

KARADENİZ TEKNİK ÜNİVERSİTESİ * SOSYAL BİLİMLER ENSTİTÜSÜ

EKONOMETRİ ANABİLİM DALI

DOKTORA PROGRAMI

**KARMA FREKANSLI VERİ ÖRNEKLEME (MIDAS) YÖNTEMİ: TEORİ VE
UYGULAMA**

DOKTORA TEZİ

Serkan SAMUT

EYLÜL – 2020

TRABZON

KARADENİZ TEKNİK ÜNİVERSİTESİ * SOSYAL BİLİMLER ENSTİTÜSÜ

EKONOMETRİ ANABİLİM DALI

DOKTORA PROGRAMI

**KARMA FREKANSLI VERİ ÖRNEKLEME (MIDAS) YÖNTEMİ: TEORİ VE
UYGULAMA**

DOKTORA TEZİ

Serkan SAMUT

ORDID: 0000-0001-8216-6482

Tez Danışmanı: Prof. Dr. Rahmi YAMAK

EYLÜL- 2020

TRABZON

ONAY

Serkan SAMUT tarafından hazırlanan “Karma Frekanslı Veri Örnekleme (MIDAS) Yöntemi: Teori ve Uygulama” adlı bu Çalışma 15.10.2020 tarihinde yapılan savunma sınavı sonucunda oybirliği / oyçokluğu ile başarılı bulunarak jürimiz tarafından Ekonometri Anabilim Dalı Doktora Programı’nda **doktora tezi** olarak kabul edilmiştir.

Jüri Üyesi		Karar		İmza
Ünvanı – Adı ve Soyadı	Görevi	Kabul	Ret	
Prof. Dr. Rahmi YAMAK	Başkan	<input type="checkbox"/>	<input type="checkbox"/>	
Prof. Dr. Mehmet Sinan TEMURLENK	Üye	<input type="checkbox"/>	<input type="checkbox"/>	
Prof. Dr. Yakup KÜÇÜKKALE	Üye	<input type="checkbox"/>	<input type="checkbox"/>	
Doç. Dr. Zehra ABDİOĞLU	Üye	<input type="checkbox"/>	<input type="checkbox"/>	
Doç. Dr. Serdar KURT	Üye	<input type="checkbox"/>	<input type="checkbox"/>	

Yukarıdaki imzaların, adı geçen öğretim üyelerine ait olduklarını onaylıyorum.

Prof. Dr. Yusuf SÜRME
Enstitü Müdürü

BİLDİRİM

Tez içindeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, ayrıca KTÜ – Sosyal Bilimler Enstitüsü Tez Yazım Klavuzu'na uygun olarak hazırlanan bu çalışmada yararlanılan kaynakların tümüne eksiksiz atıf yapıldığını, aksinin ortaya çıkması durumunda her tür yasal sonucu kabul edeceğimi beyan ederim.

Serkan SAMUT

22.09.2020

ÖNSÖZ

Geleneksel zaman serili regresyon modellerinde bağımlı ve bağımsız değişkenlerin aynı frekansta olmaları gerekmektedir. Fakat iktisadi değişkenler aynı frekans düzeylerinde yayınlanmazlar. Bu nedenle regresyon modelinde yer alan değişkenlerin farklı frekans düzeylerinde olmaları durumunda toplulaştırma işlemine başvurulmaktadır. Söz konusu bu toplulaştırma işleminde yüksek frekanslı değişken, düşük frekanslı değişkenin frekansına dönüştürülmektedir. Ancak toplulaştırma işleminde yüksek frekanslı değişkenlerdeki bilgilerin kaybolma olasılığı yüksektir. Ayrıca düşük frekanslı bir değişken yüksek frekanslı bir değişkene göre daha geç yayınlanabilmektedir. Bu sebeple geleneksel zaman serili regresyon modellerinde yüksek frekanslı değişkenin son gözlem değerlerinden faydalanılamayabilir.

Karma Frekanslı Veri Örneklemi (*Mixed Data Sampling*, MIDAS), farklı frekansa sahip bağımlı ve bağımsız değişkenlerin herhangi bir işleme tabi tutulmadan aynı regresyon denkleminde birlikte kullanılmasına imkan tanıyan bir yaklaşımdır. Böylelikle MIDAS yöntemiyle yüksek frekanslı değişkendeki bilgilerden olabildiğinde yararlanılacak ve aynı zamanda söz konusu bu değişkenin son gözlem değerlerinin de etkisi model içerisine aktarılacaktır. Bu çalışmada MIDAS yöntemiyle aylık frekanslı değişkenlerdeki yüksek frekanslı bilgiden faydalanılarak Türkiye ekonomisinin üçer aylık frekanslı Gayri Safi Yurtiçi Hasıla (GSYİH) büyüme oranı anlık olarak tahmin edilmiştir. Uygulamada MIDAS modeliyle elde edilen anlık tahmin bulguları, toplulaştırılmış değişkenlerin kullanıldığı geleneksel modelin GSYİH büyüme oranının öngörü sonuçlarıyla karşılaştırılmıştır.

Bu çalışmanın hazırlanmasında; konunun belirlenmesi aşamasından itibaren bilgi ve deneyimleriyle bana daima yol gösteren kıymetli tez danışmanım Sayın Prof. Dr. Rahmi YAMAK'a teşekkürlerimi sunarım. Aynı zamanda çalışmaya değerli katkı, eleştiri ve önerileri için tez jüri üyeleri Sayın Prof. Dr. Yakup KÜÇÜKKALE'ye, Sayın Prof. Dr. Mehmet Sinan TEMURLENK'e, Sayın Doç. Dr. Serdar KURT'a değerli bilgi birikimi ile hiçbir zaman yardımlarını esirgemeyen ve çalışmaya değerli katkı, eleştiri ve önerileri için tez jüri üyesi Sayın Doç. Dr. Zehra ABDİOĞLU'na, çalışmanın bazı bölümlerini okuyup, gözden geçiren çalışma arkadaşım Arş. Görv. Çağrı ÇOLAK'a teşekkürlerimi sunarım.

Eylül, 2020

Serkan SAMUT

İÇİNDEKİLER

ÖNSÖZ.....	IV
İÇİNDEKİLER	V
ÖZET.....	VII
ABSTRACT	VIII
TABLolar LİSTESİ.....	IX
GRAFİKLER LİSTESİ.....	X
KISALTMALAR LİSTESİ.....	XI
GİRİŞ.....	1-4

BİRİNCİ BÖLÜM

1. KARMA FREKANSLI VERİ ÖRNEKLEME (MIDAS).....	5-33
1.1. Karma Frekanslı Veriler.....	5
1.2. Karma Frekanslı Veri Örnekleme	9
1.2.1. Geleneksel Almon Polinomu	11
1.2.2. Üstel Almon Polinomu	12
1.2.3. Beta Polinomu.....	13
1.2.4. Kısıtsız MIDAS (U-MIDAS).....	13
1.2.5. Basamak Ağırlıklı MIDAS Modeli.....	15
1.3. MIDAS Modellenin Uzantıları.....	16
1.3.1. Otoregresif MIDAS (AR-MIDAS) Modeli.....	16
1.3.2. ADL-MIDAS Modeli.....	17
1.3.3. Faktör MIDAS Modeli.....	18
1.3.4. Öncülerle MIDAS Modeli	20
1.3.5. Düzgün Geçişli MIDAS (ST-MIDAS)	21
1.3.6. Markov Değişim (MS-MIDAS).....	22
1.3.7. Kısıtsız Markov Değişim (MS-U-MIDAS)	23

1.4. Karma Frekanslı VAR (MF-VAR) Modeli	23
1.4.1. Parametre Gdml MF-VAR Modeli	24
1.4.2. Gzlem Gdml MF-VAR Modeli	28
1.5. Ters MIDAS Modeli	30
1.5.1. Kısıtsız Ters MIDAS (RU-MIDAS)	31
1.5.2. Ters MIDAS (R-MIDAS)	32

İKİNCİ BÖLM

2. İKTİSADİ DEĞİŞKENLERİN ÖNGÖRS ÜZERİNE MIDAS LİTERATR..... 34-57

2.1. Öngr zerine MIDAS Literatr	36
--	----

ÇNC BÖLM

3. UYGULAMA: GSYİH TAHMİNİ 58-71

3.1. Veri Seti	58
3.2. Birim Kk Test Sonuları	61
3.3. GSYİH Byme Oranının Anlık Tahmini iin Model Kurulumu	63
3.4. MIDAS Modellerinin Tahmin Performanslarının Deėerlendirilmesi	69

DRDNC BÖLM

4. BULGULAR 72-94

4.1. GSYİH Byme Oranının Anlık Tahmin Bulguları	72
4.2. MIDAS Modellerinin Tahmin Performanslarının Deėerlendirilmesi	86
4.3. Tahmin Hata Kriterleriyle En İy Tahmin Modellerinin Belirlenmesi.....	92

SONU ve NERİLER.....95

YARARLANILAN KAYNAKLAR.....100

EKLER.....107

ZGEMİŞ.....119

ÖZET

Bilindiği üzere geleneksel zaman serili regresyon modelleriyle çalışabilmenin en önemli koşulu, modelde yer alan bağımlı ve bağımsız değişkenlerin aynı frekansta olmaları gerektiğidir. Ancak bu koşul, iktisadi ve finansal değişkenlerin farklı frekanslarda yayınlanmalarından dolayı her zaman sağlanamaz. Uygulamalı literatürde bahsi geçen bu koşulu sağlamanın geleneksel çözümü toplulaştırma yöntemine başvurmaktır. Fakat toplulaştırma neticesinde yüksek frekanslı değişkendeki yararlı ve gerekli bilgilerin kaybolması olasıdır. Gyhsels ve diğerleri (2004), literatürdeki bu sorunu ortadan kaldırmak için farklı frekanslı değişkenlerin aynı modelde kullanılabildiği bir yöntem geliştirmişlerdir. Bu yöntem Karma Frekanslı Veri Örnekleme (*Mixed Data Sampling*, MIDAS) olarak adlandırılmaktadır. MIDAS yöntemi, yüksek frekanslı değişkenlerin toplulaştırma işlemine tabi tutulmadan çok değişkenli modellere dahil edilebilmelerine imkân sağlamaktadır. Dolayısıyla MIDAS yöntemiyle birlikte ilgili literatürde ülkelerin ekonomik büyüme oranlarının öngörüsünde yüksek frekanslı bilgilerin kullanımının önemi artmıştır.

Bu çalışmanın amacı, MIDAS yöntemi altında aylık frekanslı değişkenlerden yararlanılarak Türkiye ekonomisinin üçer aylık frekanslı Gayri Safi Yurtiçi Hasıla (GSYİH) büyüme oranının anlık tahminin, belirli bir zaman aralığında gerçek zamanlı olarak uygulanmasıdır. Analizlerde aylık ve üçer aylık frekanslı değişkenler için 2020'nin Haziran ayında ulaşılabilen veri setleri temin edilerek GSYİH'nin 2015'in 1. çeyrek – 2020'nin 2. çeyrek dönemleri arasındaki büyüme oranı gerçek zamanlı olarak anlık tahmin edilmiştir. Çalışmada MIDAS modelinin anlık tahmin performansı, toplulaştırılmış değişkenlerin yer aldığı geleneksel modelin tahmin performansı ile karşılaştırılmıştır. Söz konusu bu karşılaştırma sonucunda genel olarak MIDAS modeliyle daha tutarlı tahminlerin elde edildiği belirlenmiştir.

Anahtar Sözcükler: MIDAS, Karma Frekanslı Veri Örnekleme, Anlık Tahmin, Ekonomik Büyüme.

ABSTRACT

As known, the most important requirement for traditional time series regression models is that all dependent and independent variables in the model must be at the same frequency. However, this requirement is not always ensured because economic and financial variables are released at different frequencies. The traditional solution of this aforementioned requirement is to perform aggregation method in applied literature. However, it is possible that the useful and necessary information in the high frequency variable will be likely lost as a result of aggregation. Gyhsels et al. (2004) developed a method in which variables with different frequencies can be used in the same model in order to eliminate this problem in the literature. This method is called Mixed Data Sampling (MIDAS). The MIDAS method enables high frequency variables to be included in multivariate models without being subjected to aggregation. With the MIDAS method, the importance of using high frequency information in forecasting of the economic growth rates of countries has increased in the relevant literature.

The aim of this study is the real-time application of nowcast of Turkey's economy quarterly frequency of Gross Domestic Product (GDP) growth rates during a given time interval by benefiting monthly frequency variables under the MIDAS method. In the analyses, the growth rate of GDP between the 1st quarter of 2015 and the 2nd quarter of 2020 was nowcasted in real time by providing data sets accessible in June 2020 for monthly and quarterly frequency variables. In the study, the nowcasting performance of the MIDAS model was compared with the forecasting performance of the conventional model with aggregated variables. As a result of this comparison, it is determined that more accurate forecast is generally obtained with the MIDAS model.

Keywords: MIDAS, Mixed Data Sampling, Nowcasting, Economic Growth.

TABLolar LİSTESİ

Tablo Nr.	Tablo Adı	Sayfa Nr.
1	Aylık Frekanslı Değişkenlerin Tanımlayıcı İstatistikleri.....	59
2	Üçer Aylık Olarak Toplulaştırılmış Değişkenlerin ve GSYİH'ya İlişkin Tanımlayıcı İstatistikler	61
3	Aylık Frekanslı Değişkenleri için Birim Kök Test Sonuçları.....	62
4	Üçer Aylık Frekanslı Değişkenler için Birim Kök Test Sonuçları	63
5	Reel Kesim Güven Endeksi ile Öngörü Performansı Karşılaştırılması	87
6	İmalat Sanayi Kapasite Kullanım Oranı ile Öngörü Performansı Karşılaştırılması	88
7	TÜFE ile Öngörü Performansı Karşılaştırılması	88
8	ÜFE ile Öngörü Performansı Karşılaştırılması.....	89
9	Sanayi Üretim Endeksi ile Öngörü Performansı Karşılaştırılması	90
10	Reel Toplam İhracat ile Öngörü Performansı Karşılaştırılması.....	91
11	Reel Toplam İthalat ile Öngörü Performansı Karşılaştırılması.....	91
12	Tahmin Hata Kriteri En Düşük Değer Alan Modeller	94
13	Aylık Frekanslı Reel Kesim Güven Endeksi için Birim Kök Test Sonuçları	108
14	Aylık Frekanslı İmalat Sanayi Kapasite Kullanım Oranı için Birim Kök Test Sonuçları	109
15	Aylık Frekanslı TÜFE için Birim Kök Test Sonuçları	110
16	Aylık Frekanslı ÜFE için Birim Kök Test Sonuçları.....	111
17	Aylık Frekanslı Sanayi Üretim Endeksi için Birim Kök Test Sonuçları	112
18	Aylık Frekanslı Reel Toplam İhracat için Birim Kök Test Sonuçları	113
19	Aylık Frekanslı Reel Toplam İthalat için Birim Kök Test Sonuçları	114
20	Üçer Aylık Frekanslı GSYİH ve Reel Kesim Güven Endeksi için Birim Kök Test Sonuçları	115
21	Üçer Aylık Frekanslı İmalat Sanayi Kapasite Kullanım Oranı ve TÜFE için Birim Kök Test Sonuçları	116
22	Üçer Aylık Frekanslı ÜFE ve Sanayi Üretim Endeksi için Birim Kök Test Sonuçları	117
23	Üçer Aylık Frekanslı Reel Toplam İhracat ve İthalat için Birim Kök Test Sonuçları.....	118

