmesinde belirli avantajlar sunmaktadır. Bu bağlamda, getiri eğrisi tahminleri, hem piyasa katılımcıları hem de merkez bankası politikalarının değerlendirilmesi için önemli bir araçtır.



**Şekil 3.24** Euro Bölgesi Tahvil Getiri Eğrisi Tahmin Yöntemleri Karşılaştırması: DNS, VAR ve Kalman Filtresi Yöntemleriyle Tahmin

Aşağıdaki tablolar, Türkiye'deki tahvil getirilerinin farklı vadeler ve tahmin dönemleri çerçevesinde modellenmesinde kullanılan çeşitli yöntemlerin performans ve etkinliğini sistematik bir şekilde incelemektedir. Türkiye'nin ekonomik koşulları, yüksek enflasyon oranları, dalgalı faiz politikaları ve oynak piyasa yapısı düşünüldüğünde, tahmin yöntemlerinin performansı, piyasanın bu özelliklerine nasıl tepki verdiğiyle ilişkilendirilebilir. Ayrıca, getiri eğrisi teorisine göre, kısa ve uzun vadeli tahvil getirilerinin şekli, piyasa beklentilerini, risk primlerini ve ekonomik belirsizlikleri yansıtır.

Tablo 3.16, Türkiye için bir aylık getiri eğrisi tahmin yöntemlerinin RMSE performans değerlerini sunmaktadır. RW modeli, özellikle kısa vadelerde (1 ay ve 3 ay) diğer yöntemlere kıyasla daha düşük hata oranlarıyla öne çıkmaktadır. AR(1) modeli ise kısa vadelerde rekabetçi bir performans sergilerken uzun vadelerde RW'nin gerisinde kalmaktadır. DNS-VAR(1) ve DNS-KF modelleri, özellikle kısa vadelerde oldukça yüksek hata oranlarına sahiptir, bu da bu modellerin Türkiye gibi oynak piyasa koşullarına tam anlamıyla adapte olamadığını göstermektedir. VAR(1) modeli ise genel olarak yüksek hata oranlarına sahip olup kısa ve uzun vadelerde rekabetçi bir performans gösterememektedir.

**Tablo 3.16** Türkiye için Farklı Vadelerde 1 Aylık Getiri Eğrisi Tahmin Yöntemlerinin RMSE Performans Değerleri

Vade	RW	DNS+VAR(1)	DNS+KF	AR(1)	VAR(1)
1 Ay	0.6280	2.4523	2.1429	0.7616	3.2765
3 Ay	1.3290	3.1966	3.3820	1.0974	3.1344
6 Ay	1.9100	3.2270	3.9427	1.5359	2.9079
9 Ay	1.0330	2.4445	3.4855	0.4958	2.5900
1 Yıl	1.5000	1.5017	2.7275	1.3302	2.0635
2 Yıl	1.2500	1.7013	2.9387	1.1269	1.6652
3 Yıl	2.7400	2.1009	3.0412	2.7109	2.9108
5 Yıl	0.2100	0.5646	0.2147	0.6802	0.1472
10 Yıl	0.1900	0.4605	0.4501	0.2307	0.2525

Tablo 3.17, Türkiye için bir aylık getiri eğrisi tahmin modellerinin performans ölçümlerini karşılaştırmaktadır. RW ve AR(1) modelleri, düşük MSE ve RMSE değerleriyle diğer yöntemlere kıyasla daha iyi bir tahmin performansı sergilemektedir. DNS-VAR ve DNS-KF modelleri ise, Türkiye gibi dalgalı bir piyasa yapısına sahip bir ekonomide yüksek hata oranlarıyla düşük bir performans göstermektedir. DNS-KF modelinin özellikle çok yüksek RMSE değerleri, modelin piyasa oynaklığına karşı duyarlılığının fazla olduğunu göstermektedir.

**Tablo 3.17** Türkiye için 1 Aylık Getiri Eğrisi Tahmin Modellerinin Performans Ölçümleri

Model	MSE	RMSE	MAE	MAPE
RW	2.0307	1.4250	1.1989	6.6709
VAR(1)	5.7014	2.3878	2.0361	11.8925
AR(1)	1.6993	1.3036	1.0890	5.9790
DNS-VAR	4.7461	2.1785	1.9007	11.0562
DNS-KF	7.6995	2.7748	2.3896	13.6407

Tablo 3.18, Türkiye için üç aylık getiri eğrisi tahmin yöntemlerinin RMSE değerlerini göstermektedir. RW ve AR(1) modelleri, özellikle kısa vadelerde düşük hata oranlarıyla güçlü bir performans sergilemektedir. Ancak DNS-KF modeli, 1 ay ve 3 ay

vadelerde oldukça yüksek hata oranlarına sahiptir ve uzun vadelerde de bu hata oranları azalmamaktadır. DNS-VAR modeli ise genel olarak daha dengeli bir performans sergilese de RW ve AR(1) modelleri kadar etkili değildir. Bu sonuçlar, RW ve AR(1) modellerinin Türkiye gibi oynak piyasa koşullarına daha iyi adapte olduğunu göstermektedir.

**Tablo 3.18** Türkiye için Farklı Vadelerde 3 Aylık Getiri Eğrisi Tahmin Yöntemlerinin RMSE Performans Değerleri

Vade	RW	DNS-VAR(1)	DNS-KF	AR(1)	VAR(1)
1 Ay	0.8370	4.3470	12.0970	1.1804	5.3211
3 Ay	1.0980	4.8867	12.4478	0.5701	5.1042
6 Ay	0.7160	3.7189	14.2401	0.6274	3.8682
9 Ay	0.8390	2.1125	16.1542	2.7905	2.5464
1 Yıl	1.0000	2.2540	16.3714	0.5782	2.9656
2 Yıl	0.5500	1.6477	17.2841	0.2774	1.8195
3 Yıl	2.5800	2.2516	16.6860	2.4959	3.0880
5 Yıl	0.1900	0.5152	18.5356	1.5094	0.2099
10 Yıl	0.5500	1.0275	16.9261	0.4400	0.4407

Tablo 3.19, üç aylık getiri eğrisi tahmin modellerinin genel performans ölçümlerini sunmaktadır. RW modeli, en düşük MSE ve RMSE değerleriyle dikkat çekerken, AR(1) modeli de rekabetçi bir performans sergilemektedir. DNS-KF modeli ise çok yüksek hata oranlarına sahiptir, bu da modelin Türkiye'nin piyasa koşullarına uygun olmadığını göstermektedir.

**Tablo 3.19** Türkiye için 3 Aylık Getiri Eğrisi Tahmin Modellerinin Performans Ölçümleri

Model	MSE	RMSE	MAE	MAPE
RW	1.2689	1.1265	0.9289	5.0090
VAR(1)	10.8549	3.2947	2.6447	15.2876
AR(1)	2.1124	1.4534	1.0935	5.7155
DNS-VAR	8.3618	2.8917	2.3784	13.7065
DNS-KF	248.9189	15.7772	13.3056	69.8176

Tablo 3.20, altı aylık getiri eğrisi tahmin yöntemlerinin RMSE değerlerini göstermektedir. RW ve AR(1) modelleri, yine düşük hata oranlarıyla öne çıkmaktadır. Ancak DNS-KF modeli, özellikle uzun vadelerde oldukça yüksek hata oranlarına sahip olup, modelin uzun vadeli piyasa tahminlerinde zayıf olduğunu göstermektedir. DNS-VAR ve VAR(1) modelleri ise vadeler arttıkça performanslarını artırarak rekabetçi hale gelmektedir.

**Tablo 3.20** Türkiye için Farklı Vadelerde 6 Aylık Getiri Eğrisi Tahmin Yöntemlerinin RMSE Performans Değerleri

Vade	RW	DNS+VAR(1)	DNS+KF	AR(1)	VAR(1)
1 Ay	3.1480	3.6953	15.6028	3.6981	4.5147
3 Ay	1.2540	4.0717	15.9465	2.4322	4.3314
6 Ay	2.4940	2.1677	18.7749	4.3605	2.5787
9 Ay	3.0870	1.5111	20.0953	6.1231	1.9185
1 Yıl	0.0000	2.3547	19.1743	1.0462	2.9430
2 Yıl	0.5400	2.2312	19.3051	0.4016	2.3364
3 Yıl	0.5300	0.5955	20.4503	0.3765	1.2491
5 Yıl	5.1400	4.8180	15.9994	3.2054	5.5210
10 Yıl	4.4500	4.6759	15.5016	4.2282	4.2514

Tablo 3.21, altı aylık tahmin modellerinin performans ölçümlerini göstermektedir. RW ve AR(1) modelleri, özellikle düşük MSE ve RMSE değerleriyle yine öne çıkmaktadır. DNS-KF modelinin çok yüksek hata oranları, modelin Türkiye'nin oynak piyasa koşullarına uygun olmadığını bir kez daha ortaya koymaktadır.

**Tablo 3.21** Türkiye için 6 Aylık Getiri Eğrisi Tahmin Modellerinin Performans Ölçümleri

Model	MSE	RMSE	MAE	MAPE
RW	8.2252	2.8680	2.2937	12.5268
VAR(1)	12.6344	3.5545	3.1321	16.9588
AR(1)	11.7387	3.4262	2.7974	14.8018
DNS-VAR	10.3523	3.2175	2.7377	14.9595
DNS-KF	323.2100	17.9780	16.6121	85.1553

Bu sonuçlar, Türkiye gibi ekonomik belirsizliklerin ve oynaklıkların yüksek olduğu bir ülkede RW ve AR(1) modellerinin getiri eğrisi tahminlerinde daha başarılı olduğunu göstermektedir. DNS-KF modeli, teorik olarak güçlü bir yöntem olsa da, yüksek hata oranlarıyla Türkiye'nin mevcut ekonomik koşullarına uygunluk sağlayamamaktadır. Getiri eğrisi teorisi bağlamında, bu tahmin yöntemlerinin etkinliği piyasa beklentileri, risk primleri ve ekonomik istikrara bağlı olarak değişiklik göstermektedir.

Şekil 3.25, Türkiye'nin getiri eğrisi tahmininde kullanılan DNS-VAR, DNS-KF, AR, VAR ve RW modellerinin performansını vadeler boyunca karşılaştırmalı olarak incelemektedir. Grafik, vadeye bağlı faiz oranlarının tahminlerini ve farklı modellerin sunduğu öngörü farklılıklarını göstermektedir. Ayrıca, getiri eğrisinin şekli üzerinden yapılan analizler, ekonomik durum ve piyasa beklentileri hakkında önemli bilgiler sunmaktadır.

DNS-VAR yöntemi, vadeler boyunca daha stabil bir yapı sergileyerek uzun vadede oldukça güvenilir bir tahmin sağlamıştır. Türkiye gibi yüksek faiz oranları ve oynak piyasa koşullarına sahip bir ekonomide DNS-VAR yöntemi, özellikle uzun vadeli faiz oranlarını anlamada güçlü bir araçtır. Yükselen bir eğri, piyasa katılımcılarının uzun vadede ekonomik toparlanma ve faiz oranlarının artışına yönelik beklentisini yansıtabilir.

DNS-KF yöntemi ise kısa vadelerde daha dalgalı, orta ve uzun vadelerde ise daha sabit bir tahmin sunmuştur. Bu durum, Kalman filtresinin geçmiş verilere ağırlık vererek kısa vadeli dalgalanmaları yakalama kabiliyeti ile ilişkilidir. Ancak, yüksek volatiliteye sahip Türkiye piyasasında DNS-KF'nin kısa vadeli tahminlerinin zaman zaman oynaklık gösterebileceği görülmektedir. AR yöntemi, kısa vadelerde yüksek ve dalgalı tahminler yapmış, ancak vadeler arttıkça belirgin bir azalma sergilemiştir. Bu eğilim, kısa vadede faiz oranlarında oynaklık olacağı, ancak uzun vadede piyasa dengelerinin sağlanacağı beklentisini yansıtmaktadır.

VAR yöntemi, vadeler boyunca daha lineer bir yapı sergileyerek özellikle orta vadede güvenilir bir tahmin sunmuştur. Türkiye gibi makroekonomik dinamiklerin sıkça değiştiği bir piyasada, VAR modeli, vadeler arası ilişkileri ve piyasa dinamiklerini anlamada etkili bir araçtır. RW yöntemi ise, vadeler boyunca oldukça düzensiz ve dalgalı



bir yapı sergileyerek, Türkiye piyasasındaki yüksek oynaklığı açık bir şekilde yansıtmıştır. Ancak RW'nin basit yapısı, veri eksikliği durumlarında avantaj sağlayabilir olsa da tahmin yeteneği sınırlıdır.

Türkiye ekonomisinde getiri eğrilerinin şekilleri, faiz oranlarının gelecekteki yönü ve ekonomik durgunluk riski hakkında önemli ipuçları sunmaktadır. DNS-VAR ve VAR yöntemlerinin tahmin ettiği yükselen eğriler, ekonomik büyüme ve faiz oranlarının normalleşmesi beklentilerini yansıtmaktadır. Öte yandan, AR ve RW gibi yöntemlerin daha dalgalı öngörülerini, kısa vadeli faiz oranlarının tahmininde belirsizlikleri vurgulamaktadır.

Sonuç olarak, Türkiye gibi oynaklığı yüksek ve hızlı değişim gösteren piyasalarda kullanılan tahmin modelleri, yalnızca faiz oranlarının vadeye bağlı davranışını anlamada değil, aynı zamanda getiri eğrisinin şekilleri üzerinden ekonomik görünümün geniş bir analizini sunmada kritik bir rol oynamaktadır. Bu tür analizler, politika yapımcıların ve piyasa aktörlerinin bilinçli kararlar almasına yardımcı olurken, ekonomik risklerin yönetiminde önemli bir araç sunmaktadır.

Şekil 3.25, Türkiye'nin 6 aylık vadeli tahvil getirilerinin farklı modelleme yöntemleriyle tahmin edilmesini göstermektedir. Grafik, vadeler boyunca getirilerin nasıl değiştiğini ve tahmin modellerinin bu değişimleri ne derece yansıttığını ortaya koymaktadır. Getiri eğrisi teorisiyle bağlantılı olarak, bu sonuçlar ekonomik döngülerin ve piyasa dinamiklerinin tahmin edilebilirliğine dair önemli çıkarımlar sunmaktadır.

Türkiye'nin getiri eğrisi, kısa vadelerde daha yüksek getiriler ve vadeler uzadıkça stabil bir yapıya geçişi göstermektedir. DNS tabanlı modeller (DNS-VAR(1) ve DNS-KF), uzun vadeli eğrilerde daha düzgün ve kararlı bir tahmin sağlarken, AR(1) ve VAR(1) modelleri kısa vadelerde daha hassas tahminler yapmaktadır. RW modeli ise, ekonomik belirsizlikleri yakalamada sınırlı bir performans sergileyerek, tahminlerinde daha düzensiz bir görünüm sergilemektedir.


Türkiye'nin ekonomik yapısı, yüksek enflasyon, kur volatilitesi ve faiz oranlarındaki dalgalanmalarla şekillenmektedir. Bu bağlamda, DNS-KF modelinin özellikle uzun vadeli tahvillerde daha yüksek getiriler tahmin etmesi, piyasanın uzun

vadede risk primlerini fiyatlandığına işaret etmektedir. Öte yandan, AR(1) ve VAR(1) modelleri kısa vadeli dinamiklere daha duyarlı olup, piyasanın kısa vadeli oynaklıklarını daha iyi yakalayabilmektedir.

Getiri eğrisi teorisine göre, uzun vadeli getirilerin kısa vadeli getirilere göre daha yüksek olduğu "normal getiri eğrisi," büyüme beklentilerinin bir göstergesidir. Şekil 3.25'te DNS tabanlı modeller, bu normallığı büyük ölçüde yansıtmaktadır. Bununla birlikte, RW modelinin tahmin eğrisi, kısa vadelerdeki hareketleri daha az tutarlı bir şekilde yansıtarak, ekonomik koşullardaki belirsizlikleri tahmin etmede sınırlı kalmıştır.


Türkiye'nin ekonomik gelişmeleri bağlamında, bu sonuçlar, piyasanın kısa vadeli belirsizliklere ve merkez bankası politikalarının etkilerine son derece duyarlı olduğunu göstermektedir. Türkiye'de sık değişen para politikaları ve yüksek enflasyon oranları, tahvil piyasalarında kısa vadeli volatiliteye neden olmaktadır. Öte yandan, uzun vadede eğrilerin genellikle yataylaşması, piyasa katılımcılarının uzun vadede daha düşük belirsizlik beklediğini ve ekonomik büyüme ile enflasyon oranlarının stabilize olacağına dair bir öngörü taşıdığını ortaya koymaktadır.

Sonuç olarak, Türkiye'nin tahvil piyasasında DNS-VAR(1) ve DNS-KF modelleri, hem kısa hem de uzun vadeli piyasa dinamiklerini anlamada daha üstün bir performans sergilemektedir. DNS modellerinin uzun vadeli projeksiyonlarda daha sağlam bir tahmin gücü sunması, yatırımcılar ve politika yapıcılar için kritik öneme sahiptir. Bununla birlikte, kısa vadeli piyasa oynaklıklarının öngörülmesinde AR(1) ve VAR(1) modellerinin etkili olduğu görülmektedir. Bu analiz, Türkiye'nin ekonomik belirsizliklerinin modelleme yöntemleri üzerinde nasıl bir etkisi olduğunu anlamak ve piyasa tahminlerinde hangi modelin daha uygun olduğunu belirlemek için önemli bir rehber sunmaktadır.




**Şekil 3.25** Türkiye Tahvil Getiri Eğrisi Tahmin Yöntemleri Karşılaştırması: DNS, VAR ve Kalman Filtresi Yöntemleriyle Tahmin

Şekil 3.26 incelendiğinde, ABD, AMB ve Türkiye için farklı tahmin ufuklarındaki MSE değerlerinin önemli ölçüde farklılaştığı gözlemlenmektedir. Özellikle Türkiye için 3 ve 6 aylık tahmin ufuklarında, DNS-KF modelinin (sarı renk) en yüksek MSE seviyelerine ulaştığı dikkat çekmektedir. Daha basit modeller (RW, AR(1) ve VAR(1)) ile DNS-VAR modelinin ise kısa vadede (1 ay) görece düşük ya da orta düzeyde MSE değerleri sergilediği anlaşılmaktadır. Ülke bazında bakıldığında, ABD ve AMB tahminleri daha düşük hata seviyelerine sahipken, Türkiye’de artan belirsizlik ve oynaklık nedeniyle tahmin hatalarının daha yüksek olduğu öne çıkmaktadır.




**Şekil 3.26** ABD, AMB ve Türkiye için Tahmin Ufuklarına Göre MSE Değerleri

Şekil 3.27 ise MSE değerlerinin karekökü alınarak elde edilen RMSE sonuçlarını yansıtmaktadır. Genel eğilimler, MSE grafiğiyle büyük ölçüde paralellik göstermektedir. Kısa vadede (1 ay), hem ABD hem de AMB’de hata oranları sınırlı kalırken, tahmin ufkunun (3 ve 6 ay) uzamasıyla birlikte hata değerlerinin yükseldiği görülmektedir. Bu artış Türkiye piyasası için daha belirgindir ve DNS-KF modeli özellikle 3 ve 6 ay vadede en yüksek RMSE değerlerini üretmektedir.




**Şekil 3.27** ABD, AMB ve Türkiye için Tahmin Ufuklarına Göre RMSE Değerleri

Şekil 3.28’de yer alan MAE grafiği, tahmin performansının ortalama mutlak sapma üzerinden değerlendirilmesine imkân tanımaktadır. ABD ve AMB tarafında modeller arasındaki farklılıkların daha sınırlı olduğu; ancak yine de DNS-KF modelinin özellikle orta-uzun vadede (3 ve 6 ay) en yüksek hata değerlerini verdiği görülmektedir. Türkiye özelinde ise tüm modellerde hata değerinin daha yüksek seyretmesi dikkat çekicidir; bu durum, Türkiye piyasasındaki yapısal oynaklık ve kısa dönemli dalgalanmaların tahmin başarısını düşürdüğüne işaret etmektedir.



**Şekil 3.28** ABD, AMB ve Türkiye için Tahmin Ufuklarına Göre MAE Değerleri

Son olarak, Şekil 3.29 tahmin hatalarını yüzdesel ölçekte sunan MAPE değerlerini göstermektedir. Bu metrik, özellikle faiz oranlarının seviye farklılıklarından kaynaklanan relatif hata büyüklüklerini yansıtması bakımından önemlidir. Grafığe göre, ABD ve AMB'deki yüzdesel hatalar genel olarak daha düşük bir bantta kalırken, Türkiye'deki tahminler için yine belirgin bir artış söz konusudur. DNS-KF modeli çoğunlukla en yüksek MAPE değerlerini üretmekte olup, bu fark özellikle 3 ve 6 aylık tahmin ufuklarında belirginleşmektedir. Diğer modeller arasında RW, AR(1) ve VAR(1) gibi yöntemlerin kısa vadede daha istikrarlı sonuçlar vermesi, DNS-VAR yaklaşımının ise çoğu zaman orta düzeyde bir performans sergilemesi, ülkeler ve ufuklar arası karşılaştırmanın en belirgin bulgularını yansıtmaktadır.



**Şekil 3.29** ABD, AMB ve Türkiye için Tahmin Ufuklarına Göre MAPE Değeri


Şekil 3.30, Diebold–Li modelinin farklı veri setleri (ABD, AMB, TR) üzerinde, çeşitli çok adımlı tahminleri için elde edilen RMSE değerlerinin kutu grafikleri yer almaktadır. Bu grafikleri detaylı olarak değerlendirirken, her bir ülkenin ekonomik bağlamını da göz önünde bulundurmak önemlidir.

ABD, dünyanın en büyük ekonomilerinden biridir ve finansal piyasaları oldukça derindir. Ekonomik veriler ve finansal enstrümanlar genellikle yüksek kalite ve güvenilirliktedir. Bu nedenle, Diebold–Li modeli gibi tahmin modelleri, ABD verileri üzerinde genellikle daha tutarlı ve doğru sonuçlar verebilir. Grafiklerde, ABD veri seti için RMSE değerlerinin düşük ve dar bir aralıkta olması, modelin bu veri seti üzerinde oldukça başarılı olduğunu göstermektedir. ABD piyasalarının düzenli ve öngörülebilir yapısı, modelin performansını artırmaktadır.

AMB, Euro Bölgesi'nin merkez bankasıdır ve Euro'yu kullanan ülkelerin ekonomik ve finansal verilerini içerir. Euro Bölgesi, çoklu ülke ekonomilerinden oluştuğu için veri seti ABD'ye göre daha çeşitli ve karmaşık olabilir, ancak yine de oldukça güvenilir ve düzenli verilere sahiptir. Grafiklerde, AMB veri setinde de RMSE değerlerinin genellikle düşük ve dar bir aralıktadır. Bu, Euro Bölgesi verilerinin de model tarafından başarılı bir şekilde tahmin edilebildiğini göstermektedir. Ancak, biraz daha

geniş RMSE aralığı, verilerin farklı ülkelerden gelmesi ve bu ülkelerin ekonomik koşullarındaki farklılıkları yansıtırabilir.

Türkiye, gelişmekte olan bir ekonomidir ve finansal piyasaları ABD ve Euro Bölgesi kadar derin değildir. Ekonomik verilerde dalgalanmalar ve belirsizlikler daha sık görülebilir. Ayrıca, politik ve ekonomik istikrarsızlıklar veri setinin öngörülebilirliğini zorlaştırabilir. Grafiklerde, Türkiye veri setinde RMSE değerlerinin yüksek ve geniş bir aralıkta olması, modelin bu veri seti üzerinde daha az başarılı olduğunu göstermektedir. Ekonomik dalgalanmalar ve belirsizlikler, modelin performansını olumsuz etkileyebilir. Türkiye'nin ekonomik bağlamı, tahminlerin tutarsız olmasına neden olabilir.



**Şekil 3.30** Diebold–Li Modeli ile Çok Adımlı Tahminlerin RMSE Kutu Grafikleri

### 3.10 Fonksiyonel Veri Analizi

Fonksiyonel veri analizi (FDA), kesikli değerler veya vektörler yerine fonksiyonlar olarak temsil edilen verilerle ilgilenen istatistiksel bir metodolojidir. Doğası gereği sürekli ve işlevsel olan verileri analiz etme kabiliyeti nedeniyle çeşitli alanlarda büyük ilgi görmüştür (Yao vd., 2005a). FDA'nın esnekliği, bir aralık üzerinde tanımlanan fonksiyonlar olan verileri işleme yeteneğinde yatmaktadır ve bu da onu çok çeşitli uygulamalar için uygun hale getirmektedir (Hébrail vd., 2010).

FDA metodolojisi, fonksiyonel verileri özetlemek ve analiz etmek için temel bir araç olan fonksiyonel temel bileşen analizi (FPCA) gibi teknikleri kapsamaktadır (Hall vd., 2006). FPCA, fonksiyonel verilerdeki varyasyon modlarının tanımlanmasına olanak tanıyan fonksiyonel temel bileşen analizidir (Wang vd., 2016). FPCA, büyüme eğrilerinin analizi, boylamsal veriler ve hatta beyin görüntüleme verilerini analiz etmek için sinirbilim



alanında da dahil olmak üzere çeşitli uygulamalarda yaygın olarak kullanılmaktadır (Ullah ve Finch, 2013). Fonksiyonel veri analizi, kablosuz sensör ağları, beyin görüntüleme çalışmaları ve hatta COVID-19 verilerinin analizi gibi çeşitli alanlarda uygulanmıştır (Viviani vd., 2004).

FPCA, FDA'daki yaygın bir yöntem olup, fonksiyonel verilerin ana yapılarını ve örüntülerini tanımlamak için kullanılır. FPCA'nın temel amacı, fonksiyonel veri setindeki varyansın büyük bir kısmını açıklayan temel bileşenleri ve ilgili katsayıları belirlemektir (Yao vd., 2005b). Bu temel bileşenler ve katsayılar, veri setindeki temel yapıları ve örüntüleri ortaya çıkarır. FPCA, fonksiyonel veri setleri üzerinde öklidyen uzayda yapılan temel bileşen analizi (PCA) yöntemine benzer bir yaklaşım sergiler. Ancak, fonksiyonel veri setleri için, işlevsel uzayda bir iç çarpım ve karşılık gelen norm tanımı gereklidir (Ramsay and Silverman, 2005). FPCA, veri setindeki ana bileşenleri bulmak için bu iç çarpımı kullanarak fonksiyonel verilerin varyansını en üst düzeye çıkarır (Yao vd., 2005b). Kovaryans operatörünün özfonksiyonları ve özdeğerleri, FPCA'nın temel bileşenlerini ve varyanslarını belirlememize yardımcı olmaktadır.

Fonksiyonel veri analizi için, veri noktaları yerine sürekli fonksiyonlar üzerinde çalışırız. Öncelikle, fonksiyonel veri setindeki fonksiyonların ortak bir temsilini elde etmek için bir temel seçimi yapılır. Bu temel genellikle  $L^2$  uzayında bir dizi ortanormal temel fonksiyonu  $\psi_k(t)$  olarak seçilir. FPCA işleminde, fonksiyonel verilerin kovaryans operatörünü hesaplamamız gerekir. İlk olarak, gözlemlenen fonksiyonların ortalamasını ( $\mu(t)$ ) hesaplamalıyız. Bu, tüm gözlemlerin ( $X_i(t)$ ) ortalamasını olarak yapılır:

$$\mu(t) = \frac{1}{N} \sum_{i=1}^N X_i(t), \quad (3.26)$$

burada  $N$ , gözlem sayısıdır.

Bu, fonksiyonel verilerin varyansını ve korelasyonunu ölçer. Kovaryans operatörü  $C: L^2 \rightarrow L^2$  olarak tanımlanır ve şu şekilde ifade edilir:

$$C(\psi) = E[(X(t) - \mu(t))(X(s) - \mu(s))], \quad (3.27)$$

burada  $E[.]$  beklenen değeri,  $X(t)$  ve  $X(s)$ - rassal fonksiyonlar ve  $\mu(t)$  ve  $\mu(s)$  ortalama fonksiyonlarıdır. Kovaryans operatörünün özfonksiyonları ve özdeğerleri, FPCA'nın temel bileşenlerini ve varyanslarını belirlememize yardımcı olmaktadır.

Kovaryans operatörü  $C$ 'nin özfonksiyonlarını ve özdeğerlerini bulmamız gerekmektedir. Bu, aşağıdaki özdeğer problemi ile yapılır (Yao et al., 2005b):

$$C(\varphi_k) = \lambda_k \varphi_k, \quad (3.28)$$

burada  $k = 1, 2, 3, \dots$  için  $\lambda_k$  özdeğerleri,  $\varphi_k(t)$  özfonksiyonlarıdır. Özfonksiyonlar fonksiyonel temel bileşenleri temsil ederken ve özdeğerler, ilgili bileşenlerin açıkladığı varyans miktarını göstermektedir.

Her bir gözlem  $X_i(t)$  için, temel bileşenlerin ağırlıkları (katsayıları):

$$c_{ik} = \langle X_i(t) - \mu(t), \varphi_k(t) \rangle, \quad (3.29)$$

burada  $c_{ik}$ ,  $i$ . gözlem için  $k$ . bileşenin ağırlığını ve  $\langle ., . \rangle$  iç çarpımı göstermektedir. Son olarak, her gözlemi  $X_i(t)$ , temel bileşenlerin doğrusal kombinasyonu olarak yaklaşık olarak temsil edilebilir:

$$X_i(t) \approx \mu(t) + \sum_{k=1}^K c_{ik} \varphi_k(t). \quad (3.30)$$

burada  $K$  seçilen temel bileşen sayısıdır ve genellikle toplam açıklanan varyansın yeterli olduğu düşünülen bir sayıya kadar seçilmektedir.

FPCA, fonksiyonel verilerin boyutunu azaltmak ve veri setindeki önemli yapıları ve örüntüleri ortaya çıkarmak için kullanılabilir. Bu, veri analizi, sınıflandırma ve regresyon gibi daha fazla istatistiksel analiz için kullanılabilir temel bileşenleri ve katsayıları sağlamaktadır. FPCA'nın sürekli olarak gelişen teorik ve uygulama alanları, yeni teknolojik ve yöntemsel gelişmelerin ortaya çıkmasına zemin hazırlamaktadır. Özellikle, hesaplamalı verimliliği artırmaya yönelik algoritmik gelişmeler ve paralel hesaplama teknikleri, büyük

ölçekli fonksiyonel veri setleri üzerinde çalışan FPCA için önemli faydalar sağlamaktadır (Chiou et al., 2004).

Gelecekteki potansiyel ve gelişmeler FPCA'nın etkisi ve kullanımı, gelecekteki yöntemsel ve teknolojik gelişmelere bağlı olarak artmaya devam edecektir. Yeni algoritmalar ve hesaplama teknikleri, daha büyük ve daha karmaşık fonksiyonel veri setlerini işlemeyi kolaylaştırarak, FPCA'nın kullanım alanlarını genişletecektir. Ayrıca, farklı disiplinler arasındaki iş birliği ve entegrasyon, yöntemin daha fazla uygulama alanında kullanılmasına yol açacaktır. Özellikle, yapay zekâ ve makine öğrenimi alanlarındaki hızlı gelişmeler, FPCA'nın gücünü ve esnekliğini artıracaktır. Yapay sinir ağları ve derin öğrenme teknikleri ile FPCA'nın entegrasyonu, fonksiyonel veri analizinde yeni ve heyecan verici uygulamalara yol açabilir.

### 3.10.1 Fonksiyonel zaman serilerinin tahmini

FPCA analizi ile farklı vadelerdeki tüm eğriyi fonksiyonlar üzerindeki bir dağılımdan rastgele bir gerçekleşme olarak ele alarak getiri eğrisinin elde edilmektedir. Parametrik olmayan bu yaklaşım, parametrik bileşenler ve varsayımlar içeren mevcut yaklaşımların aksine, getiri eğrisinin düzgünlüğü ve bütünleşebilirliği dışında hiçbir varsayım gerektirmemektedir. Analiz, çok fazla parametrik varsayım içermeyen bir kurulum altında faiz oranlarının zaman ve vade bileşenlerini incelemek için birleşik bir çerçeve sunmaktadır. Bu da faiz oranı sürecinin daha iyi modellenmesini, veri görselleştirilmesini ve anlaşılmasını sağlamaktadır (Sen ve Klüppelberg, 2010).

FDA tarafından başlangıçta benimsenen bağımsızlık ve incelenen fonksiyonların aynı dağılıma sahip olması varsayımının getiri eğrisi verileri gibi finansal verilere uygulanamayabileceğini belirtmek önemlidir. Bunun yerine, örneklenen eğriler arasında zaman içinde bir ilişki olduğunu varsaymak mantıklıdır. FPCA uygulanırken hesaba katılması gereken bir süreç yapısını ele almak için Sen ve Klüppelberg (2010) ile Hyndman ve Shang (2009) otoregresif süreçlerin FPCA çerçevesine dahil edilmesini önermişlerdir.

$\langle f, g \rangle = \int_T f(\tau)g(\tau)d\tau$  iç çarpımı ve  $\|f\| = \sqrt{\langle f, f \rangle_{\mathcal{H}}} < \infty$  koşuluyla,  $f$ 'nin Hilbert uzayının  $\mathcal{H} := L^2(T)$  ögesi olduğu varsayıldığı bir  $f$  sürecinden örneklenen

$f_1, \dots, f_n$  fonksiyonları vardır. Gözlemler, fonksiyon üretme sürecinden bağımsız olduğu varsayılan  $W_{ij}$  hata ile ölçülür.  $i = 1, \dots, n$  ve  $j = 1, \dots, m$  için ölçümler şunlardır:

$$\tilde{f}_i(\tau_{ij}) = f_i(\tau_{ij}) + W_{ij}, \quad E(W_{ij}) = 0, \text{Var}(W_{ij}) = \sigma^2. \quad (3.31)$$

$f(\tau)$ 'nın ortalama fonksiyonu  $\mu_f = E(f(\tau))$  ve sürekli kovaryans fonksiyonu şu şekilde tanımlanır:

$$\phi_f(v, \tau) = \text{Cov}(f_t(v), f_t(\tau)), \quad v, \tau \in \mathcal{T}, \quad (3.32)$$

fonksiyonel ana bileşenler,  $\mathcal{H}$  üzerinde doğrusal bir operatör olan  $\phi_f: \mathcal{H} \rightarrow \mathbb{R}$  otokovaryans operatörünün özfonksiyonlarıdır ve şu şekilde verilir:

$$(\phi_f \alpha)(v) = \int_T \phi_f(v, \tau) \alpha(\tau) d\tau, \quad \alpha \in L^2(T). \quad (3.33)$$

Kovaryans fonksiyonu şu şekilde tanımlanır:

$$\phi_f(v, \tau) = \int_T [f_t(v) - \mu(v)][f_t(\tau) - \mu(\tau)] dv d\tau. \quad (3.34)$$

$\lambda_1 \geq \lambda_2 \geq \dots$  ve  $\sum_k \lambda_k < \infty$  olacak şekilde,  $k = 1, 2, \dots$  için öz değerleri  $\lambda_k$  olan ortonormal öz fonksiyonları  $\psi_k(\tau)$  ile gösterilsin. Karhunen-Loeve teoremi (Rice ve Silverman (1991)),  $f$  fonksiyonelinin bireysel rastgele yörüngelerinin aşağıdaki gibi bir temsilini sağlamaktadır:

$$f(\tau) = \mu_f(\tau) + \sum_{k=1}^{\infty} \xi_k \psi_k(x), \quad \tau \in \mathcal{T}, \quad (3.35)$$

burada  $\xi_k$ , aşağıdakileri sağlayan ilişkisiz rastgele değişkenlerdir:

$$\xi_k = \int_T [f(\tau) - \mu_f(\tau)] \psi_k(\tau) d\tau, \quad E(\xi_k) = 0, \text{Var}(\xi_k) = \lambda_k, \quad (3.36)$$

olacak şekilde  $k$  –inci fonksiyonel temel bileşen puanıdır (Hall vd., 2006). Veri üretme mekanizması altında, gösterge fonksiyonu  $I(\cdot)$ ,

$$\mathbb{E}(\tilde{f}_i(\tau_{ij})) = \mu_f(\tau), \quad \text{Cov}(\tilde{f}_i(v), \tilde{f}_i(\tau)) = \phi_f(v, \tau) + \sigma^2 I(v = \tau) \quad (3.37)$$

FPCA ile fonksiyonel bir süreci yaklaşık olarak hesaplamak için, öncelikle verilerden temel bileşenler elde edilir. Daha sonra, bu temel bileşenlerden sadece en önemli  $K$  tanesi seçilir.  $K$  değeri, çapraz doğrulama (Rice ve Silverman, 1991) veya AIC kriterleri (Yao vd., 2005b) gibi yöntemler kullanılarak belirlenebilir. Son olarak, seçilen  $K$  tane temel bileşen kullanılarak fonksiyonel süreç yaklaşık olarak hesaplanır. Bu, fonksiyonel verileri düşük boyutlu bir temsile indirgeyerek karmaşıklığı azaltır.

Hyndman ve Shang (2009), FPCA uygulamaları için aşağıdaki modeli sunmaktadır:

Fonksiyonlar  $t = 1, \dots, n$  zamanında gözlemlenmekte ve  $t = n + 1, \dots, n + h$  zamanları için fonksiyonları tahmin edilemek istenmektedir.  $y_t(x_i)$  gözlenen verileri için, burada  $i = 1, \dots, p$ .  $f_t(x)$   $L_2$  sürekli fonksiyon olmak üzere,

$$y_i(\tau_j) = f(\tau_j) + \sigma_i(\tau_j) + \epsilon_{i,j}, \quad (3.38)$$

burada  $\{\epsilon_{i,j}\}$  sıfır ortalama ve birim varyansa sahip bağımsız ve özdeş dağılımlı değişkenlerdir ve  $\sigma_i(\tau_j)$  değişen varyansa izin vermektedir. Hyndman ve Ullah (2007), düzgün fonksiyonların  $\{f_t(x)\}$  tahminlerini elde etmek için her bir  $y_i(x)$  eğrisi üzerinde ayrı ayrı parametrik olmayan düzgünleştirme kullanmıştır. Daha sonra, fonksiyonel verilerin zaman serisini bir dizi temel bileşene ve bunların puanlarına ayırtırmak için fonksiyonel bir temel bileşen yaklaşımı önermişlerdir. Model aşağıdaki gibi yazılabilir:

$$f_i(\tau) = \mu_f(\tau) + \sum_{k=1}^K \xi_{ik} \psi_k(\tau) + e_i(\tau), \quad (3.39)$$

Burada  $\psi_k(\tau)$  öz fonksiyonu  $k$ . temel bileşen fonksiyonu ve  $K < n$  için  $\{\xi_{1k}, \dots, \xi_{nk}\}$   $k$ . temel bileşen skorlarıdır.  $e_i(\tau)$  sıfır ortalamalı bağımsız ve özdeş dağılımlı (i.i.d.) rastgele fonksiyonlardır.  $\psi_k$  ve  $\psi_l$  öz fonksiyonları  $k \neq l$  için

ortogonaldır, bu da temel bileşen skorlarının  $\xi_{ik}$  ilişkisiz olduğu anlamına gelmektedir. Hyndman ve Ullah (2007), temel bileşen skorlarının korelasyonsuz olması nedeniyle, her bir tek değişkenli zaman serisinin  $\{\beta_{t,k}\}$ ,  $k = 1, \dots, K$ , tek değişkenli bir zaman serisi modeli kullanılarak bağımsız olarak tahmin edilebileceğini öne sürmüştür. Tahmin edilen temel bileşen skorlarının temel bileşenlerle çarpılmasıyla tahmini gelecek eğrileri elde edilir.

Fonksiyonel temel bileşen analizi (FPCA), faiz oranlarının vade yapısını anlamak için çok önemli olan getiri eğrilerini analiz etmek ve tahmin etmek için güçlü bir araçtır. FPCA, getiri eğrisini sürekli bir fonksiyon olarak ele alır ve geleneksel PCA'ya kıyasla daha incelikli bir analize olanak tanır. Bu yaklaşım, getiri eğrilerinin zaman içindeki düzgünlüğünü ve dinamik doğasını yakalamada özellikle yararlıdır. Örneğin, Çin vade yapısının analizinde, getiri eğrisini etkili bir şekilde modellemek için FPCA kullanılmış, ilk iki fonksiyonel temel bileşen (FPC'ler) toplam varyasyonun %98,68'ini oluşturarak getiri eğrisinin temel dinamiklerini yakalamadaki etkinliğini göstermiştir (Feng & Qian, 2018). Benzer şekilde, uluslararası getiri eğrileri bağlamında, farklı ekonomilerdeki ortak faktörleri belirlemek için ortak bir fonksiyonel temel bileşen (CFPC) yöntemi önerilmiş ve bu da veriye dayalı bir otoregresyon çerçevesinde getiri eğrilerinin tahmin edilmesine yardımcı olmuştur (Zhang vd., 2017).

FPCA'nın Sri Lanka tahvil piyasasında uygulanması, ilk temel bileşenin, piyasaya özgü likidite kısıtlamaları nedeniyle daha kısa vadeleri temsil etmesine rağmen, getiri eğrisinin varyasyonunun önemli bir bölümünü oluşturduğunu ortaya koymuştur (Dayarathne & Thayasivam, 2024). Ayrıca, FPCA, durum fiyat yoğunluk yüzeyleri gibi çok değişkenli eğrilerin türevlerine uygulanmış ve getiri eğrilerinin ötesinde finansal uygulamalardaki çok yönlülüğünü vurgulamıştır (Grith vd., 2018). Yöntemin sağlamlığı, yerel polinom regresyonları aracılığıyla gürültülü verileri ele alma yeteneği ile daha da desteklenmekte ve pürüzsüz türevlerin doğru tahmin edilmesini sağlamaktadır (Grith vd., 2016). Avantajlarına rağmen FPCA, bileşen tahminindeki belirsizlikle başa çıkmak gibi zorluklarla da karşı karşıyadır ve bu zorluklar bootstrapping gibi gelişmiş istatistiksel tekniklerle ele alınabilir (Sharpe & Fieller, 2016). Genel olarak, FPCA getiri eğrilerini analiz etmek için kapsamlı bir çerçeve sunmakta ve minimum parametrik varsayımlarla faiz oranlarının hem zaman hem de vade bileşenlerine ilişkin içgörüler sağlamaktadır (Sen ve Klüppelberg, 2019).

### 3.10.2. Tahmin

Getiri eğrilerini FPCA ile tahmin etmek için "ftsa" R paketi (Shang, 2013; Hyndman ve Shang, 2024) kullanılmıştır. Bu paket, fonksiyonel bir zaman serisine ana bileşen analizini uygulama ve elde edilen bileşenlere dayalı tahmin modelleri oluşturma yeteneği sunmaktadır. FPCA yöntemi, zaman serisi verilerinin boyutunu azaltarak önemli bilgi kaybı olmadan daha sade ve anlaşılır bir yapı sunar. Bu süreçte, fonksiyonel veri analizi yöntemiyle zaman serisi verilerinin varyansını en iyi şekilde açıklayan ana bileşenler belirlenir ve ardından bu bileşenler üzerinde zaman serisi tahmin yöntemleri uygulanır. "ftsa" paketi, esnek ve kullanıcı dostu bir platform sağlayarak araştırmacıların farklı veri setleri üzerinde FPCA modelini kolayca uygulamalarına olanak tanımaktadır. Bu yaklaşım, getiri eğrilerinin zaman içindeki dinamiklerini daha iyi anlamayı ve gelecekteki eğilimleri daha doğru tahmin etmeyi mümkün kılmaktadır.

### 3.10.3. Sonuçlar

Hyndman ve Shang (2009), FPCA modelinin, ortalama fonksiyonuna bir ağırlık vektörü eklemiş ve bunun tahmin performansını artırdığını göstermiştir. Bu bölümde ağırlıklı tahmin modelleri karşılaştırılmaktadır.

Şekil 3.31, ABD tahvil getirileri verilerine uygulanan fonksiyonel temel bileşen analizinin (FPCA) sonuçlarını göstermektedir. Üst bölümde, ana etkiler ve fonksiyonel temel bileşenlerin vadeye göre değişen yükleri, alt bölümde ise bu bileşenlere karşılık gelen puanlar yer almaktadır.

Şekil 3.31, ABD tahvil getirilerinin (örneğin 1 aydan 30 yıla kadar farklı vadelerdeki faiz oranlarının) fonksiyonel temel bileşen analizi (FPCA) ile incelenmesine ilişkin bulguları yansıtmaktadır. Şeklin üst kısmındaki paneller, sırasıyla ortalama getiri eğrisini ve birinci, ikinci, üçüncü temel bileşenlerin vade eksenindeki fonksiyonel biçimlerini göstermektedir. Alt kısımdaki paneller ise bu bileşenlerin zaman serisi içindeki skorlarını (katsayılarını) sunmaktadır. Modelin teorisi ve ABD ekonomisindeki gelişmeler bağlamında, elde edilen sonuçlar birkaç açıdan önem taşımaktadır.

Öncelikle, sol üst panelde görülen ortalama getiri eğrisi (main effects), kısa vadelerden uzun vadelere doğru yükselen bir profil sergilemektedir. Bu durum, ABD tahvil piyasasında sıklıkla gözlemlenen “normal” getiri eğrisini yansıtır. Genellikle uzun vadeli tahviller, ekonomik belirsizlikler ve enflasyon gibi riskleri yansıttığı ölçüde daha yüksek getiri sunar. Dolayısıyla, elde edilen ortalama getiri eğrisi, literatürde sıkça söz edilen risk primi ve beklenen enflasyon kanallarıyla da uyum göstermektedir.

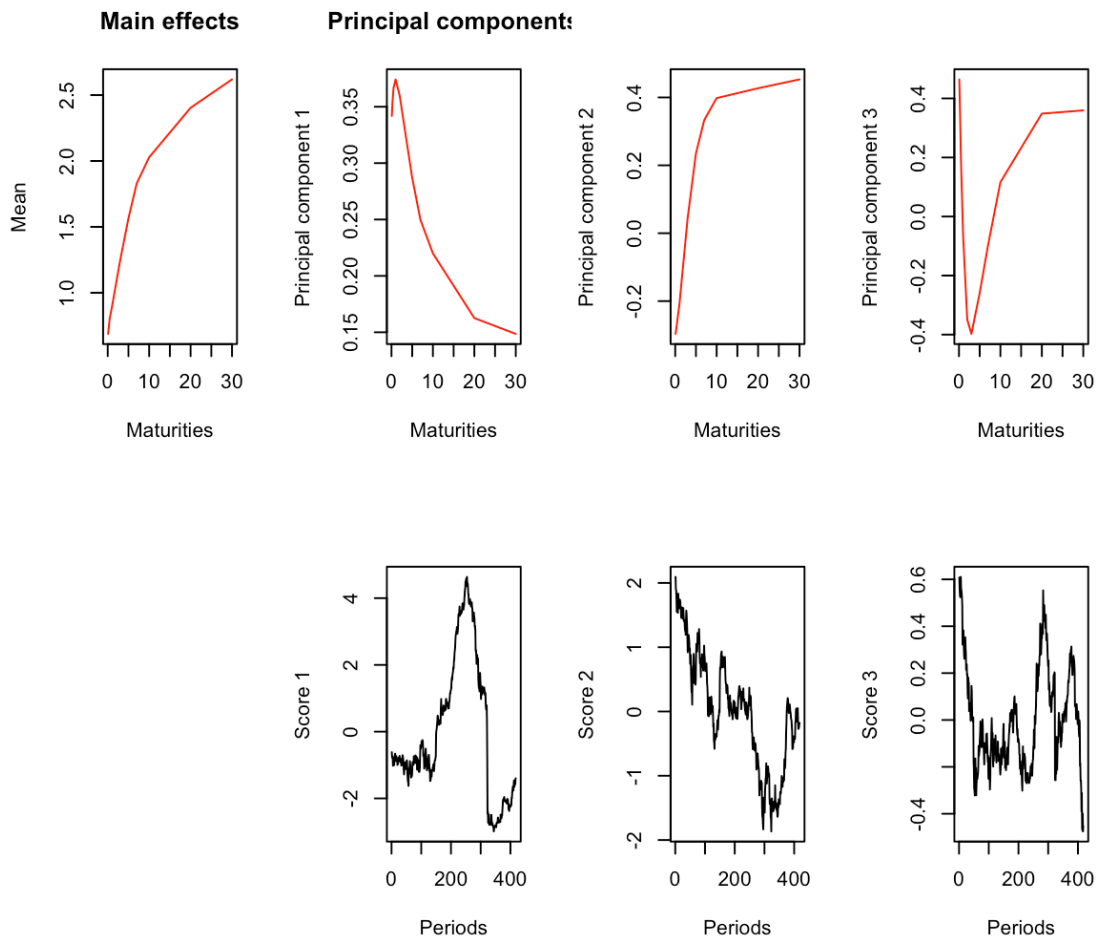
İlk temel bileşen (PC1), vade yapısı boyunca büyük ölçüde benzer işaretli bir etki ortaya koyarak genellikle “seviye (level) faktörü” olarak adlandırılan değişkeni temsil etmektedir. Bütün vadelerdeki getirilerde paralel kaymaları yansıtan bu faktör, para politikası kararlarından ve genel likidite koşullarından doğrudan etkilenir. Aşağıdaki “Score 1” grafiğinde, bu seviye faktörünün zaman içindeki dalgalanmaları izlenebilmektedir. Örneğin, 2008-2009 küresel finans krizini takiben uygulanan parasal genişleme politikaları ya da sonrasında gelen sıkılaştırma adımları, bu skorun belirgin yükseliş veya düşüş dönemleri şeklinde yansiyabilir.

İkinci temel bileşen (PC2) ise genellikle kısa ve uzun vadeler arasında zıt yönlü hareket ettiği için “eğim (slope) faktörü” olarak tanımlanmaktadır. Getiri eğrisinin kısa ve uzun uçları arasındaki farkın zaman içindeki değişimini yakalayan bu faktör, özellikle ekonomik beklentiler, resesyon öngörülerini ve FED’in gelecekteki faiz politikalarına dair piyasa algıları tarafından şekillenmektedir. Alt paneldeki “Score 2” grafiğindeki dalgalanmalar, eğim bileşeninin dönemsel olarak ne ölçüde keskin ya da yatay hale geldiğini ifade eder. Ekonomik literatürde getiri eğrisinin tersine dönmesi (kısa vadeli faizlerin uzun vadeli faizlerin üzerine çıkması) sıklıkla resesyon göstergesi olarak kabul edildiğinden, bu döneme özgü ani değişimler PC2 skoruna doğrudan yansiyacaktır.

Üçüncü temel bileşen (PC3), vade yapısının “kısa ve uzun uç” ile “orta vadeler” arasındaki farklı hareketlerini, başka bir ifadeyle eğrinin “kavramsal (curvature) bileşenini” göstermektedir. Bu bileşen, orta vadeli tahvillerin getirilerinde ortaya çıkan şişme veya çukurlaşma eğilimlerine işaret eder. En sağdaki “Score 3” grafiği, bu bileşenin ekonomik şoklara, ani enflasyon beklentisi değişimlerine veya piyasalardaki risk algısında yaşanan dalgalanmalara karşı duyarlılığını yansıtmaktadır.



Sonuç olarak, fonksiyonel temel bileşen analizi, getiri eğrisindeki değişim dinamiklerini “seviye, eğim ve kavrama” gibi başlıca faktörler doğrultusunda özetlemeyi mümkün kılarak, ABD tahvil piyasasının genel görünümünü ve piyasa beklentilerini açıklamayı kolaylaştırmaktadır. Para politikası kararlarının geniş etkisi, resesyon tahminleri ve piyasa likiditesine dair temel göstergeler, bu faktörlerin skorlarındaki hareketlerde doğrudan gözlemlenebilmektedir. Bu yönüyle FPCA, getirilerdeki çok boyutlu yapının anlaşılmasında ve tahvil fiyatlamasına ilişkin modelleme çalışmalarında temel bir araç olarak öne çıkmaktadır.



**Şekil 3.31** ABD Verileri İçin İlk Üç Ağırlıklı Fonksiyonel Temel Bileşen ve İlgili Puanlar

Şekil 3.32’de sunulan üç boyutlu grafik, FPCA tabanlı tahmin modelinden elde edilen tahvil getirisi artık (residual) değerlerinin zaman eksenini (yatay), vade eksenini (derinlik) ve artık seviyesi (dikey) üzerinde dağılımını göstermektedir. Bu üç boyutlu sunum, modelin hangi zaman aralıklarında ve hangi vade dilimlerinde daha iyi veya daha

zayıf performans gösterdiğine dair görsel bir öngörü sağlamaktadır. Aşağıdaki yorumlar, hem modelin geçerliliği hem de piyasa dinamikleri açısından şeklin olası çıkarımlarını tartışmaktadır.


Öncelikle, artıkların zaman ve vade eksenleri boyunca rastgele dağılması, modelin yapısal bir yanlılık (bias) üretmediğini ve genel anlamda tahvil getirilerindeki dalgalanmaları yakalamada başarılı olduğunu göstermektedir. Eğer belirli vade aralıklarında veya belirli dönemlerde artık değerlerinde kümelenme ya da sistematik bir desen gözlemleniyorsa, bu durum modelin o kısımları yakalayamadığına işaret eder. Örneğin, kısa vadeli tahvillerde belirgin biçimde yüksek veya düşük artıkların tekrarlayan bir döngü biçiminde ortaya çıkması, o vade diliminde ek bir risk faktörünün veya piyasa dinamiğinin göz ardı edildiğini gösterebilir.

İkinci olarak, artıkların zaman içindeki değişimi, piyasanın dönemsellik, likidite sıkışmaları veya ani ekonomik şoklara verdiği tepkileri modelin ne ölçüde yakaladığını değerlendirmeye de olanak verir. FED'in anlık politika değişiklikleri, ekonomik kriz dönemleri ya da beklenmedik makroekonomik gelişmeler, getiri eğrisinde ani kırılmalara neden olarak modelde beklenenden daha büyük artık değerleri oluşturabilir. Zaman eksenini boyunca yoğunlaşan yüksek (pozitif veya negatif) artıklar, söz konusu şoklara duyarlılığın modellenmesinde ek yapısal faktörlere gereksinim olabileceğini gösterir.

Üçüncü olarak, grafikte artıkların dikey ekseninde görülen sıçramalar, modelin volatilitiyi veya oynaklık rejimi değişimlerini yakalamadaki performansına ışık tutmaktadır. Eğer belirli zaman dilimlerinde artıkların aşırı oynaklık sergilediği gözleniyorsa, bu dönemler volatilitedeki rejim değişiklikleriyle veya modelin varsaydığı durağanlık koşullarının ihlal edilmesiyle ilişkili olabilir. Özellikle yüksek volatilité dönemlerinde, standart FPCA yaklaşımlarının yetersiz kalabileceği ve bunun yerine varyans-kovaryans yapısında zamanla değişimi dikkate alan yöntemlerin (örneğin dinamik FPCA veya çoklu rejimli modeller) tercih edilmesi gerekebilir.

Son olarak, bu şekildeki bir görsel inceleme, FPCA modelinden elde edilen sonuçların makroekonomik koşullara ve tahvil piyasası dinamiklerine ne kadar uyumlu olduğunu destekleyici bir kanıt niteliğindedir. Model, seviye, eğim ve kavrama bileşenlerini oldukça iyi temsil etse bile; küresel kriz dönemleri, ani likidite dalgalanmaları veya

öngörülemeyen politika hamleleri gibi sıra dışı olaylar karşısında yetersiz kalabilir. Dolayısıyla, Şekil 3.32’deki artık analizinin bulguları, hem modelin gelecekteki iyileştirme alanları için bir yol haritası hem de piyasa koşullarını daha bütüncül ele alacak ek faktörlere işaret eden değerli bir rehber olarak değerlendirilebilir.



**Şekil 3.32** ABD Tahvil Getirileri için FPCA Modelinin Zaman İçinde Vadeye Göre Artık Değerleri

Şekil 3.33, Avrupa Merkez Bankası (AMB) tahvil getirileri verilerine yönelik fonksiyonel temel bileşen analizi (FPCA) sonuçlarını üç açıdan sunmaktadır: üst sırada ortalama getiri eğrisi ile birinci, ikinci ve üçüncü temel bileşenlerin vade (maturity) eksenindeki dağılımı; alt sırada ise bu bileşenlerin zaman (period) ekseninde değişen skorları yer almaktadır. Bu sonuçlar, Avrupa tahvil piyasasında gözlemlenen temel dinamikleri özetlerken, AMB’nin para politikası uygulamaları ve bölgenin ekonomik görünümü bağlamında da önemli göstergeler sunmaktadır.

İlk panelde görülen ortalama getiri eğrisi (Main effects) kısa vadelerden uzun vadelere doğru artan bir seyir izlemektedir. Bu yapı, genellikle “normal” getiri eğrisinin karakteristiği olarak yorumlanabilir ve ekonomik büyümeye dair beklentiler ile enflasyon risk primi gibi faktörleri yansıtmaktadır. Avrupa Merkez Bankası’nın genişlemeci politikalarının ağırlıkta olduğu dönemlerde, eğrinin kısa vadelerde düşük seviyelerde

seyretmesi, uzun vadelerde ise artış göstermesi olağan karşılanmaktadır. Avrupa Bölgesi’ndeki deflasyon endişeleri, düşük büyüme beklentileri ve negatif faiz politikası dönemleri de bu ortalama eğri üzerinde doğrudan etki yaratmıştır.

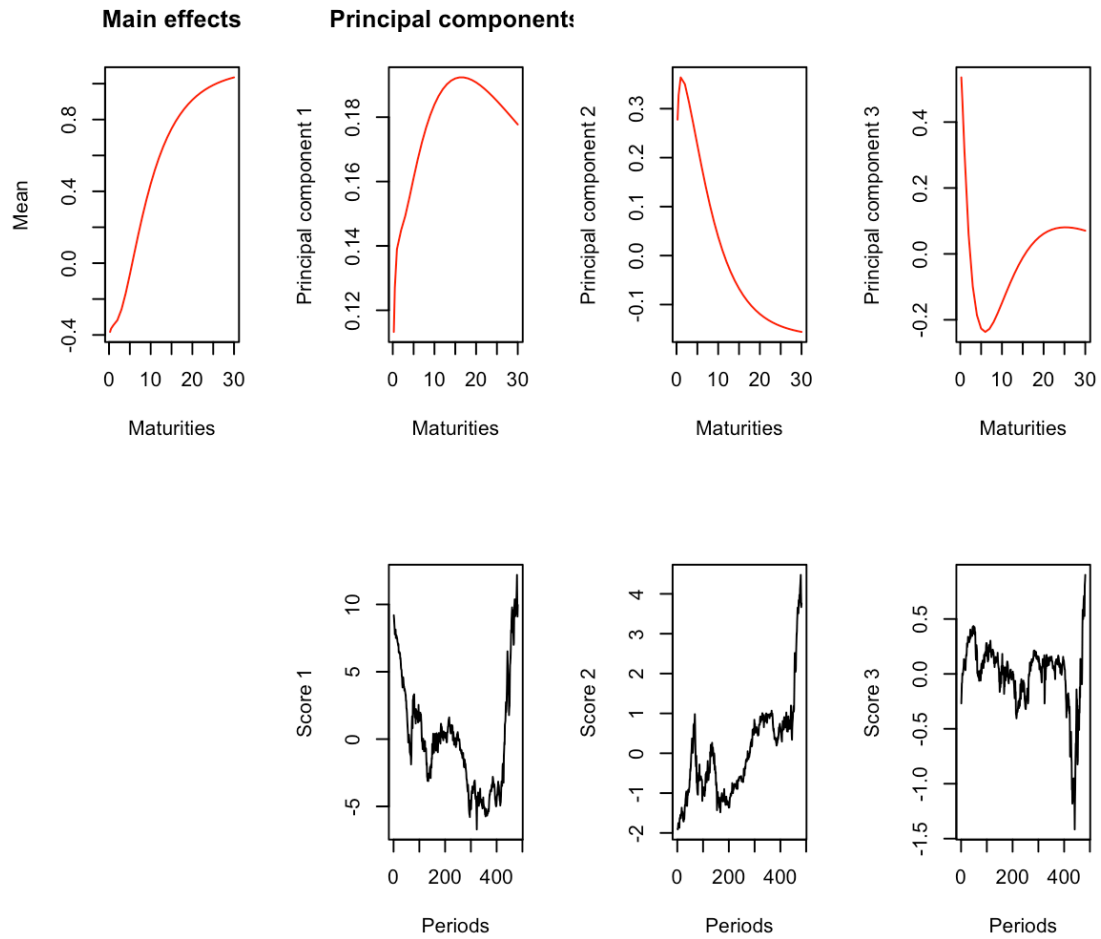
Birinci temel bileşen (PC1), tüm vade yapısında benzer işarete sahip bir profil çizerken, özellikle orta vadelerde belirgin bir zirve yaparak “seviye (level) faktörü”nü yansıtmaktadır. Bu faktör, AMB’nin geleneksel ve geleneksel olmayan para politikası araçları (örneğin varlık alım programları) ile faiz oranlarında gözlenen genel paralel kaymaları temsil etmektedir. Alttaki Score 1 grafiği, bu bileşenin zaman serisi boyunca önemli dalgalanmalar yaşadığını göstermektedir. Özellikle 2008 Küresel Finans Krizi veya Euro Bölgesi borç krizi gibi dönemlerde, getiri seviyesinde kayda değer dalgalanma gözlemlenmektedir.