GRAFİKLER LİSTESİ

Grafik Nr.	Grafik Adı	Sayfa Nr.
1	Reel Kesim Güven Endeksi ile GSYİH Büyüme Oranının Anlık Tahmini (1. Ay)	73
2	Reel Kesim Güven Endeksi ile GSYİH Büyüme Oranının Anlık Tahmini (2. Ay)	73
3	Reel Kesim Güven Endeksi ile GSYİH Büyüme Oranının Anlık Tahmini (3. Ay)	74
4	İmalat Sanayi Kapasite Kullanım Oranı ile GSYİH Büyüme Oranının Anlık Tahmini (1. Ay).....	75
5	İmalat Sanayi Kapasite Kullanım Oranı ile GSYİH Büyüme Oranının Anlık Tahmini (2. Ay).....	75
6	İmalat Sanayi Kapasite Kullanım Oranı ile GSYİH Büyüme Oranının Anlık Tahmini (3. Ay).....	76
7	TÜFE ile GSYİH Büyüme Oranının Anlık Tahmini (1. Ay).....	77
8	TÜFE ile GSYİH Büyüme Oranının Anlık Tahmini (2. Ay).....	77
9	TÜFE ile GSYİH Büyüme Oranının Anlık Tahmini (3. Ay).....	77
10	ÜFE ile GSYİH Büyüme Oranının Anlık Tahmini (1. Ay).....	79
11	ÜFE ile GSYİH Büyüme Oranının Anlık Tahmini (2. Ay).....	79
12	ÜFE ile GSYİH Büyüme Oranının Anlık Tahmini (3. Ay).....	79
13	Sanayi Üretim Endeksi ile GSYİH Büyüme Oranının Anlık Tahmini (1. Ay).....	81
14	Sanayi Üretim Endeksi ile GSYİH Büyüme Oranının Anlık Tahmini (2. Ay).....	81
15	Sanayi Üretim Endeksi ile GSYİH Büyüme Oranının Anlık Tahmini (3. Ay).....	81
16	Reel Toplam İhracat ile GSYİH Büyüme Oranının Anlık Tahmini (1. Ay).....	83
17	Reel Toplam İhracat ile GSYİH Büyüme Oranının Anlık Tahmini (2. Ay).....	83
18	Reel Toplam İhracat ile GSYİH Büyüme Oranının Anlık Tahmini (3. Ay).....	83
19	Reel Toplam İthalat ile GSYİH Büyüme Oranının Anlık Tahmini (1. Ay).....	85
20	Reel Toplam İthalat ile GSYİH Büyüme Oranının Anlık Tahmini (2. Ay).....	85
21	Reel Toplam İthalat ile GSYİH Büyüme Oranının Anlık Tahmini (3. Ay).....	85

KISALTMALAR LİSTESİ

ABD	: Amerika Birleşik Devletleri
ADF	: Augmented Dickey-Fuller – Genişletilmiş Dickey-Fuller
ADL-MIDAS	: Augmented Distributed Lag Mixed Data Sampling – Genişletilmiş Gecikmesi Dağıtılmış Karma Frekanslı Veri Örneklemesi
AGL	: Adaptive Group Least Absolute Shrinkage And Selection Operator – Grup Uyumlaştırılmış En Az Mutlak Seçim ve Daraltma İşlemcisi
AIC	: Akaike Information Criteria – Akaike Bilgi Kriteri
AR	: Autoregressive Process – Otoregresif Süreç
ARMA	: Autoregressive Moving Average – Otoregresif Hareketli Ortalama
AR-MIDAS	: Autoregressive Mixed Data Sampling – Otoregresif Karma Frekanslı Veri Örneklemesi
BIC	: Bayesian Information Criteria – Bayesyen Bilgi Kriteri
BMFSV	: Bayesian Mixed Frequency With Stochastic Volatility – Stokastik Oynaklığı Bayesyen Karma Frekans
DFM	: Dynamic Factor Model – Dinamik Faktör Modeli
DL	: Distributed Lag – Gecikmesi Dağıtılmış
DM	: Diebold ve Mariano
EKK	: En Küçük Kareler
EM	: Expectation-Maximization – Beklenti Maksimizasyon
FADL-MIDAS	: Factor Augmented Distributed Lag Mixed Data Sampling – Faktör Genişletilmiş Gecikmesi Dağıtılmış Karma Frekanslı Veri Örneklemesi
FA-MIDAS	: Factor Mixed Data Sampling – Faktör Karma Frekanslı Veri Örneklemesi
FTSE100	: Financial Times And Stock Exchange 100
GEKK	: Genelleştirilmiş En Küçük Kareler
GP-U-MIDAS	: Group Penalized Unrestricted Mixed Data Sampling – Grup Cezalandırılmış Kısıtsız Karma Frekanslı Veri Örneklemesi
GSYİH	: Gayri Safi Yurtiçi Hasıla
GÜV	: Reel Kesim Güven Endeksi
HAR-RV	: Heterogeneous Autoregressive Model Of The Realized Volatility – Gerçekleşen Oynaklığın Heterojen Otoregresif Model
HF	: High Frequency – Yüksek Frekans
HICP	: Harmonized Index Of Consumer Price – Uyumlaştırılmış Tüketici Fiyat Endeksi

ISM	: Institute Of Supply Management – Tedarik Yönetim Enstitüsü
KAP	: İmalat Sanayi Kapasite Kullanım Oranı
KPSS	: Kwiatkowski-Phillips-Schmidt-Shin
KTÜ	: Karadeniz Teknik Üniversitesi
LASSO	: Least Absolute Shrinkage And Selection Operator – En Az Mutlak Seçim Ve Daraltma İşlemcisi
LF	: Low Frequency – Düşük Frekans
M	: Reel Toplam İthalat
MA	: Moving Average Process – Hareketli Ortalama Süreç
MAE	: Mean Absolute Error – Ortalama Mutlak Hata
MAPE	: Mean Absolute Percent Error – Ortalama Mutlak Yüzde Hata
MASE	: Mean Absolute Scaled Error – Mutlak Ölçeklendirilmiş Hata Ortalaması
MCP	: Minimax Concave Penalty - Minmax Konkav Ceza
MF-DL	: Mixed-Frequency Distributed Lag – Karma Frekanslı Gecikmesi Dağıtılmış
MF-VAR	: Mixed Frequency Vector Autoregression Model – Karma Frekanslı Vektör Otoregresif Model
MIDAS	: Mixed Data Sampling – Karma Frekanslı Veri Örnekleme
MIDAS-IT	: Iterative Mixed Data Sampling – Döngüsel Karma Frekanslı Veri Örnekleme
MIDASSO	: Unrestricted Mixed Data Sampling Least Absolute Shrinkage And Selection Operator – Kısıtsız Karma Frekanslı Veri Örnekleme En Az Mutlak Seçim ve Daraltma İşlemcisi
ML	: Maximum Likelihood – En Çok Olabilirlik
MS	: Markov-Switching – Markov Değişim
MS-DL	: Markov-Switching Distributed Lag – Markov Değişim Gecikmesi Dağıtılmış
MSE	: Mean Squared Error – Ortalama Kare Öngörü Hatası
MS-MIDAS	: Markov-Switching Mixed Data Sampling – Markov Değişim Karma Frekanslı Veri Örnekleme
MS-U-MIDAS	: Unrestricted Markov-Switching Mixed Data Sampling – Kısıtsız Markov Değişim Karma Frekanslı Veri Örnekleme
NBER	: National Bureau Of Economic Research – Amerikan Ulusal Ekonomik Araştırma Bürosu
NLS	: Nonlinear Least Squares – Doğrusal Olmayan En Küçük Kareler
PCA	: Principal Component Analysis – Temel Bileşen Analizi
PP	: Phillips-Perron
QPS	: Quadratic Probability Scores – Quadratik Olasılık Skoru
R-MIDAS	: Reverse Mixed Data Sampling – Ters Karma Frekanslı Veri Örnekleme

RMSE	: Root Mean Square Error – Kök Ortalama Kare Öngörü Hatası
RU-MIDAS	: Unrestricted Reverse Mixed Data Sampling – Kısıtsız Ters Karma Frekanslı Veri Örnekleme
RW	: Random Walk – Rassal Yürüyüş
S&P500	: Standard And Poor 500
SAN	: Sanayi Üretim Endeksi
SCAD	: Smoothly Clipped Absolute Deviation – Düzgünleştirilmiş Mutlak Sapma
SIC	: Schwarz Information Criteria – Schwarz Bilgi Kriteri
SPF	: Survey Of Professional Forecasters – Profesyonel Tahminciler Anketi
ST-MIDAS	: Smooth Transition Mixed Data Sampling – Düzgün Geçişli Karma Frekanslı Veri Örnekleme
TCMB	: Türkiye Cumhuriyet Merkez Bankası
TCMB-EVDS	: Türkiye Cumhuriyet Merkez Bankası Elektronik Veri Dağıtım Sistemi
TÜİK	: Türkiye İstatistik Kurumu
TÜFE	: Tüketici Fiyat Endeksi
U-MIDAS	: Unrestricted Mixed Data Sampling – Kısıtsız Karma Frekanslı Veri Örnekleme
ÜFE	: Üretici Fiyat Endeksi
VAR	: Vector Autoregression Model – Vektör Otoresif Model
WML	: Weighted Maximum Likelihood – Ağırlıklı En Yüksek Olabilirlik
X	: Reel Toplam İhracat

GİRİŞ

Bilindiği üzere iktisadi ve finansal değişkenlerdeki hareketliliğin gelecekte nasıl bir seyir izleyeceği politika yapıcılarını, girişimcileri ve hane halkı gibi kesimler için önemlidir. Literatürde söz konusu bu değişkenlerin öngörüsü iki yaklaşımla belirlenmektedir. Bunlar bağımlı değişkenin gecikmelerini kullanan tek değişkenli (*univariate*) öngörü modelleri ve öngörüsü gerçekleştirilmek istenilen değişkenin gecikmeleriyle birlikte açıklayıcı değişken veya değişkenler içeren çok değişkenli (*multivariate*) öngörü modelleridir. Eğer bir modelde birden fazla değişken yer alıyorsa söz konusu bu değişkenlerin aynı frekansta olmaları gerektiği bilinen bir gerçektir. Fakat iktisadi ve finansal değişkenler doğaları gereği aynı frekanslarda toplanıp raporlanmazlar. Özellikle bazı değişkenler günlük periyotlarda hatta dakika periyotlarında ölçülebilirken; bazı değişkenler ise aylık, üçer aylık ve yıllık periyotlarda ölçülebilmektedir. Örneğin birçok ekonomide Gayri Safi Yurtiçi Hasıla (GSYİH) üçer aylık dönemler halinde yayınlanırken; enflasyon oranı, sanayi üretim endeksi, işsizlik oranı, faiz oranları, borsa endeksleri gibi değişkenler üçer aylık frekanstan daha yüksek frekanslarda yani aylık, haftalık, günlük veya saatlik frekanslarda yayınlanmaktadır.

Ampirik literatürde çoklu zaman serilerinde yaşanan bu frekans farkını ortadan kaldırmanın etkili yöntemi, modelde bulunan yüksek frekanslı değişken veya değişkenleri modeldeki en düşük frekanslı değişkenin frekansına dönüştürülmesidir. Bu işlem genellikle yüksek frekanslı değişkenlerin modelde yer alan düşük frekanslı değişkenin periyoduna dönüştürülmesiyle gerçekleştirilmektedir. Örneğin bir modelde üçer aylık frekanslı GSYİH ve aylık frekanslı enflasyon oranı değişkenleri yer alıyorsa, yapılan ilk işlem enflasyon oranının üçer aylık frekansa dönüştürülmesidir. Diğer bir deyişle aylık frekanslı enflasyon oranının toplulaştırılarak üçer aylık frekanslı hale getirilmesidir. Fakat bu toplulaştırma neticesinde yüksek frekanslı serilerdeki potansiyel bilgilerin ortadan kaybolma olasılığı yüksek olacaktır (Götz vd., 2016: 418). Bu nedenle, bu yaklaşımla herhangi bir zaman serisinin frekansını azaltmak, serideki potansiyel bilgilerin kaybına izin vermek anlamına gelmektedir. Üstelik Granger (1988) tarafından yapılan bir çalışmada toplulaştırma işleminden dolayı bilgi kaybı olabileceği ve böylelikle yüksek frekanslı değişkenin öngörü performansını kaybedebileceği kanıtlanmıştır. Söz konusu bilgi kaybının yanı sıra Granger ve Siklos (1995); mevsimsel birim köklerde, Pierse ve Snell (1995); eşbütünleşme ilişkisinde ve Wei (1982), Granger (1988) ve Marsilli (1999); nedensellik ilişkisi üzerinde toplulaştırmanın, yüksek frekanslı değişkenlerin zamansal bileşenleri üzerinde de etkisi bulunabileceğini ispatlamışlardır.

Yukarıda bahsedilen toplulaştırma işleminin olumsuz yönleriyle birlikte öngörü literatüründe değişkenlerin farklı frekanslarda olmalarının bir başka olumsuz yönü daha bulunmaktadır. Bu da

iktisadi ve finansal deęişkenlerin farklı gecikmeler ile yayınlamalarıdır. Bahsi geçen bu yayın gecikmeleri genellikle deęişkenlerin frekans seviyeleriyle ters orantılı olmaktadır. Örneęin Türkiye ekonomisinde ilgili çeyrek döneme ait üçer aylık frekanslı GSYİH verisi izleyen çeyrek dönemin ikinci veya üçüncü ayında açıklanırken; aylık frekanslı enflasyon oranı, hemen bir sonraki ayın 3'ünde açıklanmaktadır. Hatta deęişkenin frekansı daha da arttığında veri yayınlanması neredeyse anlık olabilmektedir. Şöyle ki birçok ekonomide günlük finansal veriler aynı gün içerisinde açıklanabilmektedir. Söz konusu yayın gecikmelerinden dolayı geleneksel çoklu zaman serilerinde yüksek frekanslı deęişkenlere ait son gözlemlerden doğal olarak faydalanılamamaktadır. Varsayalım ki geleneksel yöntemlerle Türkiye ekonomisinin GSYİH büyüme oranı öngörülme isteniliyor. Öncelikle söz konusu GSYİH deęişkenin son gözlem verisi, bir ya da iki çeyrek dönem öncesine ait olacaktır. Öte yandan cari döneme ilişkin yüksek frekanslı deęişkenlerin verileri ulaşılabilir olacaktır. Her ne kadar cari dönemde yüksek frekanslı verilere ulaşılsa da ilgili dönemde yüksek frekanslı deęişkene ait tüm gözlem deęerlerine hemen ulaşılacaktır. Yüksek frekanslı deęişkenin çeyrek dönemin sonlarındaki gözlemlerinin açıklanması bir sonraki çeyrek döneme sarkabilecektir. Böylelikle yüksek frekanslı deęişkenin cari dönemine ait verileri tam olarak toplulaştırılamayacaktır. Ayrıca cari döneme ait GSYİH verisi olmadığından da geleneksel modellerde yüksek frekanslı deęişkenin cari döneme ait verisinden faydalanılamayacaktır. Hatta bir önceki çeyrek dönemin GSYİH verisi de yayınlanmamışsa henüz söz konusu dönemde açıklanan yüksek frekanslı deęişkenlerden de yararlanılamayabilir.