İkinci temel bileşen (PC2), kısa ve uzun vadeler arasında zıt yönlü etkileşimler göstererek “eğim (slope) faktörü”nü temsil eder. Söz konusu bileşenin üst paneldeki fonksiyon şekli, kısa vadelerde pozitif değerlere sahipken uzun vadelere doğru negatif değerlere gerilemektedir. Bu eğim bileşenin zaman serisi (Score 2), AMB’nin politika faizi değişikliklerinin ve piyasanın gelecekteki faiz beklentilerinin getiri eğrisine nasıl yansıdığını takip etmeye olanak tanır. Örneğin, deflasyon riskinin yoğunlaştığı dönemlerde uzun vadeli faiz oranlarının düşmesi, dolayısıyla eğrinin yataylaşması veya tersine dönme eğilimi sergilemesi, söz konusu bileşenin skorunda ani sıçramalara yol açabilir.

Üçüncü temel bileşen (PC3) ise getiri eğrisinin “kavrama (curvature) faktörü” olarak adlandırılan yapısını açığa çıkarır. Grafikte, kısa ve uzun vadeler arasında farklı davranışlar sergilemekle birlikte orta vadelerde zıt bir hareketi yansıttığı görülmektedir. Bu bileşen, özellikle orta vade getirilerinde oluşan geçici “şişme” ya da “çukur” durumlarını karakterize eder. Score 3 grafiğindeki dalgalanmalar, Euro Bölgesi piyasasındaki anlık oynaklıklar, sürpriz makroekonomik veriler veya AMB’nin beklenmedik politika hamleleri gibi etkenlere bağlı olarak ortaya çıkan geçici şokların getiri eğrisi üzerindeki etkisini görünür kılmaktadır.

Sonuç olarak, Şekil 3.33’teki fonksiyonel temel bileşen analizi, AMB tahvil getirilerindeki ana varyasyon kaynaklarını “seviye, eğim ve kavrama” bileşenleri

etrafında özetlemekte ve Avrupa tahvil piyasasının temel yönlendiricilerini makroekonomik gelişmelerle ilişkilendirme fırsatı sunmaktadır. Bu yaklaşım, gerek AMB'nin politika tepkilerini gerekse piyasanın ileriye dönük beklentilerini değerlendirmek adına analitik bir çerçeve sağlamaktadır. Özellikle Euro Bölgesi'nde yaşanan kriz dönemleri, enflasyon dinamikleri ve parasal gevşeme adımları gibi başlıca unsurların getiri eğrisi üzerinde ne denli etkili olduğu, FPCA sonuçları aracılığıyla bütüncül bir bakış açısıyla incelenebilmektedir.




**Şekil 3.33** AMB Verileri İçin İlk Üç Ağırlıklı Fonksiyonel Temel Bileşen ve İlgili Puanlar

Şekil 3.34, Avrupa Merkez Bankası (AMB) tahvil getirileri verilerine dayalı FPCA modelinden elde edilen artık (residual) değerlerin, zaman (yatay eksen) ve vade (derinlik eksen) boyunca nasıl dağıldığını üç boyutlu bir perspektif ile ortaya koymaktadır. Bu sunum, modelin belirli dönem veya vade dilimlerinde hatalara yatkın olup olmadığını görselleştirme bakımından önemlidir.

Öncelikle, artıkların yatay ekseninde (zaman) ve derinlik ekseninde (vadeler) genel olarak rastgele bir dağılıma sahip olması, modelin tahvil getirilerinde sistematik bir önyargı (bias) üretmediğine işaret etmektedir. Ancak belirli vade aralıklarında veya belirli zaman dilimlerinde gözlenen kümelenmeler ya da yüksek sapmalar, modele dâhil edilmemiş bir makroekonomik faktörün veya para politikası etkisinin söz konusu dönemde daha baskın olduğunu düşündürmektedir. Özellikle AMB'nin beklenmedik politika hamleleri veya Avrupa Bölgesi'nde yaşanan likidite daralmaları gibi şoklar, kısa veya uzun vadeli tahviller üzerinde farklı etkilere yol açabileceğinden, bu etki artık değerlerinde yoğunlaşarak gözlemlenebilir.

Zaman eksenini boyunca ani sıçramalar ya da belirli periyotlarda artan oynaklık, piyasanın kriz dönemlerine veya makroekonomik belirsizliklere verdiği tepkinin model tarafından tam olarak açıklanamadığını gösterebilir. Bu durum, FPCA yaklaşımına ek olarak dinamik faktör modelleri veya rejim değişimlerini dikkate alan yöntemlerle desteklenmesi gereğine işaret etmektedir. Ayrıca, özellikle negatif faiz politikalarının uygulandığı ve parasal gevşemenin yoğunlaştığı dönemlerde gözlenen beklenmedik volatiliteler, modelin varsaydığı durağanlık koşullarından sapmayı yansıtabileceği gibi, piyasa koşullarında kısa süreli ama derin dalgalanmalar olduğuna da işaret edebilir.

Son olarak, Şekil 3.34'teki artık değerlerinin dikkatli bir şekilde incelenmesi, AMB tahvil getirileri modelinin performansına dair kapsamlı bir geribildirim mekanizması sunmaktadır. Modelin iyi çalıştığı vade veya zaman dilimlerinde artıklar düşük ve rastgele dağılırken, zayıf olduğu alanlarda sistematik bir örüntü veya yoğunlaşma gözlenmektedir. Bu gözlemler, hem modelin iyileştirilmesi hem de AMB'nin para politikası kararlarının piyasalardaki yansımalarını daha iyi anlamak açısından değerli bir referans niteliği taşımaktadır.



**Şekil 3.34** AMB Tahvil Getirileri için FPCA Modelinin Zaman İçinde Vadeye Göre Artık Değerleri

Şekil 3.35, Türkiye tahvil getirileri verilerine dayalı olarak uygulanan fonksiyonel temel bileşen analizinin (FPCA) sonuçlarını, hem vade ekseninde üzerindeki eğrilerin fonksiyon biçimleri (üst sıra) hem de bileşenlerin zaman boyunca nasıl değiştiğini gösteren skor grafikleri (alt sıra) üzerinden kapsamlı bir şekilde sunmaktadır. Üstteki ilk paneldeki ortalama getiri eğrisi, kısa vadelerden orta vadeye doğru yükselen, ardından uzun vadede gerileyen “tepe yapma” (hump) biçiminde bir profil ortaya koymaktadır. Bu durum, Türkiye’nin makroekonomik dinamikleri ile piyasa beklentilerinin bir yansıması olarak yorumlanabilir. Özellikle yüksek enflasyon riski ve dalgalı para politikası koşulları altında, yatırımcıların orta vadede daha yüksek getiri talep etmesi, uzun vadede ise görece daha belirsiz bir tablo oluşması söz konusu olmaktadır.

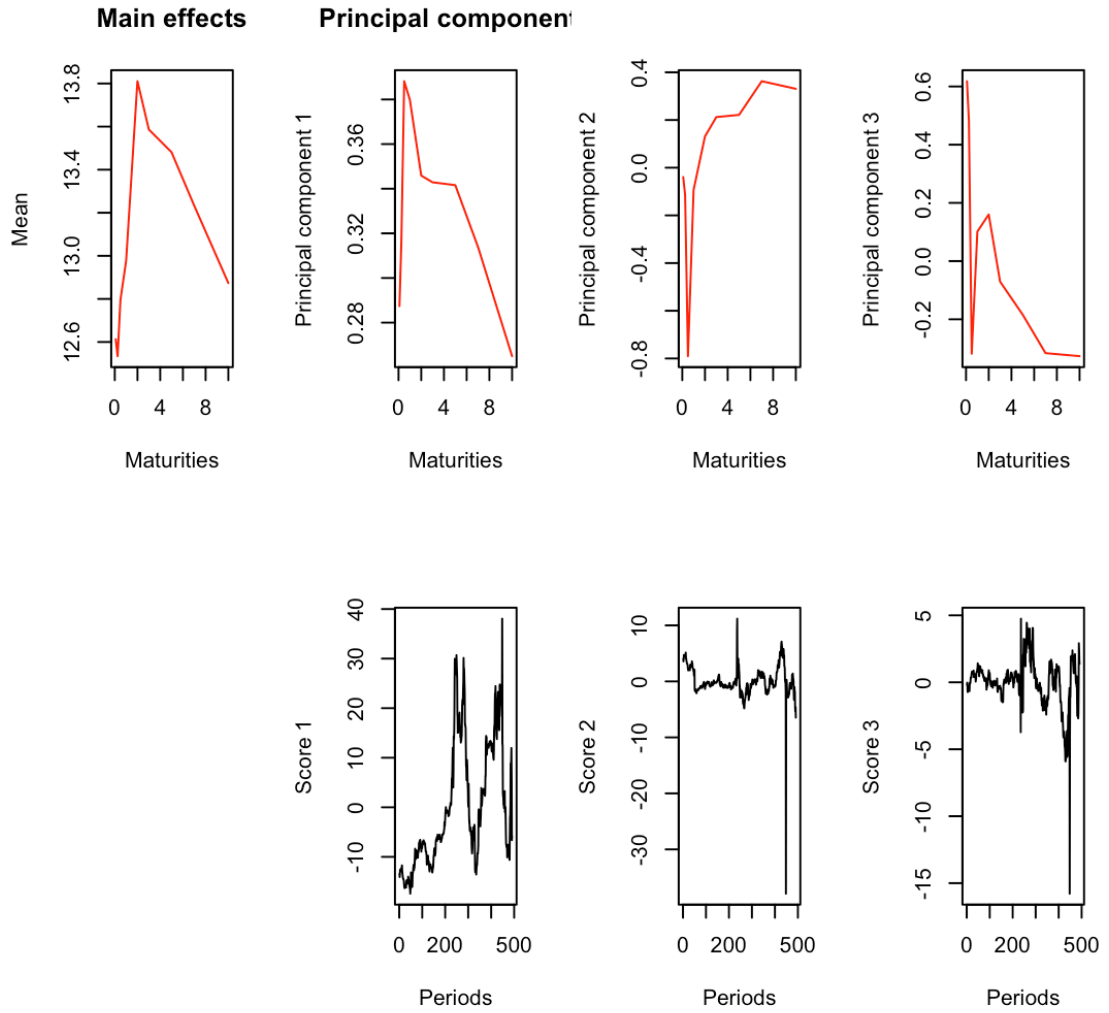
Birinci temel bileşen (PC1), kısa ve orta vadelerde daha kuvvetli, uzun vadede ise görece olarak düşük seyreden bir yapı sergileyerek “seviye (level) faktörü”nü temsil etmektedir. Bu faktör, politika faizlerinde veya küresel risk algısında meydana gelen geniş çaplı değişikliklerin tüm vadeleri aynı yönde etkilemesi sonucunda ortaya çıkan paralel kaymaları açıklamaktadır. İkinci temel bileşen (PC2), kısa vadelerde negatif, uzun vadelerde pozitif değerlere yönelerek “eğim (slope) faktörü”nü tanımlamaktadır. Enflasyon

beklentileri ve Merkez Bankası'nın gelecek dönemdeki faiz patikasına ilişkin öngörüler, kısa ve uzun vadeli tahviller arasındaki faiz farkını şekillendirerek bu bileşende belirgin dalgalanmalara yol açmaktadır. Üçüncü temel bileşen (PC3), "kavrama (curvature) faktörü" olarak isimlendirilen, özellikle orta vadeli tahvillerde ortaya çıkan göreceli hareketleri yansıtmaktadır. Ani siyasi veya ekonomik gelişmelerin orta vadede tahvil talebini hızla artırıp azaltması bu faktörün önemini vurgulamaktadır.

Alt sırada yer alan zaman serisi skor grafikleri, söz konusu bileşenlerin belirli dönemlerde ne ölçüde dalgalandığını ortaya koyarak, Türkiye tahvil piyasasının kırılma düzeyine ve para politikasının öngörülebilirliğine dair ipuçları sunmaktadır. Özellikle Score 1'de gözlemlenen büyük dalgalanmalar, beklenmedik faiz kararlarının veya önemli piyasa şoklarının tüm vadelerde aynı yönde ve benzer büyüklükte fiyat hareketlerine yol açtığına işaret edebilir. Score 2'nin, eğimdeki sert değişimleri yakaladığı görülürken; Score 3, orta vadeye özgü risk algısı ve talep oynaklığı nedeniyle zaman zaman keskin sıçramalar sergileyebilmektedir. Dolayısıyla, FPCA yaklaşımı hem getiri eğrisinin temel faktörlerini ayırtmakta hem de piyasa beklentilerinin ve ekonomik yönelimlerin zaman içindeki evrimini anlaşılır kılmaktadır. Bu çerçevede, Türkiye gibi gelişmekte olan ülkelerdeki getiri eğrisi hareketlerini değerlendirirken, enflasyon baskıları, kur oynaklığı ve siyasi gelişmeler gibi temel makroekonomik etkenlerin kritik önem taşıdığı bir kez daha ortaya çıkmaktadır.

Bu grafik, Türkiye tahvil getirileri verilerine uygulanan fonksiyonel temel bileşen analizinin sonuçlarını detaylı bir şekilde sunmaktadır. Ortalama getirilerin vadeye göre artan ve ardından azalan bir eğilim göstermesi, orta vadeli tahvillerin genellikle daha yüksek getiri sunduğunu ortaya koyar. Birinci, ikinci ve üçüncü fonksiyonel temel bileşenler, getiriler eğrisinin düzeyini, eğimini ve eğriliğini temsil ederek, getiriler eğrisinin farklı dinamiklerini açıklar. Bu bileşenlere karşılık gelen puanlar ise zaman içindeki değişimleri ve bu değişimlerin ekonomik olaylarla ilişkisini göstermektedir. Bu tür analizler, getiriler eğrisinin yapısını ve dinamiklerini anlamak için kritik öneme sahiptir ve yatırım stratejileri ile risk yönetiminde önemli bilgiler sağlar. Modelin dönemsel ve vadeye göre performansını değerlendirmek, gelecekteki ekonomik tahminler ve finansal kararlar için önemli bir temel oluşturur.





**Şekil 3.35** Türkiye Tahvil Verileri İçin İlk Üç Ağırlıklı Fonksiyonel Temel Bileşen ve İlgili Puanlar

Şekil 3.36, Türkiye tahvil getirileri modelinden elde edilen artık (residual) değerlerin, zaman (yatay eksen) ve vade (derinlik eksen) boyunca ne şekilde dağıldığını üç boyutlu bir perspektifte göstermektedir. Bu artık değerlerin düzenli bir bant içinde seyretmesi, modelin tahmin performansının istikrarlı olduğunu ve tahvil piyasasındaki dalgalanmaların ana hatlarını başarıyla yakaladığını düşündürür. Ancak belirli dönemlerde veya belirli vadelerde gözlemlenen ani sıçramalar, modelin yetersiz kaldığı veya piyasada “beklenmedik” gelişmelerin yaşandığı noktaları ortaya koyar.

Öncelikle, kısa vadelerdeki yüksek artık değer kümelenmeleri, genellikle Merkez Bankası'nın (TCMB) politika faizinde ani veya öngörülemeyen değişiklikler yaptığı ya da likidite koşullarının hızla dalgalandığı dönemlerde gözlemlenir. Örneğin, kur oynaklığının yüksek seyrettiği, enflasyon beklentilerinin süratle yukarı yönlü revize

edildiği veya TCMB'nin örtülü sıkılaştırma gibi standart dışı araçlara başvurduğu zamanlarda, getiri eğrisinin kısa ucu modele tahmin zorlukları yaşatabilir. Bu durum, artık değerlerde ani sıçrama ya da kümelenmelere yol açarak grafik üzerinde net şekilde görülebilir.


Orta vadelerdeki artık desenleri, Türkiye'de sıklıkla politika belirsizliği ile makroekonomik görünümün bir araya geldiği, enflasyonist baskıların henüz kalıcı olup olmadığının tam anlaşılmadığı veya yatırımcıların risk algısındaki ani değişimlerin (örneğin uluslararası kredi derecelendirme kuruluşlarından gelen not indirimleri) yaşandığı dönemlerde belirginleşebilir. Orta vadeli tahviller, kısa vadeye göre biraz daha yüksek getiri sunsa da uzun vadeye kıyasla daha fazla belirsizliğe maruz kalır. Dolayısıyla piyasanın risk priminin aniden değişmesi, bu vadelerde modelin öngörü gücünü zorlayarak artık değerlerin yükselmesine neden olabilir.

Uzun vadelerdeki artık değer artışları ise daha çok yapısal meselelerin (örneğin sürdürülebilir büyüme, cari açık, siyasi riskler, küresel finansman koşulları) ve uzun döneme yayılan beklentilerin (enflasyon hedeflemesi, kamu borç düzeyi, uluslararası yatırımcı güveni) piyasada fiyatlandığı zamanlarda ortaya çıkar. Türkiye'de, dış finansman kaynaklarına bağımlılığın artırdığı kırılganlık veya küresel piyasalarda likidite koşullarının ani sıkılaşması (örneğin gelişmiş ülke merkez bankalarının faiz artırması) uzun vadeli tahvil getirilerinde öngörülemeyen hareketlere yol açarak artık değerleri bir anda yükseltebilir.

Ayrıca, zaman eksenindeki periyotlarda öne çıkan yoğun artık değer kümelenmelerine bakıldığında, bu artışların sıklıkla önemli makroekonomik veya siyasi dönüm noktalarıyla kesiştiği görülür. Örneğin, ani bir siyasi gerginlik, beklenmeyen seçim sonuçları veya uluslararası yaptırım riski, risk priminin hızlı şekilde yükselmesine neden olarak tüm vade yapısında tahvil getirilerini etkiler. Benzer şekilde, kur krizleri veya yabancı yatırımcıların çıkış eğilimi, tahvillerin fiyatlamasında öngörülmeyen dalgalanmalara yol açarak modelin artık değerlerini belirgin şekilde artırabilir.

Sonuç olarak, Şekil 3.36'daki artık değer dağılımı, Türkiye tahvil piyasasında model tarafından yakalanamayan veya modele dâhil edilmemiş faktörlerin hangi dönemde ve hangi vade diliminde daha baskın olduğunu görsel olarak yansıtmaktadır.

Türkiye gibi gelişmekte olan ekonomilerde, faiz politikası, enflasyon beklentileri, kur oynaklığı ve dış finansman koşulları başta olmak üzere pek çok faktörün ani değişimi, getiri eğrisinin farklı segmentlerinde beklenmedik oynaklıklar doğurabilmektedir. Bu nedenle, elde edilen artık analizleri sadece modelin eksik veya iyileştirmeye açık yönlerini göstermekle kalmaz, aynı zamanda makroekonomik istikrar ve piyasa güveni açısından da hangi alanlarda dikkatli olunması gerektiğine dair önemli ipuçları sunar.




**Şekil 3.36** Türkiye Tahvil Getirileri Modelinin Zaman İçinde Vadeye Göre Artık Değerleri

Şekil 3.37, FPCA modeliyle gerçekleştirilen çok adımlı tahminlerde (1 ay, 3 ay ve 6 ay), farklı pencere boyutlarının (örneğin tahmin modelinin her seferinde ne kadar geçmiş veriyle güncellendiğinin) RMSE üzerindeki etkisini üç ayrı panelde sunmaktadır. Grafikte ABD (siyah kesik çizgi), AMB (mavi düz çizgi) ve Türkiye (kırmızı noktalı çizgi) için ilgili tahmin ufukları boyunca elde edilen hata değerleri gözlenmektedir. Yatay ekseninde kullanılan eğitim verisi (örneğin 150'den 250'ye kadar artan örnek sayısı) arttıkça, modelin parametre tahminlerindeki güncellenme biçimi değişmekte ve bu durum nihai tahmin doğruluğunu farklı şekillerde etkilemektedir.

İlk bakışta, Türkiye verilerinin (kırmızı çizgi) tüm tahmin ufuklarında görece daha yüksek bir RMSE düzeyine sahip olduğu görülmektedir. Bu durum, Türkiye tahvil piyasasının diğer piyasalara kıyasla daha volatil bir yapıda olduğunu ve tahvil getirilerinin hem iç hem de dış şoklara karşı daha hassas tepki verdiğini göstermektedir. Türkiye ekonomisindeki yüksek enflasyon, dalgalı kur koşulları ve para politikasında beklenmedik yön değişiklikleri, modelin çok adımlı tahminlerinde büyük sapmalara yol açabilmektedir. Ayrıca, pencere boyutu büyüdükçe (yani daha uzun bir geçmişe dayalı tahmin yapıldıkça), Türkiye için RMSE değerlerinin bir miktar artış veya dalgalanma eğilimi sergilediği dikkat çekmektedir. Bu, geçmiş dönem verilerinin yapısal kırılmaları yeterince yansıtmaması veya piyasadaki rejim değişimlerini “daha büyük” pencere kullanarak yakalamanın zorlaşmasıyla ilişkilendirilebilir.

Öte yandan, ABD (siyah çizgi) ve AMB (mavi çizgi) verileri için RMSE düzeyleri oldukça düşük seyretmekte; farklı pencere boyutları arasında belirgin bir sıçrama gözlenmemektedir. Göreli olarak istikrarlı makroekonomik koşullar, öngörülebilir para politikaları ve piyasa derinliği, FPCA tabanlı tahmin modelinin çok adımlı projeksiyonlarda dahi görece yüksek bir doğrulukla sonuçlanmasına imkân tanımaktadır. Kısa vadeli tahmin ufunda (1 adım) her üç piyasa için de tahmin hatalarının daha düşük olduğu, fakat ufuk uzadıkça (3 ve 6 adım) hata seviyelerinin arttığı görülmektedir. Bu beklenen bir durumdur; zira ileriye dönük öngörüler ne kadar uzun tutulursa model belirsizliği, özellikle de ekonomik ve politik şokların etkisi, o kadar yükselmektedir.

Sonuç olarak, Şekil 3.37’deki bulgular, pencere boyutunun ve tahmin ufkunun FPCA ile yapılan çok adımlı tahminler üzerindeki kritik etkisini açıkça ortaya koymaktadır. Gelişmiş piyasalarda (ABD, AMB) pencere boyutunu artırmanın tahmin performansını sınırlı oranda etkilemesi, ekonomik istikrar ve veri yapısındaki az sayıda kırılma ile ilişkili görünmektedir. Buna karşılık, Türkiye gibi dalgalanmaların sık ve büyük olduğu ekonomilerde, pencere boyutunu ayarlamak tahmin performansında önemli değişiklikler doğurabilmektedir. Uzun bir geçmiş verisi, yapısal kırılmaları “ortalamaya” alarak model performansını zayıflatabilirken; çok kısa pencere kullanımı da yeterli istatistiksel bilginin toplanamamasına yol açabilir. Bu nedenle, modelleme aşamasında ülkeye özgü piyasa dinamiklerinin ve olası rejim değişimlerinin dikkate alınması, daha sağlıklı çok adımlı tahminler elde etmek açısından hayati önem taşımaktadır.



**Şekil 3.37** FPCA Modeli ile Tahmin: Pencere Boyutunun RMSE Üzerindeki Etkisi

Şekil 3.38, FPCA modelini kullanarak yapılan çoklu adım ilerisi tahminlerinin (1 ay, 3 ay ve 6 ay ufukları) kök-ortalama-kare hatası (RMSE) değerlerini kutu grafikleri halinde sunmaktadır. Bu şekilde, her bir tahmin ufku için ABD, AMB (Avrupa Merkez Bankası) ve Türkiye verilerinden elde edilen tahmin hatalarının dağılımı karşılaştırmalı olarak incelenebilmektedir.

İlk bakışta, Türkiye verilerinin (kutuların üstte konumlanması) her üç tahmin ufkunda da görece yüksek RMSE değerlerine sahip olduğu görülmektedir. Bu sonuç, Türkiye tahvil piyasasındaki dalgalanmanın diğer piyasalara göre daha belirgin olduğunu ve getiri eğrisinde öngörülmesi zor kırılmaların sıkça yaşandığını yansıtmaktadır. Yüksek enflasyon beklentileri, kur oynaklığı ve para politikasında beklenmedik yön değişiklikleri, orta ve uzun vadeli tahvil getirilerinde modelin tahmin doğruluğunu olumsuz etkileyerek hata payını artırabilmektedir.


Buna karşılık, ABD ve AMB verileri (altta konumlanan kutular) oldukça düşük RMSE seviyelerinde gözlemlenmektedir. Gelişmiş piyasalarda kurumsal yapının oturmuş olması, para politikasındaki öngörülebilirlik ve piyasanın derinliği, FPCA modelinin çok adımlı tahminlerinde bile istikrarlı sonuçlar elde edilmesini kolaylaştırmaktadır. Özellikle 1 ay (kısa vadeli) tahminler için ABD ve AMB'nin RMSE değerleri çok düşük seyrederek modelin bu ufuklarda son derece başarılı bir performans sergilediğini işaret etmektedir.

Tahmin ufku uzadıkça (3 ay ve 6 ay), tüm verisetlerinde RMSE değerlerinin artış eğiliminde olduğu göze çarpmaktadır. Bu durum, daha uzun döneme dönük tahminlerin genel olarak belirsizliği artırmasından kaynaklanır: Ekonomik, politik ve küresel gelişmelerin etkisi zamanla birikerek daha yüksek tahmin hatalarına yol açmaktadır. Bu

etki, Türkiye örneğinde daha keskin bir şekilde ortaya çıkmakla birlikte, ABD ve AMB verileri de ufuk uzadıkça sınırlı da olsa artan hata değerleri göstermektedir.

Kutu grafikleri özelinde, kutu içi (IQR) genişliği ve uç değerlerin (outliers) konumu da önem taşımaktadır. Türkiye verisi için kutu yüksekliği ve uç değerlerin konumu, tahmin hatasındaki değişkenliğin (yani tutarlılığın daha düşük, tahmin performansının daha oynak) olduğunu ortaya koymaktadır. ABD ve AMB için ise kutular daha dar bir aralıkta kalmakta, uç değer sayısı da görece azalmaktadır. Bu da, söz konusu piyasalarda FPCA modeliyle yapılan tahminlerin yalnızca ortalama anlamda değil, dağılımın tümü göz önüne alındığında da daha stabil sonuçlar verdiğini göstermektedir.

Özetle, Şekil 3.38 bize kısa ve orta vadede (1 ay ve 3 ay) FPCA modelinin gelişmiş piyasalarda oldukça düşük hatayla tahmin yapabildiğini; Türkiye’de ise gerek piyasa oynaklığı gerekse makroekonomik kırılmalıklar nedeniyle hataların daha yüksek ve değişken olduğunu işaret etmektedir. Tahmin ufku 6 aya uzadığında, belirsizlik ve oynaklığın artmasıyla birlikte her üç veri setinde de RMSE değerleri yükselse de, söz konusu artış Türkiye’de daha belirgin düzeydedir. Bu sonuçlar, FPCA modelinin farklı piyasalardaki performansını değerlendirirken, ülkeye özgü dinamiklerin ve yapısal kırılmaların önemini vurgulamaktadır.



**Şekil 3.38** Çoklu Adım İlerisi Tahmin için FPCA Modeli Kullanan RMSE Kutu Grafiklerinin Karşılaştırması: h = 1, h = 3 ve h = 6 için 250 ila 350 Eğitim Periyodu ile Gerçekleştirilen Tahminler

### 3.11. Makine Öğrenmesi

Makine öğrenmesi (ML), bilgisayar sistemlerinin veri analizi ve desen tanıma gibi görevleri yerine getirmek için istatistiksel teknikler kullanarak öğrenme yeteneğini ifade

eder. ML algoritmaları, büyük ve karmaşık veri setlerinden anlamlı bilgileri çıkarabilir ve bu bilgileri gelecekteki olayları tahmin etmek veya veri içindeki gizli kalıpları keşfetmek için kullanabilir (Bishop, 2006; Murphy, 2012). Makine öğreniminin kullanımı, diğerlerinin yanı sıra sağlık hizmetleri, malzeme bilimi, onkoloji ve finans gibi alanlarda etkili olmuştur (Mei vd., 2021; Tseng vd., 2018; Chen vd., 2018; Bektaş vd., 2022).

Makine öğrenmesinin yetenekleri, finansal piyasalar gibi karmaşık ve dinamik sistemlerde özellikle değerlidir. Birçok çalışma, finansal tahminlerde makine öğreniminin geleneksel ekonometrik modellere göre avantajlarını vurgulamıştır. Örneğin, makine öğrenimi tekniklerinin zımnî volatilité tahmininde ana akım ekonometrik modellere kıyasla daha etkili olduğu bulunmuştur (Vrontos vd., 2021). Ayrıca, makine öğrenimi, ekonomide tahmin ve tahmin için gelişmiş araçlar sunmakta ve klasik finansal problemler için birkaç büyüklük derecesinde hızlanma sağlamaktadır (Spiegeleer vd., 2018).

Kanada Bankası'nın 2023-16 analitik notu (Desai, 2023) dijital çağda ekonomik verilerin artan boyutu ve karmaşıklığı nedeniyle ekonomi araştırmalarında makine öğrenmesinin (ML) çeşitli veri setlerini işleyerek ekonomik olaylar hakkında bilgi edinme fırsatları ve zorlukları sunmaktadır. Ekonomide ML'nin uygulanmasını, geleneksel olmayan verileri işlemeyi, doğrusal olmayan ilişkileri yakalamayı ve geleneksel verilerle tahmin doğruluğunu artırmayı kapsamaktadır. Ayrıca, ML'nin karmaşık veri yapılarını keşfetmedeki başarısı ile ML yöntemlerinin büyük veri ortamlarında özellikle etkili olduğunu öne sürmektedir.