2000'li yılların başından bu yana literatürde toplulaştırma yaklaşımının olumsuz etkilerine ve deęişkenlerin farklı zaman gecikmeleriyle yayınlanmalarına dikkat çekilmiş ve bu nedenle de çözüm odaklı çalışmalara yoğunlaşmıştır. Bu alandaki öncü çalışmalardan biri Ghysels ve dięerleri (2004)'nin çalışmasıdır. Ghysels ve dięerleri (2004), çalışmalarında farklı frekanslı serilerin aynı anda kullanılmasına izin veren Karma Frekanslı Veri Örnekleme (*Mixed Data Sampling*, MIDAS) adlı bir yöntem geliştirmişlerdir. Söz konusu bu yöntem, düşük frekanslı bağımlı deęişkenle birlikte yüksek frekanslı bağımsız deęişken veya deęişkenlerin birlikte kullanıldığı tek denklemlilik bir model yaklaşımıdır. Bu yaklaşımla birlikte deęişkenler orijinal frekanslarıyla çoklu zaman serileri modellerinde kullanılabilir. MIDAS yaklaşımında farklı frekanslı deęişkenlerin aynı anda modele dahil edilebilmelerinden dolayı yüksek frekanslı deęişken veya deęişkenlerin cari dönemdeki gözlemleri de kullanılabilir. Böylelikle öngörü literatüründe "anlık tahmin" ("*nowcasting*") kavramı kullanılmaya başlanmıştır. Anlık tahmin, herhangi bir deęişkenin cari döneme ait deęerinin öngörüsü için söz konusu deęişkenden görece daha yüksek frekanslı deęişken veya deęişkenlerin cari dönem içerisindeki gözlemlerinden yararlanılması olarak tanımlanabilir. MIDAS modeliyle birlikte literatürde MIDAS modelinin farklı uzantıları da geliştirilmiştir. Geliştirilen bu modellerle birlikte öngörü literatürünün ilgi odağı üçer aylık frekanslı ekonomik büyüme oranının anlık tahmini üzerine olmuştur. Bahsi geçen bu anlık tahminler başta ABD olmak üzere birçok ülkeye uygulanmıştır. MIDAS modeli ve onun çeşitli uzantılarıyla özellikle ekonomik büyüme oranının anlık tahmini ve öngörüsünü gerçekleştiren çalışmalara ABD için Tay (2006, 2007); Clements ve

Galvão (2008); Clements ve Galvão (2009); Armesto ve diğerleri (2010); Andreou ve diğerleri (2013); Galvão (2013); Guérin ve Marcellino (2013); McCracken ve diğerleri (2015); Foroni ve diğerleri (2015); Barsoum ve Stankiewicz (2015) ve Blasques ve diğerleri (2016), Euro bölgesi için Kuzin ve diğerleri (2011); Ferrara ve Marsilli (2013) ve Schumacher (2016), İtalya için Frale ve Monteforte (2009), Almanya için Marcellino ve Schumacher (2010), Çin için Jiang ve diğerleri (2017) İsviçre için Siliverstovs (2017) ve İsveç için Den Reijer ve Johansson (2019) örnek olarak gösterilebilir.

Öngörü literatüründe yaşanan bu gelişmeler, Türkiye ekonomisinin büyüme oranı üzerine gerçekleştirilen çalışmalara da kısmen yansımıştır. MIDAS yaklaşımıyla Türkiye ekonomisinin büyüme oranının anlık tahminini ve öngörüsünü gerçekleştiren çalışmalara Şen Doğan ve Midiliç (2016) başta olmak üzere Yamak ve diğerleri (2018); Erdoğan (2020) ve Ekinci ve Sakarya (2020) tarafından gerçekleştirilen çalışmalar örnek olarak verilebilir. Ancak Türkiye ekonomisi üzerine gerçekleştirilen bu çalışmalarda Şen Doğan ve Midiliç (2016)'in çalışması hariç sadece örneklem sonu anlık tahminlerin ve öngörülerin gerçekleştirildiği görülmektedir. Bu kapsamda bu çalışmanın amacı, MIDAS yöntemiyle Türkiye ekonomisinin üçer aylık frekanslı GSYİH büyüme oranının anlık tahmininin belirli bir zaman periyodunda gerçek zamanlı olarak gerçekleştirilerek daha tutarlı bir anlık tahmin elde edilebilir mi sorusunun cevabının araştırılmasıdır. Bahsi geçen bu araştırma için yedi farklı aylık frekanslı değişkenden yararlanılmıştır. GSYİH büyüme oranı öngörüsünde kullanılacak olan aylık frekanslı değişkenler şu şekilde sıralanabilir; reel kesim güven endeksi, imalat sanayi kapasite kullanım oranı, sanayi üretim endeksi, tüketici fiyat endeksi, üretici fiyat endeksi, reel toplam ihracat ve reel toplam ithalat. Sıralanan bu aylık frekanslı değişkenlerin her biriyle ayrı ayrı MIDAS modelleri oluşturularak GSYİH'nin büyüme oranının anlık tahminleri gerçekleştirilmiştir.

Söz konusu bu anlık tahminler için 2020 yılının Haziran ayının son işlem gününde ulaşılabilen veri setinden faydalanılmıştır. Anlık tahmini gerçekleştirilmek istenilen GSYİH büyüme oranı için veri aralığı 2007 yılı 1. çeyrek 2020 yılı 1. çeyreğini kapsamaktadır. MIDAS modellerinde bağımsız değişken olarak kullanılacak olan aylık frekanslı değişkenlerin ise ilk gözlemleri 2007'nin ocak ayına aittir. Ancak daha önce de değinildiği gibi iktisadi ve finansal değişkenlerin farklı gecikmelerle yayınlanmaktadır. Bu nedenle analizlerde kullanılan değişkenlerin ilk gözlemleri aynı zaman dilimine denk gelirken, son gözlemleri farklı zaman dilimlerine denk gelmektedir. Çalışmada yer alan aylık frekanslı değişkenlerin son gözlemleri; sanayi üretim endeksi, reel toplam ihracat ve reel toplam ithalat için 2020'nin nisan ayı, tüketici fiyat endeksi ve üretici fiyat endeksi için 2020'nin mayıs ayı ve son olarak reel kesim güven endeksi ve imalat sanayi kapasite kullanım oranı için 2020'nin haziran ayına aittir.

Uygulamada GSYİH, mevsimsel etkilerden arındırılmış ve ardından logaritmik 1. devresel farkı alınarak dönemlik GSYİH büyüme oranı hesaplanmıştır. Böylelikle çalışmada GSYİH'nin

dönemlik büyüme oranının anlık tahminine odaklanılmıştır. Çalışmada Türkiye ekonomisi üzerine gerçekleştirilen MIDAS yaklaşımını kullanan çalışmalardan farklı olarak GSYİH büyüme oranının sadece örneklem sonu anlık tahminine değinilmemiştir. Söz konusu bu anlık tahminlerde ilk olarak 2015'in ocak ayının son işlem gününde olduğu varsayılarak o tarihte ulaşılabilen veri setiyle 2015'in 1. çeyrek anlık tahmini gerçekleştirilmiştir. Ardından 2015'in şubat ayında yeni açıklanan gözlem değerleriyle 2015'in 1. çeyrek anlık tahmini tekrar yapılmıştır. Söz konusu dönemin anlık tahmini son kez 2015'in mart ayında ulaşılabilen veri setiyle tekrarlanmıştır. Bahsi geçen bu işlem 2020'nin haziran ayına kadar devam ettirilerek 2015 yılı 1. çeyrek 2020 yılı 2. çeyrek dönemleri arası GSYİH büyüme oranının anlık tahmin serileri oluşturulmuştur. Benzer işlemler MIDAS modelinin performansını karşılaştırabilmek için aylık frekanslı değişkenlerin üçer aylık frekansta toplulaştırılmış hallerinin kullanıldığı geleneksel modelle de GSYİH büyüme oranının öngörüsü gerçekleştirilmiştir. MIDAS modellerinde olduğu gibi geleneksel modelle de 2015'in ilk çeyreği 2020'nin 2. çeyreği dönemleri arasında GSYİH büyüme oranının öngörü serileri elde edilmiştir. Söz konusu bu öngörülerde ilgili çeyrek dönemin son işlem gününde ulaşılabilen veri setinden yararlanılmıştır. Ardından hem tahmin serilerinin hem de öngörü serilerinin ortalama mutlak hata (MAE), ortalama mutlak yüzde hata (MAPE), ortalama kare öngörü hatası (MSE) kök ortalama kare öngörü hatası (RMSE) ve mutlak ölçeklendirilmiş hata ortalaması (MASE) gibi tahmin hata kriterleri hesaplanmıştır. Ardından tahmin hata kriteriyle MIDAS yaklaşımıyla GSYİH büyüme oranının daha tutarlı anlık tahmini elde edilip edilmediği incelenmiştir.

Yukarıda anlatılan tüm bu işlemler gerçekleştirilirken her bir dönemde çalışmada yer alan değişkenlerin içinde bulunduğu varsayılan dönemde ulaşılabilen veri setleri, mevsimsellikten arındırılarak doğal logaritmik 1. devresel farkları alınmıştır.

Çalışma, dört bölümden oluşmaktadır. Bu bölümlerin ilkinde ampirik literatürde farklı frekanslı değişkenlerin bir arada olduğu modellerde nasıl bir yöntem izlendiği ve bu yöntemin eksik yanlarına değinilmiştir. Ardından Ghysels ve diğerleri (2004)'nin MIDAS yaklaşımı tanıtılarak MIDAS modelinin uzantıları ayrıntılı olarak anlatılmıştır. Çalışmanın 2. bölümünde ise MIDAS yaklaşımının öngörü literatürüne getirmiş olduğu avantajlarına değinilmiştir. Daha sonra yine bu bölümde MIDAS yaklaşımlarıyla ekonomik büyüme oranının anlık tahminini uygulayan çalışmalara yer verilmiştir. Üçüncü bölüme gelindiğinde ise Türkiye ekonomisi üzerine gerçekleştirilecek olan uygulamaya yer verilmiştir. Bu bölümde öncelikle analizlerde yer alacak değişkenler tanıtılmış ve değişkenlerin öngörü için durağanlık seviyeleri incelenmiştir. Ardından GSYİH büyüme oranının nasıl anlık tahmin edileceği MIDAS modelleriyle ayrıntılı olarak gösterilmiştir. Son bölüm olan 4. bölümde de bir önceki bölümde oluşturulan MIDAS modellerinin çözümleri gerçekleştirilmiş ve elde edilen bulgular, grafikler ve tablolar halinde sunulmuş ve değerlendirilmiştir. Sonuç ve öneriler bölümüyle de çalışma sonlandırılmıştır.

BİRİNCİ BÖLÜM

1. KARMA FREKANSLI VERİ ÖRNEKLEME (MIDAS)

1.1. Karma Frekanslı Veriler

Karma frekanslı verilerin kullanıldığı regresyon modellerini daha iyi anlamak adına gözlem değerleri, sadece $t = 1, \dots, T$ zaman dilimlerinde gözlemlenen ve kovaryans durağan sürece sahip düşük frekanslı y_t değişkeninin bağımlı değişken olarak yer aldığı regresyon modelini ele alalım. Bu regresyon modelinde kovaryans durağan sürece sahip ancak gözlem değerleri, t ile $t - 1$ zaman dilimleri arasında m kez gözlemlenebilen yüksek frekanslı $x_t^{(m)}$ değişkeni açıklayıcı değişken olarak yer alsın. Bir regresyon modelinde bulunması gereken değişkenlerin farklı frekanslarda olmaları durumunda, ampirik analizlerin uygulanması geleneksel çoklu zaman serileri yöntemlerinde neredeyse mümkün olmamaktadır. Özellikle makro iktisadi değişkenlerin frekansları büyük ölçüde farklılık göstermektedir. Ülkemizde Gayri Safi Yurtiçi Hasıla (GSYİH), üç aylık frekansta mevcutken; tüketici fiyat endeksi, işsizlik oranı, faiz oranları, para arzları gibi değişkenler aylık veya daha yüksek bir frekansta bulunabilmektedirler. Ampirik uygulamalarda çoğunlukla, değişkenler arasındaki frekans farkını ortadan kaldırmak için toplulaştırma işlemine başvurulmaktadır. Toplulaştırma işlemi prensipte yüksek frekanslı değişkenin, düşük frekanslı değişkenle aynı frekansa dönüştürülmesi ile gerçekleştirilmektedir.

Standart toplulaştırma yöntemleri, değişkenlerin stok ve akım yapısına bağlıdır. Stok değişkenler için toplulaştırma işlemi, sistematik örnekleme de olarak adlandırılan bir yöntemle başvurularak yapılmaktadır. Bu yöntem, düşük frekanslı değişkenin t zaman diliminden yüksek frekanslı değişkenin herhangi bir gözleminin alınması yoluyla yapılmaktadır.

$$x_t = \{x_t^{(m)}\}_t \quad (1)$$

Yukarıdaki (1) numaralı eşitlikte m ; düşük frekanslı t zaman dilimi içerisindeki yüksek frekanslı zaman dilimlerinin sayısıdır. Aynı denklemde x_t ; $x_t^{(m)}$ yüksek frekanslı değişkenin, düşük frekanslı değişkenin t zaman dilimi içerisindeki son gözlemlerinin alınmasıyla toplulaştırılmış bir değişkeni ifade etmektedir. Örnek olarak aylık frekansa sahip bir değişkenin çeyrek dönem içerisindeki aylık gözlemlerinin toplulaştırılarak söz konusu değişkenin üçer aylık frekansa dönüştürülmesi gösterilebilir. Öte yandan yüksek frekanslı değişken akım değişken olması

durumunda toplulaştırma işlemi, düşük frekanslı değişkenin t dönemi içerisindeki yüksek frekanslı $x_t^{(m)}$ değişkenine ait gözlem değerlerinin ya toplamlarıyla ya da aritmetik ortalamalarının alınmalarıyla gerçekleştirilmektedir. Bu toplulaştırma işlemi sırasıyla (2) ve (3) numaralı denklemlerde gösterildiği şekilde yapılmaktadır (Marcellino, 1999: 129 ve Marsilli, 2014: 19).

$$x_t = \sum_{m=0}^{m-1} x_t^{(m)} \quad (2)$$

$$x_t = \sum_{m=0}^{m-1} \frac{1}{m} x_t^{(m)} \quad (3)$$

Yukarıdaki modellerde x_t ; toplulaştırma işlemi ile düşük frekanslı değişken ile aynı frekansa dönüştürülmüş zaman serisidir. Toplulaştırılmış yüksek frekanslı değişken ile regresyon modeli aşağıdaki gibi kurulabilmektedir.

$$y_t = \beta_0 + \beta_1 x_t + u_t \quad (4)$$

Bu yöntemde yüksek frekanslı değişkenin t dönemi içerisindeki gözlemlerine eşit ağırlık verilmektedir. Söz konusu toplulaştırma işleminde, yüksek frekanslı değişkendeki birçok potansiyel olarak yararlı ve gerekli bilgi yok olabilir ve böylelikle etkin olmayan ve sapmalı tahminciler elde edilebilir (Andreou vd., 2010a: 246). Granger (1988), toplulaştırılmış değişkenin tüm bilgisinin ulaşılamayacağından dolayı bu değişkenin öngörü performansını kaybedebileceğini kanıtlamıştır. Granger'in ardından Nijman ve Palm (1990), Hollanda'nın Gayri Safi Milli Hasıla (GSMH) üzerine gerçekleştirdikleri çalışmalarında ARIMA modellerinde üçer aylık veriler yerine aylık verilerinin kullanılmasının öngörü performansının artacağına dair bulgulara ulaşmışlardır.

Toplulaştırma işleminin, değişkenlerin öngörü performansları üzerindeki etkilerinin yanı sıra bu değişkenlere ait zamansal bileşenler üzerinde de etkisi bulunabilmektedir. Granger ve Siklos (1995), ampirik olarak toplulaştırmanın, G-7 ülkelerine ait sanayi üretim değişkenlerine ait mevsimsel birim kökün, yapılarını değiştirebileceğini göstermişlerdir. Pierse ve Snell (1995), birim kök testlerinin asimptotik yerel gücünün (*asymptotic local power*) toplulaştırma derecesinden bağımsız olduğunu kanıtlamıştır. Bu kanıtla birlikte Pierse ve Snell, veri aralığının küçük olması durumunda birim kök testlerinin düşük gücünden (*power*) dolayı İngiltere için servet ile tüketim değişkeleri arasında gerçekte var olan eşbütünleşme ilişkisinin bulunamayabileceğini göstermişlerdir. Diğer yandan Granger (1988), 1. devresel farkında entegre olan değişkenlerin toplulaştırma altında 1. devresel farklarında entegre kalmaya devam etmelerinden dolayı toplulaştırmadan sonra değişkenler arasındaki eşbütünleşme ilişkisinin korunduğunu, fakat hata

düzeltilme modelinin yapısını deęişebileceğini ispatlamıştır. Öte yandan ampirik bir çalışmada Marsilli (1999), Kanada ekonomisi için kısa ve uzun vadeli faiz oranları arasındaki eşbütünlüşme ilişkisinin toplulaştırma ile deęişmediğini gözlemlemiştir.