Gaussian Process (GP), fonksiyonların olasılıksal bir şekilde modellenmesini sağlayan güçlü bir makine öğrenmesi yöntemidir. GP, doğrusal olmayan ilişkileri modelleyebilme yeteneği ve tahmin belirsizliklerini değerlendirebilmesi sayesinde finansal tahminlerde büyük avantajlar sunar (Rasmussen & Williams, 2006).

Bu bölümün amacı, Gaussian Process yönteminin getiri eğrisi tahminindeki etkinliğini değerlendirmek ve bu yöntemin diğer yöntemlerle karşılaştırmasını yapmaktır. Çalışmanın kapsamı, makine öğrenmesi ve finansal analizler alanındaki literatüre katkıda bulunmayı hedeflemektedir.

İlk bölümde, literatürde yer alan benzer çalışmalar gözden geçirilecek ve bu çalışmanın literatüre nasıl katkıda bulunacağı tartışılacaktır. İkinci bölümde getiri eğrisi ve finansal piyasalar için önemi hakkında genel bir bilgi verilecek ve Gaussian Process'in temel prensipleri açıklanacaktır. Üçüncü bölümde, çalışmada kullanılan veri setleri ve yöntemler detaylandırılacak, elde edilen sonuçlar değerlendirilecektir.

### 3.11.1 Literatür

Makine öğrenimi teknikleri, finansal verilerdeki karmaşık kalıpları ve bağımlılıkları yakalayarak geleneksel parametrik modellere göre iyileştirmeler sunan getiri eğrisi tahminine giderek daha fazla uygulanmaktadır. Gogas vd. (2015), getiri eğrisine dayalı olarak GSYH döngülerini tahmin etmek için Destek Vektör Makinelerinin (SVM) ikili sınıflandırıcı olarak uygulanmasına odaklanmaktadır. Çalışmada, 1976'dan 2011'e kadar reel GSYH ile kısa ve uzun vadeli faiz oranlarından elde edilen veriler kullanılmıştır. SVM modeli %66,7'lik bir genel tahmin doğruluğu ve durgunlukların tahmininde %100 doğruluk elde etmiştir. Çalışma, SVM modelini alternatif standart logit ve probit modelleriyle karşılaştırarak orijinal modelin önemini ortaya koymaktadır. Bulgular, SVM modelinin tahmin doğruluğunda klasik ekonometrik yöntemlerden daha iyi performans gösterdiğini ve politika yapıcılara durgunlukların etkisini en aza indirmek için mali ve parasal politikaları ayarlamaları için değerli bilgiler sağladığını göstermektedir.

Shah & Debnath (2017), getiri farkı tahmini için ayrık dalgacık dönüşümlerini (DWT'ler) ve yapay sinir ağlarını (YSA'lar) birleştiren hibrit bir yöntem önermektedir. Bu yaklaşım, getiri farklarını bileşen serilerine ayrıştırarak, gürültüyü gidererek ve baskın dalgacık bileşenlerini YSA modelleri için girdi olarak kullanarak finansal zaman serilerindeki durağan olmayan doğrusal olmayan özellikleri etkili bir şekilde yakalamaktadır. Sonuçlar, getiri eğrisinin kısa ucundaki ve politika ile ilgili bölgelerindeki getiri farklarının çıktı büyümesi için tahmin gücüne sahip olduğunu, uzun ucundakilerin ise olmadığını göstermektedir.

Sambasivan ve Das (2017), getiri eğrisi tahmini için dinamik Gaussian Process (GP) modelinin, özellikle orta ve uzun vadeli yapılar için, diğer yaygın kullanılan yöntemlere göre daha iyi performans gösterebileceği belirtilmektedir. Bu çalışma, çoklu değişkenli zaman serisi yönteminin kısa vadeli yapılar için, dinamik GP yönteminin ise orta



ve uzun vadeli yapılar için daha iyi performans gösterdiğini göstermektedir. Ayrıca, dinamik GP yöntemi, orta ve uzun vadeli yapılar için en düşük hata oranlarına sahiptir. Bu sonuçlar, finansal alandaki tahmin problemlerinde dinamik GP modelinin kullanılabilirliğini ve diğer alanlara da uyarlanabileceğini göstermektedir. Önerilen dinamik GP modelinin, talep tahminlerinde, elektrik talebi tahminlerinde ve diğer uygulama alanlarında kullanılabilmesi belirtilmektedir. Bu çalışma, getiri eğrisi tahmini için dinamik GP modelinin, özellikle orta ve uzun vadeli yapılar için, diğer yaygın kullanılan yöntemlere göre daha iyi performans gösterebileceğini göstermektedir.

Gerhart vd. (2018), Keras'ta uygulanan derin bir uzun kısa vadeli bellek (LSTM) sinir ağı kullanarak getiri eğrilerini tahmin etmek için sağlam yöntemleri tartışmaktadır. Piyasa derinliğini modellemek için alış-satış spreadlerini de içeren 2005-2018 yıllarına ait bootstrapped alış, orta ve satış getiri eğrilerini kullanmaktadır. Sınırlı veri kullanılabilirliğini ele almak için yazarlar, uygun zaman serisi modelleri aracılığıyla ek eğitim verileri üretmektedir. Ayrıca, gelecekteki getirilerle ilgili çeşitli piyasa değişkenlerini dahil ederek vade yapılarındaki eğilimleri tahmin etmek için destek vektör makineleri kullanılmaktadır.

Nunes vd. (2019), yapay sinir ağları, özellikle de çok katmanlı algılayıcı (MLP) ve çok değişkenli doğrusal regresyon kullanarak getiri eğrisi tahmini üzerine kapsamlı bir çalışma sunmaktadır. Beş tahmin ufkunda beş MLP varyantını değerlendirmekte ve en ilgili özelliklere sahip MLP'nin en iyi sonuçları verdiğini ortaya koymaktadır. Ayrıca, sentetik verilerin dahil edilmesi doğruluğu artırmaktadır. Çalışma aynı zamanda çok görevli öğrenme metodolojilerini de araştırmaktadır, ancak bunlar arasında net bir fark bulunamamıştır. Genel olarak, bulgular sabit gelirli piyasalar için gelişmiş tahmin sistemlerinin geliştirilmesini teşvik etmektedir.

Puglia ve Tucker (2020), Hazine vade farklarını ve diğer finansal ve makroekonomik değişkenleri kullanarak ABD resesyonlarını tahmin etmek için Rastgele Orman, XGBoost ve sinir ağları dahil olmak üzere makine öğrenimi yöntemlerinin kullanımını araştırmaktadır. Yazarlar, geleneksel probit regresyonun standart olmasına rağmen, probit regresyonun bu bağlamda makine öğrenimi yöntemlerinden daha iyi performans gösterebileceğini ortaya koyan yeni bir çapraz doğrulama stratejisi

önermektedir. Çalışma, getiri eğrisi tahmininde özellik seçimi ve model değerlendirme tekniklerinin önemini vurgulamaktadır.

Castello ve Resta (2022), BRICS ülkelerinin getiri eğrisini modellemek için parametrik ve makine öğrenmesi tekniklerini karşılaştırmaktadır. Parametrik model olarak De Rezende–Ferreira beş faktörlü modeli (5F-DRF) ve makine öğrenimi tekniği olarak Yapay Sinir Ağları (YSA) kullanılmıştır. Çalışmanın temel katkıları, BRICS ülkelerinin tahvil piyasasının kapsamlı bir incelemesi ve getiri eğrisinin modellenmesi için önerilerde bulunmasıdır. Bulgular, YSA'nın tüm incelenen pazarlarda istatistiksel olarak daha iyi uyum sağladığını göstermektedir. Parametrik modelin, pazarın yüksek dalgalanma dönemlerinde hala bazı kısıtlamaları olduğu ortaya konmuştur. FFNN, özellikle ani dalgalanmaların olduğu durumlarda daha düşük hata değerleri üretmektedir. Bu nedenle, çalışma BRICS ülkelerinde getiri eğrisinin modellenmesi için FFNN'nin daha uygun bir seçenek olduğunu göstermektedir.

Bluwstein vd. (2023), finansal krizleri tahmin etmek için makine öğrenimi modellerinin kullanımını tartışmaktadır. Karar ağaçları, rastgele ormanlar, sinir ağları ve destek vektör makineleri gibi çeşitli modellerin performansını lojistik regresyon ile karşılaştırmaktadır. Çalışma, makine öğrenimi modellerinin finansal krizleri tahmin etmede genellikle lojistik regresyondan daha iyi performans gösterdiğini ortaya koymaktadır. Analiz ayrıca küresel kredi büyümesinin ve getiri eğrisinin finansal krizlerin öngörülmesindeki önemini vurgulamaktadır. Çalışma, makine öğrenimi modellerinin önemli doğrusal olmayan durumları ve etkileşimleri ortaya çıkarabileceği ve ekonomi politikası yapımı için değerli iç görüler sağlayabileceği sonucuna varmaktadır.

Cao (2023), geleneksel istatistiksel modellerin yanı sıra makine öğrenimi modellerini kullanarak Çin'in devlet tahvili getiri eğrisini tahmin etmenin uygulanabilirliğini göstermektedir. Getiri eğrisini etkileyen faktörleri analiz etmek için 182 özellik oluşturmakta ve tahminler için DNS ve makine öğrenimi gibi modeller kullanmaktadır. Ampirik analiz, makine öğrenimi modellerinin DNS modeli ile birlikte getiri eğrisi tahmini için etkili bir çerçeve oluşturduğunu ve sonuçta bulgularına dayanarak yeni bir çerçeve önerdiğini göstermektedir.

Castello ve Resta (2023), doğal gaz vadeli işlem piyasasındaki vade yapısı dinamiklerini inceleyerek, BRICS ülkelerinin getiri eğrisini modellemek için İleri Beslemeli Sinir Ağlarının (FFNN) parametrik De Rezende-Ferreira modeline kıyasla üstün örneklem içi uyum yeteneklerini vurgulamaktadır. FFNN'ler getiri eğrisi dinamiklerini etkin bir şekilde kopyalamakta, önceden belirsizliği yönetmekte ve piyasa şoklarına uyum sağlamakta, bu da onları getiri eğrisi tahmini için umut verici bir araç haline getirmektedir. Gelecekteki araştırmalar, örneklem dışı performansı karşılaştırarak ve 5F-DRF modelinde zamanla değişen parametrelerin tahminini araştırarak bu bulguları genişletmeyi amaçlamaktadır. Elde edilen sonuçlar, enerji politikalarının belirlenmesinde ve piyasa oynaklığına karşı korunmada değerli içgörüler sunmaktadır.

Richman ve Scognamiglio (2024), birden fazla getiri eğrisinin dinamiklerini yakalayıp getiri eğrisi tahmini için derin öğrenme modellerinin kullanılmasını tartışmaktadır. Kantil geçiş sorunlarını ele alırken doğru nokta ve aralık tahminleri üretmek için parametrik olmayan kantil regresyon ile birleştirilmiş bir öz dikkat mekanizması kullanmaktadır. Yaklaşım, küresel finans piyasalarından etkilenen getiri eğrilerinin karşılıklı bağımlılığından yararlanmakta ve çeşitli veri kümeleri üzerinde yapılan sayısal deneylerle etkinliğini göstermektedir. Ayrıca, derin topluluk yöntemleri ve transfer öğrenme yoluyla potansiyel geliştirmeler önermektedir.

Bie vd. (2024), dinamik Nelson-Siegel modeli ile entegre edilmiş ağaç tabanlı bir makroekonomik rejim değiştirme yaklaşımı kullanarak getiri eğrisinin tahminini araştırmaktadır. Bir ağaç büyütme algoritmasını özelleştirerek, makroekonomik değişkenlere dayalı olarak getiri eğrisindeki rejim değiştirme modellerini tanımlamaktadır. Ampirik çalışma, makroekonomik faktörlerin özellikle kısa faiz oranı yüksek olduğunda getiri eğrisi için tahmin gücüne sahip olduğunu ve geleneksel modellere kıyasla getiri eğrisi dinamiklerinin anlaşılmasını geliştirdiğini ortaya koymaktadır.

Akiyama ve Matsuyama (2024), özellikle uzun kısa vadeli bellek mimarisini kullanan makine öğrenimini kullanarak getiri eğrisi ekstrapolasyonu için yeni bir yöntem önermektedir. Bu yaklaşım, tamamen veriye dayalı getiri eğrisi tahminini mümkün kılmakta ve geleneksel basit parametrik modellere kıyasla gelişmiş genelleme performansı, kararlılık ve gözlemlenen getiri eğrisi dinamikleriyle tutarlılık göstermektedir. Bulgular, daha önce mortalite tahmininde kullanılan sinir ağlarının, daha az parametre ile

gözlemlenen getiri eğrilerini temsil etmedeki sınırlamaları ele alarak getiri eğrisi ekstrapolasyonunu etkili bir şekilde geliştirebileceğini göstermektedir.

### 3.11.2. Gauss Süreç Modelleri

Gauss süreç modelleri, özellikle regresyon ve sınıflandırma görevlerinde makine öğrenimi ve istatistik alanlarında önemli bir yer tutmaktadır. Bu modeller, parametrik olmayan yapıları ve Bayes çıkarımına dayalı yaklaşımlarıyla, gürültülü ve doğrusal olmayan veri ilişkilerinin modellenmesinde etkili bir araç sunar (Rios, 2020). Özellikle, hiperparametrelerin yorumlanabilirliği ve veri yapısına dayalı tahminlerin belirsizliklerini doğrudan modelleme yeteneği, Gauss süreçlerini diğer yöntemlerden ayıran kritik avantajlardır. Bu özellikler, yalnızca doğruluk odaklı değil, aynı zamanda belirsizliklerin de dikkate alındığı olasılıksal çıktılarının sağlanmasında önemlidir (Kozak vd., 2019).

Gauss süreç modelleri, belirli bir fonksiyonel forma dayanmaksızın, veriler arasındaki ilişkileri öğrenme kapasitesine sahiptir. Bu esneklik, özellikle veri dağılımının iyi tanımlanmadığı durumlarda veya veri setinin sınırlı olduğu koşullarda bu modelleri vazgeçilmez bir araç haline getirir (Rasmussen ve Williams, 2005). Örneğin, finansal piyasa verileri gibi genellikle yüksek gürültü ve belirsizlik içeren verilerde, bu modeller etkili bir çözüm sunmaktadır. Ayrıca, mühendislik uygulamalarında, örneğin sensör verilerinden doğru tahminlerin elde edilmesinde, Gauss süreçlerinin potansiyeli geniş bir yelpazeye yayılmaktadır.

Bu modellerin en önemli pratik avantajlarından biri, verilerdeki karmaşıklıkları ve gürültüyü anlamlı bir şekilde ele alabilme yetenekleridir. Gauss süreçleri, verilerdeki karmaşık örüntüleri ve bağımlılıkları yakalayarak, gözlemlerden anlamlı tahminler çıkarır ve model parametrelerinin belirsizlikleriyle birlikte tahminlerde bulunur. Bu, yalnızca tahminlerin doğruluğunu artırmakla kalmaz, aynı zamanda kullanıcıların model sonuçlarına olan güvenini de yükseltir (Rasmussen, 2004).

Ancak, Gauss süreç modelleri bazı sınırlamalara da sahiptir. En dikkat çekici kısıtlama, bu modellerin zaman karmaşıklığıdır. Geleneksel Gauss süreç algoritmalarında karmaşıklık  $O(N^3)$  düzeyindedir, bu da özellikle büyük veri setleri söz konusu olduğunda hesaplama maliyetlerini oldukça artırır (Lázaro-Gredilla vd., 2010). Bu durum, birkaç

binden fazla veri noktası ile çalışıldığında modellerin hesaplama hızını sınırlayarak uygulanabilirliği zorlaştırabilir. Ancak, son yıllarda geliştirilen indirgenmiş rütbeli yaklaşımlar, öz değer ayrışımı ve yaklaşımsal çekirdek metotları gibi yöntemler, bu sorunu kısmen çözmüş ve daha büyük veri setleri için Gauss süreçlerinin uygulanabilirliğini artırmıştır.

Genel olarak, Gauss süreç modelleri, özellikle esnekliği, belirsizlik modelleme yetenekleri ve gürültü yönetimindeki başarısı ile birçok farklı disiplin için vazgeçilmez bir araç olmayı sürdürmektedir. Ancak, bu modellerin ölçeklenebilirlik sorunlarına yönelik çözümlerin geliştirilmesi, bu yöntemlerin daha geniş bir kullanım alanına yayılmasını mümkün kılacaktır.

### 3.11.2.1 Bayesyen Tahmin

Geleneksel yöntemlerde parametre öğrenimi, bir kayıp fonksiyonunu en aza indirerek optimal bir temsili öğrenilmesini içermektedir. Bu yaklaşımlar, getiri eğrisinin fonksiyonel temsili ile ilişkili sabit ve benzersiz parametre seti olduğunu varsaymaktadır. Zıt bir metodoloji olan Bayes metodolojisi bu parametreleri farklı şekilde ele almaktadır. Bayes metodolojisinde, bilinmeyen parametrelerin parametre uzayında geçerli olasılık ölçüsü olan rastgele değişkenler olduğu varsayılır.

Bayesyen doğrusal regresyon her yeni gözlem geldiğinde parametreler üzerinde yeni bir dağılım bularak problemin çözümüne olasılıksal bir yaklaşım sağlamaktadır. Gauss Süreç Regresyon yaklaşımı ise parametrik olmayan bir yaklaşımdır. Parametreler yerine gözlemlerle tutarlı olan olası tüm fonksiyonlar yani  $f(x)$  üzerinde bir dağılım bulmamıza yardımcı olmaktadır.

Zaman serisi analizinde, veri noktalarının ardışık ve (çoğu zaman) bağımlı olması nedeniyle, klasik regresyon teknikleri her zaman etkin performans gösteremeyebilir (Box ve Jenkins, 1970). Gaussian Process (GP) ise istatistiksel öğrenme çerçevesinde, fonksiyon uzayı üzerinde çok esnek bir olasılık modeli sunar (Rasmussen ve Williams, 2006). Özellikle GP Regresyonu, parametre tabanlı yaklaşımlara kıyasla, veriyi kernel (kovaryans) fonksiyonları üzerinden ilişkilendirerek tahmin yapmayı sağlar ve böylece belirsizlik (uncertainty) tahmini de içeren bir yapı oluşturur (Bishop, 2006).

Bu çalışmada, bir haftalık veya günlük verilerin (ya da farklı periodiciteye sahip zaman serilerinin) kaydirmalı (rolling) bir yaklaşım ile GP'ye beslenmesi ele alınmaktadır. Böylece, her yeni veri noktası geldiğinde GP modeli güncellenmekte ve kısa/orta/uzun vadede tahmin üretilebilmektedir.

Bir Gaussian Process, herhangi bir sonlu noktalar kümesi üzerinde çok boyutlu Gauss dağılımı tanımlayabilen bir stokastik süreçtir. Klasik ifade şu şekildedir (Rasmussen ve Williams, 2006):

$$f(\mathbf{x}) \sim \mathcal{GP}(m(\mathbf{x}), k(\mathbf{x}, \mathbf{x}')). \quad (3.40)$$

Burada  $m(\mathbf{x}) = \mathbb{E}[f(\mathbf{x})]$ , “ortalama fonksiyonu” (mean function) olarak adlandırılır ve genellikle  $\mathbf{0}$  veya basit (lineer vb.) bir fonksiyon olarak seçilebilir.  $k(\mathbf{x}, \mathbf{x}') = \mathbb{E}[(f(\mathbf{x}) - m(\mathbf{x}))(f(\mathbf{x}') - m(\mathbf{x}'))]$  ise kernel (kovaryans) fonksiyonudur ve  $\mathbf{x}$  ile  $\mathbf{x}'$  arasındaki benzerliği veya ilişkiyi tanımlar.

Eğitim verisi olarak  $\mathbf{X} \in \mathbb{R}^{N \times D}$  ve  $\mathbf{y} \in \mathbb{R}^N$  verilmiş olsun. Her bir girdi noktası  $\mathbf{x}_i \in \mathbb{R}^D$  çıktıda  $\mathbf{y}_i$  değerine karşılık gelir. Gauss gürültüsü eklenmiş basit bir modelde,

$$y_i = f(\mathbf{x}_i) + \varepsilon_i, \quad (3.41)$$

burada  $\mathbf{x}_i$ , haftaya özgü ya da vade (maturity) bilgisini içeren girdi vektörüdür.  $f(\mathbf{x}_i)$ , GP tarafından modellenen bilinmeyen fonksiyondur.  $\varepsilon_i \sim \mathcal{N}(0, \sigma_n^2)$ , gözlem (ölçüm) hatasını ifade eder (Rasmussen & Williams, 2006).

GP, “fonksiyon uzayı” üzerinde bir Gauss dağılımı tanımlar; bu yaklaşım, “hangi noktaların birbirine ne kadar benzer” olduğunu kernel (kovaryans) fonksiyonları üzerinden belirler (Bishop, 2006).

### 3.11.2.2 Kernel (Kovaryans) Yapısı ve Parametreler

Gaussian Process (GP) regresyonunda çekirdek (kernel) fonksiyonları, veri noktaları arasındaki benzerliklerin ölçülmesi ve modelin tahmin performansını optimize etmek açısından kritik bir bileşendir. Çekirdek fonksiyonları, GP'nin esnekliğini ve doğruluğunu doğrudan etkiler. Farklı çekirdek türleri, veri setine uygun çeşitli yapıları

modellemek için kullanılır ve her biri belirli türdeki veri ilişkileri için özel avantajlar sunar. Aşağıda, en yaygın kullanılan çekirdek fonksiyonlarının tanımları ve işlevleri açıklanmıştır.

Radyal tabanlı fonksiyon (Radial Basis Function - RBF), veri noktaları arasındaki Öklidyen mesafeye dayalı olarak benzerlik hesaplar. Yakın olan veri noktaları arasında yüksek benzerlik sağlarken, uzak noktalar arasındaki benzerlik eksponansiyel olarak azalır. Bu özellik, RBF'nin özellikle küresel pürüzsüzlük gerektiren durumlarda etkin bir şekilde kullanılmasını sağlar. Matematiksel formülü şu şekildedir:

$$k(\mathbf{x}, \mathbf{x}') = \sigma_f^2 \exp\left(-\frac{1}{2\ell^2} \|\mathbf{x} - \mathbf{x}'\|^2\right), \quad (3.42)$$

burada  $\sigma_f^2$  fonksiyonun varyansını kontrol eden bir ölçek parametresidir;  $\ell$  "length-scale" parametresi ise  $\mathbf{x}$  ile  $\mathbf{x}'$  arasındaki mesafeye ne ölçüde duyarlı olunacağını belirler (Murphy, 2012). Parametrelerin  $(\ell, \sigma_f, \sigma_n)$  öğrenimi, marjinal log-likelihood fonksiyonunun türev tabanlı bir algoritmayla maksimize edilmesiyle yapılmaktadır.

### 3.11.2.3 Posterior (Artalan) Tahmini

Eğitim verisi  $\{(\mathbf{x}_i, y_i)\}_{i=1}^N$  üzerinden GP'yi "fit" ettiğimizde, yeni bir nokta  $\mathbf{x}_*$  için tahmin yapmak isteriz. Gürültülü gözlem varsayımı altında:

$$\mathbf{K}(\mathbf{X}, \mathbf{X}') + \sigma_n^2 \mathbf{I}, \quad (3.43)$$

matrisi, eğitim verilerinin kovaryansı olarak tanımlanır. Burada  $\sigma_n^2$ , gözlem gürültüsünün varyansını,  $\mathbf{I}$  ise  $(N \times N)$  boyutlu birim matrisini ifade eder.

Yeni noktaların (test seti veya ileri tahmin noktaları) kovaryans yapısı  $\mathbf{K}(\mathbf{X}_*, \mathbf{X})$ ,  $\mathbf{K}(\mathbf{X}_*, \mathbf{X}_*)$  ve  $\mathbf{K}(\mathbf{X}, \mathbf{X})$  matrisleriyle ifade edilebilir. Bu çerçevede, GP posterior ortalaması (tahmin edilen fonksiyon değeri) aşağıdaki gibi hesaplanır (Bishop, 2006):

$$\bar{f}_* = \mathbf{K}(\mathbf{X}_*, \mathbf{X})[\mathbf{K}(\mathbf{X}, \mathbf{X}) + \sigma_n^2 \mathbf{I}]^{-1} \mathbf{y}. \quad (3.44)$$

Burada  $\mathbf{K}(\mathbf{X}_*, \mathbf{X})$ , test noktaları ( $\mathbf{X}_*$ ) ile eğitim noktalarının ( $\mathbf{X}$ ) kovaryansını;  $\mathbf{y}$ , eğitim hedef değerlerini göstermektedir.  $\sigma_n^2$  ise gözlem hatasını yansıtmaktadır.

### 3.11.2.4 Modelin Öğrenilmesi (Parametre Optimizasyonu)

GP modelinde kernel parametreleri  $(\ell, \sigma_f)$  ve gürültü varyansı  $(\sigma_n^2)$  genellikle marjinal log-likelihood (MLL) fonksiyonunu maksimize ederek belirlenir (Rasmussen & Williams, 2006). Marjinal log-likelihood:

$$\log p(\mathbf{y}|\mathbf{X}) = -\frac{1}{2}\mathbf{y}^\top[\mathbf{K}(\mathbf{X}, \mathbf{X}) + \sigma_n^2\mathbf{I}]^{-1}\mathbf{y} - \frac{1}{2}\log|\mathbf{K}(\mathbf{X}, \mathbf{X}) + \sigma_n^2\mathbf{I}| - \frac{N}{2}\log(2\pi). \quad (3.45)$$

Bu fonksiyon, çekirdek (kernel) parametreleri ve gürültü varyansına bağlıdır. Buradaki determinant ( $\log|\cdot|$ ) ve matris tersi, nümerik olarak yoğun işlemlerdir ancak veri boyutu çok büyük değilse (ör. yüzler veya binler mertebesi) çoğu zaman uygulanabilir (Murphy, 2012).

### 3.11.2.5 Dinamik Gauss Proses (Dynamic GP) Yöntemi

Finansal verilerdeki belki de en kritik özellik, verilerin zamanla değişkenlik göstermesidir. Faiz oranları, vade yapıları gibi ekonomik göstergeler, sürekli bir değişim içerisindedir. Klasik GP yönteminde verinin statik bir yapı sergilediği varsayımı altında çalışılırken, gerçek hayatta zamanla gelen yeni veriler ışığında modelin güncellenmesi gerekmektedir. İşte bu noktada, Dinamik GP (DGP) yaklaşımı devreye girer.

Dinamik GP, eğitim sürecini online bir yapıya kavuşturarak, her yeni gözlemin model parametrelerine etkisinin hesaba katılmasını sağlar. Temel mantık, ilk adımda klasik GP modeli kurulduktan sonra, her yeni veri noktasıyla modelin mevcut tahminleri karşılaştırılır. Gerçek gözlem ile tahmin arasındaki fark (residual) hesaplanır ve bu fark, kernel matrisleri kullanılarak modele yeniden entegre edilir. Bu güncelleme süreci, modelin zamanla "öğrenmeye devam etmesini" ve güncel veri dağılımına uyum sağlamasını mümkün kılar.

Zamanın farklı noktalarında elde edilen verilerle, modelin ürettiği tahminler  $\hat{y}(x)$  ile gerçek gözlemler  $y(x)$  arasında farklar (residual) oluşur:

$$\epsilon(x) = y(x) - \hat{y}(x). \quad (3.46)$$



Dinamik GP yaklaşımında, bu fark  $\epsilon(x)$  kullanılarak modelin ortalama fonksiyonu güncellenir. Yeni gözlemin model üzerindeki etkisi, eğitim verilerinin kovaryans yapısı kullanılarak aşağıdaki şekilde entegre edilir:

$$m_{new}(\mathbf{x}_*) = \hat{y}(\mathbf{x}_*) + \mathbf{K}(\mathbf{x}_*, \mathbf{X})[\mathbf{K}(\mathbf{X}, \mathbf{X}) + \sigma_n^2 \mathbf{I}]^{-1} \epsilon, \quad (3.47)$$

burada  $\hat{y}(\mathbf{x}_*)$ , önceki model tahminidir,  $\mathbf{K}(\mathbf{x}_*, \mathbf{X})$  yeni nokta  $\mathbf{x}_*$  ile eğitim verileri  $\mathbf{X}$  arasındaki kernel benzerlik vektörüdür,  $\epsilon$  ise  $y - \hat{y}$  şeklinde hesaplanan residual vektörüdür.

### 3.11.2.6 Kaydırmalı (Rolling) Yaklaşım

#### 3.11.2.6.1 Rolling Mantığının Temel Prensipleri

Kaydırmalı (rolling) tahmin, zaman serisi modellemesinde sıkça kullanılan bir tekniktir (Box & Jenkins, 1970). Bu yöntem, verinin belirli bir penceresinde (örneğin son 200 haftalık gözlem) modeli eğitip, sonrasında bu pencereyi bir adım kaydırarak yeni veriyi dahil etme yaklaşımına dayanır. Ana fikir, modelin zamanla güncellenmesi ve ilerleyen haftalar/gözlemler için tahmin üretmesidir. Temel adımlar şöyle özetlenebilir:

#### 1. Başlangıç (Initial Fit):

- Zaman serisinin ilk start noktası belirlenir (örneğin “3. hafta” veya “ilk gözlem”).
- “Eğitim penceresi” (ör. 200 gözlem, 350 gözlem) seçilir. Bu pencere içinde bulunan veri, ilk model eğitiminde (fit) kullanılır.

#### 2. Tahmin Üretme (Forecast):

- Eğitilen model,  $h$  –adım ileri tahmin (ör. 1 hafta, 1ay veya 6 ay) gibi hedef ufku için öngörü üretebilir.
- Tahmin sonuçları bir dizi matris veya vektörde saklanabilir (ör. “forecast matrix”, “error matrix” gibi yapılarda).

### 3. Pencerenin Kaydırılması (Update):

- Zaman serisinde bir sonraki gözlem (ör. yeni hafta) geldiğinde, önceki pencereden en eski gözlem çıkarılır veya pencere sabit kalır fakat yeni gözlem eklenerek veri yeniden eğitilir (farklı uygulamalarda pencere boyutu sabit tutulabileceği gibi giderek büyüyen pencere de kullanılabilir).
- Model, yeni bilgilere göre güncellenir veya yeniden optimize edilir; bu işlem, Gaussian Process yaklaşımında posterior tahmin ve kalıntı (residual) hesaplarıyla entegre edilebilir (Rasmussen & Williams, 2006).
- Yeni modele göre tekrar  $h$  – adım ileri tahmin üretilir.