Wei (1982), deęişkenler arasında gerçekte var olan tek yönlü nedensellik ilişkisinin toplulaştırma sonrasında çift yönlü bir nedensellik ilişkisine dönüşebileceğini teorik olarak ispatlamıştır. Granger (1988), yüksek frekanslı deęişkenle düşük frekanslı deęişken arasında frekans oranı m 'nin büyük olması durumunda toplulaştırmadan sonra durağan serilerin sanki eşanlı olarak birlikte hareket edebileceklerini ve bundan dolayı da deęişkenler arasındaki gerçek nedensellik ilişkisinin ortadan kaybolabileceğini belirtmiştir. Bununla birlikte Marsilli (1999), toplulaştırma işleminin, zayıf dışsallığı ve Granger nedensellięi etkilediğini hem teorik olarak hem de Kanada ekonomisi için kısa ve uzun vadeli faiz oranları ile gerçekleştirdięi ampirik olarak kanıtlamıştır.

Yukarıda bahsedilen toplulaştırma işleminin yanı sıra farklı frekanslı deęişkenlerin yer aldığı regresyon denklemlerinde Köprü Modelleri de kullanılmaktadır. Literatürde Köprü Modelleriyle, yüksek frekanslı deęişken veya deęişkenlerden faydalanılarak düşük frekanslı makro ekonomik deęişkenlerin öngörülleri gerçekleştirilmektedir.

$$y_t = \beta_0 + \sum_{i=1}^p \beta_i(L)x_{t-i} + u_t \quad (5)$$

Yukarıdaki (5) numaralı Köprü Modelinde, x_t ; $x_t^{(m)}$ yüksek frekanslı deęişkenin akım veya stok deęişken olmasına baęlı olarak toplulaştırılmış deęişkeni ve $\beta_i(L)$; x_t deęişkeni için p dereceli gecikme polinom işlemcisini göstermektedir. Ancak Köprü Modellerinde yüksek frekanslı deęişkenden faydalanabilmek için düşük frekanslı t dönemine kadar yüksek frekanslı $x_t^{(m)}$ deęişkenine ait tüm gözlemlerin yer alması gerekmektedir. Bunun yanı sıra söz konusu modelde düşük frekanslı deęişken y_t 'nin cari dönemi öngörülebilmektedir. Eęer Köprü Modelleri ile y_t 'nin daha uzun dönemlerde bir başka ifade ile $h \geq 1$ için y_{t+h} 'nin öngörüsü gerçekleştirilmek istenildiğinde yüksek frekanslı $x_t^{(m)}$ deęişkenin $t + h$ döneminin sonuna kadar gözlemlerinin eksiksiz olması gerekmektedir. Bu nedenle köprü modeliyle düşük frekanslı y_t 'nin daha uzun dönemlerdeki öngörüsü için döngüsel öngörü işlemi gerçekleştirilmektedir. Döngüsel öngörü için öncelikle yüksek frekanslı $x_t^{(m)}$ 'nin $t + h$ dönemine kadar olan gözlem deęerleri, ařaęıda (6) numaralı denklemde gösterilen otoregresif (AR) modelleri ile öngörülmektedir.

$$x_t^{(m)} = \alpha_0 + \sum_{i=1}^p \alpha_i(L^{i/m})x_{t-i/m}^{(m)} \quad (6)$$

Yukarıdaki (6) numaralı denklemde α_i ; yüksek frekanslı $x_t^{(m)}$ 'nin i 'nci gecikmesinin katsayısını, $\alpha_i(L^{i/m})$; yüksek frekanslı $x_t^{(m)}$ 'nin gecikme polinom işlemcisini ve p ; geleneksel model seçme kriterleriyle belirlenmiş AR derecesini göstermektedir. Yüksek frekanslı $x_t^{(m)}$ 'nin $t + h$ dönemine kadar olan gözlem değerleri belirlendikten sonra bu gözlem değerleriyle birlikte yukarıdaki (5) numaralı Köprü Modeliyle düşük frekanslı y_t 'nin $t + h$ dönemine kadar öngörüsü gerçekleştirilebilir (Froni ve Marcellino, 2013: 4 ve Schumacher, 2016: 260-261).

Karma frekanslı verilerle çalışmanın bir diğer yolu Durum Uzay Modelidir. Durum Uzay Modeli, gözlenen serileri saklı durum sürecine bağlayan bir Ölçüm Denklemi ve geçiş süreç dinamiklerini tanımlayan bir Geçiş Denkleminde oluşmaktadır. Ölçüm ve Geçiş Denklemlerinde yer alan katsayılar ve kovaryans matrisleri sistem matrisleri olarak bilinir ve bu matrislerin stokastik bir süreç izlemedikleri varsayılır. Böylelikle Durum Uzay Modelindeki sistem matrisleri, zamanla değişseler bile söz konusu bu değişim, önceden belirlenmiş kurallar çerçevesinde gerçekleşir. Eğer söz konusu sistem matrisleri, zamanla değişmezlerse Durum Uzay Modeli, zamanla değişmeyen (*time-invariant*) ya da zaman homojen (*time-homogeneous*) olur. Durum Uzay Modelinin amacı, ölçüm denleminde yer alan geçiş vektörünün, t zamanında sistemdeki tüm bilgileri içerecek şekilde ve mümkün olduğunda az sayıda öğeye sahip olacak şekilde oluşturulmasıdır. Durum Uzay Modelindeki sistem matrisleri, bilinmeyen bir parametre setine bağımlıdır. Bu parametreler hiper parametreler olarak bilinir. Hiper parametreler, modelin stokastik özelliklerinden belirlenebilmektedir. Bir model Durum Uzay Modeli formatında oluşturulduğunda Kalman Filtresi uygulanabilmektedir. Kalman Filtre yöntemi, düşük frekanslı t zaman diliminde ulaşılabilen bilgiler ile t zaman dilimindeki ölçüm denkleminde yer alan geçiş vektörünün optimal tahmincilerinin hesaplanması için döngüsel süreci sunmaktadır. Bunun yanı sıra Kalman Filtresi, yeni bilgilerin gelmesiyle söz konusu geçiş vektörünün sürekli olarak güncellenmesine olanak sağlamaktadır. Kalman Filtre yönteminde hata terimlerinin ve ölçüm denkleminde yer alan başlangıç geçiş vektörünün normal dağılımları varsayılmaktadır. Eğer normallik varsayımı sağlanamazsa Kalman Filtre yöntemi, söz konusu geçiş vektörünün koşullu ortalamasının hesaplanacağına dair bir garanti sunmamaktadır. Ancak yine de Kalman Filtre yöntemi, tüm doğrusal tahmin ediciler arasında ortalama kare öngörü hatasını (MSE) en aza indirgemesi açısından hala optimal bir tahmin edici olabilmektedir (Harvey, 1989: 100-105).

Durum Uzay Modelinde yer alan değişkenler karma frekanslarda olmaları halinde düşük frekanslı değişken sanki yüksek frekanslı değişkenmiş gibi hareket edilmektedir. Söz konusu modelde düşük frekanslı değişkenin yüksek frekansta gözlemlenemeyen değerleri “eksik gözlem” olarak ele alınmaktadır. Eksik gözlemlerin hesaplanmasında Kalman Filtre yöntemi uygun hesaplama aracı olarak kullanılmaktadır. Verilerde eksik gözlemin olması geçiş vektörü için uygun önsel parametreler elde edildikten sonra Kalman Filtre yöntemini etkilememektedir. Ancak Kalman Filtresinde Ölçüm ve Geçiş Denklemleri ve hata süreçleri için birçok varsayımların uygulanması ve

çok sayıda parametrenin tahmin edilmesi gerekmektedir (Harvey, 1989: 144, Andreou vd., 2010b: 1-2 ve Bai vd., 2013: 780).

1.2. Karma Frekanslı Veri Örnekleme

Bir önceki bölümde değinilen farklı frekanslı değişkenlerin bir arada bulunduğu regresyon modelindeki zorlukların üstesinden gelebilmek için Ghysels ve diğerleri (2004), gecikmesi dağıtılmış modeliyle yakından ilgili olan Karma Frekanslı Veri Örnekleme (*Mixed Data Sampling*) (MIDAS) yaklaşımını ortaya koymuşlardır. MIDAS modelinde yüksek frekanslı $x_t^{(m)}$ değişkeni ekonomik biçimde ve veri güdümlü (*data-driven*) olarak ağırlıklandırılarak modele dahil edilmektedir. Burada ekonomik biçimden kasıt, az sayıdaki parametre ile yüksek frekanslı $x_t^{(m)}$ değişkeninin modelde yer almasının sağlanmasıdır. Çünkü bazı modellerde yer alması gereken değişkenler arasındaki m frekans oranı bir hayli fazla olabilmektedir. Örneğin aylık enflasyon oranı ile günlük faiz oranlarının yer aldığı bir modelde m , 22'ye eşit olacaktır. Böyle bir durumda yüksek frekanslı değişkenin ağırlıklandırılması için 22 adet parametre yerine sadece birkaç parametre yeterli olacaktır. MIDAS modelinde yüksek frekanslı değişkenin t dönemi içerisindeki geçmiş değerleri aşağıdaki ağırlıklandırma fonksiyon kalıbı ile gösterilmektedir.

$$x_t^{(m)}(\theta) = W\left(L^{\frac{1}{m}}; \theta\right) x_t^{(m)} = \sum_{j=1}^q \omega_j(\theta) L^{\frac{j-1}{m}} x_t^{(m)} \quad (7)$$

Yukarıdaki modelde $W\left(L^{\frac{1}{m}}; \theta\right)$; yüksek frekanslı değişkenin ağırlıklandırma polinomu, $L^{\frac{1}{m}}$; yüksek frekanslı değişken için gecikme işlemcisini, q ; yüksek frekanslı değişken için gecikme sayısını ve θ ; hiper parametre olarak adlandırılan $r \times 1$ boyutlu parametre vektörünü göstermektedir. Burada r ; MIDAS modelinde tahmin edilmesi gereken parametre sayısıdır. Yukarıdaki (7) numaralı ağırlıklandırma fonksiyon kalıbıyla birlikte MIDAS regresyon modeli şu şekilde temsil edilebilir.

$$y_t = \beta_0 + \beta_1 \left\{ \sum_{j=0}^q \omega_j(\theta) L^{\frac{j}{m}} x_t^{(m)} \right\} + u_t \quad (8)$$

Bu modelde $\omega_j(\theta) L^{\frac{j}{m}} \in (0,1)$ ve $\sum_{j=0}^q \omega_{i+j}(\theta) L^{\frac{j}{m}} = 1$ varsayımları bulunmaktadır. Böylelikle MIDAS regresyon modelinde eğim katsayısı β_1 belirlenmesine izin verilmektedir (Andreou vd., 2010b: 5). (8) numaralı model doğrusal olmayan en küçük kareler (NLS) yöntemi ile tahmin edilmektedir.

Düşük frekanslı değişken y_t 'nin üçer aylık frekansa ve yüksek frekanslı değişken $x_t^{(m)}$ 'nin aylık frekansa sahip olması durumunda (8) numaralı denklem, aşağıdaki gibi açık bir biçimde yazılabilir.

$$y_t = \beta_0 + \beta_1[\omega_0 x_t^{(3)} + \omega_1 x_{t-\frac{1}{3}}^{(3)} + \dots + \omega_q x_{t-\frac{q}{3}}^{(3)}] + u_t \quad (9)$$

MIDAS modelinde yüksek frekanslı açıklayıcı değişken sayısı birden fazla olabilir. Bu durumda (8) numaralı MIDAS modeli, birden fazla yüksek frekanslı açıklayıcı değişkene genişletilebilir. Aynı frekansa sahip k adet $x_t^{(m)}$ yüksek frekanslı değişkenin açıklayıcı değişken olarak yer aldığı (8) numaralı MIDAS modeli aşağıdaki gibi yeniden yazılabilir.

$$y_t = \beta_0 + \sum_{i=1}^k \beta_i \sum_{j=0}^q \omega_j(\theta) L^{\frac{j}{m}} x_{i,t}^{(m)} + u_t \quad (10)$$

Ghysels ve diğerleri (2004), MIDAS regresyonlarının tüm serileri düşük frekansta toplulaştırılan geleneksel yaklaşımlardan daha etkin bir tahminde bulunabileceğini göstermişlerdir. Ayrıca, ayrıştırma sapmasının MIDAS ve gecikmesi dağıtılmış modelleri için aynı olduğunu ve açıklayıcı değişkenlerin daha yüksek frekansta örneklendiğinde ortadan kaybolduğunu da belirtmişlerdir.

MIDAS modelinin haricinde Durum Uzay Modelleriyle de karma frekanslı değişkenlerle çalışıldığı ve söz konusu modelde, Kalman Filtre yöntemiyle düşük frekanslı y_t değişkeninin yüksek frekansta eksik olan gözlem değerlerinin hesapladığı bir önceki alt bölümde değinilmişti. Ancak Kalman Filtre Yönteminde, söz konusu denklem sisteminin tamamen belirlenmesini gerektirmektedir. MIDAS Modeli, Durum Uzay Modeli yaklaşımından türetilen doğrusal projeksiyonun indirgenmiş formu olarak ele alınabilir. Böylelikle MIDAS Modeli, Durum Uzay Modelinin spesifikasyonlarını gerektirmemektedir. (Andreou vd., 2010b: 13 ve Ghysels, 2017: 1). Bai ve diğerleri (2013), Çarpımsal MIDAS regresyonunun Kalman filtresinin tam bir temsili olduğunu, diğer durumlarda ise çok küçük olan yaklaşım hatalarını (*approximation errors*) içerdiğini göstermişlerdir.

MIDAS modelin, bir önceki alt bölümün sonlarında bahsedilen karma frekanslı değişkenler için uygulanan Köprü Modelinden farkları şu şekilde sıralanabilir. İlk olarak MIDAS modeli, Köprü Modellerinin aksine düşük frekanslı değişken uzun dönemlerde döngüsel süreç gerektirmeden direkt olarak öngörüsü yapabilmektedir. İkinci olarak Köprü Modelleri bir önceki bölümde toplulaştırmanın olumsuzluklarını değinilen toplulaştırma işlemine tabi tutulmaktadır. Oysa ki MIDAS modelinde yüksek frekanslı değişken belirli ağırlıklandırma polinomları ile MIDAS

modeline dahil edilmektedir. Ayrıca literatürde düşük frekanslı makro iktisadi değişkenlere ait verilerin gecikmeli açıklanmasından dolayı söz konusu bu değişkenlere ait cari dönem değerleri öngörülme istenilmektedir. Bu öngörülerde MIDAS modelleri ile cari döneme ait yüksek frekanslı gözlemlerden yararlanılabilirken; Köprü Modellerinde cari döneme ait gözlem değerlerinden faydalanılabilmek için cari döneme ait yüksek frekanslı değişkenin eksik gözlemlerin uygun AR modelleri ile öngörülmesi gerekmektedir (Schumacher, 2016: 258).

MIDAS modellerinde hata terimlerinin genel özellikleri yanı sıra model spesifikasyonu konularında iki önemli sorun bulunmaktadır. Bunlardan ilki, yüksek frekanslı değişkenin optimal gecikme uzunluğunun belirlenmesine yöneliktir. Yüksek frekanslı değişkenin gecikme sayısı parametre sayısını etkilemediği için geleneksel Akaike bilgi kriteri (AIC), Schwarz bilgi kriteri (SIC) gibi ceza fonksiyonları uygulanamamaktadır. İkinci bir husus ise yüksek frekanslı değişkenin geçmiş değerlerini ağırlıklandırılacak olan ω_j için uygun fonksiyon kalıbının seçimidir. İzleyen alt bölümde yüksek frekanslı değişkenin ağırlıklandırılması için önerilmiş olan polinomlara değinilecektir.