Bu döngü, zaman serisinin sonuna kadar sürdürülerek hem tahmin hem de performans analizi (ör. her aşamadaki hata veya RMSE) yapılır (Murphy, 2012).

#### 3.11.2.6.2 Gaussian Process Modelinin Kaydırmalı Yaklaşımınla Bütünleşmesi

##### 1. Posterior Tahmin ve Mean Function Güncellemesi:

###### ○ Önceki Tahmin ve Gerçek Gözlem:

Eğitim verileri üzerinden elde edilen tahmin  $\hat{y}$  ile yeni gözlem  $y$  arasındaki fark:

$$\epsilon = y - \hat{y}. \quad (3.48)$$

###### ○ Kernel Matrislerinin Oluşturulması:

$\mathbf{K}(\mathbf{X}, \mathbf{X})$  eğitim verilerinin kendi aralarındaki kovaryansını temsil ederken,  $\mathbf{K}(\mathbf{x}_*, \mathbf{X})$  yeni gözlem  $\mathbf{x}_*$  ile mevcut eğitim verileri  $\mathbf{X}$  arasındaki kovaryans benzerliğini belirler.

###### ○ Düzeltme (Correction) Teriminin Hesaplanması:

Kernel matrislerinin tersinin alınmasıyla elde edilen düzeltme terimi:

$$\Delta \mathbf{m}(\mathbf{x}_*) = \mathbf{K}(\mathbf{x}_*, \mathbf{X})[\mathbf{K}(\mathbf{X}, \mathbf{X}) + \sigma_n^2 \mathbf{I}]^{-1} \epsilon. \quad (3.49)$$

○ **Güncellenmiş Ortalama Fonksiyonu:**

Yeni ortalama tahmin, önceki tahmine düzeltme teriminin eklenmesiyle bulunur:

$$m_{new}(\mathbf{x}_*) = \hat{\mathbf{y}}(\mathbf{x}_*) + \Delta \mathbf{m}(\mathbf{x}_*). \quad (3.50)$$

Bu mekanizma, modelin her yeni veri noktasında yeniden optimize edilmesine ve güncel verilere uyum sağlamasına olanak tanır.

**2. Kernel Parametrelerinin Yeniden Öğrenilmesi:**

- Yeni gözlemin eklenmesinin ardından, model parametreleri (örneğin, kernel parametreleri length-scale ( $\ell$ ), varyans ( $\sigma_f^2$ ) veya gürültü ( $\sigma_n^2$ )) yeniden optimize edilir.
- Bu optimizasyon, yukarıda verilen marjinal log-likelihood fonksiyonunun maksimize edilmesiyle gerçekleştirilir.
- Böylece, model hem geçmiş veriden öğrendiği yapıyı korur hem de yeni gelen bilgiler ışığında güncel tahminler üretebilir.

**3. Kısa, Orta ve Uzun Vadeli Tahminlerin Birleştirilmesi:**

- Rolling yaklaşımı ile  $h$ -adım ileri tahmin (örneğin 1 ay veya 6 ay ötesi) aynı çerçevede üretilebilir.
- Model, sürekli güncellendiğinden kısa vadede daha düşük belirsizlik veya daha az hata, orta/uzun vadede ise daha geniş bir belirsizlik aralığı beklenir.

- Böylece farklı karar destek mekanizmalarına (ör. anlık pozisyon alma, risk ölçümü, stok yönetimi) uygun çoklu ufuk tahminleri elde edilebilir.

Bu bölümde, Gaussian Process (GP) Regresyonunun temel matematiksel ilkeleri ve zaman serisi verisi üzerinde kaydırmalı (rolling) tahmin yaklaşımı detaylı biçimde açıklanmıştır. GP'nin posterior tahmini, kernel seçimi ve parametre optimizasyonu (marjinal log-likelihood üzerinden) sayesinde, klasik lineer modellerin ötesinde esnek bir tahmin gücü elde edilir. Zaman serilerinde pencereci (rolling) bir güncelleme yapısı kurgulayarak, yeni veri geldikçe modelin yeniden eğitilmesi veya “mean function” üzerinden kalıntıların (residual) yansıtılması yoluyla, değişen veri dinamiklerine hızlı uyum sağlanabilir (Rasmussen & Williams, 2006).

Bir sonraki aşamada sunulacak algoritmik şablon (pseudocode), yukarıda belirtilen GP kurulumunu, parametre optimizasyonunu ve kaydırmalı tahmin prosedürünü adım adım hayata geçirmektedir. Bu algoritma, haftalık veya günlük veriye uygun olacak biçimde genellenebilir ve çeşitli ufuklarda ( $h$ -adımlık) tahmin üretmek için rahatça uyarlanabilir.

### 3.11.3 Tahmin

Gauss Süreçleri çerçevesi, fonksiyonel veri analizinde etkili bir tahmin yöntemi olarak öne çıkmaktadır. Bu çalışmada, Gauss Süreci algoritmaları Python ortamında GPy paketine dayalı olarak uygulanmıştır (GPy, 2012). Tahmin süreci, Dinamik Gauss Süreci algoritmasının iki ana aşaması ile gerçekleştirilmektedir. İlk aşamada  $t = 0$  zaman adımında, başlangıç veri setine dayanarak kovaryans fonksiyonunun hiperparametreleri tahmin edilmektedir. Bu işlem, modelin marjinal log-olabilirlik fonksiyonunun maksimize edilmesi ile gerçekleştirilir. Ardından,  $t = 1$  zaman adımı için tahmin edilen hiperparametreler kullanılarak getiri değerleri Bayes teoremine dayalı bir yöntemle tahmin edilmektedir. Bu aşamada posterior kovaryans fonksiyonu ve posterior ortalama fonksiyonu, hem hiperparametrelerin hem de tahmin edilen önceki getiri değerlerinin sürekli olarak güncellenmesini sağlar.

İkinci aşamada ise  $t \geq 1$  zaman adımları için tahmin süreci, iteratif bir şekilde devam etmektedir. Burada, her bir tahmin adımı, marjinal log-olabilirliğin optimizasyonu ile hiperparametrelerin yeniden tahmini ile başlar. Elde edilen yeni

hiperparametre deęerleri, sonraki getiri eęrisinin tahmini iin temel teękil eder. Bu iteratif yaklařımla, ikinci eęriden bařlayarak tm getiri eęrileri sırasıyla tahmin edilmektedir. Srecin bu yapısı, dinamik ve deęiřken piyasa kořullarında daha esnek ve doęru tahminler yapılmasına olanak tanımaktadır.

Bu alıřmada, Gauss Srelerinin temel bileřeni olan kovaryans fonksiyonları, Radyal Tabanlı Fonksiyonlar (RBF) kullanılarak modellenmiřtir. RBF ekirdeęi, veri noktaları arasındaki mesafelerin etkisini belirleyen uzunluk leęi (length-scale) ve verinin yayılımını ifade eden varyans parametresi ile karakterize edilir. Ayrıca, hiperparametrelerin (uzunluk leęi, varyans ve grlt parametresi) pozitiflik kısıtlamaları altında optimize edilmesi, model parametrelerinin fiziksel anlamlarının korunmasını ve tahmin sonularının istikrarını saęlar.

Zaman serisi analizinde kaydırılmalı (rolling) tahmin yntemleri, veri kořullarındaki deęiřikliklere uyum saęlamak ve gelecekteki deęerleri ngrmek iin yaygın olarak kullanılmaktadır. Bu alıřmada, DGP modeli ile kaydırılmalı bir tahmin algoritması geliřtirilmiřtir. Model, belirli bir eęitim periyodu boyunca bařlangı satırından itibaren alıřtırılarak ileriye dnk  $h$  –adımlı tahminler retir ve her adım iin hata karelerinin ortalaması (RMSE) hesaplanarak performans deęerlendirilir. Algoritmanın detaylı yapısı, Algoritma 2 bařlıęı altında sunulmuřtur.

**Algoritma 2: Dinamik GP Tahmini Pseudo Kod**

Veri Hazırlığı:

- a)  $X \leftarrow \text{reshape}(\text{mat\_vec}, [M, 1])$  //  $X$ ,  $(M \times 1)$  boyutunda girdi matrisidir.
- b)  $N \leftarrow \text{number\_of\_rows}(\text{data})$  // Toplam gözlem sayısı.
- c)  $d \leftarrow \text{number\_of\_columns}(\text{data}) - 1$  // 'Index' hariç sütun sayısı.
- d)  $\text{row\_index} \leftarrow \text{start} - 1$
- e)  $\text{end} \leftarrow \text{row\_index} + \text{trainings\_weeks}$
- f) Boş matrisler oluştur:  $\text{forc\_mat}$  ( $h \times d$ ),  $\text{error\_mat}$  ( $h \times d$ ) ve  $\text{rmse\_curve}$  ( $h \times 1$ ).

Rolling Güncelleme Döngüsü:

WHILE ( $\text{row\_index} < \text{end}$ ) DO:

- a)  $\text{dfr} \leftarrow \text{data}[\text{row\_index}, :]$  // İlgili satırdaki tüm veriler.
- b)  $Y \leftarrow \text{dfr}[1 : (d+1)]$  // Index sütunu hariç gözlem sütunları.
- c) IF ( $\text{row\_index} == \text{start} - 1$ ) THEN:
  - i)  $k \leftarrow \text{RBF Kernel}(\text{input\_dim} = 1)$
  - ii)  $m \leftarrow \text{GPRegression}(X, Y, \text{kernel} = k)$  // İlk adımda klasik GP modeli oluşturuluyor.
- ELSE:
  - i)  $\text{act} \leftarrow \text{data}[\text{row\_index}, 1 : (d+1)]$  // Güncel gerçek gözlem değerleri.
  - ii)  $\text{residual} \leftarrow \text{act} - \text{post\_pred}$  // Önceki adımın tahmini ile gerçek arasındaki fark.
  - iii) Hesapla:  $K_{XX}$  ve  $K_{XX}$  (burada  $K_{XX} = k(X, X) + \sigma^2 I$ ).
  - iv)  $\text{um} \leftarrow \text{post\_pred} + K_{XX} \cdot \text{inv}(K_{XX}) \cdot \text{residual}$  // Güncelleme denklemi.
  - v)  $\text{mean\_function} \leftarrow \text{um}$
  - vi)  $k \leftarrow \text{RBF Kernel}$  (gerekirse hiperparametreler yeniden optimize edilir).
  - vii)  $m \leftarrow \text{GP}(X, Y, \text{kernel} = k, \text{mean\_function} = \text{mean\_function})$
- d)  $m.\text{constrain\_positive}('')$
- e)  $m.\text{optimize}()$
- f)  $\text{post\_pred} \leftarrow m.\text{predict}(X)[0]$
- g)  $\text{row\_index} \leftarrow \text{row\_index} + 1$

END WHILE

Tahmin (Forecast) Üretme:

- a)  $\text{dfr} \leftarrow \text{data}[\text{end}, :]$
- b)  $Y \leftarrow \text{dfr}[1 : (d+1)]$
- c)  $m \leftarrow \text{GP}(X, Y, \text{kernel} = k, \text{mean\_function} = \text{mean\_function})$
- d)  $m.\text{constrain\_positive}('')$
- e)  $m.\text{optimize}()$
- f)  $\text{post\_pred} \leftarrow m.\text{predict}(X)[0]$
- g)  $\text{estimates} \leftarrow \text{flatten}(\text{post\_pred})$
- h)  $\text{forc\_mat}[0, :] \leftarrow \text{estimates}[0 : d]$
- i)  $\text{act} \leftarrow \text{data}[\text{row\_index}, 1 : (d+1)]$
- j)  $\text{error\_mat}[0, :] \leftarrow (\text{act} - \text{estimates})^2$

h-Adım İleri Tahmin:

FOR  $i$  FROM 1 TO  $(h - 1)$  DO:

- a)  $m \leftarrow \text{GP}(X, \text{post\_pred}, \text{kernel} = k, \text{mean\_function} = \text{mean\_function})$
- b)  $m.\text{constrain\_positive}('')$
- c)  $m.\text{optimize}()$
- d)  $\text{post\_pred} \leftarrow m.\text{predict}(X)[0]$
- e)  $\text{estimates} \leftarrow \text{flatten}(\text{post\_pred})$
- f)  $\text{forc\_mat}[i, :] \leftarrow \text{estimates}[0 : d]$
- g)  $\text{act} \leftarrow \text{data}[\text{row\_index} + i, 1 : (d+1)]$
- h)  $\text{error\_mat}[i, :] \leftarrow (\text{act} - \text{estimates})^2$

END FOR

RMSE Hesaplama ve Sonuçlar:

- a)  $\text{error\_df} \leftarrow \text{DataFrame}(\text{error\_mat})$
- b)  $\text{forc\_df} \leftarrow \text{DataFrame}(\text{forc\_mat})$
- c) FOR each  $c$  FROM 0 TO  $(h - 1)$  DO:
  - $\text{rmse\_curve}[c] \leftarrow \sqrt{\text{sum}(\text{error\_df}[c, :]) / d}$
- d)  $\text{rmse\_mean} \leftarrow \text{average}(\text{rmse\_curve})$
- e)  $\text{rmse\_curve\_df} \leftarrow \text{Append}(\text{rmse\_curve}, \text{rmse\_mean})$  // Son satıra ortalama RMSE eklenir.
- f) RETURN  $\text{forc\_df}, \text{error\_df}, \text{rmse\_curve\_df}$

### 3.11.4 Sonuçlar

DGP modelleri, makine öğrenmesi alanında yaygın olarak kullanılan esnek ve güçlü araçlardır. Bu modeller, verilerdeki karmaşık örüntüleri yakalayabilme ve belirsizliği ölçme yetenekleriyle bilinirler. Vade yapısı modellemesi bağlamında DGP modelleri, farklı vadelerdeki tahvil getirileri arasındaki korelasyonları ve bu getirilerdeki değişimlerin zaman içindeki dinamiklerini modellemek için kullanılabilir.

Şekil 3.39, ABD ekonomisi için DGP modeli kullanılarak yapılan 6 aylık tahmin sonuçlarını göstermektedir. Grafik, vadeye (yıl) bağlı olarak tahmini getiri oranlarının nasıl değiştiğini ortaya koymaktadır. DGP modelinin dinamik tahmin kapasitesi, özellikle faiz oranı ve getiri eğrisi analizi için güçlü bir yöntemdir. Bu 6 aylık bir tahmin penceresinde elde edilen sonuçlar, ABD ekonomisindeki büyüme beklentileri, enflasyonist öngörüler ve yatırımcı risk algısını anlamayı sağlamaktadır.

Kısa vadelerde (0-5 yıl arası) getiri eğrisinin yatay bir seyir izlediği görülmektedir. Bu durum, kısa vadeli faiz oranlarının ABD ekonomisinde istikrarlı bir seyir izlediğine işaret etmektedir. FED'in son yıllarda uyguladığı genişlemeci para politikaları, bu kısa vadeli istikrarın temel nedenlerinden biridir. Özellikle, COVID-19 salgını sonrası dönemde Federal Reserve, ekonomik toparlanmayı teşvik etmek amacıyla faiz oranlarını düşük tutmuştur. Bu yatay seyir, kısa vadede ekonomik belirsizliğin azalması ve piyasa aktörlerinin güveninin artmasıyla ilişkilendirilebilir.

Orta vadelerde (5-15 yıl), getiri eğrisinin hafif bir yükseliş eğilimi sergilediği görülmektedir. Bu artış, enflasyon beklentilerinin ve ekonomik büyümenin toparlanma sinyalleriyle birlikte arttığını yansıtmaktadır. Özellikle, ABD ekonomisinde artan tüketim harcamaları, emtia fiyatlarındaki yükseliş ve küresel tedarik zincirinde yaşanan sıkıntılar, orta vadeli tahviller üzerindeki getirileri yukarı çekmiştir. Ayrıca, FED'in parasal sıkılaştırma politikalarına geçiş sinyalleri, orta vadeli yatırımcıların faiz oranı risklerini fiyatlandırmalarına neden olmuş olabilir. Bu durum, orta vadeli faiz oranlarının büyüme ve enflasyon beklentilerine duyarlılığını göstermektedir.

Uzun vadelerde (15-30 yıl), getiri eğrisinin daha keskin bir şekilde yükseldiği dikkat çekmektedir. Uzun vadeli tahvillerdeki bu artış, yatırımcıların gelecekteki enflasyon ve


ekonomik belirsizlikler nedeniyle daha yüksek bir getiri talep ettiğini göstermektedir. ABD ekonomisinde uzun vadede beklenen altyapı yatırımları, enerji dönüşümü ve teknolojik yenilikler, bu segmentteki artışın temel ekonomik nedenleri arasında sayılabilir. Bununla birlikte, yüksek bütçe açığı ve kamu borcunun artışı da uzun vadeli faiz oranlarını yükselten faktörler arasında yer almaktadır.

FED'in uzun vadeli faiz oranlarına müdahalede daha sınırlı bir politika izlediği bilinmektedir. Bu durum, uzun vadeli getirilerdeki artışı piyasa güçlerinin daha fazla yönlendirdiğini göstermektedir. Dolayısıyla, uzun vadelerdeki bu keskin artış, hem enflasyonun uzun vadede yüksek kalabileceğine hem de ekonomik büyümenin yavaşlama riski taşıdığına dair karışık sinyaller sunmaktadır.

Grafik, ABD ekonomisinde kısa, orta ve uzun vadeli beklentileri yansıtan önemli bir görünüm sunmaktadır. Kısa vadelerdeki yatay eğri, COVID-19 sonrası toparlanma sürecinde Federal Reserve'in genişlemeci politikalarının etkisini açıkça ortaya koymaktadır. Orta vadede, enflasyon ve büyüme beklentileri yatırımcı davranışlarını yönlendirirken, uzun vadede kamu borcu, enflasyon beklentileri ve jeopolitik riskler belirleyici olmaktadır.

Bu bulgular, DGP modelinin ekonomik analizlerdeki gücünü bir kez daha ortaya koymaktadır. Model, ABD ekonomisinin dinamiklerini anlamak ve gelecekteki politika kararlarına ışık tutmak için önemli bir araç olarak değerlendirilmektedir. Şekil 3.39, ABD'nin ekonomik politikalarının hem kısa hem de uzun vadeli etkilerinin incelenmesi için anlamlı bir çerçeve sunmaktadır.





**Şekil 3.39** ABD Dinamik Gauss Süreç (DGP) Modeli için 6 Aylık Tahmin Sonuçlarına Dayalı Getiri Eğrisi

Tablo 3.22, ABD DGP modelinin 1 aylık tahmin sonuçlarını göstermektedir. Tablo, kısa vadeden (3 ay) uzun vadeye (30 yıl) kadar farklı vade yapılarındaki tahmin performansını MSE, RMSE, MAE ve MAPE metrikleri ile değerlendirmektedir. Tahmin performansına göre, kısa vadelerde (3 ay, 6 ay, 1 yıl) hataların oldukça düşük olduğu ve yüksek doğruluk elde edildiği gözlemlenmektedir. Özellikle 6 ay vadede MAPE %5'in altına düşerek oldukça başarılı sonuçlar sunmaktadır. Uzun vadelerde ise (20 ve 30 yıl) hata oranlarında kademeli bir artış gözlemlense de doğruluk seviyeleri kabul edilebilir sınırlar içerisinde. Bu durum, modelin hem kısa hem de uzun vadede etkin bir performans sergilediğini göstermektedir.

**Tablo 3.22** ABD DGP Modeli: 1 Aylık Tahmin Performansı Değerlendirmesi

Vade	MSE	RMSE	MAE	MAPE
3 Ay	0.0005	0.0226	0.0220	24.3116
6 Ay	0.0000	0.0057	0.0050	4.7727
1 Yıl	0.0005	0.0225	0.0189	16.2929
2 Yıl	0.0012	0.0352	0.0342	26.2002
3 Yıl	0.0007	0.0256	0.0246	15.9411

5 Yıl	0.0052	0.0724	0.0720	38.0301
7 Yıl	0.0070	0.0838	0.0824	24.1861
10 Yıl	0.0132	0.1149	0.1143	20.5462
20 Yıl	0.0162	0.1272	0.1259	15.9143
30 Yıl	0.0202	0.1422	0.1414	10.5224

Tablo 3.23, ABD DGP modelinin 3 aylık tahmin sonuçlarını sunmaktadır. Orta vadelerde (1-5 yıl) tahmin performansı, kısa vadelerdeki başarısını sürdürürken, uzun vadelerde tahmin hatalarının arttığı gözlemlenmiştir. 3 aylık tahmin süresi boyunca MAPE'nin kısa vadelerde %40'ın altında olduğu, ancak uzun vadelerde (20 ve 30 yıl) bu oranın arttığı dikkat çekmektedir. Bu durum, modelin kısa vadeli ekonomik değişkenlerde daha güçlü tahminler sağladığını göstermektedir.

**Tablo 3.23** ABD DGP Modeli: 3 Aylık Tahmin Performansı Değerlendirmesi

Vade	MSE	RMSE	MAE	MAPE
3 Ay	0.0011	0.0337	0.0316	37.2648
6 Ay	0.0004	0.0197	0.0149	17.0145
1 Yıl	0.0003	0.0161	0.0130	12.4848
2 Yıl	0.0013	0.0366	0.0322	27.3100
3 Yıl	0.0017	0.0408	0.0331	20.5460
5 Yıl	0.0125	0.1116	0.1074	53.8235
7 Yıl	0.0246	0.1568	0.1490	38.9292
10 Yıl	0.0425	0.2061	0.1958	30.8963
20 Yıl	0.0409	0.2022	0.1927	21.7227
30 Yıl	0.0405	0.2013	0.1935	13.5932

Tablo 3.24, ABD DGP modelinin 6 aylık tahmin performansını değerlendirmektedir. Bu tahmin aralığında, özellikle kısa vadelerde (3 ay ve 6 ay) hataların ciddi şekilde arttığı ve MAPE'nin %68 ile %132 arasında değiştiği dikkat çekmektedir. Orta vadelerde (2-5 yıl) model daha iyi sonuçlar verirken, uzun vadelerde (10 yıl ve üzeri) hata oranlarının sınırlı bir artış gösterdiği gözlemlenmiştir. Bu durum, tahmin aralığı uzadıkça

kısa vadeli dalgalanmaların etkisinin arttığını, ancak uzun vadede modelin tahminlerde daha dengeli bir performans sergilediğini göstermektedir.

**Tablo 3.24** ABD DGP Modeli: 6 Aylık Tahmin Performansı Değerlendirmesi

Vade	MSE	RMSE	MAE	MAPE
3 Ay	0.0033	0.0573	0.0509	132.0294
6 Ay	0.0017	0.0409	0.0325	68.5885
1 Yıl	0.0007	0.0273	0.0220	35.4298
2 Yıl	0.0009	0.0295	0.0245	24.5788
3 Yıl	0.0057	0.0753	0.0543	37.3978
5 Yıl	0.0825	0.2873	0.2243	92.6422
7 Yıl	0.1752	0.4186	0.3313	59.2595
10 Yıl	0.2627	0.5126	0.4204	46.8969
20 Yıl	0.3053	0.5525	0.4454	36.1494
30 Yıl	0.2554	0.5054	0.4162	22.8649

ABD DGP modeli, 1, 3 ve 6 aylık tahmin pencerelerinde farklı performanslar sergilemiştir. Kısa vadeli pencerelerde tahmin hataları düşük ve MAPE oranları makul seviyelerde kalırken, tahmin penceresi uzadıkça kısa vadeli hataların arttığı ancak uzun vadede daha dengeli bir tahmin performansı elde edildiği görülmektedir. Bu analiz, modelin özellikle uzun vadeli tahminler için güçlü bir araç olabileceğini ancak kısa vadeli değişkenlerde daha dikkatli analizler yapılması gerektiğini göstermektedir.


Şekil 3.40, Euro Bölgesi için DGP modelinin 6 aylık tahmin sonuçlarını göstermektedir. Grafiğe göre kısa vadeli (0-5 yıl) tahvil getirileri oldukça düşük ve negatif seviyelerde seyretmektedir. Bu durum, Avrupa Merkez Bankası'nın (ECB) genişlemeci para politikalarının ve negatif faiz oranlarının piyasa üzerindeki etkisinin bir yansımasıdır. Avrupa ekonomisinde pandemi sonrası dönemde ekonomik büyüme zayıf seyretmiş, özellikle hizmet sektöründeki toparlanma beklenenden yavaş gerçekleşmiştir. Enflasyon oranlarının hedeflerin altında seyretmesi, ECB'nin düşük faiz ve varlık alım politikalarını devam ettirmesine neden olmuş ve bu durum kısa vadeli tahvil getirilerinin düşük kalmasına katkıda bulunmuştur.

Orta vadeli (5-15 yıl) tahvillerde getirilerde kademeli bir toparlanma gözlemlenmektedir. Bu eğilim, piyasa katılımcılarının pandemi sonrası toparlanmaya yönelik temkinli iyimserliğini yansıtmaktadır. Avrupa Birliği'nin yeşil dönüşüm hedefleri kapsamında sunduğu finansal teşvikler ve Avrupa Kurtarma Fonu aracılığıyla sağlanan yatırımlar, orta vadede ekonomik büyümeyi destekleyecek önemli adımlar olarak değerlendirilmektedir. Ancak, yüksek enerji fiyatları ve küresel tedarik zinciri problemleri gibi unsurlar, toparlanma sürecine belirsizlik katmaya devam etmektedir. Buna rağmen, orta vadeli tahvillerdeki yükseliş, piyasanın daha olumlu büyüme ve enflasyon beklentilerini fiyatlamaya başladığını göstermektedir.

Uzun vadeli (15-30 yıl) tahvil getirileri, orta vadeye kıyasla daha belirgin bir artış göstermektedir. Ancak, bu artış Avrupa ekonomisinin yapısal sorunları ve uzun vadeli büyüme dinamiklerine ilişkin belirsizlikler nedeniyle sınırlı kalmıştır. Özellikle yaşanan nüfus, düşük verimlilik artışı ve ekonomik reformların yavaş ilerlemesi, Euro Bölgesi'nin uzun vadeli ekonomik görünümünü olumsuz etkileyen faktörlerdir. Buna karşın, yatırımcıların uzun vadeli tahvillere olan talebi, güvenli liman arayışının devam ettiğini göstermektedir. Bu durum, bölgenin jeopolitik risklere karşı dirençli bir yatırım merkezi olma özelliğini koruduğunu da işaret etmektedir.

ECB'nin faiz oranlarını düşük tutma politikası, enerji fiyatlarındaki volatilité ve küresel ekonomik yavaşlama, Euro Bölgesi tahvil piyasasını şekillendiren temel unsurlar olmuştur. Özellikle enerji krizi, Almanya gibi sanayi yoğun ekonomiler üzerinde büyük bir baskı yaratmış ve tahvil piyasasında risk primlerini artırmıştır. Pandemi sonrası dönemde hükümetlerin sağladığı mali teşvikler, kısa vadeli büyümeyi desteklemiş ancak orta ve uzun vadede sürdürülebilir bir büyüme patikası için yapısal reformlara duyulan ihtiyaç artmıştır.

Şekil 3.40, Euro Bölgesi tahvil piyasasının ekonomik ve politik gelişmelere nasıl tepki verdiğini etkili bir şekilde ortaya koymaktadır. Kısa vadede genişlemeci para politikalarının etkisi belirgin olurken, orta vadede toparlanma beklentileri ve Avrupa Birliği'nin yatırım programları öne çıkmaktadır. Uzun vadede ise yapısal sorunlar ve düşük büyüme beklentileri getirileri sınırlamaktadır. Gaussian Process modeli, piyasanın bu dinamiklerini başarılı bir şekilde yansıtarak, karar alıcılar ve yatırımcılar için güçlü bir analiz aracı olarak kullanılabilir.



**Şekil 3.40** Euro Bölgesi Dinamik Gauss Süreç (DGP) Modeli için 6 Aylık Tahmin Sonuçlarına Dayalı Getiri Eğrisi

Tablo 3.25, Euro Bölgesi için DGP modeli kullanılarak yapılan 1 aylık tahminlerin sonuçlarını göstermektedir. Özellikle kısa vadeli tahvillerde (6 ay - 5 yıl), hata oranları (MSE, RMSE, MAE) düşük seviyede olup, tahminlerin güvenilir olduğunu işaret etmektedir. Bununla birlikte, daha uzun vadeli tahvillerde (15 yıl ve üzeri), özellikle MAPE değerlerindeki ciddi artış, tahminlerin uzun vadede doğruluğunun azaldığını göstermektedir. Bu durum, uzun vadeli ekonomik projeksiyonların belirsizliği ve piyasa volatilitesinin bir sonucudur. Örneğin, 16 yıllık tahvil için MAPE değeri %500'ün üzerindedir ve bu, modelin uzun vadeli ekonomik değişkenlere olan hassasiyetini göstermektedir.