1.2.1. Geleneksel Almon Polinomu

MIDAS regresyon modelinde yüksek frekanslı bağımsız değişken, Almon (1965), tarafından geliştirilen Almon Polinomu ile ağırlıklandırılabilir. Düşük frekanslı y_t değişkeninin bağımlı ve yüksek frekanslı $x_t^{(m)}$ değişkeninin bağımsız olduğu regresyon modeli için Almon modeli şu şekildedir.

$$y_t = \beta_0 + \sum_{m_0}^{k-1} x_t^{(m)} \left(\sum_{j=0}^p \tau^j \alpha_j \right)' + u_t \quad (11)$$

Yukarıdaki modelde p ; polinom derecesini, k ; optimal gecikme uzunluğunu ve m_0 ; yüksek frekanslı değişkenin, düşük frekanslı t zaman dilimindeki ilk gözlemini temsil etmektedir. Değişkenler arasındaki frekans oranı m 'yi 3, optimal gecikme uzunluğunu 3 ve polinom derecesini 2 kabul ettiğimizde yukarıdaki Almon denklemi, aşağıdaki gibi yazılabilir.

$$y_t = \beta_0 + \left[x_t^{(3)} + x_{t-1/3}^{(3)} + x_{t-2/3}^{(3)} \right] [\tau^0 \alpha_0 + \tau^1 \alpha_1 + \tau^2 \alpha_2]' + u_t \quad (12)$$

Burada geleneksel Almon yönteminde olduğu gibi $p + 1$ adet değişken oluşturulur. Bu değişkenler şu şekilde oluşturulmaktadır.

$$Z_{0,t} = \tau^0 x_t^{(3)} + \tau^0 x_{t-1/3}^{(3)} + \tau^0 x_{t-2/3}^{(3)} \quad (13)$$

$$Z_{1,t} = \tau^1 x_t^{(3)} + \tau^1 x_{t-1/3}^{(3)} + \tau^1 x_{t-2/3}^{(3)} \quad (14)$$

$$Z_{2,t} = \tau^2 x_t^{(3)} + \tau^2 x_{t-1/3}^{(3)} + \tau^2 x_{t-2/3}^{(3)} \quad (15)$$

Sonra oluşturulan bu değişkenlerin düşük frekanslı değişkenin t dönemi içerisindeki herhangi bir yüksek frekans dönemine denk gelen gözlemleri alınarak aşağıdaki indirgenmiş regresyon modeli tahmin edilmektedir.

$$y_t = \beta_0 + \alpha_0 Z_{0,t} + \alpha_1 Z_{1,t} + \alpha_2 Z_{2,t} + u_t \quad (16)$$

Yukarıdaki (16) numaralı denklem EKK yöntemi ile tahmin edilebilir. Söz konusu EKK yönteminin uygulanabilmesi için atlamalı örnekleme (*skip-sampled*) seçimi yapılır. Burada atlamalı örnekleme, yüksek frekanslı değişkenin Almon modeliyle ağırlıklandırılmasından sonra düşük frekanslı değişkenin t zaman dilimi içerisindeki yüksek frekanslı değişkenin gözlemlerinden sadece bir tanesinin seçilmesidir. Ancak söz konusu gözlem seçimi rastgele yapılmamaktadır. Örneğin düşük frekanslı t zaman diliminde yüksek frekanslı değişkenin ilk gözlemi seçilmişse $t - 1, t - 2, \dots$ düşük frekanslı zaman dilimlerinde de yüksek frekanslı değişkenin ilk gözlemi seçilmelidir. Diğer yandan Ghysels ve diğerleri (2004), atlamalı örnekleme ile tahmin edilen MIDAS Modelinin otokorelasyonlu hata terimlerine neden olacağını, ancak yine de EKK yönteminin, tutarlı ve gecikmesi dağıtılmış modellerine benzer şekilde sapmasız özellikleri taşıyan tahminler elde edebileceğini ifade etmişlerdir.

1.2.2. Üstel Almon Polinomu

Ghysels ve diğerleri (2005) ve Ghysels ve diğerleri (2007), MIDAS modelinde yüksek frekanslı değişkeni ağırlıklandırmak için aşağıdaki üstel Almon Polinomunu önermişlerdir. k adet parametreye sahip üstel Almon Polinomu (17) numaralı denklemde gösterilmiştir.

$$\omega_j(\theta_1, \dots, \theta_k) = \left(\frac{e^{(\theta_1 j + \dots + \theta_k j^k)}}{\sum_{j=1}^K e^{(\theta_1 j + \dots + \theta_k j^k)}} \right) \quad (17)$$

Yukarıdaki üstel Almon Polinomu oldukça esnek bir yapıdadır ve sadece birkaç parametre ile çeşitli şekiller alabilmektedir. Ghysels ve diğerleri (2005), yukarıdaki üstel Almon Polinomunu iki parametreye kullanmayı önermişlerdir. İki parametrenin bile kullanılması üstel Almon Polinomunda büyük bir esneklik sağlamak ve regresyonda kaç gecikmenin bulunduğu belirlenebilmektedir. İki parametrelili üstel Almon Polinomu aşağıdaki gibi ifade edilebilir.

$$\omega_j(\theta_1, \theta_2) = \left(\frac{e^{(\theta_1 j + \theta_2 j^2)}}{\sum_{j=1}^m e^{(\theta_1 j + \theta_2 j^2)}} \right) \quad (18)$$

Üstel Almon Polinomun kullanılması ağırlıkları doğal olarak pozitif olmaya zorlamaktadır. (18) numaralı modelle birlikte $W\left(L^{\frac{1}{m}}; \theta\right)$ gecikme polinomunun q gecikmesi için ekonomik biçimde bir yol sunmaktadır. Yüksek frekanslı değişkenin haftalık, düşük frekanslı değişkenin üç aylık olduğu yani $m = 12$ eşit olduğu bir modelde sabit terimle beraber 13 adet parametre tahmini yapılmaktadır. Ancak yukarıdaki üstel Almon fonksiyonu ile sadece 2 adet parametrenin tahmin edilmesi yeterli olacaktır. $\theta_1 = \theta_2 = 0$ olması durumunda üstel Almon Polinomu, yüksek frekanslı değişkenin gecikmeleri için eşit ağırlıklandırma verecektir (Andreou vd., 2010b: 5).

1.2.3. Beta Polinomu

Ghysels ve diğerleri (2007), üstel Almon Polinomunun yanı sıra $x_t^{(m)}$ yüksek frekanslı değişkenin ağırlıklandırılması için Beta Dağılımını da önermişlerdir. Normalleştirilmiş Beta olasılık yoğunluk fonksiyonu şu şekilde gösterilebilir.

$$\omega_j(\theta_1, \theta_2) = \frac{f(j, \theta_1; \theta_2)}{\sum_{j=1}^M f(j, \theta_1; \theta_2)} \quad (19)$$

Yukarıdaki (19) numaralı eşitlikte $f(j, \theta_1; \theta_2) = \frac{j^{a-1}(1-j)^{b-1}\Gamma(a+b)}{\Gamma(a)\Gamma(b)}$ Beta Dağılımıdır. Bu dağılımdaki $\Gamma(a) = \int_0^\infty e^{-j} j^{a-1} dx$ ise Gama Dağılımını göstermektedir. Beta Dağılımı, gecikme formunun spesifikasyonlarına bağlı olarak önemli özelliklere sahip olabilmektedir. Örneğin, polinomunun yığın boyutunun sadece θ_1 parametresi ile sınırlandırılması, azalan ağırlık değerlerini empoze edecektir. Sadece bir hiper parametresi θ_1 içeren bu ağırlıklandırma şeması aşağıdaki gibidir.

$$\varphi(k, \theta) = \varphi K(k, \theta_1) = \theta_1 (1 - k)^{\theta_1 - 1} \quad (20)$$

Üstel Almon ve Beta Polinomları, oynaklık hesaplanmasının pozitif tanımlılığı için gerekli olan pozitif katsayıları sağlamaktadırlar. Her iki polinomda doğrusal olmayan en küçük kareler (NLS) yöntemi kullanılarak tahmin edilebilir.

1.2.4. Kısıtsız MIDAS (U-MIDAS)

Foroni ve diğerleri (2015), yüksek frekansa sahip değişkenlerdeki bilgiyi yansıtabilmek adına kısıtsız MIDAS (U-MIDAS) yöntemini geliştirmişlerdir. U-MIDAS yöntemi, özellik mikro ve

makro iktisadi alanda deęişkenler arasında frekans farkının fazla olmadığı durumlarda yüksek frekanslı serilerde kullanılan dięer aęırlıklandırma yöntemlerine göre daha iyi performans göstermektedir. Genel hatları ile U-MIDAS modeli ařaęıdaki regresyon modelinde gösterilmiştir.

$$y_t = \beta_0 + \beta_1(L^{i/m})x_t^{(m)} + u_t \quad (21)$$

Burada $(L^{i/m})$; yüksek frekanslı deęişkenin gecikme katsayılarını temsil etmektedir. U-MIDAS yönteminde, üstel Almon gibi aęırlıklandırma yönteminin aksine yüksek frekanslı deęişkenin, düşük frekanslı deęişken periyoduna karşılık gelen deęerlerine eşit aęılıklar verilmektedir. Söz gelimi, aylık frekanslı serilerden yararlanılarak üçer aylık büyüme oranlarını tahmin ettięimizi varsayalım. Bununla birlikte yüksek frekanslı deęişken için optimal gecikme uzunluęu $p \geq 1$ olarak belirlenmiş olsun. Bu örneęimizde yüksek frekanslı deęişkendeki ilk gecikme döneminde düşük frekanslı $t - 1$ dönemi içerisinde yer alan 3. aylara denk gelen yüksek frekanslı deęişkenin verileri yer alacaktır. Başka bir ifade ile aralık, eylül, haziran ve mart aylarına ait veriler yer alacaktır. İkinci gecikme döneminde ise düşük frekanslı $t - 1$ dönemindeki 2. aylara ait yüksek frekanslı veriler yer alacaktır. 3. gecikme döneminde ise düşük frekanslı $t - 1$ döneminde bulunan ilk aylara denk gelen yüksek frekanslı veriler kullanılacaktır. 4. gecikmede ise düşük frekanslı $t - 2$ dönemi içerisinde yer alan 3. aylara denk gelen yüksek frekanslı deęişkenin verilerinden faydalanılacaktır. Bu durum belirlenen optimal gecikme uzunluęuna kadar devam etmektedir. Foroni ve dięerleri (2015), optimal gecikme uzunluęunun geleneksel zaman serileri analizlerinde kullanılan bilgi kriterleri ile belirlenebileceęini belirtmişlerdir.

U-MIDAS yönteminde, üstel Almon gibi aęırlıklandırma yöntemlerinin aksine doğrusal olmasından dolayı EKK ile parametre tahmini gerçekleştirilebilmektedir. Ancak regresyon modelinde deęişkenler arasında frekans farkının çok yüksek olması durumunda tahmin edilmesi gereken parametre sayısı bir hayli fazla olacaktır. Örneęin günlük verili bir deęişkenle üçer aylık verili bir deęişkenin aynı regresyon modelinde kullanıldığı düşünelim. Bu durumda düşük frekansta bir dönem gecikmeye gidilmesi yüksek frekansta 66 gecikmeye kadar gidilmesi anlamına gelecektir. Böylelikle parametrelerin serbestlik dereceleri bir hayli düşecektir. Hatta bazı durumlarda tahmin edilmesi gereken parametre sayısı düşük frekanslı deęişkenin gözlem sayısından daha fazla olması olacaktır.

1.2.5. Basamak Ağırlıklı MIDAS Modeli

Bir önceki alt bölümde anlatılan U-MIDAS modelinde, m değerinin büyük olması durumunda parametre sayısının olağanüstü bir biçimde arttığı görülmüştür. Şöyle ki, frekans oranının bir hayli yüksek olması durumunda U-MIDAS Modeli, EKK yöntemi altında tahmin edilmesi imkansız hale gelebilecektir. Öte yandan Forsberg ve Ghysels (2007), Corsi (2004) tarafından oluşturulan yüksek frekanslı gerçekleşen oynaklığın heterojen otoregresif model (*heterogeneous autoregressive model of the realized volatility, HAR-RV*) modelinden yola çıkarak basamak fonksiyonlarına sahip bir basamak ağırlıklı MIDAS Modelini geliştirmişlerdir. Forsberg ve Ghysels, bu modeli geliştirirken Andersen ve diğerleri (2005)'nin HAR-RV modelinin Oynaklık kısmını sürekli ve kesikli kısımlarına ayırmasından faydalanmışlardır. Söz konusu modelde RV'nin kesikli kısmından yararlanılarak yüksek frekanslı değişkenin geçmiş değerlerinin belli bir basamak sayısı kadar benzer katsayı değerleri aldığı varsayılmaktadır. Değişkenler arasındaki frekans oranı m değerinin büyük olması durumunda bile basamak Ağırlıklı MIDAS modeli, EKK yöntemiyle tahmin edilebilmektedir. S basamağa sahip basamak Ağırlıklı MIDAS modeli aşağıda gösterildiği şekildedir.

$$y_t = \beta_0 + \beta_1 \sum_{j=1}^{\lfloor q/S \rfloor} \left(\sum_{s=0}^{S-1} \gamma_j \right) L^{\frac{j}{m}} x_t^{(m)} + u_t \quad (22)$$

Yukarıdaki denklemde γ_j ; yüksek frekanslı değişkenin geçmiş değerlerinin S basamak kadar olan kısmının benzer katsayıya eşit olacağını ifade etmektedir. Aynı denklemde $\lfloor q/S \rfloor$; ise basamak sayısının optimal gecikme uzunluğu q 'ya bölünmesiyle elde edilecek değer bir üst tam sayıya yuvarlanmasıyla oluşturulan parametre sayısıdır. Basamak Ağırlıklı MIDAS modelinde optimal gecikme uzunluğu geleneksel zaman serilerindeki gibi Akaike, Schwarz gibi bilgi kriterleri ile belirlenebilmektedir. Söz konusu modelde optimal gecikme uzunluğunun modelde oluşturacağı gözlem kaybı, $\lfloor q/S \rfloor - 1$ 'e eşit olmaktadır. Örneğin yüksek frekanslı değişkenin aylık, düşük frekanslı değişkenin de üçer aylık olduğu bir durumda basamak sayısının 3 ve yüksek frekanslı değişken için optimal gecikme uzunluğunun 5 olduğunu varsayalım. Bu durumda $\lfloor (5/3) - 1 \rfloor = 1$ 'den gözlem kaybı 1 olacaktır. Basamak ağırlıklı MIDAS yönteminde yüksek frekanslı değişken, dönüşüme tabi tutulacaktır. Bu dönüşüm ile oluşturulacak olan serilerin sayısı, optimal gecikme sayısının, basamak sayısına bölünmesi ile elde edilecek değer bir üst sayıya yuvarlanmasına eşit olacaktır. Örneğimizde bu değer $\lfloor (5/3) \rfloor = 2$ olarak hesaplanmıştır. Burada ilk seri $S_1 = L^{\frac{0}{m}} x_t^{(m)} + L^{\frac{1}{m}} x_t^{(m)} + L^{\frac{2}{m}} x_t^{(m)}$ şeklinde oluşturulurken; 2. seri $S_2 = L^{\frac{3}{m}} x_t^{(m)} + L^{\frac{4}{m}} x_t^{(m)}$ biçiminde oluşturulmaktadır. Başka bir ifade ile yüksek frekanslı değişkenin ocak, şubat ve mart¹ aylarına denk gelen gözlemleri toplanarak ilk gözlemi; şubat, mart ve nisan aylarına ait gözlemleri toplanarak 2.

¹ Yüksek frekanslı değişkenin ilk gözlemi ocak ayında başladığı varsayılmıştır.

gözlemi ve yüksek frekanslı değişkenin son gözlemine kadar bu işlem devam ederek ilk seri oluşturulmaktadır. İkinci seri için ise ocak ayından önce gözlem değeri olmadığı için veri kaybı söz konusu olacaktır. İkinci serinin ilk gözlemi, ocak ve şubat aylarının gözlem değerlerinin toplanmasına; 2. gözlemi ise şubat ve mart aylarına ait gözlem değerlerinin toplanmasına eşit olacaktır. Burada yüksek frekanslı değişkenin 3 ve 4 dönem gecikmeleri kullanılacağı için 2. serinin ilk gözlemi 1. serinin 3. gözlemine denk gelecektir.

Daha sonra düşük frekanslı değişkenin t dönemine ya da $(t - j)/m$ dönemine denk gelen S_1 ve S_2 değişkenlerine ait gözlemlerin kullanılması suretiyle aşağıdaki regresyon modeli EKK yöntemi ile tahmin edilmektedir.

$$Y_t = \beta_0 + \gamma_1 S_1 + \gamma_2 S_2 + u_t \quad (23)$$

Yukarıdaki regresyon modelinden tahmin edilecek olan γ_1 parametresi yüksek frekanslı değişkenin ilk 3 gecikme katsayısına ve γ_2 parametresi ise 4 ve 5 gecikme katsayılarına eşit olacaktır. Tekrar edilecek olunursa S_1 ve S_2 , yüksek frekanslı $x_t^{(m)}$ değişkenin sırasıyla 3 ve 2 dönem gecikmelerinin toplanmaları yoluyla oluşturulmuş serilerdir.

1.3. MIDAS Modellenin Uzantıları

İlgili literatürde Ghysels ve diğerleri (2004)'nin ardından MIDAS modeli, geleneksel zaman serilerinde kullanılan yöntemlerle harmanlanarak MIDAS modelinin farklı versiyonları geliştirilmiştir. Geliştirilen bu modeller ile, genellikle ekonomik büyüme oranı öngörü performansını iyileştirilip iyileştirmediği incelenmiştir.

1.3.1. Otoregresif MIDAS (AR-MIDAS) Modeli

Yüksek frekanslı değişkenin toplulaştırılmasıyla oluşturulan x_t değişkeniyle regresyon modeli aşağıdaki gibi yazılabildiği daha önce de değinilmiştir.

$$y_t = \beta_0 + \beta_1 x_t + u_t \quad (24)$$

Yukarıdaki (24) numaralı modelde u_t hata terimi otokorelasyonlu olabilir. Otokorelasyon sorununu gidermek amacıyla uygulamada bağımlı değişkenin gecikme veya gecikmeleri modelin sağ tarafına açıklayıcı değişken olarak getirilir. Bu da genelleştirilmiş en küçük kareler (GEKK) anlamına gelir. Söz konusu modelde bağımlı değişken y_t 'nin bir dönem gecikmesinin yer aldığı gecikmesi dağıtılmış model şu şekilde gösterilebilir.

$$y_t = \beta_0 + \alpha_1 y_{t-1} + \beta_1 x_t + u_t \quad (25)$$

Clements ve Galvão (2008), yukarıdaki (25) numaralı modeli, MIDAS spesifikasyonu ile birleştirerek otoregresif MIDAS (AR-MIDAS) modelini geliştirmişlerdir.

$$y_t = \beta_0 + \alpha_1 y_{t-1} + \beta_1 \sum_{j=0}^q \omega_{i+j}(\theta) L^{\frac{j}{m}} x_{t-1}^{(m)} + u_t \quad (26)$$

Bu modelde $\sum_{i=0}^p \sum_{j=0}^q \omega_{i+j}(\theta) L^{\frac{j}{m}} = 1$ varsayımı ile β_1 eğim katsayısını temsil etmektedir. Clements ve Galvão, yukarıdaki (26) numaralı modeli yeniden yazdıklarında aşağıdaki eşitliğe ulaşmışlardır.

$$y_t = \beta_0 (1 - \alpha_1)^{-1} + \beta_1 (1 - \alpha_1)^{-1} \sum_{j=0}^q \omega_{i+j}(\theta) L^{\frac{j}{m}} x_{t-1}^{(m)} + \tilde{u}_t \quad (27)$$

Bu eşitlikte $\tilde{u}_t = (1 - \alpha_1)^{-1} u_t$ 'dir. $x_{t-1}^{(m)}$ 'deki polinomun $L^{\frac{j}{m}}$, $\sum_{j=0}^q \omega_{i+j}(\theta) L^{\frac{j}{m}}$ 'teki polinomun ve L , $\sum \alpha_1^j L^j$ 'teki polinomun çarpımıdır. Bu durum $x_t^{(m)}$ 'nin mevsimsellik içerip içermemesinden bağımsız olarak $x_t^{(m)}$ 'ye y_t 'nin mevsimsel tepkisi olabilmektedir. Clements ve Galvão, ortak faktör kısıtlaması yoluyla MIDAS modeline otoregresif gecikmeler eklenebileceğini önermişlerdir.

$$y_t = \beta_0 + \alpha_1 y_{t-1} + \beta_1 (1 - \alpha_1)^{-1} \sum_{j=0}^{m-1} \omega_{i+j}(\theta) L^{\frac{j}{m}} x_{t-1}^{(m)} + u_t \quad (28)$$

Böylelikle y_t 'nin $x_t^{(m)}$ 'e verdiği tepki mevsimsel olmaktan çıkmaktadır (Clements ve Galvão, 2008: 547).

1.3.2. ADL-MIDAS Modeli

Andreou ve diğerleri (2013), Genişletilmiş Gecikmesi Dağıtılmış modelini MIDAS modeline uyarlayarak ADL-MIDAS modelini sunmuşlardır. Sunmuş oldukları bu model aşağıdaki şekilde gösterilebilir.

$$y_t = \beta_0 + \sum_{i=1}^p \alpha_i y_{t-i} + \beta_1 + \sum_{i=0}^p \sum_{j=0}^{m-1} \omega_{i+j}(\theta) L^{\frac{i+j}{m}} x_t^{(m)} + u_t \quad (29)$$

Yukarıdaki ADL-MIDAS modelinde p 'ye kadar olan gecikme uzunluğu, yüksek frekanslı değişkenin geçmiş değerlerinin, düşük frekanslı değişken içerisindeki son zaman dilimini aşmasına izin verilmektedir. Andreou ve diğerleri (2010b), iterasyona gereksinim duyulmadan ADL-MIDAS modeli ile düşük frekanslı y_t değişkeninin birkaç dönem sonrasındaki değerlerinin doğrudan öngörülebileceğini savunmuşlardır.

1.3.3. Faktör MIDAS Modeli

Bilindiği üzere zaman serili iktisadi değişkenlerin öngörüsünde çok fazla sayıda değişkenden yararlanılması öngörü doğruluğunu artırabilmektedir. Ancak herhangi bir modelde çok fazla sayıda açıklayıcı değişkenin bulunması modelin serbestlik derecesini bir hayli düşürecektir. Hatta bazı durumlarda öngörü modeline örneklem boyutundan daha fazla değişken katılmak istenebilir. Böyle bir durumda klasik yaklaşımlarla modelin tahmin edilmesi imkansız hale gelmektedir. Nitekim literatürde bir çok zaman serili değişkendeki bilgileri, bir veya birkaç değişkene indirgeyebilen faktör yaklaşımları geliştirilmiştir. Karma frekanslı modellerinin de gelişimiyle beraber literatürde bir çok yüksek frekanslı değişken ile düşük frekanslı iktisadi değişkenlerin öngörüsüne yoğunlaşmıştır. Bu kapsamda Marcellino ve Schumacher (2010), birçok öngörücü değişkenin bulunması halinde cimrilik (*parsimony*) eksikliği gidermenin bir yolu olarak Boivin ve Ng (2005)'nin dinamik Faktör Modelini MIDAS yöntemine uyarlayarak dinamik bir Faktör MIDAS (FA-MIDAS) modelini geliştirmişlerdir. Faktör MIDAS modelinde öncelikle yüksek frekanslı değişkenlerle faktör ya da faktör değişkenleri oluşturulmaktadır. Tek bir statik faktör değişkeni şu şekilde oluşturulabilir.

$$X_t^{(m)} = \Lambda f_t^{(m)} + u_t^{(m)} \quad (30)$$

Burada $X_t^{(m)}$; N adet yüksek frekanslı $x_{i,t}^{(m)}$ değişkenlerini içeren değişkenler vektörünü, $f_t^{(m)}$; çok fazla sayıdaki yüksek frekanslı değişkenlerin ortak bileşimini ifade eden faktör değişkenini ve Λ ; yüksek frekanslı her bir değişkenin ortak bileşenini temsil eden yükleme matrisidir. Daha sonra oluşturulan bu faktör değişkeni, MIDAS modeline eklenerek aşağıda yer alan (31) numaralı FA-MIDAS modeli kurulur.

$$y_t = \beta_0 + \beta_1 \sum_{j=0}^q \omega_{i+j}(\theta) L^j f_t^{(m)} + u_t \quad (31)$$

Marcellino ve Schumacher (2010), yukarıdaki FA-MIDAS modelinde yer alan yüksek frekanslı $f_t^{(m)}$ faktör değişkenini, üstel Almon Polinomu ile ağırlıklandırmışlardır. Yukarıdaki $f_t^{(m)}$ faktör değişkenine AR terimleri eklenerek aşağıdaki gibi dinamik faktör değişkeni oluşturulabilir.

$$f_t^{(m)} = \sum_{i=1}^p p_i f_{t-i}^{(m)} + e_t^{(m)} \quad (32)$$

Bununla birlikte (30) numaralı modeldeki $u_t^{(m)}$ hata terimi bağımsız ve özdeş dağılmış beyaz gürültülü süreç izlemesini sağlamak için ilgili modele, hareketli ortalama (MA) süreci eklenebilir.

$$u_t^{(m)} = \sum_{i=1}^q q_i u_{t-i}^{(m)} + e_t^{(m)} \quad (33)$$

Yukarıdaki (32) ve (33) numaralı eşliklerde Hem AR hem de MA terimlerinin karakteristik köklerinin birim çember içinde buldukları varsayılmaktadır (Boivin ve Ng, 2005: 3). Böylelikle yukarıdaki (31) numaralı FA-MIDAS modeli dinamik formda yazılabilir.

$$y_t = \beta_0 + \beta_1 \left[\sum_{j=0}^q \omega_{i+j}(\theta) L^{\frac{j}{m}} \left[\sum_{i=1}^p p_i f_{t-i}^{(m)} + e_t^{(m)} \right] \right] + \left[\sum_{i=1}^q q_i u_{t-i}^{(m)} + e_t^{(m)} \right] \quad (34)$$

Bazı durumlarda modelde yer alan yüksek frekanslı değişkenlerden birden fazla faktör değişkeni oluşturulabilir. Böyle bir durumda yukarıdaki (31) numaralı FA-MIDAS modeli, r adet faktör olacak şekilde aşağıdaki gibi genişletilebilir.

$$y_t = \beta_0 + \sum_{i=1}^r \beta_{1,i} \left[\sum_{j=0}^q \omega_{i+j}(\theta) L^{\frac{j}{m}} F_{i,t}^{(m)} \right] + u_t \quad (35)$$

Bu modelde $F_{i,t}^{(m)} = (f_{1,t}^{(m)}, f_{2,t}^{(m)} \dots f_{r,t}^{(m)})'$; (30) numaralı modeldeki gibi oluşturulmuş faktör değişkenleridir.

Marcellino ve Schumacher (2010), çalışmalarının ampirik kısmında oluşturmuş oldukları faktör sayısını, Bai ve Ng (2002) tarafından önerilen kriterleri kullanarak hesaplamışlardır. Bai ve Ng (2002), faktör sayısını belirlemek için Akaike Bilgi Kriterine (AIC) ve Bayesyen Bilgi Kriterine (BIC) benzer şekilde ceza fonksiyonlarına dayalı üç farklı kriter önermişlerdir.

$$IC_{p1}(r) = \ln(V(r, F_{i,t}^{(m)})) + r \left(\frac{N + T * m}{NT * m} \right) \ln \left(\frac{NT * m}{N + T * m} \right) \quad (36)$$

$$IC_{p2}(r) = \ln(V(r, F_{i,t}^{(m)})) + r \left(\frac{N + T * m}{NT * m} \right) \ln C_{NT*m}^2 \quad (37)$$

$$IC_{p3}(r) = \ln(V(r, F_{i,t}^{(m)})) + r \left(\frac{\ln C_{NT*m}^2}{C_{NT*m}^2} \right) \quad (38)$$

Yukarıda yer alan bilgi kriterlerinde N ; yüksek frekanslı değişken sayısını, $T * m$; gözlem sayısını ve r ; oluşturulan faktör sayısını temsil etmektedir. Bunların yanı sıra bu kriterlerde $C_{NT*m} = \min(\sqrt{N}, \sqrt{T * m})$ eşittir ve $V(r, F_{i,t}^{(m)})$; aşağıda da gösterildiği gibi hata terimlerin varyanslarının ortalamasıdır.

$$V(r, F_{i,t}^{(m)}) = N^{-1} \sum_{i=1}^N \hat{\sigma}_i^2 \quad (39)$$

(39) numaralı eşitlikte $\hat{\sigma}_i^2 = \hat{u}'_{i,t} \hat{u}_{i,t} / T$; i . değişkene ait hata terimlerin varyansıdır.

Marcellino ve Schumacher (2010), geliştirmiş oldukları FA-MIDAS modelini Clements ve Galvão (2008)'nin AR-MIDAS modeliyle birleştirerek Faktör AR MIDAS modelini de sunmuşlardır.

$$y_t = \beta_0 + \alpha_1 y_{t-1} + \sum_{i=1}^r \beta_{1,i} \sum_{j=0}^q \omega_{i+j}(\theta) L^{\frac{j}{m}} F_{t,i}^{(m)} + u_t \quad (40)$$

Fakat bir önceki bölümde değinildiği gibi $F_{i,t}^{(m)}$, y_t 'nin mevsimsel tepkisi olabilmektedir. Bu nedenle Clements ve Galvão (2008)'in önerisi izlenerek bağımlı değişken y_t 'nin bir dönem gecikmesi FA-MIDAS modelinin sağ tarafına eklenebilir. Böylelikle aşağıda yer alan (41) numaralı Faktör AR-MIDAS modeline ulaşılır.

$$y_t = \beta_0 + \alpha_1 y_{t-1} + \sum_{i=1}^r \left[\beta_{1,i} (1 - \alpha_1)^{-1} \sum_{j=0}^q \omega_{i+j}(\theta) L^{\frac{j}{m}} F_{t,i}^{(m)} \right] + u_t \quad (41)$$

1.3.4. Öncülerle MIDAS Modeli

Uygulamada yüksek frekanslı değişkenlere ait verilerin açıklanması veya yayınlanması çoğunlukla düşük frekanslı değişkenlerinkine göre daha erken olmaktadır. Örneğin $t + 1$ çeyrek döneminde, t çeyrek dönemine ait GSYİH verileri açıklanmadan önce aylık frekansa sahip enflasyon, işsizlik gibi makro iktisadi değişkenlerin $t + 1$ çeyrek dönemi içerisindeki aylık verileri açıklanabilmektedir. Nunes (2005) ve Giannone ve diğerleri (2008), yüksek frekanslı değişkenler için yeni verilerin yayınlanması durumunda anlık tahmin (*nowcasting*) terminolojisini kullanarak

düşük frekanslı değişkenin öngörülerini güncelleyecek çeşitli modeller geliştirmişlerdir (Andreou vd., 2013: 3). Diğer yandan Andreou ve diğerleri (2013), öncü verilerle MIDAS regresyonlarına dayalı alternatif model sunmuşlardır. Bu modelde $t + 1$ zaman dilimi içerisindeki yüksek frekanslı değişkenin bilgilerini de içerecek şekilde ADL-MIDAS modeli öncülerle birlikte, şu şekilde yazılabilir.

$$y_t = \beta_0 + \sum_{i=1}^p \alpha_i y_{t-i} + \beta_1 \left[\sum_{i=0}^{m-1} \omega_i(\theta) L^{\frac{i}{m}} x_{t-i+1}^{(m)} + \sum_{i=0}^p \sum_{j=0}^{m-1} \omega_{i+j}(\theta) L^{\frac{j}{m}} x_t^{(m)} \right] + u_t \quad (42)$$

Bu modelde $\sum_{i=0}^{m-1} \omega_i(\theta) L^{\frac{i}{m}} x_{t-i+1}^{(m)}$, $t + 1$ dönemindeki yüksek frekanslı değişkene ait bilgileri içermektedir.