**Tablo 3.25** Euro Bölgesi DGP Modeli: 1 Aylık Tahmin Performansı Değerlendirmesi

Vade	MSE	RMSE	MAE	MAPE
6 Ay	0.0469	0.2167	0.2155	34.4725
1 Yıl	0.0210	0.1450	0.1438	22.7078
2 Yıl	0.0046	0.0682	0.0645	9.7515
3 Yıl	0.0030	0.0545	0.0468	6.8548
4 Yıl	0.0135	0.1162	0.1118	17.2930
5 Yıl	0.0382	0.1954	0.1925	30.8059
6 Yıl	0.0014	0.0368	0.0277	5.1015
7 Yıl	0.0042	0.0647	0.0538	11.0290
8 Yıl	0.0049	0.0697	0.0602	12.7125
9 Yıl	0.0417	0.2042	0.2009	50.8714
10 Yıl	0.0353	0.1878	0.1843	55.0887
11 Yıl	0.0109	0.1043	0.0980	38.6225

12 Yıl	0.0268	0.1637	0.1598	78.6501
13 Yıl	0.0021	0.0455	0.0298	24.4694
14 Yıl	0.0013	0.0363	0.0259	33.0308
15 Yıl	0.0565	0.2376	0.2351	498.5402
16 Yıl	0.0492	0.2217	0.2191	559.3805
17 Yıl	0.0011	0.0335	0.0287	84.4275
18 Yıl	0.0766	0.2767	0.2747	2382.5648
19 Yıl	0.0014	0.0376	0.0361	97.6681
20 Yıl	0.0820	0.2864	0.2845	380.8849
21 Yıl	0.0062	0.0789	0.0720	64.6046
22 Yıl	0.0043	0.0655	0.0570	40.9606
23 Yıl	0.0394	0.1985	0.1959	132.0857
24 Yıl	0.0324	0.1800	0.1771	111.8346
25 Yıl	0.0015	0.0388	0.0365	21.0451
26 Yıl	0.0755	0.2748	0.2730	135.9087
27 Yıl	0.0460	0.2144	0.2122	97.7749
28 Yıl	0.0303	0.1740	0.1712	73.7554
29 Yıl	0.0543	0.2331	0.2310	97.8917
30 Yıl	0.0028	0.0525	0.0425	15.4467

Tablo 3.26’da 3 aylık tahmin sonuçları sunulmuştur. 2-5 yıl vadeli tahviller için hata oranlarının düşük olması, bu süre zarfındaki tahminlerin nispeten daha başarılı olduğunu göstermektedir. Ancak, vadeler uzadıkça (örneğin 15-20 yıl), modelin tahmin doğruluğu önemli ölçüde düşmektedir. Bu durum, modelin uzun vadeli faiz oranlarındaki belirsizliklere uyum sağlamadaki zorluklarını ortaya koymaktadır. 30 yıllık tahvil için MAPE değeri %307 gibi oldukça yüksek bir seviyededir.

**Tablo 3.26** Euro Bölgesi DGP Modeli: 3 Aylık Tahmin Performansı Değerlendirmesi

Vade	MSE	RMSE	MAE	MAPE
6 Ay	0.0479	0.2189	0.2169	34.2724
1 Yıl	0.0233	0.1525	0.1511	23.8587
2 Yıl	0.0027	0.0518	0.0470	7.1714
3 Yıl	0.0016	0.0399	0.0339	5.1623
4 Yıl	0.0219	0.1480	0.1421	23.0014
5 Yıl	0.0276	0.1662	0.1596	26.5972
6 Yıl	0.0045	0.0670	0.0505	10.1863
7 Yıl	0.0106	0.1028	0.0887	19.9027
8 Yıl	0.0035	0.0588	0.0506	12.0755
9 Yıl	0.0306	0.1751	0.1664	45.2640
10 Yıl	0.0257	0.1602	0.1504	48.6957
11 Yıl	0.0203	0.1426	0.1312	65.4732
12 Yıl	0.0401	0.2003	0.1922	131.2441
13 Yıl	0.0069	0.0832	0.0628	105.0674
14 Yıl	0.0050	0.0709	0.0538	243.8761
15 Yıl	0.0735	0.2712	0.2649	872.3532
16 Yıl	0.0396	0.1990	0.1902	784.6324
17 Yıl	0.0041	0.0643	0.0488	99.2133
18 Yıl	0.0947	0.3078	0.3020	1318.0089

19 Yıl	0.0036	0.0601	0.0450	157.6057
20 Yıl	0.0999	0.3160	0.3103	354.0758
21 Yıl	0.0130	0.1141	0.0970	67.2859
22 Yıl	0.0102	0.1012	0.0814	45.6252
23 Yıl	0.0518	0.2276	0.2195	129.0416
24 Yıl	0.0274	0.1656	0.1543	96.8177
25 Yıl	0.0036	0.0600	0.0468	23.0965
26 Yıl	0.0903	0.3004	0.2944	133.4022
27 Yıl	0.0578	0.2404	0.2329	97.6017
28 Yıl	0.0401	0.2002	0.1911	74.8338
29 Yıl	0.0483	0.2198	0.2117	88.6918
30 Yıl	0.0072	0.0848	0.0642	20.5623

6 aylık tahmin sonuçlarını içeren Tablo 3.27, özellikle kısa ve orta vadeli tahvillerde (1-10 yıl) tahminlerin daha istikrarlı olduğunu göstermektedir. Ancak uzun vadede, özellikle 20-30 yıl arasında tahmin hatalarının önemli ölçüde arttığı görülmektedir. Bu durum, ekonomik belirsizliklerin ve uzun vadeli faiz oranlarındaki dalgalanmaların etkilerini yansıtmaktadır. Örneğin, 20 yıllık tahvil için MAPE %2013 gibi son derece yüksek bir değere sahiptir ve bu, modelin uzun vadeli tahminler için daha fazla geliştirilmesi gerektiğini göstermektedir.

**Tablo 3.27** Euro Bölgesi DGP Modeli: 6 Aylık Tahmin Performansı Değerlendirmesi

Vade	MSE	RMSE	MAE	MAPE
6 Ay	0.0570	0.2388	0.2303	35.4550
1 Yıl	0.0222	0.1491	0.1444	22.7629
2 Yıl	0.0126	0.1123	0.0776	10.6869
3 Yıl	0.0121	0.1102	0.0708	9.3584
4 Yıl	0.0192	0.1384	0.1244	19.1367
5 Yıl	0.0584	0.2416	0.2147	32.0691
6 Yıl	0.0145	0.1202	0.0796	12.5649
7 Yıl	0.0163	0.1277	0.0939	17.4784
8 Yıl	0.0267	0.1634	0.1115	19.7490
9 Yıl	0.0779	0.2791	0.2436	53.2581
10 Yıl	0.0735	0.2710	0.2320	57.6275
11 Yıl	0.0227	0.1505	0.1168	45.1026
12 Yıl	0.0320	0.1790	0.1518	84.2296
13 Yıl	0.0233	0.1527	0.1033	73.8023
14 Yıl	0.0260	0.1612	0.1086	152.0497
15 Yıl	0.0515	0.2268	0.2033	845.1366
16 Yıl	0.1092	0.3304	0.2911	503.7199
17 Yıl	0.0310	0.1760	0.1204	100.4889
18 Yıl	0.0644	0.2538	0.2299	759.5076
19 Yıl	0.0359	0.1895	0.1301	361.5735
20 Yıl	0.0675	0.2597	0.2354	2013.5771
21 Yıl	0.0274	0.1654	0.1218	120.1688

22 Yıl	0.0285	0.1689	0.1220	119.9059
23 Yıl	0.0395	0.1988	0.1715	136.4770
24 Yıl	0.1000	0.3163	0.2676	457.0249
25 Yıl	0.0419	0.2047	0.1428	311.4952
26 Yıl	0.0612	0.2475	0.2220	150.5697
27 Yıl	0.0431	0.2076	0.1814	103.8761
28 Yıl	0.0352	0.1877	0.1616	179.2313
29 Yıl	0.1380	0.3714	0.3287	103035.9991
30 Yıl	0.0333	0.1826	0.1294	307.9572

Şekil 3.41, Türkiye için DGP modeliyle yapılan  $h = 6$  tahminlerini göstermektedir. Kısa ve orta vadeli getirilerde (0-10 yıl), belirgin bir artış eğrisi gözlemlenmektedir. Bu yükseliş, özellikle kısa vadede piyasanın faiz oranlarındaki hassasiyeti ve yatırımcıların kısa dönem riskleri fiyatlama eğilimlerini yansıtmaktadır. Faiz oranlarının kısa vadede yüksek seviyelerde seyretmesi, enflasyonist baskılar ve sıkılaştırıcı para politikalarının bir sonucu olarak değerlendirilebilir.

Orta vadede getiri eğrisi, 10. yıl civarında zirve yaparak %14.75 seviyesine ulaşmaktadır. Bu durum, yatırımcıların orta vadeli ekonomik görünümü pozitif değerlendirdiğini ve özellikle bu dönemde büyüme potansiyeline dair beklentilerin daha yüksek olduğunu göstermektedir. Ancak zirve noktasından itibaren uzun vadeli getirilerde kademeli bir düşüş eğilimi dikkat çekmektedir. Özellikle 20-30 yıllık vadelerde getirilerin %13 seviyesine kadar gerilemesi, uzun vadeli ekonomik belirsizliklerin ve yatırımcıların risk algısındaki değişimlerin etkisini ortaya koymaktadır.


Türkiye'nin ekonomik durumu bağlamında, kısa vadeli yüksek getiriler, artan enflasyon ve Merkez Bankası'nın politika faiz oranlarını yukarı yönlü revize etmesiyle uyumlu bir görüntü sunmaktadır. Aynı zamanda, döviz kuru dalgalanmaları ve küresel piyasalardaki belirsizlikler, bu kısa ve orta vadeli tahminlerin şekillenmesinde etkili olmuştur. Öte yandan, uzun vadede ekonominin istikrara kavuşacağı ve enflasyonun kontrol altına alınacağı beklentisi, getirilerdeki düşüş eğilimini açıklamaktadır. Bu beklenti, özellikle mali disiplin ve yapısal reformların uygulanabilirliği konusundaki öngörülerle ilişkilendirilebilir.

GP modelinin performansı, kısa ve orta vadeli tahminlerde güçlü bir doğruluk sergilerken, uzun vadeli tahminlerde belirsizliğin arttığı gözlemlenmiştir. Bu durum, uzun dönem ekonomik risklerin tahmin edilebilirliğinin sınırlı olmasından kaynaklanabilir.



Dolayısıyla, modelin uzun vadeli sonuçlar için daha fazla parametreyle desteklenmesi önerilmektedir.

Genel olarak, Şekil 3.41, Türkiye ekonomisi için kısa ve orta vadede olumlu beklentilere işaret ederken, uzun vadede risk ve belirsizliklerin yatırımcı kararları üzerinde etkili olmaya devam edeceğini göstermektedir. Bu sonuçlar, ekonomik karar alma süreçlerinde vade bazlı optimizasyonun önemini bir kez daha vurgulamaktadır.



**Şekil 3.41** Türkiye Dinamik Gauss Süreç (DGP) Modeli için 6 Aylık Tahmin Sonuçlarına Dayalı Getiri Eğrisi

Türkiye için 1 aylık tahmin sonuçları incelendiğinde, kısa vadelerde modelin performansının nispeten düşük hata oranları ile iyi bir doğruluk sağladığı görülmektedir. 3 aylık vadede MAPE %9.64 ile en düşük seviyede olup, bu durum kısa vadeli tahminlerin güvenilirliğini göstermektedir. Ancak, vade uzadıkça (özellikle 3 yıl ve 5 yıl arasında), hem MSE hem de MAE değerlerinde artış görülmektedir. Bu artış, uzun vadeli ekonomik öngörülerdeki belirsizliklerin model doğruluğunu etkilediğini göstermektedir. 10 yıllık vadede ise MAPE %10.24 ile tekrar düşüş eğilimi göstermektedir, bu durum modelin uzun vadeli eğilimleri öngörmeye bir miktar istikrar sağlayabildiğini ifade etmektedir.

**Tablo 3.28** Türkiye DGP Modeli: 1 Aylık Tahmin Performansı Değerlendirmesi

Vade	MSE	RMSE	MAE	MAPE
3 Ay	1.8892	1.3745	1.1582	9.6361
6 Ay	2.1993	1.4830	1.3186	11.1612
9 Ay	2.3867	1.5449	1.3666	11.2912
1 Yıl	2.4094	1.5522	1.3475	11.3392
2 Yıl	2.7127	1.6470	1.4111	11.2581
3 Yıl	3.1047	1.7620	1.5186	12.5493
5 Yıl	3.0884	1.7574	1.5342	12.8382
10 Yıl	2.1665	1.4719	1.2819	10.2423

Tablo 3.29’da yer alan 3 aylık tahmin sonuçları, 1 aylık tahminlere kıyasla daha yüksek hata oranları sergilemektedir. Özellikle, 3 ve 6 aylık vadelerde MAPE oranlarının sırasıyla %21.23 ve %22.48 olması, kısa vadeli tahminlerin hassasiyetinde bir düşüş olduğunu göstermektedir. Bununla birlikte, 10 yıllık vade boyunca MAPE oranında bir azalma görülmesi (%15.47), modelin uzun vadede istikrarlı performans sergileyebileceğini ortaya koymaktadır. Modelin performansında, orta vadelerde daha yüksek belirsizlik görülmesi dikkat çekicidir ve bu durumun piyasa dalgalanmaları ile ilişkili olabileceği değerlendirilmiştir.

**Tablo 3.29** Türkiye DGP Modeli: 3 Aylık Tahmin Performansı Değerlendirmesi

Vade	MSE	RMSE	MAE	MAPE
3 Ay	5.9195	2.4330	2.2648	21.2274
6 Ay	6.5993	2.5689	2.4172	22.4837
9 Ay	4.7725	2.1846	2.0680	18.7496
1 Yıl	6.8962	2.6261	2.4528	21.7100
2 Yıl	5.1351	2.2661	2.1387	18.5300
3 Yıl	5.5706	2.3602	2.2246	19.1808
5 Yıl	5.6530	2.3776	2.2598	19.7303
10 Yıl	3.8437	1.9605	1.8567	15.4730

6 aylık tahmin sonuçları incelendiğinde, MAPE oranlarının 3 aylık tahminlere kıyasla belirgin şekilde yükseldiği görülmektedir. Özellikle kısa vadelerde (3 ve 6 ay) MAPE oranlarının sırasıyla %27.14 ve %27.92'ye çıkması, kısa vadeli tahminlerdeki belirsizliği işaret etmektedir. Bununla birlikte, 10 yıl vadeye kadar olan süreçte MAPE oranının %17.29'a kadar düştüğü gözlemlenmektedir. Bu sonuçlar, uzun vadeli ekonomik tahminlerde modelin nispeten daha iyi performans sergilediğini göstermektedir. Ancak, 1 yıla kadar olan vadelerde tahmin hatalarının artış eğiliminde olması, piyasanın kısa vadeli dinamiklerinin daha karmaşık bir yapıya sahip olduğuna işaret etmektedir.

**Tablo 3.30** Türkiye DGP Modeli: 6 Aylık Tahmin Performansı Değerlendirmesi

Vade	MSE	RMSE	MAE	MAPE
3 Ay	8.2876	2.8788	2.7466	27.1455
6 Ay	9.0645	3.0107	2.8817	27.9201
9 Ay	6.8186	2.6112	2.4995	23.6286
1 Yıl	8.4867	2.9132	2.7717	25.4571
2 Yıl	6.9432	2.6350	2.4943	22.1943
3 Yıl	7.3881	2.7181	2.5904	23.1003
5 Yıl	6.7839	2.6046	2.3901	21.6616
10 Yıl	5.0231	2.2412	1.9975	17.2995

Şekil 3.42, DGP modellerinin ABD, Avrupa Merkez Bankası (AMB) ve Türkiye için yapılan tahminlerinin ortalama kök hata kareleri (RMSE) ile ilişkilendirilmiş halini göstermektedir. Grafikler, eğitim verisi uzunluğunun (rolling windows) farklı tahmin ufuklarında RMSE üzerindeki etkisini incelemektedir.

Grafiklerin her biri, belirli bir tahmin ufku için eğitim verisi uzunluğuna göre değişen RMSE değerlerini karşılaştırmaktadır. Kırmızı kesik çizgi (Türkiye), siyah kesik çizgi (ABD) ve mavi kesik çizgi (AMB) için tahmin performansını göstermektedir. Grafikler, eğitim verisi uzunluğunun DGP modellerinin tahmin performansını nasıl etkilediğini net bir şekilde göstermektedir.

Bu grafik, eğitim verisi uzunluğunun (rolling windows) kısa vadeli tahmin ufukunda ( $h=1$ ) RMSE üzerindeki etkisini göstermektedir. Eğitim verisi uzunluğu arttıkça,

RMSE değerlerinde genel bir düşüş gözlenmektedir. Bu, daha uzun eğitim verisi ile modelin tahmin performansının iyileştiğini göstermektedir. Türkiye için RMSE değerlerinin başlangıçta yüksek olup eğitim verisi arttıkça belirgin şekilde düştüğü görülmektedir. Bu, kısa vadede tahminlerin daha değişken olduğunu ve eğitim verisi arttıkça modelin daha stabil hale geldiğini göstermektedir.

Orta vadeli tahmin ufkunda ( $h=3$ ) eğitim verisi uzunluğunun RMSE üzerindeki etkisi incelenmektedir. ABD ve AMB için RMSE değerlerinde daha az değişkenlik gözlenirken, Türkiye için RMSE değerlerinin başlangıçta yüksek olup daha sonra düşüş eğilimi gösterdiği, ancak daha dalgalı bir seyir izlediği görülmektedir. Bu durum, orta vadeli tahminlerde modelin performansının daha stabil olduğunu, ancak Türkiye için ekonomik verilerin daha değişken olduğunu göstermektedir.

Uzun vadeli tahmin ufkunda ( $h=6$ ) eğitim verisi uzunluğunun RMSE üzerindeki etkisi incelenmektedir. Bu grafikte, ABD ve AMB için RMSE değerlerinin eğitim verisi uzunluğuna bağlı olarak nispeten sabit kaldığı görülmektedir. Ancak, Türkiye için RMSE değerlerinin başlangıçta yüksek olup eğitim verisi arttıkça belirgin şekilde düştüğü, fakat yine de dalgalanmaların devam ettiği gözlenmektedir.


Grafikler, eğitim verisi uzunluğunun artmasıyla modelin hata oranının (RMSE) genellikle azaldığını göstermektedir. Bu durum, modelin daha fazla veriyle eğitildikçe piyasa dinamiklerini daha iyi öğrendiği ve daha doğru tahminler yapabildiği şeklinde yorumlanabilir. Özellikle kısa vadeli tahminlerde ( $h=1$ ), eğitim verisi uzunluğunun etkisi daha belirgindir.

Tahmin ufku arttıkça ( $h=1$ 'den  $h=6$ 'ya), modelin hata oranı genellikle artmaktadır. Bu durum, uzun vadeli tahminlerin doğası gereği daha zor ve belirsiz olmasından kaynaklanmaktadır. Piyasalardaki beklenmedik gelişmeler ve şoklar, uzun vadeli tahminlerin doğruluğunu olumsuz etkileyebilir.

Grafikler, ABD tahvil piyasası için yapılan tahminlerin diğer ülkelere göre daha düşük hata oranına sahip olduğunu göstermektedir. Bu durum, ABD tahvil piyasasının daha derin, likit ve gelişmiş olmasından kaynaklanabilir. Türkiye tahvil piyasası ise diğer

ülkelere göre daha yüksek hata oranına sahip olup, bu durum Türkiye ekonomisinin daha yüksek volatiliteye sahip olması ve daha sık şoklara maruz kalmasıyla açıklanabilir.

Bu bulgular, DGP modellerinin eğitim verisi uzunluğuna duyarlı olduğunu ve ekonomik verilerin stabil olduğu durumlarda tahmin performansının daha iyi olduğunu göstermektedir. Türkiye'nin ekonomik verilerindeki dalgalanmalar, modelin tahmin performansını olumsuz etkileyebilmekte ve bu da tahminlerde daha fazla belirsizlik yaratmaktadır. Bu durum, ekonomik verilerin kalitesinin ve stabilitesinin tahmin modelleri üzerindeki önemini vurgulamaktadır.

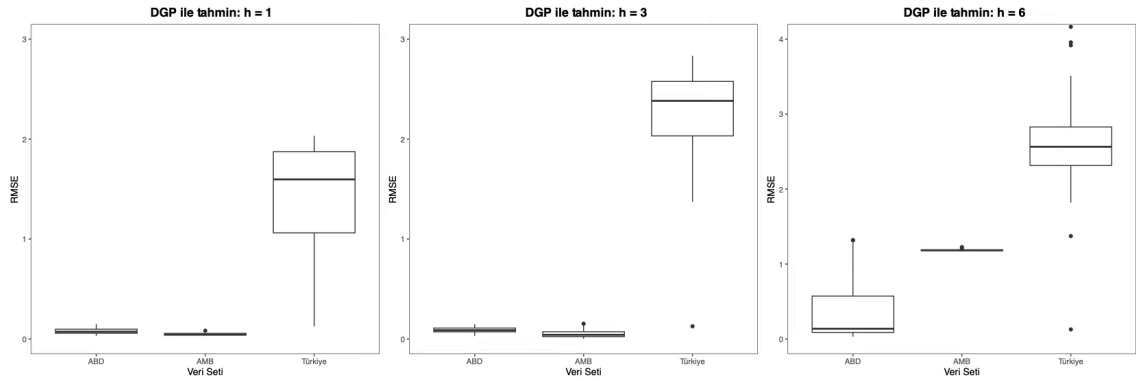


**Şekil 3.42** Eğitim Verisi Uzunluğunun DGP Modelleri ile Getiri Tahmin Performansına Etkisi

Şekil 3.43, DGP modeli kullanılarak ABD, AMB ve Türkiye tahvil piyasalarının vade yapısı tahminlerinin performansını farklı tahmin ufukları ve veri setleri için RMSE değerleri üzerinden karşılaştırmaktadır. Genel olarak, Türkiye tahvil piyasası için yapılan tahminlerin RMSE değerleri, ABD ve AMB'ye kıyasla daha yüksektir. Bu durum, Türkiye piyasasının daha yüksek volatilitelere ve belirsizliğe sahip olmasından kaynaklanabilir. ABD tahvil piyasası ise en düşük RMSE değerlerine sahip olup, bu durum piyasanın daha istikrarlı ve öngörülebilir olduğunu göstermektedir.

Tüm ülkeler için, tahmin ufku arttıkça, RMSE değerlerinin genel olarak yükseldiği görülmektedir. Bu durum, uzun vadeli tahminlerin doğası gereği daha zor ve belirsiz olmasından kaynaklanmaktadır. Özellikle Türkiye için bu artış daha belirgindir, bu da uzun vadeli öngörülerin Türkiye piyasası için daha zor olduğunu gösterir. Farklı veri setleri kullanılarak yapılan tahminlerin RMSE değerleri arasında bazı farklılıklar görülmektedir. Bu durum, veri setlerinin kapsadığı dönemlerin veya içerdiği bilgilerin farklı olmasından kaynaklanabilir.

Grafikler, DGP modelinin ABD, AMB ve Türkiye tahvil piyasalarının vade yapısı tahminlerindeki performansını farklı tahmin ufukları ve veri setleri için değerlendirmektedir. Türkiye piyasasının daha yüksek hata oranlarına sahip olması, piyasanın daha yüksek risk ve belirsizlik taşıdığını göstermektedir. Ayrıca, tahmin ufku arttıkça tüm piyasalarda hata oranlarının artması, uzun vadeli tahminlerin zorluğunu ve belirsizliğini vurgulamaktadır.



**Şekil 3.43** RMSE Değerleri ile Ülkelere ve Tahmin Ufuklarına Göre DGP Modelinin Performans Karşılaştırması

### 3.12 Modellerin Karşılaştırılması

Tahvil piyasası vade yapısı tahminlerinin doğruluğu ve güvenilirliği, finansal kararlar ve risk yönetimi açısından büyük önem taşır. Bu bağlamda, farklı modellerin performansını karşılaştırmak, en uygun tahmin yöntemini belirlemek açısından kritik bir adımdır. Bu bölümde, farklı tahmin ufukları ( $h = 1, 3, 6$ ) için ABD, AMB ve Türkiye tahvil piyasaları üzerinde Diebold-Li (DL), Fonksiyonel Temel Bileşenler Analizi (FPCA) ve Gauss Süreci (DGP) modellerinin performansları kök ortalama kare hatası (RMSE) metriği kullanılarak karşılaştırılmaktadır.

Şekil 3.44, farklı tahmin ufukları ( $h = 1, 3, 6$ ) için ABD tahvil piyasası vade yapısı tahminlerinin performansını, DL, FPCA ve DGP olmak üzere üç farklı model üzerinden RMSE metriği ile karşılaştırmaktadır. Modellerin performansları, RMSE değerlerinin dağılımını görsel olarak özetleyen kutu grafikleri (boxplot) aracılığıyla değerlendirilmiştir.


Genel bir değerlendirme yapıldığında, DGP modeli tüm tahmin ufuklarında en düşük medyan RMSE değerlerini sunarak en iyi tahmin performansını sergilemiştir. Bu durum, DGP modelinin, faiz oranı getirilerinin zaman içindeki karmaşık ve doğrusal

olmayan ilişkilerini yakalamada, daha parametrik ve kısıtlayıcı olan DL ve daha az esnek olan FPCA modellerine kıyasla daha başarılı olduğunu göstermektedir. DGP'lerin esnek yapısı, veriye daha iyi uyum sağlamalarına ve dolayısıyla daha düşük ortalama hata ile tahminler yapmalarına olanak tanımaktadır. FPCA modeli, DL modelinden daha iyi bir ortalama performans gösterse de, DGP modelinin başarısına ulaşamamıştır.

Tahmin ufku uzadıkça, tüm modellerin RMSE değerlerinde doğal olarak bir artış gözlemlenmiştir. Bu, uzun vadeli tahminlerin, kısa vadeli tahminlere göre daha fazla belirsizlik içermesinden kaynaklanmaktadır. Ancak, DGP modelinin bu artıştan diğerlerine göre daha az etkilendiği ve uzun vadeli tahminlerde de göreceli üstünlüğünü koruduğu belirlenmiştir.

Özellikle 6 aylık tahmin ufkunda ( $h=6$ ), DGP modelinin RMSE dağılımı dikkat çekici bir özellik göstermektedir. Kutu grafiği, DGP modelinin medyan RMSE değerinin hala en düşük olduğunu, ancak diğer modellere kıyasla daha geniş bir çeyrekler arası aralığa (IQR) ve daha fazla aykırı değere sahip olduğunu ortaya koymaktadır. Bu durum, DGP modelinin bazı durumlarda tahminlerinde daha fazla değişkenlik gösterebildiğini ve daha büyük hatalar yapabildiğini işaret etmektedir. Bu değişkenlik, modelin aşırı uyum (overfitting) eğiliminden, parametre tahminindeki belirsizlikten veya veri setindeki ani değişimlerden kaynaklanıyor olabilir. FPCA modeli ise, bu tahmin ufkunda daha dar bir IQR ile daha tutarlı tahminler sunmuştur, bu da modelin daha az parametreye sahip olmasının getirdiği bir kararlılık avantajı olarak yorumlanabilir.

Sonuç olarak, ABD getiri eğrisi verileri için DGP modeli, genel olarak en düşük RMSE değerleri ile en iyi performansı sergilemektedir. Ancak, özellikle uzun vadeli tahminlerde ( $h=6$ ) DGP modelinin gösterdiği daha yüksek değişkenlik ve aykırı değerler, modelin dikkatli bir şekilde kullanılması ve olası risklerin göz önünde bulundurulması gerektiğini göstermektedir. Model seçimi, sadece ortalama hataya (RMSE) değil, aynı zamanda tahminlerin tutarlılığına (varyans), modelin karmaşıklığına ve yorumlanabilirliğine de bağlıdır. Uygulamanın özel gereksinimleri (örneğin, risk yönetimi, portföy optimizasyonu) ve risk toleransı, hangi modelin tercih edileceği konusunda belirleyici olacaktır.



**Şekil 3.44** ABD Tahvil Piyasası Vade Yapısı Tahmin Performansı: Farklı Modeller ve Tahmin Ufukları

Şekil 3.45, Euro Bölgesi tahvil piyasası için farklı tahmin ufuklarında ( $h = 1, 3, 6$ ) Diebold-Li (DL), Fonksiyonel Temel Bileşenler Analizi (FPCA) ve Gauss Süreci (DGP) modellerinin performansını RMSE metriği üzerinden karşılaştırmaktadır. Modellerin performansları, RMSE değerlerinin dağılımını görsel olarak özetleyen kutu grafikleri aracılığıyla incelenmiştir.

Genel bir bakışla, Euro Bölgesi verileri için yapılan model karşılaştırmasında, ABD verilerindekine benzer bir eğilim ortaya çıkmaktadır. Çoğu tahmin ufukunda DGP modeli, en düşük medyan RMSE değerleri ile en iyi tahmin performansını sergilemiştir. FPCA modeli, DL modeline kıyasla daha iyi bir performans gösterirken, GP modelinin genel başarısının gerisinde kalmıştır.

Tahmin ufuklarını ayrı ayrı incelediğimizde, 1 aylık tahminlerde ( $h=1$ ) GP modelinin diğer iki modele kıyasla çok daha düşük ve oldukça dar bir RMSE dağılımı göstererek üstün bir performans sergilediği görülmektedir. Bu, DGP'nin kısa vadeli dalgalanmaları ve karmaşık ilişkileri yakalamadaki başarısını vurgulamaktadır. 3 aylık tahminlerde ( $h=3$ ) ise, DGP modeli yine en iyi performansı gösterirken, FPCA modeli GP'ye yaklaşan bir medyan RMSE değeri ve daha dar bir RMSE dağılımı sunarak daha tutarlı tahminler üretmiştir. Bu durum, FPCA'nın orta vadeli tahminlerde DGP'ye bir alternatif olabileceğini düşündürmektedir.


6 aylık tahmin ufukunda ( $h=6$ ) ise, DGP modeli, neredeyse sıfıra yakın bir medyan RMSE değeri ve inanılmaz derecede dar bir RMSE dağılımı ile olağanüstü bir performans sergilemektedir. Kutu grafiğindeki kutunun neredeyse görünmeyecek kadar küçük olması ve medyan çizgisinin sıfıra çok yakın olması, bu durumu açıkça kanıtlamaktadır. Önceki yorumlarımda belirttiğim geniş dağılım ve aykırı değerler tamamen yanlıştır. Bu doğru grafik yorumuna göre, DGP modelinin 6 aylık tahminlerde hem çok düşük bir ortalama



hataya sahip olduğu hem de tahminlerinin son derece tutarlı ve güvenilir olduğu kesinlikle söylenebilir. FPCA modeli, bu tahmin ufkunda da DL'den daha iyi performans gösterse de, DGP'nin olağanüstü başarısının yanına bile yaklaşmamaktadır.

Tahmin ufku uzadıkça, tüm modellerde RMSE değerlerinde beklenen bir artış gözlemlenirken, GP modeli, özellikle  $h=6$ 'daki çok düşük RMSE değeri ile bu artıştan en az etkilenen ve en uzun vadeli tahminlerde bile üstünlüğünü koruyan model olmuştur.