1.3.5. Düzgün Geçişli MIDAS (ST-MIDAS)

Galvão (2013), yüksek frekanslı değişkenin, düşük frekanslı değişkenin gelecekteki değeri üzerindeki etkisinin farklı rejimlerle birlikte değişimini dikkate alan Düzgün Geçişli MIDAS (ST-MIDAS) modelini geliştirmiştir. Geliştirilen bu model, şu şekilde gösterilebilir.

$$y_t = \beta_0 + \beta_1 x_t^{(m)}(\theta) [1 - G_t(x_t^{(m)}(\alpha); \gamma, c)] + \beta_2 x_t^{(m)}(\theta) [G_t(x_t^{(m)}(\alpha); \gamma, c)] + u_t \quad (43)$$

Bu modelde γ ; ölçekten bağımsız (*independent of scale*) olacak şekilde yüksek frekanslı değişkenin koşulsuz standart sapması ($\hat{\sigma}_x$) ile standartlaştırılmış düzgünleştirme parametresini, α ; yüksek frekanslı değişkeni bir geçiş değişkeni olarak kullanırken uygulanan ağırlığı gösteren parametre vektörünü ve $G_t(x_t^{(m)}(\alpha); \gamma, c)$; aşağıdaki (44) numaralı denklemde gösterilen geçiş fonksiyonunu temsil etmektedir.

$$G_t(x_t^{(m)}(\alpha); \gamma, c) = \frac{1}{1 + e^{-(\gamma/\hat{\sigma}_x)(x_t^{(m)}(\alpha) - c)}} \quad (44)$$

Bu denklemde $G_t(x_t^{(m)}(\alpha); \gamma, c)$ geçiş fonksiyonu, 0 ile 1 arasında değerler alan ve yüksek frekanslı değişkenin ağırlıklı toplamına bağlı olan bir lojistik fonksiyondur. Düzgünleştirme parametresi γ büyük olduğu zaman geçiş fonksiyonu, $x_t^{(m)}(\alpha) \leq c$ olduğunda sıfır olan ve $x_t^{(m)}(\alpha) > c$ olduğunda 1'e eşit olan bir gösterge fonksiyonuna benzemektedir. Dolayısıyla, $x_t^{(m)}(\theta)$ 'nin y_t 'yi tahmin etmedeki etkisi, $x_t^{(m)}$ 'nin ağırlıklı toplamı küçük olduğunda β_1 'e ve $x_t^{(m)}$ 'nin ağırlıklı toplamı büyük olduğunda ise β_2 'ye eşittir. Öte yandan düzgünleştirme parametresi

γ küçük fakat sıfıra eşit olmadığı zaman, $x_t^{(m)}(\theta)$ 'nin y_t 'yi öngörmedeki etkisi, $G_t(x_t^{(m)}(\theta); \gamma, c)$ 'nin değerine bağlı olarak β_1 ve β_2 'nin zamanla değişen ağırlıklı bir toplamıdır.

Geçiş değişkeni geçmiş değerlerin ağırlıklı toplamı olduğu zaman ST-MIDAS regresyon denkleminin tahmini için geçiş değişkeninin gecikmesinin belirlenmesi zorunlu değildir. Bununla birlikte ST-MIDAS regresyon modelinde yinelemeli tahminlere ihtiyaç duymadan çok adımlı doğrudan öngörü yapılabilmektedir (Galvão, 2013: 398).

1.3.6. Markov Değişim (MS-MIDAS)

Bilindiği üzere özellikle makro iktisadi değişkenler olmak üzere tüm iktisadi değişkenler az veya çok konjonktürel dalgalanmalar sergilemektedirler. Yüksek frekanslı değişkenlerin öngörü yeteneği, ekonominin durumuna göre değişiklik gösterebilir. Bu kapsamda Guérin ve Marcellino (2013), Markov Modelini MIDAS çerçevesiyle birleştirerek Markov Değişim MIDAS regresyonunu (MS-MIDAS) geliştirmişlerdir. Belirli bir rejimde olma olasılığının gerçek zamanlı olarak değerlendirilmesine ve öngörülmesine olanak sağlayan MS-MIDAS modeli (45) numaralı denklemde gösterilmiştir.

$$y_t = \beta_0(S_t) + \beta_1(S_t) \sum_{j=0}^q \omega_j(\theta) L^j x_t^{(m)} + u_t(S_t) \quad (45)$$

Bu denklemde S_t ; veri oluşturma sürecindeki farklı rejimleri temsil etmektedir. Aynı denklemde $u_t | S_t \sim NID(0, \sigma^2(S_t))$; yani, hata terimleri, sıfır ortalama ve değişen rejim durumuna göre $\sigma^2(S_t)$ varyansı ile normal ve özdeş dağılıma sahiptir. Rejim üreten süreç, aşağıdaki geçiş olasılıkları ile tanımlanan sınırlı sayıda $S_t = \{1, \dots, M\}$ durumu olan bir ergodik Markov zinciridir.

$$p_{i,j} = Pr(S_{t+1} = j | S_t = i) \quad (46)$$

$$\sum_{j=1}^M p_{i,j} = 1 \quad \forall i, j \in \{1, \dots, M\} \quad (47)$$

(46) numaralı eşitlikte $p_{i,j}$; t döneminde i rejimindeyken $t + 1$ döneminde j rejimine geçme olasılığını belirtmektedir. Bu geçiş olasılıklarının zaman içinde sabit kaldığı varsayılmaktadır. Ancak (45) numaralı modelde β_0 sabit terimi, β_1 eğim parametresi ve $\sigma^2(S_t)$ hata teriminin varyansının değişimine izin verilmektedir. Özellikle eğim parametresindeki değişimler, yüksek frekanslı değişkenin dünyanın farklı rejimlerindeki değişimlerini öngörebilmesine imkan tanımaktadır.

MIDAS parametrelerindeki bir deęişim rejimler arasında aęrılıklandırma fonksiyonunun farklı bir yapısına yol açacaktır. Ancak bu durum, modelde tahmin edilmesi gereken parametre sayısını arttıracak ve böylelikle aęrılıklandırma fonksiyonu oldukça doęrusal olmayan bir hale geleceğinden modelin tahmini zorlaşacaktır. Bu nedenle Guérin ve Marcellino, uygulamış oldukları algoritma ile yakınsama problemleriyle karşılaşmışlardır. Bundan dolayı da baęımlı deęişken için genellikle aykırı öngörü sonuçları elde etmişlerdir.

1.3.7. Kısıtsız Markov Deęişim (MS-U-MIDAS)

Belirli bir fonksiyon tarafından kısıtlanan gecikme polinomlarına sahip MIDAS modelleri, gerçek veri oluşturma sürecini iyi yansıtabilecek kadar esnek olmayabilir. Bu durum, Guérin ve Marcellino (2013) tarafından sunulan MS-MIDAS modeli için de geçerlidir. Barsoum ve Stankiewicz (2015), Foroni ve dięerleri (2015)'in, kısıtsız MIDAS'ın öngörü performansını artırabileceğini tespit etmelerinden dolayı, U-MIDAS modelini, Markov rejim deęişim modeli ile birleştirerek, aşağıda (48) numaralı eşitlikte gösterilen kısıtsız Markov deęişim MIDAS (MS-U-MIDAS) modelini tanıtmışlardır.

$$y_t = \beta_0(S_t) + \sum_{j=0}^{J-1} \left\{ \beta_{j+1}(S_t) \sum_{m=0}^q \omega_j(\theta) L^m x_t^{(m)} \right\} + u_t(S_t) \quad (48)$$

Konjonktürel hareketleri hesaba katmak için yukarıdaki denklemin parametreleri, yani sabit terim β_0 , eğim parametreleri β_{j+1} ve σ_u^2 hata teriminin varyansı farklı rejimlere baęlı olarak deęişebilmektedir. Yüksek frekanslı deęişkenin aęrılıklandırılmasında kullanılan θ ; hiper parametre vektörünün Guérin ve Marcellino (2013) tarafından tanıtılan MS-MIDAS modelinde sabit kalmaktadır, ancak MS-U-MIDAS modelinde tüm parametrelerin deęişebileceğinden bu model MS-U-MIDAS modeli, MS-MIDAS modelinden daha esnek hale gelmektedir. (Barsoum ve Stankiewicz, 2015: 36).

1.4. Karma Frekanslı VAR (MF-VAR) Modeli

Daha önceki alt bölümlerde tek denklemlı MIDAS modelleri üzerinde durulmuştur. Bu alt bölümde birden fazla denklem ile kurulan Karma Frekanslı VAR (MF-VAR) Modelleri tanıtılacaktır. MIDAS literatüründe MF-VAR modeli iki farklı şekilde ele alınmaktadır. Bunlardan birincisi, parametre güdümlü (*parameter-driven*) MF-VAR modeli, ikincisi ise gözlem güdümlü (*observation driven*) MF-VAR modelidir. Parametre güdümlü MF-VAR modeli, düşük frekanslı serilerin yüksek frekanslı gözlemlerini eksik veri olarak ele alan ve dolayısıyla açık olmayan durumları ayıklamak için filtrelemeye dayanan, saklı süreçleri içeren, Durum Uzayı modelidir. Öte yandan gözlem

güdümlü MF-VAR modeli, geleneksel VAR modellerine benzer bir biçimde veri esaslı oluşturulabilmektedir.

1.4.1. Parametre Güdümlü MF-VAR Modeli

Parametre güdümlü MF-VAR modelinde düşük frekanslı değişkenin gözlemleri eksik gözlem olarak ele alınarak sistemde yer alan bütün değişkenler yüksek frekanslı değişkenler gibi değerlendirilmektedir. Mariano ve Murasawa (2003, 2010), düşük frekanslı y_t değişkeninin yüksek frekanslı gözlemlerini oluşturmak için ayrıştırma yöntemini önermişlerdir. Mariano ve Murasawa (2003, 2010), düşük frekanslı y_t değişkeninin üçer aylık frekansta olduğu ve yüksek frekanslı değişken $x_t^{(3)}$, aylık frekansta bulunduğu bir durum üzerinden düşük frekanslı değişkenin aylık gözlemlerinin nasıl oluşturulacağını göstermişlerdir. Bunun için düşük frekanslı y_t değişkenini, aylık frekansta gözlemlenemeyen $y_t^{(3)}$ değişkeni ile aşağıdaki şekilde oluşturmuşlardır.

$$\ln y_t = \frac{1}{3} (\ln y_t^{(3)} + \ln y_{t-1/3}^{(3)} + \ln y_{t-2/3}^{(3)}) \quad (49)$$

Yukarıdaki (49) numaralı eşitlikte $y_t^{(3)}$; üçer aylık frekanslı y_t değişkeninin aylık frekanslı halini ve \ln ; doğal logaritmayı temsil etmektedir. Bu denklemin birinci devresel farkı alındığında aşağıdaki eşitliğe ulaşılır.

$$\begin{aligned} \ln y_t - \ln y_{t-1} = & \frac{1}{3} (\ln y_t^{(3)} - \ln y_{t-1}^{(3)}) + \frac{1}{3} (\ln y_{t-1/3}^{(3)} - \ln y_{t-4/3}^{(3)}) + \frac{1}{3} (\ln y_{t-2/3}^{(3)} \\ & - \ln y_{t-5/3}^{(3)}) \end{aligned} \quad (50)$$

Mariano ve Murasawa (2003), (50) numaralı eşitliği yeniden düzenleyerek aşağıdaki (51) ve (52) numaralı eşitliklere ulaşmışlardır.

$$\begin{aligned} \Delta^{(3)} y_t = & \frac{1}{3} (\Delta y_t^{(3)} + \Delta y_{t-1/3}^{(3)} + \Delta y_{t-2/3}^{(3)}) + \frac{1}{3} (\Delta y_{t-1/3}^{(3)} + \Delta y_{t-2/3}^{(3)} + \Delta y_{t-1}^{(3)}) + \frac{1}{3} (\Delta y_{t-2/3}^{(3)} \\ & + \Delta y_{t-1}^{(3)} + \Delta y_{t-4/3}^{(3)}) \end{aligned} \quad (51)$$

$$\Delta^{(3)} y_t = \frac{1}{3} \Delta y_t^{(3)} + \frac{2}{3} \Delta y_{t-1/3}^{(3)} + \Delta y_{t-2/3}^{(3)} + \frac{2}{3} \Delta y_{t-1}^{(3)} + \frac{1}{3} \Delta y_{t-4/3}^{(3)} \quad (52)$$

Yukarıdaki eşitliklerde $\Delta^{(3)}$; düşük frekanslı y_t değişkeninin devresel farkını; Δ ; saklı yüksek frekanslı $y_t^{(3)}$ değişkeninin 1. devresel farkını temsil etmektedir. Yüksek frekanslı $x_t^{(3)}$ ve saklı

yüksek frekanslı $y_t^{(3)}$ değişkenlerini içeren $Z_t^{(3)}$ değişkenler vektörü, (53) numaralı eşitlikte gösterilmektedir.

$$Z_t^{(3)} = (x_t^{(3)}, y_t^{(3)})' \quad (53)$$

Benzer şekilde $x_t^{(3)}$ yüksek frekanslı değişkeni ve y_t düşük frekanslı değişkeni içeren Z_t değişkenler vektörü aşağıdaki gibi yazılabilir.

$$Z_t = (x_t^{(3)}, y_t)' \quad (54)$$

Yukarıdaki (53) ve (54) numaralı eşitliklerden hareket edilerek çıkılarak aşağıdaki (55) numaralı eşitliğe ulaşılmaktadır.

$$Z_t - \mu = H(L^{1/3}) (Z_t^{(3)} - \mu^{(3)}) \quad (55)$$

(55) numaralı eşitlikte μ ve $\mu^{(3)}$; sırasıyla Z_t ve $Z_t^{(3)}$ 'ün beklenen değerlerini, $L^{1/3}$; yüksek frekanslı gecikme işlemcisini ifade etmektedir. Aynı eşitlikte $H(L^{1/3})$, y_t 'nin üçer aylık gözlemlerini, aylık frekansta gözlemlenemeyen $y_t^{(3)}$ değişkeninin k gerçekleştirmelerine bağlayan ağırlıklandırma matrisinin k dereceden polinomudur.