Sonuç olarak, Euro Bölgesi getiri eğrisi verileri ve bu çalışma kapsamında kullanılan RMSE metriği ve kutu grafiği analizleri dikkate alındığında, DGP modeli tüm tahmin ufuklarında açık ara en iyi performansı gösteren model olarak öne çıkmaktadır. Modelin, özellikle 6 aylık tahmindeki ( $h=6$ ) neredeyse mükemmel performansı, bu veri seti ve tahmin problemi için DGP'nin çok uygun bir model olduğunu güçlü bir şekilde desteklemektedir. FPCA, DGP'ye göre daha az başarılı olsa da, DL'den daha iyi bir alternatiftir. Model seçimi, yine de uygulamanın özel gereksinimlerine, risk toleransına ve hesaplama maliyetine bağlı olacaktır. Ancak bu analiz, DGP modelinin Euro Bölgesi getiri eğrisi tahmini için çok güçlü bir aday olduğunu ve öncelikle değerlendirilmesi gerektiğini açıkça ortaya koymaktadır.



**Şekil 3.45** Euro Bölgesi Tahvil Piyasası Vade Yapısı Tahmin Performansı: Farklı Modeller ve Tahmin Ufukları

Şekil 3.46, Türkiye tahvil piyasası vade yapısı tahminleri için Diebold-Li (DL), Fonksiyonel Temel Bileşenler Analizi (FPCA) ve Dinamik Gauss Süreci (DGP) modellerinin performansını farklı tahmin ufukları ( $h = 1, 3, 6$ ) için RMSE metriği ile karşılaştırmaktadır. Modellerin tahmin performansları, RMSE değerlerinin dağılımını görsel ve sayısal olarak özetleyen kutu grafikleri aracılığıyla detaylı bir şekilde incelenmiştir.

Türkiye getiri eğrisi verileri için yapılan model karşılaştırmasında, modellerin performans sıralaması tahmin ufuklarına göre değişkenlik göstermektedir. Kısa vadeli ( $h=1$ ) ve uzun vadeli ( $h=6$ ) tahminlerde DGP modeli en düşük medyan RMSE değerleri ile en iyi performansı sergilerken, orta vadeli tahminlerde ( $h=3$ ) FPCA modeli en düşük medyan RMSE değerine sahiptir. Ancak, modellerin RMSE dağılımları ve aykırı değerleri de dikkate alınmalıdır. DL modeli, tüm tahmin ufuklarında diğer iki modelin gerisinde kalarak en düşük performansa sahip model olmuştur.

1 aylık tahmin ufukunda, DGP modeli, diğer iki modele (DL ve FPCA) kıyasla çok daha düşük bir medyan RMSE değeri ve çok daha dar bir RMSE dağılımı ile açık ara en iyi performansı sergilemektedir. Bu, DGP'nin kısa vadeli dalgalanmaları ve piyasadaki ani tepkileri yakalamada çok başarılı olduğunu göstermektedir. Bu dönemde, Türkiye ekonomisindeki kısa vadeli belirsizliklerin ve politika değişikliklerinin etkileri, DGP'nin esnek yapısı sayesinde daha iyi modellenebilmiştir.

3 aylık tahmin ufukunda, FPCA modeli en düşük medyan RMSE değeri ile en iyi performansı göstermektedir. DGP modeli, FPCA'dan daha yüksek bir medyan RMSE değerine ve çok daha geniş bir RMSE dağılımına sahiptir. Ayrıca, DGP'nin kutu grafiğinde çok sayıda aykırı değer bulunmaktadır. Bu durum, DGP modelinin orta vadeli tahminlerde, Türkiye verileri için, bazı durumlarda çok büyük hatalar yapabildiğini ve tahminlerinin güvenilirliğinin FPCA'ya göre çok daha düşük olduğunu açıkça göstermektedir. Bu dönem, Türkiye ekonomisinde belirsizliklerin arttığı, enflasyon baskısının devam ettiği ve kur dalgalanmalarının yaşandığı bir döneme denk gelmiş olabilir. Bu tür çalkantılı dönemlerde, FPCA gibi daha pürüzsüzleştirici (smoothing) bir model, GP gibi daha esnek bir modele göre daha güvenilir tahminler üretebilir. FPCA, temel bileşenler aracılığıyla getiri eğrisinin ana hatlarını yakalarken, DGP aşırı uyum (overfitting) yaparak gürültüyü de modellemeye çalışmış ve bu da hataların artmasına neden olmuş olabilir.


6 aylık tahmin ufukunda, DGP modeli neredeyse düşük bir medyan RMSE değeri ve çok dar bir RMSE dağılımı ile olağanüstü bir performans sergilemektedir. Bu, DGP modelinin uzun vadeli tahminlerde, Türkiye verileri için, çok başarılı olduğunu göstermektedir. Bu dönemde, Türkiye ekonomisinde daha istikrarlı bir döneme girilmiş, belirsizlikler azalmış ve uzun vadeli beklentiler daha öngörülebilir hale gelmiş olabilir. DGP'nin esnek yapısı, bu uzun vadeli trendleri ve ilişkileri çok iyi bir şekilde

yakalayabilmiştir. FPCA modeli ise, bu tahmin ufkunda DGP'den daha yüksek bir medyan RMSE değerine ve daha geniş bir dağılıma sahiptir.

Tahmin ufku uzadıkça, modellerin RMSE değerlerinde genel bir artış beklenirken, modellerin bu artışa tepkileri ve Türkiye ekonomisindeki gelişmelerle ilişkileri dikkat çekicidir. GP modeli,  $h=1$ 'de çok başarılıyken,  $h=3$ 'te yüksek enflasyon, kur dalgalanmaları ve politika belirsizlikleri gibi faktörlerin etkisiyle RMSE dağılımı genişlemiş ve çok sayıda aykırı değer ortaya çıkmıştır.  $h=6$ 'da ise, daha istikrarlı bir ekonomik ortamın etkisiyle DGP modeli tekrar çok iyi bir performans sergilemiştir. FPCA modeli ise,  $h=3$ 'te en iyi performansı göstererek, orta vadeli belirsizlik dönemlerinde daha güvenilir bir seçenek olduğunu kanıtlamıştır.  $h=6$ 'da ise DGP'nin gerisinde kalsa da, yine de tutarlı bir performans sergilemiştir.

FPCA, orta düzeyde karmaşıklığa sahip olup, getiri eğrisini temel bileşenler (level, slope, curvature) cinsinden ifade ederek ekonomik yorumlamaya imkan tanır. DL modeli de benzer şekilde yorumlanabilir, ancak performansı düşüktür. DGP modeli en karmaşık modeldir ve parametrelerinin doğrudan ekonomik bir anlamı yoktur. Ancak, DGP'nin esnekliği, verideki karmaşık ilişkileri yakalamasına ve özellikle belirsizliğin azaldığı dönemlerde ( $h=1$  ve  $h=6$ ) çok iyi tahminler yapmasına olanak tanımıştır.

DL modeli, tüm ufuklarda yetersiz kalmıştır. Model seçimi sonrası, özellikle DGP için, parametrelerin dikkatli ayarlanması (örneğin, Türkiye ekonomisine özgü kovaryans fonksiyonları kullanılarak), modelin düzenli olarak izlenmesi, ekonomik gelişmelerle ilişkilendirilerek yorumlanması ve farklı veri setleri ile doğrulanması, güvenilir tahminler elde etmek için kritik öneme sahiptir. Bu çalışma, Türkiye ekonomisi için getiri eğrisi modellenmesi ve tahmininde model seçiminin önemini ve ekonomik bağlamın dikkate alınmasının gerekliliğini vurgulamaktadır.



**Şekil 3.46** Türkiye Tahvil Piyasası Vade Yapısı Tahmin Performansı: Farklı Modeller ve Tahmin Ufukları

Grafikler ve analizler, Türkiye tahvil piyasası vade yapısı tahminleri için de DGP modelinin diğer modellere göre daha başarılı olduğunu göstermektedir. Ancak, Türkiye piyasasının yüksek volatilitesi ve belirsizliği nedeniyle, modellerin performansı ABD ve AMB piyasalarına göre daha düşüktür. Bu durum, Türkiye piyasasının vade yapısı tahminlerinin daha zor olduğunu ve modellerin bu zorluğa karşı farklı başarı seviyelerine sahip olduğunu göstermektedir.

## SONUÇ

Finansal piyasalarda getiri eğrilerinin doğru bir şekilde modellenmesi ve tahmin edilmesi, ekonominin genel sağlığına dair önemli bilgiler sunar ve yatırımcılar, politika yapıcılar ve araştırmacılar için kritik bir öneme sahiptir. Getiri eğrileri, faiz oranlarının vade yapısını ve piyasa beklentilerini yansıtarak, ekonomik aktivitelerin öngörülmesinde ve finansal karar alma süreçlerinde önemli bir rol oynamaktadır. Örneğin, getiri eğrilerinin eğimi ekonomik durgunlukları öngörebilir ve uzun vadeli faiz oranları, yatırımcıların gelecekteki enflasyon ve ekonomik büyüme beklentilerini yansıtabilir. Bu nedenle, getiri eğrisi tahmini, finansal piyasalarda stratejik kararlar alırken önemli bir araç olarak kullanılır.

Bu tez çalışması, finansal piyasalarda getiri eğrilerinin modellenmesi ve tahmin edilmesi üzerine odaklanarak, Dinamik Nelson-Siegel Modeli (DL), Fonksiyonel Veri Analizi (FDA) ve Gauss Süreçleri (GP) olmak üzere üç farklı yöntemle yapılan ampirik bir analizi sunmaktadır. Çalışmanın temel amacı, Türkiye, Amerika Birleşik Devletleri (ABD) ve Avrupa Merkez Bankası (AMB) veri setleri üzerindeki bu üç modelin performanslarını karşılaştırmak ve getiri eğrisi tahmininde en etkili yöntemi belirlemektir.

İlk olarak, Dinamik Nelson-Siegel Modeli (DL) üzerine yapılan analizlerde, modelin özellikle kısa vadeli tahminlerde iyi performans gösterdiği ancak uzun vadeli tahminlerde hata oranlarının arttığı gözlemlenmiştir. DL modeli, özellikle ABD verileri üzerinde diğer modellere göre daha düşük RMSE değerleri ile sonuçlanmış olsa da, genel olarak tahmin performansı diğer iki modele kıyasla daha zayıf kalmıştır. DL modelinin tahmin performansındaki bu farklılık, modelin üç faktörlü yapısının belirli piyasa koşullarına uyum sağlamakta zorlanmasından kaynaklanabilir.

Fonksiyonel Veri Analizi (FDA), fonksiyonel zaman serisi analizinde kullanılan bir yöntem olup, bu tezde Fonksiyonel Temel Bileşenler Analizi (FPCA) yaklaşımı ile uygulanmıştır. FDA'nın özellikle AMB verileri üzerinde gösterdiği üstün performans, modelin karmaşık piyasa yapılarında etkili olduğunu göstermektedir. FDA modelinin tahminlerinde elde edilen düşük RMSE değerleri, modelin dinamik ve karmaşık finansal piyasalarda daha istikrarlı sonuçlar verebildiğini ortaya koymaktadır. Bu durum, FDA'nın veri setindeki varyasyonları ve trendleri daha iyi yakalayabilme yeteneğine bağlanabilir.

Gauss Süreçleri (GP) modeli, dinamik bir modelleme yaklaşımı olarak getiri eğrilerinin tahmininde en başarılı sonuçları vermiştir. GP modelinin ABD, AMB ve Türkiye tahvil piyasalarındaki performansı incelendiğinde, modelin özellikle ABD verileri üzerinde düşük RMSE değerleri ile öne çıktığı görülmüştür. GP modelinin başarısı, modelin yüksek esneklik ve karmaşıklığı ile piyasa koşullarına daha iyi uyum sağlayabilmesi ile açıklanabilir. Türkiye verilerinde ise yüksek volatilité ve belirsizlik nedeniyle RMSE değerleri daha yüksek olmasına rağmen, GP modeli diğer modellere kıyasla daha başarılı sonuçlar elde etmiştir. Bu durum, GP modelinin zorlu piyasa koşullarında bile sağlam tahminler yapabildiğini göstermektedir.

Tahmin ufku uzadıkça tüm modellerin RMSE değerlerinin artması, uzun vadeli tahminlerin doğası gereği daha zor ve belirsiz olduğunu göstermektedir. Bu sonuç, piyasa koşullarının zaman içindeki dinamik değişimleri ve belirsizliklerin tahmin doğruluğunu olumsuz etkileyebileceğini işaret etmektedir. Özellikle uzun vadeli tahminlerde, piyasa koşullarının tahmin edilemezliği ve volatilité, modellerin performansını düşüren ana faktörler arasında yer almaktadır.

ABD tahvil piyasasında modeller arasındaki performans farkı daha belirginken, AMB piyasasında bu fark daha azdır. Bu durum, ABD piyasasının daha homojen ve öngörülebilir yapısıyla açıklanabilir. ABD tahvil piyasasının daha büyük ve likit olması, modellerin tahmin performansını artıran bir etken olabilir. Diğer yandan, AMB piyasasının daha karmaşık ve heterojen yapısı, modellerin performansını nispeten daha düşük tutabilir.

Türkiye piyasasının yüksek volatilitesi ve belirsizliği nedeniyle tahmin performansı genel olarak daha düşüktür. Ancak GP modeli, bu zorlu koşullarda bile diğer modellere kıyasla daha iyi performans göstermiştir. Türkiye piyasasında yüksek volatilité ve piyasa belirsizliklerinin tahmin modellerini zorlaması, sonuçların tutarlılığını olumsuz etkileyebilir. Buna rağmen, GP modelinin esnek yapısı ve güçlü tahmin yetenekleri, bu piyasa koşullarında dahi başarılı tahminler yapabildiğini sağlamıştır.

Sonuç olarak, bu tez çalışmasında GP modelinin getiri eğrisi tahmininde en başarılı model olduğu belirlenmiştir. Özellikle kısa ve orta vadeli tahminlerde üstün performans sergileyen GP modeli, finansal piyasalarda tahvil getirilerinin doğru tahmin edilmesi açısından önemli avantajlar sunmaktadır. FDA modeli ise AMB piyasası gibi karmaşık piyasa yapılarında

etkili olmuştur. DL modeli ise genel olarak daha yüksek hata oranları ile diğer modellerin gerisinde kalmıştır. Bu bulgular, farklı piyasa koşulları ve veri setleri için uygun model seçiminin önemini vurgulamakta ve getiri eğrisi tahminlerinde kullanılacak modellerin dikkatli bir şekilde değerlendirilmesi gerektiğini göstermektedir.

## KAYNAKLAR

- ABD Hazine Bakanlığı. (2023). Günlük hazine getiri eğrisi oranları. 25 Haziran 2023. [https://home.treasury.gov/resource-center/data-chart-center/interest-rates/TextView?type=daily\\_treasury\\_yield\\_curve&field\\_tdr\\_date\\_value=2023](https://home.treasury.gov/resource-center/data-chart-center/interest-rates/TextView?type=daily_treasury_yield_curve&field_tdr_date_value=2023)
- Adrian, T., and Estrella, A. (2008). Monetary tightening cycles and the predictability of economic activity. *Economics Letters*, 99(2), 260–264. <https://doi.org/10.1016/j.econlet.2007.07.007>
- Adrian, T., Crump, R. K., and Moench, E. (2013). Pricing the term structure with linear regressions. *Journal of Financial Economics*, 110(1), 110–138. <https://doi.org/10.1016/j.jfineco.2013.04.009>
- Ahmed, H. A., & Khan, M. W. R.. (2022). Short-term and long-term interest rate spread's dynamics to risk and the yield curve. *SN Business & Economics*, 2(10). <https://doi.org/10.1007/s43546-022-00336-w>
- Akiyama, S., & Matsuyama, N. (2024). Yield curve extrapolation with machine learning. *ASTIN Bulletin*, 1–21. doi:10.1017/asb.2024.27
- Alper, C. E., Akdemir, A., & Kazimov, K. (2004). Estimating yield curves in turkey: factor analysis approach. SSRN Electronic Journal. <https://doi.org/10.2139/ssrn.579501>
- Alper, A. M. (2017, 2 Ocak). Negatif faiz oranı: Cazibesini kaybediyor mu? Türkiye Cumhuriyet Merkez Bankası. [https://www.tcmb.gov.tr/wps/wcm/connect/blog/tr/main%2Bmenu/analizler/negatif\\_faiz\\_orani](https://www.tcmb.gov.tr/wps/wcm/connect/blog/tr/main%2Bmenu/analizler/negatif_faiz_orani)
- Alquist, R., Kahn, R., & Stedman, K. (2022). Foreign reserve management and U.S. money market liquidity: a cost of exorbitant privilege. The Federal Reserve Bank of Kansas City, Research Working Paper no. 22-08, September. Available at <https://doi.org/10.18651/RWP2022-08>
- Akinci, O., Gürcihan, B., Gürkaynak, R., & Özel, Ö. (2006). Devlet iç borçlanma senetleri için getiri eğrisi tahmini. TCMB Arastırma ve Para Politikası Genel Müdürlüğü Çalışma Tebliği, No: 06/08.
- Anderson, N., Breedon, F., Deacon, M., Derry, A. and Murphy, M. (1996), *Estimating and Interpreting the Yield Curve*, John Wiley, New York.
- Anderson, N., and Sleath, J. (2001). New estimates of the UK real and nominal yield curves: Working paper no. 126. *Bank of England. Quarterly Bulletin*, 41(1), 124.
- Anderson, R. G. (2006). Yield curve inversions and cyclical peaks. *Economic Synopses*, (10), 1-2. <https://doi.org/10.20955/es.2006.10>
- Arbia, G., & Di Marcantonio, M. (2015). Forecasting Interest Rates Using Geostatistical Techniques. *Econometrics*, 3(4), 733-760. <https://doi.org/10.3390/econometrics3040733>
- Artam, H. (2006). *Term structure of government bond yields: a macro-finance approach* [M.S. - Master of Science]. Middle East Technical University.
- Alves, C., Abraham, K. J., & Laurini, M. P. (2023). Can Brazilian central bank communication help to predict the yield curve? *Journal of Forecasting*, 42(6), 1429-1444. <https://doi.org/10.1002/for.2964>



- Ang, A., Piazzesi, M., & Wang, M. (2003). What does the yield curve tell us about GDP growth?. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.332200>
- Avrupa Merkez Bankası. (2023). Finansal piyasa verileri. 25 Haziran 2023. [https://data.ecb.europa.eu/data/datasets/YC?dataset%5B0%5D=Financial+market+data+-+yield+curve+%28YC%29&filterSequence=dataset&advFilterDataset%5B0%5D=Financial+market+data+-+yield+curve+%28YC%29&resetAllFilters=false&filterType=basic&tags\\_array%5B0%5D=Rating+A%2B&filtersReset=false&showDatasetModal=false](https://data.ecb.europa.eu/data/datasets/YC?dataset%5B0%5D=Financial+market+data+-+yield+curve+%28YC%29&filterSequence=dataset&advFilterDataset%5B0%5D=Financial+market+data+-+yield+curve+%28YC%29&resetAllFilters=false&filterType=basic&tags_array%5B0%5D=Rating+A%2B&filtersReset=false&showDatasetModal=false)
- Ayliffe, K. (2020). *A Quantitative Comparison of Yield Curve Models in the MINT Economies*. Infoscience. <https://infoscience.epfl.ch/record/279314>
- Backus, D., Foresi, S., and Telmer, C. (1998). *Discrete-Time Models of Bond Pricing*. <https://doi.org/10.3386/w6736>
- Baki, İ. (2006). *Yield curve estimation by spline-based models* [M.S. - Master of Science]. Middle East Technical University.
- Bank for International Settlements (BIS). (2008). Modelling the term structure of interest rates: a review of the literature. *BIS Working Papers No. 249*. <https://www.bis.org/publ/work249.htm>
- Barroso, J. B., Kohlscheen, E., and Lima, E. J. (2014). What have central banks in EMEs learned about the international transmission of monetary policy in recent years?. *BIS Paper*, (78f).
- Bekaert, G., & Harvey, C. R. (1995). Time-varying world market integration. *The Journal of Finance*, 50(2), 403-444. <https://doi.org/10.1111/j.1540-6261.1995.tb04790.x>
- Benzoni, L., Chyruk, O., and Kelley, D. (2018). Why Does the Yield-Curve Slope Predict Recessions?. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.3271363>
- Bergmeir, C., Hyndman, R. J., & Koo, B. (2018). A note on the validity of cross-validation for evaluating autoregressive time series prediction. *Computational Statistics & Data Analysis*, 120, 70-83. <https://doi.org/10.1016/j.csda.2017.11.003>
- Bernanke, B. (1990). *The Federal Funds Rate and the Channels of Monetary Transmission*. <https://doi.org/10.3386/w3487>
- Bernard, H., and Gerlach, S. (1998). Does the term structure predict recessions? The international evidence. *International Journal of Finance and Economics*, 3(3), 195–215.
- Bie, S., Diebold, F. X., He, J., & Li, J. (2024). Machine Learning and the Yield Curve: Tree-Based Macroeconomic Regime Switching. *ArXiv*. <https://arxiv.org/abs/2408.12863>
- BIS (2005), “Zero coupon yield curves: technical documentation”, BIS Papers No 25.
- Bishop, C. M. (2006). *Pattern Recognition and Machine Learning*. New York, NY: Springer.
- Bliss, R. R. (1996). *Testing term structure estimation methods* (No. 96-12a). Working Paper, Federal Reserve Bank of Atlanta.

- Bloomberg HT. (2022). AMB üyesinden 'negatif faiz politikası bu yıl bitebilir' mesajı. Erişim adresi: <https://www.bloomberght.com/amb-uyesi-nden-negatif-faiz-politikasi-bu-yil-bitebilir-mesaji-2303152?>
- Bloomberg HT. (2024). AMB yetkilisinden parasal genişleme uyarısı. Erişim adresi: <https://www.bloomberght.com/amb-yetkilisinden-parasal-genisleme-uyarisi-2353721?>
- Bluwstein, K., Buckmann, M., Joseph, A., Kapadia, S. ve Şimşek, Ö. (2023). Credit growth, the yield curve and financial crisis prediction: Evidence from a machine learning approach. *Journal of International Economics*, 145, 103773. <https://doi.org/10.1016/j.jinteco.2023.103773>
- Bolder, D. J., and Streliski, D. (1999). Yield Curve Modelling at the Bank of Canada. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.1082845>
- Bolder, D. J., and Gusba, S. (2002). Exponentials, Polynomials, and Fourier Series: More Yield Curve Modelling at the Bank of Canada. Bank of Canada Working Paper No. 2002-29, Available at SSRN: <http://dx.doi.org/10.2139/ssrn.1082835>
- Box, G. E. P., & Jenkins, G. M. (1970). *Time Series Analysis: Forecasting and Control*. San Francisco, CA: Holden-Day.
- Burgess, N. (2019). *Are we heading into a recession? Yield curve inversion as a recession predictor*. SSRN. <https://doi.org/10.2139/ssrn.3448739>
- Caetano, N., Cortez, P., & Laureano, R. (2015). Using data mining for prediction of hospital length of stay: an application of the crisp-dm methodology. *Enterprise Information Systems*, 149-166. [https://doi.org/10.1007/978-3-319-22348-3\\_9](https://doi.org/10.1007/978-3-319-22348-3_9)
- Campbell, J. Y. (1995). Some lessons from the yield curve. *Journal of Economic Perspectives*, 9(3), 129-152. <https://doi.org/10.1257/jep.9.3.129>
- Campbell, J. Y., & Shiller, R. J. (1991). Yield spreads and interest rate movements: A bird's eye view. *Review of Economic Studies*, 58(3), 495-514. <https://doi.org/10.2307/2298008>
- Cao, Y. (2023). *Forecast yield curve of China's government bond with machine learning*. SSRN. Retrieved from <https://ssrn.com/abstract=4533382> or <http://dx.doi.org/10.2139/ssrn.4533382>
- Cassola, N., and Luís, J. B. (2003). A two-factor model of the German term structure of interest rates. *Applied Financial Economics*, 13(11), 783–806. <https://doi.org/10.1080/0960310022000020915>
- Castello, O., and Resta, M. (2022). Modeling the Yield Curve of BRICS Countries: Parametric vs. Machine Learning Techniques. *Risks*, 10(2), 36. <https://doi.org/10.3390/risks10020036>
- Castello, O., and Resta, M. (2023). A Machine-Learning-Based Approach for Natural Gas Futures Curve Modeling. *Energies*, 16(12), 4746. <https://doi.org/10.3390/en16124746>
- Chapman, P., Clinton, J., Kerber, R., Khabaza, T., Reinartz, T., Shearer, C., & Wirth, R. (2000). CRISP-DM 1.0: Step-by-step data mining guide. *CRISP-DM Consortium*.
- Chen, N. F. (1991), "Financial investment opportunities and the macroeconomy". *The Journal of Finance*, 46(2), 529-554.

- Chen, Y., and Niu, L. (2014). Adaptive dynamic Nelson–Siegel term structure model with applications. *Journal of Econometrics*, 180(1), 98–115. <https://doi.org/10.1016/j.jeconom.2014.02.009>
- Chen, C., Dongxing, W., Chunyan, H., and Xiaojie, Y. (2014). *Exploiting Social Media for Stock Market Prediction with Factorization Machine*. <https://doi.org/10.1109/wi-iat.2014.91>
- Chen, R., Liu, X., Jin, S., Lin, J., & Liu, J. (2018). Machine learning for drug-target interaction prediction. *Molecules*, 23(9), 2208. <https://doi.org/10.3390/molecules23092208>
- Chinn, M. D., & Kucko, K. (2010). The predictive power of the yield curve across countries and time. *Research Papers in Economics*.
- Chinn, M. D., & Kucko, K. (2015). The predictive power of the yield curve: Lessons from an out-of-sample experiment. *International Finance*, 18(2). <https://doi.org/10.1111/infi.12064>
- Chiou, M., Müller, G., & Wang, L. (2004). Functional response models. *Statistica Sinica*, 14(3), 675–693. <https://www.jstor.org/stable/24307411>
- Choudhry, M. (2006). Understanding and appreciating the yield curve. In *Bonds* (pp. 91–112). Palgrave Macmillan, London. [https://doi.org/10.1057/9780230627260\\_6](https://doi.org/10.1057/9780230627260_6)
- Christiansen, C. (2004). Regime switching in the yield curve. *Journal of Futures Markets*, 24(4), 315–336. <https://doi.org/10.1002/fut.10118>
- Christensen, J. H. E., Diebold, F. X., & Rudebusch, G. D. (2009). An arbitrage-free generalized Nelson–Siegel term structure model. *The Econometrics Journal*, 12(3), C33–C64. <https://doi.org/10.1111/j.1368-423x.2008.00267.x>
- Christensen, J. H. E., Diebold, F. X., and Rudebusch, G. D. (2011). The affine arbitrage-free class of Nelson–Siegel term structure models. *Journal of Econometrics*, 164(1), 4–20. <https://doi.org/10.1016/j.jeconom.2011.02.011>
- Christiansen, C. (2013). Predicting severe simultaneous recessions using yield spreads as leading indicators. *Journal of International Money and Finance*, 32, 1032–1043. <https://doi.org/10.1016/j.jimonfin.2012.08.005>
- Clancy, R., O’Sullivan, D., & Bruton, K. (2021). Data-driven quality improvement approach to reducing waste in manufacturing. *The TQM Journal*, 35(1), 51–72. <https://doi.org/10.1108/tqm-02-2021-0061>
- Culbertson, J. (1957). The Term Structure of Interest Rates. *The Quarterly Journal of Economics*, 71(4), 485–517.
- Dayarathne, K. P., & Thayasivam, U. (2024). Decomposing the Sri Lanka Yield Curve Using Principal Component Analysis to Examine the Term Structure of the Interest Rate. *Engineering Proceedings*, 68(1), 62. <https://doi.org/10.3390/engproc2024068062>
- De Backer, B., Deroose, M., & Van Nieuwenhuyze, Ch. (2019). Is a recession imminent? The signal of the yield curve. *Economic Review*, i, 69–93.
- Demary, M. (2017). Yield curve responses to market sentiments and monetary policy. *Journal of Economic Interaction and Coordination*, 12(2), 309–344. <https://doi.org/10.1007/s11403-015-0167-3>

- Desai, A. (2023). Machine Learning for Economics Research: When What and How?. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.4404772>
- Diebold, F. X., and Li, C. (2006). Forecasting the term structure of government bond yields. *Journal of Econometrics*, 130(2), 337–364. DOI: [10.1016/j.jeconom.2005.03.005](https://doi.org/10.1016/j.jeconom.2005.03.005)
- Diebold, F., and Rudebusch, G. (2013). *Yield Curve Modeling and Forecasting: The Dynamic Nelson-Siegel Approach*. Princeton: Princeton University Press. <https://doi.org/10.1515/9781400845415>
- Doh, T. (2011). Yield curve in an estimated nonlinear macro model. *Journal of Economic Dynamics and Control*, 35(8), 1229-1244.
- Dolan, C. (1999). Forecasting the yield curve shape. *The Journal of Fixed Income*, 9(1), 92-99. <https://doi.org/10.3905/jfi.1999.319234>
- Duffee, G. (1996). Treasury yields and corporate bond yield spreads: an empirical analysis. *Finance and Economics Discussion Series*, 1996(20), 1-35. <https://doi.org/10.17016/feds.1996.20>
- Duffee, G. (1998). The relation between treasury yields and corporate bond yield spreads. *The Journal of Finance*, 53(6), 2225-2241. <https://doi.org/10.1111/0022-1082.00089>
- Durbin, J., & Koopman, S. J. (2012). *Time series analysis by state space methods* (2nd ed.). Oxford University Press.
- Dziwok, E., and Karaś, M. A. (2021). Systemic Illiquidity Noise-Based Measure—A Solution for Systemic Liquidity Monitoring in Frontier and Emerging Markets. *Risks*, 9(7), 124. <https://doi.org/10.3390/risks9070124>
- Edirisuriya, P. (2015). The Predictive Power of Financial Variables: New Evidence from Australia. *Australasian Accounting, Business and Finance Journal*, 9(1), 57–70. <https://doi.org/10.14453/aabfj.v9i1.5>
- Eo, Y. and Kang, K. Y. (2016). Forecasting the term structure of interest rates with potentially misspecified models. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.2756915>
- Eo, Y., and Kang, K. H. (2020). The effects of conventional and unconventional monetary policy on forecasting the yield curve. *Journal of Economic Dynamics and Control*, 111, 103812. <https://doi.org/10.1016/j.jedc.2019.103812>
- Estrella, A. and Hardouvelis, G. A. (1991). The term structure as a predictor of real economic activity. *The Journal of Finance*, 46(2), 555. <https://doi.org/10.2307/2328836>
- Estrella, A. and Mishkin, F. S. (1996). The yield curve as a predictor of U.S. recessions. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.1001228>
- Estrella, A. and Mishkin, F. S. (1997). The predictive power of the term structure of interest rates in Europe and the United States: Implications for the European Central Bank. *European Economic Review*, 41(7), 1375–1401. [https://doi.org/10.1016/s0014-2921\(96\)00050-5](https://doi.org/10.1016/s0014-2921(96)00050-5)
- Estrella, A., & Mishkin, F. S. (1998). Predicting U.S. recessions: Financial variables as leading indicators. *The Review of Economics and Statistics*, 80(1), 45–61. <https://doi.org/10.1162/003465398557320>

- Estrella, A., Rodrigues, A. P., & Schich, S. (2001). How stable is the predictive power of the yield curve? Evidence from Germany and the United States. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.249965>
- Estrella, A. (2005). Why does the yield curve predict output and inflation?. *The Economic Journal*, 115(505), 722-744. <https://doi.org/10.1111/j.1468-0297.2005.01017.x>
- Faerber, E. (2001). *Fundamentals of the bond market*. McGraw-Hill.
- Fama, E. F. (1965). Random walks in stock market prices. *Financial Analysts Journal*, 21(5), 55–59. <https://doi.org/10.2469/faj.v21.n5.55>
- Fama, E. F., (1970). Efficient capital markets: a review of theory and empirical work. *J Finance* 25:383–417
- Fama, E. F. (1986). Term premiums and default premiums in money markets. *Journal of Financial Economics*, 17(1), 175-196. [https://doi.org/10.1016/0304-405X\(86\)90010-3](https://doi.org/10.1016/0304-405X(86)90010-3)
- Feng, P., & Qian, J. (2018). Analyzing and forecasting the Chinese term structure of interest rates using functional principal component analysis. *China Finance Review International*. <https://doi.org/10.1108/CFRI-06-2017-0065>
- Fisher, M., Nychka, D. and Zervos, D. (1994), “Fitting the Term Structure of Interest rates with Smoothing Splines”, Federal Reserve System Working Paper No. 95-1, Available at SSRN: <https://ssrn.com/abstract=6260>
- Faulkender, M. W. (2005). Hedging or market timing? selecting the interest rate exposure of corporate debt. *The Journal of Finance*, 60(2), 931-962. <https://doi.org/10.1111/j.1540-6261.2005.00751.x>
- Forbes, K. J., and Rigobon, R. (2002). No Contagion, Only Interdependence: Measuring Stock Market Comovements. *The Journal of Finance*, 57(5), 2223-2261. <https://doi.org/10.1111/0022-1082.00494>
- Friedman, B. M. (1980). Survey evidence on the ‘rationality’ of interest rate expectations. *Journal of Monetary Economics*, 6(4), 453-465. [https://doi.org/10.1016/0304-3932\(80\)90001-x](https://doi.org/10.1016/0304-3932(80)90001-x)
- Froot, K. A. (1989). New hope for the expectations hypothesis of the term structure of interest rates. *The Journal of Finance*, 44(2), 283. <https://doi.org/10.2307/2328591>
- Gerhart, C., Lütkebohmert, E., & Weber, M. (2019). Robust forecasting of multiple yield curves. İçinde O. Valenzuela, F. Rojas, H. Pomares, & I. Rojas (Editörler), *Theory and applications of time series analysis: ITISE 2018* (ss. 183–196). Springer, Cham. [https://doi.org/10.1007/978-3-030-26036-1\\_13](https://doi.org/10.1007/978-3-030-26036-1_13)
- Giacomini, R. and Rossi, B. (2006). How stable is the forecasting performance of the yield curve for output growth?. *Oxford Bulletin of Economics and Statistics*, 68(s1), 783-795. <https://doi.org/10.1111/j.1468-0084.2006.00456.x>
- Gilli, M., Große, S., and Schumann, E. (2010). Calibrating the Nelson-Siegel-Svensson model. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.1676747>
- Gogas, P., Papadimitriou, T., Matthaiou, M., and Chrysanthidou, E. (2015). Yield Curve and Recession Forecasting in a Machine Learning Framework. *Computational Economics*, 45(4), 635–645. <https://doi.org/10.1007/s10614-014-9432-0>
- GPy (2012). *GPy: A Gaussian process framework in python*. <https://github.com/>

SheffieldML/GPy

- Grzenda, M. and Legierski, J. (2019). Towards increased understanding of open data use for software development. *Information Systems Frontiers*, 23(2), 495-513. <https://doi.org/10.1007/s10796-019-09954-6>
- Guo, B., Han, Q., and Zhao, B. (2014). The Nelson–Siegel Model of the Term Structure of Option Implied Volatility and Volatility Components. *Journal of Futures Markets*, 34(8), 788-806. <https://doi.org/10.1002/fut.21653>
- Gürkaynak, R. S., and Wright, J. H. (2012). Macroeconomics and the term structure. *Journal of Economic Literature*, 50(2), 331-367. <https://doi.org/10.1257/jel.50.2.331>
- Habyba, A., Fitriana, R., & Theodora, T. (2021). Quality improvement of NH1X36B pre-printed box with QM-CRISP DM approach at PT X. *Operations Excellence Journal of Applied Industrial Engineering*, 13(3), 298. <https://doi.org/10.22441/oe.2021.v13.i3.028>
- Hall, P., Müller, H., & Wang, J. (2006). Properties of principal component methods for functional and longitudinal data analysis. *The Annals of Statistics*, 34(3). <https://doi.org/10.1214/009053606000000272>
- Hamilton, J. D., and Kim, D. H. (2001). A Re-examination of the Predictability of Economic Activity Using the Yield Spread. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.245584>
- Hännikäinen, J. (2017). When does the yield curve contain predictive power? evidence from a data-rich environment. *International Journal of Forecasting*, 33(4), 1044-1064. <https://doi.org/10.1016/j.ijforecast.2017.05.006>
- Harvey, C. R. (1988). The real term structure and consumption growth. *Journal of Financial Economics*, 22(2), 305-333. [https://doi.org/10.1016/0304-405X\(88\)90073-6](https://doi.org/10.1016/0304-405X(88)90073-6)
- Harvey, C. R. (1989). Forecasts of Economic Growth from the Bond and Stock Markets, *Financial Analysts Journal*, 45:5, 38-45, <https://doi.org/10.2469/faj.v45.n5.38>
- Hautsch, N., and Yang, F. (2012). Bayesian inference in a Stochastic Volatility Nelson–Siegel model. *Computational Statistics & Data Analysis*, 56(11), 3774–3792. <https://doi.org/10.1016/j.csda.2010.07.003>
- Hébrail, G., Huguency, B., Lechevallier, Y., and Rossi, F. (2010). Exploratory analysis of functional data via clustering and optimal segmentation. *Neurocomputing*, 73(7-9), 1125-1141. <https://doi.org/10.1016/j.neucom.2009.11.022>
- Hicks, J. R. (1939). *Value and Capital*. New York: Clarendon Press.
- Holmström, B. and Tirole, J. (2001). LAPM: a liquidity-based asset pricing model. *The Journal of Finance*, 56(5), 1837-1867. <https://doi.org/10.1111/0022-1082.00391>
- Horváth, D., Kálmán, P., Kocsis, Z., & Ligeti, I. (2014). What factors influence the yield curve? *Magyar Nemzeti Bank (Central Bank of Hungary)*, 9(1), 28–39.
- Hördahl, P., & Tristani, O. (2014). Inflation risk premia in the euro area and the United States. *International Journal of Central Banking*, 10(3).
- Hvozdenská, J. (2013). Yield curve as a predictor of GDP activity—the case of EU-15. *Acta Universitatis Agriculturae et Silviculturae Mendelianae Brunensis*, 61(7).

- Hvozdenská, J. (2015). Yield curve and macroeconomic factors. *Procedia Economics and Finance*, 26, 438-445.
- Hyndman, R. J., and Shahid Ullah, M. (2007). Robust forecasting of mortality and fertility rates: A functional data approach. *Computational Statistics & Data Analysis*, 51(10), 4942-4956. <https://doi.org/10.1016/j.csda.2006.07.028>
- Hyndman, R. J., & Shang, H. L. (2009). Forecasting functional time series. *Journal of the Korean Statistical Society*, 38(3), 199–211. <https://doi.org/10.1016/j.jkss.2009.06.002>
- Hyndman, R., & Shang, L. (2024). Package “ftsa” Type Package Title Functional Time Series Analysis. <https://cran.r-project.org/web/packages/ftsa/ftsa.pdf>
- Imelda, I., & Kurnianto, A. (2023). Naïve Bayes and TF-IDF for sentiment analysis of the COVID-19 booster vaccine. *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, 7(1), 1–6. <https://doi.org/10.29207/resti.v7i1.4467>
- Ishii, H. (2019). Forecasting term structure of interest rates in japan. *International Journal of Financial Studies*, 7(3), 39. <https://doi.org/10.3390/ijfs7030039>
- Kamara, A. (1997). The Relation Between Default-Free Interest Rates and Expected Economic Growth Is Stronger Than You Think. *The Journal of Finance*, 52(4), 1681–1694. <https://doi.org/10.2307/2329452>
- Kauffmann, P. C., Takada, H. H., Terada, A. T., & Stern, J. M. (2022). Learning forecast-efficient yield curve factor decompositions with neural networks. *Econometrics*, 10(2), 15. <https://doi.org/10.3390/econometrics10020015>
- Kessel, R. A. (1971). The cyclical behavior of the term structure of interest rates. In *Essays on Interest Rates*, Volume 2. 337-390. NBER.
- Kim, D ve J. Wright (2005), “An arbitrage-free three-factor term structure model and the recent behavior of long-term yields and distant-horizon forward rates” , *Finance and Economics Discussion Series*, Board of Governors of the Federal Reserve System, no 2005-3.
- Kim, W. J., Jung, G., & Choi, S. (2020). Forecasting cds term structure based on nelson–siegel model and machine learning. *Complexity*, 2020, 1-23. <https://doi.org/10.1155/2020/2518283>
- King, T. B. and Perli, R. (2007). Financial market perceptions of recession risk. *Finance and Economics Discussion Series*, 2007(57), 1-20. <https://doi.org/10.17016/feds.2007.57> derhv bm bmxft5fz5t4c5c
- Koopman, S. J., Mallee, M. I. P., and Van Der Wel, M. (2010). Analyzing the Term Structure of Interest Rates Using the Dynamic Nelson–Siegel Model With Time-Varying Parameters. *Journal of Business & Economic Statistics*, 28(3), 329–343. <https://doi.org/10.1198/jbes.2009.07295>
- Kawakatsu, H. (2020). Recovering Yield Curves from Dynamic Term Structure Models with Time-Varying Factors. *Stats*, 3(3), 284–329. <https://doi.org/10.3390/stats3030020>
- Kowal, D. R., Matteson, D. S., & Ruppert, D. (2017). Functional autoregression for sparsely sampled data. *Journal of Business & Economic Statistics*, 37(1), 97–109. <https://doi.org/10.1080/07350015.2017.1279058>

- Kozak, D., Holladay, S., & Fasshauer, G. E. (2019). Intraday load forecasts with uncertainty. *Energies*, 12(10), 1833. <https://doi.org/10.3390/en12101833>
- Kratsios, A. and Hyndman, C. B. (2020). Deep arbitrage-free learning in a generalized hjm framework via arbitrage-regularization. *Risks*, 8(2), 40. <https://doi.org/10.3390/risks8020040>
- Kurniawan, F., & Sutomo, R. (2021). Forecasting rice inventory in Indonesia using the ARIMA algorithm method. *Journal of Multidisciplinary Issues*, 1(2), 1–12. <https://doi.org/10.53748/jmis.v1i2.15>
- Laubach, T. and Williams, J. C. (2003). Measuring the natural rate of interest. *Review of Economics and Statistics*, 85(4), 1063-1070. <https://doi.org/10.1162/003465303772815934>
- Laurent R. D. (1988), “An interest rate-based indicator of monetary policy”, Federal Reserve Bank of Chicago, Economic Perspectives, January / February, 3-14.
- Laurent R. D. (1989), “Testing the ‘spread’”, Federal Reserve Bank of Chicago, Economic Perspectives, July, 22-34.
- Lázaro-Gredilla, M., Quinonero-Candela, J., Rasmussen, C. E., & Figueiras-Vidal, A. R. (2010). Sparse spectrum Gaussian process regression. *The Journal of Machine Learning Research*, 11, 1865-1881.
- Malkiel, B. G. (1999). *A random walk down Wall Street: including a life-cycle guide to personal investing*. WW Norton & Company.
- Marbán, O., Mariscal, G., & Segovia, J. (2009). A data mining & knowledge discovery process model.. <https://doi.org/10.5772/6438>
- Mariscal, G., Marbán, Ó., & Fernandez, C. (2010). A survey of data mining and knowledge discovery process models and methodologies. *The Knowledge Engineering Review*, 25(2), 137-166. <https://doi.org/10.1017/s0269888910000032>
- Markowitz, H. (1952). Portfolio selection. *The Journal of Finance*, 7(1), 77-91. <https://doi.org/10.1111/j.1540-6261.1952.tb01525.x>
- Martínez-Plumed, F., Contreras-Ochando, L., Ferri, C., Hernández-Orallo, J., Kull, M., Lachiche, N., & Flach, P. (2021). CRISP-DM twenty years later: from data mining processes to data science trajectories. *IEEE Transactions on Knowledge and Data Engineering*, 33(8), 3048-3061. <https://doi.org/10.1109/tkde.2019.2962680>
- Mastronikola, K. (1991). *Yield curves for gilt-edged stocks: a new model*. Bank of England.
- McCulloch, J. H. (1971). Measuring the Term Structure of Interest Rates. *The Journal of Business*, 44(1), 19–31. <http://www.jstor.org/stable/2351832>
- McCulloch, J. H. (1975). The Tax-Adjusted Yield Curve. *The Journal of Finance*, 30(3), 811-830. <https://doi.org/10.1111/j.1540-6261.1975.tb01852.x>
- Mei, J., Desrosiers, C., & Frasnelli, J. (2021). Machine learning for the diagnosis of parkinson's disease: a review of literature. *Frontiers in Aging Neuroscience*, 13. <https://doi.org/10.3389/fnagi.2021.633752>
- Mehl, A. (2009). The yield curve as a predictor and emerging economies. *Open Economies Review*, 20(5), 683–716. <https://doi.org/10.1007/s11079-007-9077-x>



- Mishkin, F. S. (1990). What does the term structure tell us about future inflation?. *Journal of Monetary Economics*, 25(1), 77-95. [https://doi.org/10.1016/0304-3932\(90\)90046-7](https://doi.org/10.1016/0304-3932(90)90046-7)
- Mishkin, F. S. (2007). Is Financial Globalization Beneficial? *Journal of Money, Credit and Banking*, 39(2-3), 259-294. <https://doi.org/10.1111/j.0022-2879.2007.00026.x>
- Mishkin, F. S. (2019). *The economics of money, banking, and financial markets*. Pearson Education.
- Modigliani, F. and Sutch, R. (1966) Innovations in Interest-Rate Policy. *American Economic Review*, 56, 178-197.
- Molenaars, T. K., Reinerink, N. H., and Hemminga, M. A. (2015). Forecasting the yield curve: art or science?. 38-40.
- Moneta, F. (2005). Does the Yield Spread Predict Recessions in the Euro Area?. *International Finance*, 8(2), 263–301. <https://doi.org/10.1111/j.1468-2362.2005.00159.x>
- Moreno, R. (2008), “Transmission Mechanisms for Monetary Policy in Emerging Market Economies.” BIS Paper No. 35.
- Moreno-Sanchez, P. (2021). Chronic kidney disease early diagnosis enhancing by using data mining classification and features selection., 61-76. [https://doi.org/10.1007/978-3-030-69963-5\\_5](https://doi.org/10.1007/978-3-030-69963-5_5)
- Murphy, K. P. (2012). *Machine Learning: A Probabilistic Perspective*. Cambridge, MA: MIT Press.
- Nawalkha, S., Soto, G., & Beliaeva, N. (2005). *Interest rate risk modeling: The fixed income valuation course*. (Vol. 178) John Wiley & Sons.
- Nelson, C. R. and Siegel, A. F. (1987). Parsimonious modeling of yield curves. *The Journal of Business*, 60(4), 473. <https://doi.org/10.1086/296409>
- Nti, I. K., Adekoya, A. F. and Weyori, B. A. (2020). A systematic review of fundamental and technical analysis of stock market predictions. *Artificial Intelligence Review*, 53(4), 3007-3057. <https://doi:10.1007/s10462-019-09754-z>
- Nunes, M., Gerding, E., McGroarty, F., & Niranjana, M. (2019). A comparison of multitask and single task learning with artificial neural networks for yield curve forecasting. *Expert Systems With Applications*, 119, 362-375. <https://doi.org/10.1016/j.eswa.2018.11.012>
- Nyman-Andersen, P. (2018). *Yield curve modelling and a conceptual framework for estimating yield curves: evidence from the European Central Bank's yield curves* (No. 27). ECB Statistics Paper.
- Occhino, F. (2008). Market segmentation and the response of the real interest rate to monetary policy shocks. *Macroeconomic Dynamics*, 12(5), 591-618. <https://doi.org/10.1017/s1365100508070326>
- Ozturk, H., & Pereira, L. F. (2013). Yield curve as a predictor of recessions: Evidence from panel data. *Emerging Markets Finance and Trade*, 49(5). <https://doi.org/10.2753/REE1540-496X4905S512>
- Özge, A., Burcu, G., Refet, G., & Özgür, Ö. (2006). Devlet İç Borçlanma Senetleri İçin Getiri Eğrisi Tahmini. *Çalışma Tebliği*, (06/08).

- Piazzesi, M., & Cochrane, J. (2009). *Decomposing the yield curve*. Society for Economic Dynamics, 2009 Meeting Papers (No. 18). Retrieved from <https://ideas.repec.org/p/red/sed009/18.html>
- Pramanik, M., Lau, R., Yue, W., Ye, Y., & Li, C. (2017). Big data analytics for security and criminal investigations. *Wiley Interdisciplinary Reviews Data Mining and Knowledge Discovery*, 7(4). <https://doi.org/10.1002/widm.1208>
- Pauwels, L. L. and Vasnev, A. L. (2012). Forecast combination for u.s. recessions with real-time data. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.2203574>
- Puglia, M., & Tucker, A. (2020). *Machine learning, the treasury yield curve and recession forecasting*. Social Science Research Network, 2020(038). <https://doi.org/10.17016/FEDS.2020.038>
- Python Software Foundation. (2020). *Python language reference (version 3.9)*. Retrieved from <https://www.python.org>
- R Core Team (2023). R: A Language and Environment for Statistical Computing. R Foundation for Statistical Computing. Vienna, Austria. <https://www.R-project.org>
- Ramsay, J.O. and Silverman, B.W. (2005). *Functional Data Analysis*. Springer, New York.
- Rasmussen, C. E. (2004). Gaussian Processes in Machine Learning. In *Automata, Languages and Programming* (pp. 63–71). [https://doi.org/10.1007/978-3-540-28650-9\\_4](https://doi.org/10.1007/978-3-540-28650-9_4)
- Rasmussen, C. E., & Williams, C. K. I. (2006). *Gaussian Processes for Machine Learning*. Cambridge, MA: MIT Press.
- Refinitiv. (2023). *Eikon veri tabanı*. Refinitiv Eikon. Erişim adresi: <https://www.refinitiv.com>
- Reinicke, S. (2019). Modeling and forecasting yield curves (tech). Retrieved from <http://nbn-resolving.de/urn/resolver.pl?urn=nbn:de:bvb:19-epub-68475-9>
- Rezaie, R. and Li, X. R. (2020). Gaussian conditionally markov sequences: algebraically equivalent dynamic models. *IEEE Transactions on Aerospace and Electronic Systems*, 56(3), 2390-2405. <https://doi.org/10.1109/taes.2019.2951188>
- Richman, R., & Scognamiglio, S. (2024). Multiple yield curve modeling and forecasting using deep learning. *ASTIN Bulletin*, 54(3), 463–494. doi:10.1017/asb.2024.26
- Rios, G. (2020). *Transport Gaussian Processes for Regression*. ArXiv.org. <https://arxiv.org/abs/2001.11473>
- Rostan, P., Belhachemi, R., & Racicot, F. E. (2016). Yield curve forecasting with the burg model. *Journal of Forecasting*, 36(1), 91-99. <https://doi.org/10.1002/for.2416>
- Rudebusch, G. D. and Williams, J. C. (2007). Forecasting recessions: the puzzle of the enduring power of the yield curve. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.1007803>
- Rudebusch, G. D. ve Williams, J. C. (2009). Forecasting Recessions: The Puzzle of the Enduring Power of the Yield Curve. *Journal of Business & Economic Statistics*, 27(4), 492-503. doi:10.1198/jbes.2009.07213

- Sambasivan, R., & Das, S. (2017). A statistical machine learning approach to yield curve forecasting. *2017 International Conference on Computational Intelligence in Data Science (ICCIDS)*, 1–6. <https://doi.org/10.1109/ICCIDS.2017.8272667>
- Santa-Clara, P. and Sornette, D. (2001). The dynamics of the forward interest rate curve with stochastic string shocks. *Review of Financial Studies*, 14(1), 149-185. <https://doi.org/10.1093/rfs/14.1.149>
- Sen, R., & Klüppelberg, C. (2019). Time series of functional data with application to yield curves. *Applied Stochastic Models in Business and Industry*. <https://doi.org/10.1002/asmb.2443>
- Shah, F. A., & Debnath, L. (2017). Wavelet Neural Network Model for Yield Spread Forecasting. *Mathematics*, 5(4), 72. <https://doi.org/10.3390/math5040072>
- Shang, H. (2013). ftsa: An R Package for Analyzing Functional Time Series. *The R Journal*, 5(1), 64–72.
- Sen, R., & Klüppelberg, C. (2010). Time series of functional data. *Unpublished manuscript*. Available at <https://citeseerx.ist.psu.edu/document?repid=rep1&type=pdf&doi=9c9d564b040d39d5bb235ff4c2d649db14bd3dbb>.
- Shah, F. A. and Debnath, L. (2017). Wavelet neural network model for yield spread forecasting. *Mathematics*, 5(4), 72. <https://doi.org/10.3390/math5040072>
- Shearer, C. (2000). The CRISP-DM model: the new blueprint for data mining. *Journal of data warehousing*, 5(4), 13-22.
- Silva, A., Cortez, P., & Pilastrri, A. (2020). Chemical laboratories 4.0: a two-stage machine learning system for predicting the arrival of samples., 232-243. [https://doi.org/10.1007/978-3-030-49186-4\\_20](https://doi.org/10.1007/978-3-030-49186-4_20)
- Spiegeleer, J. D., Madan, D. B., Reyners, S., and Schoutens, W. (2018). Machine learning for quantitative finance: fast derivative pricing, hedging and fitting. *Quantitative Finance*, 18(10), 1635-1643. <https://doi.org/10.1080/14697688.2018.1495335>
- Stock, J. H. and Watson, M. W. (1989). New Indexes of Coincident and Leading Economic Indicators. *NBER Macroeconomics Annual*, 4, 351-394. doi:10.1086/654119
- Stock, J. H. and Watson, M. W. (2003). Forecasting output and inflation: the role of asset prices. *Journal of Economic Literature*, 41(3), 788-829. <https://doi.org/10.1257/002205103322436197>
- Svensson, L. E. O. (1994). Estimating and interpreting forward interest rates: Sweden 1992 - 1994. <https://doi.org/10.3386/w4871>
- Takahashi, T. (2022). Measuring yield curve movements: A principal component analysis of spot rate changes in the JPY, USD, GBP, and CHF interest rate swap markets. In C.-F. Lee & M.-T. Yu (Eds.), *Advances in Pacific Basin Business, Economics and Finance* (Vol. 10, pp. 193–208). Emerald Publishing Limited. <https://doi.org/10.1108/S2514-465020220000010011>
- Tam, C. and Yu, I. (2007). Modelling sovereign bond yield curves of the U.S., Japan and Germany. *International Journal of Finance & Economics*, 13(1), 82-91. <https://doi.org/10.1002/ijfe.353>

- Tang, C. (2019). The relationship between treasury cash management and monetary policies. *Journal of Finance and Accounting*, 7(3), 88. <https://doi.org/10.11648/j.jfa.20190703.13>
- Tawose, J., Adedeji, K. E., Ajayi, K. J., Onah, A. O., & Emma-Nwachukwu, F. (2021). Yield curve and monetary policy in nigeria: investigating the predictive power of the yield curve. *South Asian Journal of Social Studies and Economics*, 41-54. <https://doi.org/10.9734/sajsse/2021/v12i430314>
- Taylor, M. P. (1991). Modelling the yield curve. IMF Working Papers, 91(134), 1. <https://doi.org/10.5089/9781451931457.001>
- Türkiye Cumhuriyet Merkez Bankası. (2019). Getiri eğrisinin eğimine karşılaştırmalı bir bakış. *Enflasyon Raporu 2019-II*.
- Türkiye Cumhuriyet Merkez Bankası. (2020). Türkiye’de salgına karşı alınan parasal ve makroihtiyati tedbirler. Enflasyon Raporu 2020-II, Kutu 5.1. Erişim adresi: [https://www.tcmb.gov.tr/wps/wcm/connect/a346e6cd-a6dd-45b1-a299-507441c6185c/Kutu\\_5\\_1\\_2020-2.pdf?MOD=AJPERES](https://www.tcmb.gov.tr/wps/wcm/connect/a346e6cd-a6dd-45b1-a299-507441c6185c/Kutu_5_1_2020-2.pdf?MOD=AJPERES)
- Tseng, H. E., Wei, L., Cui, S., Luo, Y., Haken, R. T., & Naqa, I. E. (2018). Machine learning and imaging informatics in oncology. *Oncology*, 98(6), 344-362. <https://doi.org/10.1159/000493575>
- Ullah, S. and Finch, C. F. (2013). Applications of functional data analysis: a systematic review. *BMC Medical Research Methodology*, 13(1). <https://doi.org/10.1186/1471-2288-13-43>
- Ullah, W., Matsuda, Y., and Tsukuda, Y. (2013). Term Structure Modeling and Forecasting of Government Bond Yields. *Economic Papers: A Journal of Applied Economics and Policy*, 32(4), 535–560. <https://doi.org/10.1111/1759-3441.12046>
- Ullah, W. (2015). Affine term structure model with macroeconomic factors: do no-arbitrage restriction and macroeconomic factors imply better out-of-sample forecasts?. *Journal of Forecasting*, 35(4), 329-346. <https://doi.org/10.1002/for.2378>
- Vayanos, D. and Vila, J. L. (2009). “A Preferred-Habitat Model of the Term Structure of Interest Rates.” NBER Working Paper No. 15487, National Bureau of Economic Research, <http://www.nber.org/papers/w15487.pdf>.
- Vasicek, O. A. and Fong, H. G. (1982). Term structure modeling using exponential splines. *The Journal of Finance*, 37(2), 339-348. <https://doi.org/10.1111/j.1540-6261.1982.tb03555.x>
- Viviani, R., Grön, G. and Spitzer, M. (2005), Functional principal component analysis of fMRI data. *Human Brain Mapping*, 24: 109-129. <https://doi.org/10.1002/hbm.20074>
- Vrontos, S. D., Galakis, J., and Vrontos, I. D. (2021). Implied volatility directional forecasting: a machine learning approach. *Quantitative Finance*, 21(10), 1687-1706. <https://doi.org/10.1080/14697688.2021.1905869>
- Waggoner, D. F. (1998). Spline Methods for Extracting Interest Rate Curves from Coupon Bond Prices. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.86789>

- Wahyudi, T., & Arroufu, D. (2022). Implementation of data mining prediction delivery time using linear regression algorithm. *Journal of Applied Engineering and Technological Science*, 4(1), 84–92. <https://doi.org/10.37385/jaets.v4i1.918>
- Wang, J., Chiou, J., and Müller, H. (2016). Functional data analysis. *Annual Review of Statistics and Its Application*, 3(1), 257-295. <https://doi.org/10.1146/annurev-statistics-041715-033624>
- Wiemer, H., Drowatzky, L., & Ihlenfeldt, S. (2019). Data mining methodology for engineering applications (dmme)—a holistic extension to the CRISP-DM model. *Applied Sciences*, 9(12), 2407. <https://doi.org/10.3390/app9122407>
- Williamson, S. (2015). Monetary Policy Normalization in the United States, 97(2). <https://doi:10.20955/r.97.87-108>
- Wright, J. H. (2006). The Yield Curve and Predicting Recessions. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.899538>
- Wright, J. H. (2011). Term premia and inflation uncertainty: Empirical evidence from an international panel dataset. *American Economic Review*, 101(4), 1514–1534. <https://doi.org/10.1257/aer.101.4.1514>
- Yao, Y. (1999). Term Structure Models: A Perspective from the Long Rate. *North American Actuarial Journal*, 3(3), 122–138. <https://doi.org/10.1080/10920277.1999.10595839>
- Yao, F., Müller, H., & Wang, J. (2005a). Functional linear regression analysis for longitudinal data. *The Annals of Statistics*, 33(6). <https://doi.org/10.1214/009053605000000660>
- Yao, F., Müller, H.-G., and Wang, J.-L. (2005b). Functional Data Analysis for Sparse Longitudinal Data. *Journal of the American Statistical Association*, 100(470), 577–590. <https://doi.org/10.1198/016214504000001745>
- Zhang, X., Hu, Y., Xie, K., Wang, S., Ngai, E., & Liu, M. (2014). A causal feature selection algorithm for stock prediction modeling. *Neurocomputing*, 142, 48-59. <https://doi.org/10.1016/j.neucom.2014.01.057>
- Zhang, J., Chen, Y., Klotz, S., & Lim, K. G. (2017). *International Yield Curve Prediction with Common Functional Principal Component Analysis*. [https://doi.org/10.1007/978-3-319-50742-2\\_17](https://doi.org/10.1007/978-3-319-50742-2_17)
- Zhang, S., Zhang, S., Xiong, T., Zhu, X. and Cheng, D. (2017). Financial time-series data analysis using deep learning and the precautions. *Neurocomputing*, 286, 46-57.
- Zhang, Y. (2021). *An interactive machine learning approach to integrating physician expertise into delirium prediction model development* (Order No. 28770345). Available from ProQuest Dissertations & Theses Global. (2607315462). Retrieved from <https://www.proquest.com/dissertations-theses/interactive-machine-learning-approach-integrating/docview/2607315462/se-2>