Yukarıdaki (53) numaralı eşitlikte gösterilen $Z_t^{(3)}$ değişkenler vektöründen hareket edilerek p gecikmeli yüksek frekanslı VAR(p) modeli aşağıdaki şekilde oluşturulabilir.

$$Z_t^{(3)} = \sum_{i=1}^p A_i Z_{t-i}^{(3)} + u_t^{(3)} \quad (56)$$

Bu eşitlikte A_i ; p adet 2×2 boyutundaki katsayı matrisini; $u_t^{(3)}$; $u_{y,t}^{(3)}$ ve $u_{x,t}^{(3)}$ hata terimlerini içeren 2×1 boyutundaki hata terimleri sütun vektörünü göstermektedir. Bu vektörde yer alan hata terimleri aşağıdaki (57) numaralı eşitlikte gösterildiği gibi ortalamaları sıfır, varyansları sabit olan ve normal dağıldıkları varsayılmaktadır.

$$\begin{bmatrix} u_{y,t}^{(3)} \\ u_{x,t}^{(3)} \end{bmatrix} \sim N \left(0, \begin{bmatrix} \sigma_y^2 & 0 \\ 0 & \sigma_x^2 \end{bmatrix} \right) \quad (57)$$

Yukarıdaki (56) numaralı yüksek frekanslı VAR(p) modelinde saklı yüksek frekanslı $y_t^{(3)}$ değişkeninin gözlemlenemeyen aylık frekanslı değişkenleri olduğu için Durum Uzay Modeline başvurulmaktadır. Söz konusu Durum Uzay Modelinde Ölçüm Denklemi, gözlemlenebilir Z_t vektörü ile aylık frekanslı $Z_t^{(3)}$ vektörü arasındaki ilişkiyi belirtirken; Geçiş Denklemi, (56) numaralı denklemde gösterilen VAR sürecini belirtmektedir. Böylelikle (56) numaralı yüksek frekanslı VAR(p) modeli, (52) numaralı toplulaştırma denklemi ile birlikte $p \leq 4$ varsayımıyla Durum Uzay Modeli olarak aşağıda yer alan denklemler ile gösterilebilir.

$$s_t = F s_{t-1/3} + G v_t \quad (58)$$

$$\begin{bmatrix} y_t - \mu_y \\ x_t^{(3)} - \mu_x^{(3)} \end{bmatrix} = H(L^{1/3}) s_t \quad (59)$$

Yukarıdaki Durum Uzay Modelinde (58) numaralı denklem Ölçüm Denklemi, (59) numaralı denklem ise Geçiş Denklemi temsil etmektedir. Ölçüm denkleminde yer alan v_t hata teriminin G vektörü ile çarpımı (56) numaralı denklemde yer alan yüksek frekanslı VAR(p) modelinin hata terimi $u_t^{(3)}$, ye eşittir. Aynı zamanda v_t hata terimi, sıfır ortalama ve sabit varyans ile normal dağılıma sahiptir $v_t \sim N(0, I_N)$. Söz konusu Durum Uzay Modelinde yer alan s_t geçiş vektörü, yüksek frekanslı $x_t^{(3)}$ ve saklı yüksek frekanslı $y_t^{(3)}$ değişkenlerin beklenen değerlerinin çıkartılmasıyla elde edilmektedir. Aşağıdaki (60) ve (61) numaralı denklemlerde s_t geçiş vektörünün hesaplanması gösterilmektedir.

$$s_t = \begin{bmatrix} z_t \\ \vdots \\ z_{t-4/3} \end{bmatrix} \quad (60)$$

$$z_t = \begin{bmatrix} y_t^{(3)} - \mu_y^{(3)} \\ x_t^{(3)} - \mu_x^{(3)} \end{bmatrix} \quad (61)$$

Durum Uzay modelinde yer alan matrisler aşağıdaki şekilde tanımlanabilir.

$$F = \begin{bmatrix} A_1 & A_2 & \cdots & A_p \\ I_N & 0_{N \times N} & \cdots & 0_{N \times N} \\ 0_{N \times N} & \ddots & \cdots & \vdots \\ \vdots & \cdots & I_N & 0_{N \times N} \end{bmatrix} \quad (62)$$

$$G = \begin{bmatrix} \Sigma^{1/2} \\ 0_{N \times N} \\ \vdots \\ 0_{N \times N} \end{bmatrix} \quad (63)$$

$$H(L^{1/3}) = \begin{bmatrix} 1/3 & 0 \\ 0 & 1 \end{bmatrix} + \begin{bmatrix} 2/3 & 0 \\ 0 & 0 \end{bmatrix} L^{1/3} + \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} L^{2/3} + \begin{bmatrix} 2/3 & 0 \\ 0 & 1 \end{bmatrix} + \begin{bmatrix} 1/3 & 0 \\ 0 & 1 \end{bmatrix} L^{4/3} \quad (64)$$

Yukarıdaki eşitliklerde N ; yüksek ve düşük frekanslı $x_t^{(3)}$ ve y_t 'nin toplam gözlem sayısını, I_N ; $N \times N$ boyutlu birim matrisini, $0_{N \times N}$; sıfırlardan oluşan $N \times N$ boyutlu matrisi, $\Sigma^{1/2}$; (56) numaralı $VAR(p)$ modelindeki $u_t^{(3)} = (u_{y,t}^{(3)}, u_{x,t}^{(3)})'$ hata terimlerinin standart sapmalarını göstermektedir.

Yukarıda (58) ve (59) numaralı denklemlerde gösterilen Durum Uzay Modeli, düşük frekanslı y_t değişkeninin yüksek frekansta gözlemlenemeyen verileri nedeniyle Kalman Filtresi kullanılarak maksimum olabilirlik yöntemi altında tahmin edilebilir.

Yüksek frekanslı VAR modelinin tahmini için öncelikle düşük frekanslı y_t değişkeninin yüksek frekansta eksik gözlemleri olmasından dolayı Ölçüm Denklemi, aşağıda yer alan (65) numaralı denklemde gösterildiği şekilde belirtilmektedir.

$$y_t^+ = \begin{cases} y_t & \text{eğer } y_t \text{ gözlemlenebiliyorsa} \\ e_t & \text{diğer durumda} \end{cases} \quad (65)$$

Mariano ve Murasawa (2010), (65) numaralı denklemdeki e_t serisini Durum Uzay Modelinin parametrelerinden bağımsız olarak sanki standart normal dağılımdan çekilmiş gibi oluşturmuşlardır $e_t \sim N(0, I_{N \times N})$. Böylelikle (56) numaralı modeldeki $u_t^{(3)} = (u_{y,t}^{(3)}, u_{x,t}^{(3)})'$ hata terimleri için (57) numaralı eşitlikte gösterilen sıfır ortalama, sabit varyans ve normal dağılım şartları sağlanabilir.

Yukarıda (65) numaralı denklemde e_t serisinin oluşturulmasının ardından (58) ve (59) numaralı denklemde yer alan Durum Uzay Modeli yeniden aşağıda gösterilen (66) ve (67) numaralı denklemdeki yeniden gibi yazılabilir.

$$s_t = F s_{t-1/3} + G v_t \quad (66)$$

$$\begin{bmatrix} y_t^+ - \mu_{y_t^+} \\ x_t^{(3)} - \mu_x^{(3)} \end{bmatrix} = \mu_t + H(L^{1/3}) s_t + D_t e_t \quad (67)$$

Yeniden ifade edilen Durum Uzay Modelinde $v_t \sim N(0, I_N)$ ve $e_t \sim N(0, I_{N_1})$ ile standart normal dağılıma sahiptirler. Söz konusu Durum Uzay Modelinde $t = \frac{1}{3}, \frac{2}{3}, 1, \frac{4}{3}, \dots, T$ için (66) numaralı denklem aşağıdaki gibi gösterilebilir.

$$\begin{pmatrix} y_t^+ \\ x_t^{(3)} \end{pmatrix} = \begin{pmatrix} \mu_{y_t} \\ \mu_{x_t^{(3)}} \end{pmatrix} + \begin{pmatrix} F_{y_t} \\ F_{x_t^{(3)}} \end{pmatrix} s_t + \begin{pmatrix} G_{y_t} \\ 0 \end{pmatrix} e_t \quad (68)$$

Bu modelin zamana bağlı olarak değişen yapısı aşağıda yer alan denklemlerle oluşturulabilir.

$$\mu_{y_t} = \begin{cases} \mu_{y_t^{(3)}} & \text{eğer } y_t \text{ gözlemlenebiliyorsa} \\ 0 & \text{diğer durumda} \end{cases} \quad (69)$$

$$F_{y_t} = \begin{cases} F_{y_t^{(3)}} & \text{eğer } y_t \text{ gözlemlenebiliyorsa} \\ 0 & \text{diğer durumda} \end{cases} \quad (70)$$

$$G_{y_t} = \begin{cases} 0 & \text{eğer } y_t \text{ gözlemlenebiliyorsa} \\ I_{N_1} & \text{diğer durumda} \end{cases} \quad (71)$$

1.4.2. Gözlem GÜdümlü MF-VAR Modeli

Ghysels (2016), Mariano ve Murasawa (2003)'dan farklı olarak karma frekanslı seriler için gözlem güdümlü MF-VAR modeli geliştirmiştir. Bir önceki bölümde anlatılan yüksek frekanslı VAR modelinden farklı olarak MF-VAR modeli, düşük frekanslı y_t değişkeni aynı frekansta ele alınmaktadır. Söz konusu MF-VAR modelinde yüksek frekanslı $x_t^{(m)}$ değişkenin düşük frekansta sisteme katılabilmesi için ayrıştırma işlemine tabi tutulmaktadır. Bu ayrıştırma işleminde $x_t^{(m)}$ değişkenin düşük frekanslı t zaman periyodundaki ilk gözlem değerleriyle 1. değişken, 2. gözlem değerleriyle 2. değişken elde edilmektedir. Bu durum yüksek frekanslı $x_t^{(m)}$ değişkenin, düşük frekanslı t zaman dilimindeki m 'nci gözleme kadar sürdürülerek $x_t^{(m)}$ 'nin m adet farklı alt değişkeni oluşturulmaktadır. Aşağıda (72) numaralı denklemde, yüksek frekanslı $x_t^{(m)}$ değişkeni ve düşük frekanslı y_t değişkeni için MF-VAR(P) modeli oluşturulmuştur.

$$\begin{bmatrix} x_{t-(m-1)/m}^m \\ x_{t-(m-2)/m}^m \\ \vdots \\ x_t^m \\ y_t \end{bmatrix} = \begin{bmatrix} \alpha_{0,1} \\ \alpha_{0,2} \\ \vdots \\ \alpha_{0,m} \\ \alpha_{0,m+1} \end{bmatrix} + \sum_{j=1}^P \alpha_j \begin{bmatrix} x_{t-j-(m-1)/m}^m \\ x_{t-j-(m-2)/m}^m \\ \vdots \\ x_{t-j}^m \\ y_{t-j} \end{bmatrix} + \begin{bmatrix} u_{t,1} \\ u_{t,2} \\ \vdots \\ u_{t,m} \\ u_{t,m+1} \end{bmatrix} \quad (72)$$

Yukarıdaki (72) numaralı denklemden u_t 'ler; hata terimlerini, t ; düşük frekanslı zaman dilimini, $j - (m - 2)/m$; yüksek frekanslı zaman diliminde gecikmeyi, j ; düşük frekans zaman diliminde gecikmeyi göstermektedir. Ayrıca α_j ; j adet $(m + 1) \times (m + 1)$ boyutunda katsayılar matrisidir. $j = 1, \dots, P$ için α_j katsayılar matrisi (73) numaralı denklemden gösterilmiştir.

$$\alpha_j = \begin{bmatrix} \alpha_j^{1,1} & \alpha_j^{1,2} & \dots & \alpha_j^{1,m} & \alpha_j^{1,m+1} \\ \alpha_j^{2,1} & \alpha_j^{2,2} & \dots & \alpha_j^{2,m} & \alpha_j^{2,m+1} \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ \alpha_j^{m,1} & \alpha_j^{m,2} & \dots & \alpha_j^{m,m} & \alpha_j^{m,m+1} \\ \alpha_j^{m+1,1} & \alpha_j^{m+1,2} & \dots & \alpha_j^{m+1,m} & \alpha_j^{m+1,m+1} \end{bmatrix} \quad (73)$$

Söz konusu MF-VAR modelindeki sistemde birer tane düşük ve yüksek frekanslı değişken olmasına rağmen sistemde sanki $m + 1$ adet değişken varmış gibi oluşturulmuştur. Bu nedenle Kalman Filtre Yöntemi ile düşük frekanslı y_t değişkeni için yüksek frekanslı gözlemler oluşturulmasına gerek duyulmamaktadır. Bunun yanı sıra iktisadi değişkenler açısından çoğunlukla düşük frekanslı değişkenler, yüksek frekanslı değişkenlerden daha geç açıklanmalarından dolayı düşük frekanslı y_t değişkeni, sistemde en son sıraya eklenmiştir. Ayrıca düşük frekanslı y_t değişkeni için gizli saklı yüksek frekanslı gözlemler oluşturulmadığı için MF-VAR modelinde etki-tepki fonksiyonu standart VAR modelindeki tekniklerle uygulanabilmektedir.

Özellikle makro iktisadi göstergelerin farklı frekanslarda yayınlanmalarından dolayı nedensellik ve eş-bütünleşme gibi zaman serisi analizleri güçleştirmektedir. Bu güçlüğü aşmak için çoğunlukla yüksek frekanslı değişkenler toplulaştırma işlemi ile düşük frekans haline dönüştürülmektedir. Ancak Marcellino (1999), yüksek frekanslı bir değişkenin toplulaştırma ile düşük frekanslı değişkene dönüştürülmesi halinde değişkenler arasında sahte nedensel ilişkilerin ortaya çıkabileceğini ya da tam tersinin olabileceğini çalışmasında göstermiştir. Ghysels ve diğerleri (2016a), Granger nedensellik analizinde toplulaştırılmış değişkenler yerine serilerin orijinal frekanslarının kullanılmasının değişkenler arasındaki olası nedenselliğin daha iyi yakalanabileceğini teorik açıdan ispatlamışlardır.

Ghysels ve diğerleri (2016a), çalışmalarında yüksek frekanslı değişkenin aylık ve düşük frekanslı değişkenin üçer aylık olduğu iki değişken için MF-VAR modelinde nedensellik ilişkisinin nasıl elde edileceğini göstermişlerdir. Bunun için yüksek frekanslı değişkenin, δ parametresi ve düşük frekanslı değişkenin de α parametresiyle AR(1) süreci izledikleri varsayılarak (72) numaralı denklemden yer alan MF-VAR modelini sistemin derecesi 1 olacak şekilde yapısal formda yeniden oluşturmuşlardır.

$$\underbrace{\begin{bmatrix} 1 & 0 & 0 & 0 \\ -\delta & 1 & 0 & 0 \\ 0 & -\delta & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}}_{\equiv N} \begin{bmatrix} x_{t-2/3}^3 \\ x_{t-1/3}^3 \\ x_t^3 \\ y_t \end{bmatrix} = \underbrace{\begin{bmatrix} 0 & 0 & \delta & \gamma_1 \\ 0 & 0 & 0 & \gamma_2 \\ 0 & 0 & 0 & \gamma_3 \\ \beta_3 & \beta_2 & \beta_1 & \alpha \end{bmatrix}}_{\equiv M} \begin{bmatrix} x_{t-1-2/3}^3 \\ x_{t-1-1/3}^3 \\ x_{t-1}^3 \\ y_{t-1} \end{bmatrix} + \begin{bmatrix} u_{t,1} \\ u_{t,2} \\ u_{t,3} \\ u_{t,4} \end{bmatrix} \quad (74)$$

Yukarıdaki (74) numaralı denklemde γ parametreleri; düşük frekanslı değişkenin yüksek frekanslı değişken üzerindeki etkisini, β parametreleri; yüksek frekanslı değişkenin düşük frekanslı değişken üzerindeki etkisini göstermektedir. Ghysels ve diğerleri (2016a), söz konusu yapısal MF-VAR modelinin sol tarafında yer alan N katsayılar matrisinin tersini almışlardır. Elde edilen N^{-1} matrisi ile modelin her iki yanını çarpıldığında M katsayılar matrisi aşağıdaki gibi olmaktadır.

$$N^{-1}M = \begin{bmatrix} 0 & 0 & \delta & \sum_{i=1}^1 \delta^{1-i} \gamma_i \\ 0 & 0 & \delta^2 & \sum_{i=1}^2 \delta^{2-i} \gamma_i \\ 0 & 0 & \delta^3 & \sum_{i=1}^3 \delta^{3-i} \gamma_i \\ \beta_3 & \beta_2 & \beta_1 & \alpha \end{bmatrix} \quad (75)$$

(75) numaralı denklemde yer alan katsayılar matrisi ile yüksek ve düşük frekanslı değişkenler arasındaki nedensellik ilişkisine bakılabilmektedir. Bahsi geçen matriste yüksek frekanslı x_t^3 değişkeninin, düşük frekanslı y_t değişkeninin Granger nedeni olmadığını belirten H_0 hipotezi (76) numaralı denklemde yer almaktadır.

$$H_0: \beta_1 = \beta_2 = \beta_3 = 0 \quad (76)$$

Benzer şekilde aşağıda (77) numaralı denklemde, düşük frekanslı y_t değişkeninin, düşük frekanslı x_t^3 değişkeninin Granger nedeni olmadığını belirten H_0 hipotezi bulunmaktadır.

$$H_0: \sum_{i=1}^1 \delta^{1-i} \gamma_i = \sum_{i=1}^2 \delta^{2-i} \gamma_i = \sum_{i=1}^3 \delta^{3-i} \gamma_i = 0 \quad (77)$$

1.5. Ters MIDAS Modeli

MIDAS yönteminin geliştirilmesiyle birlikte farklı frekanslarda yayınlanan makro iktisadi göstergeler toplulaştırma yöntemine başvurulmadan aynı model üzerinde çalışılmıştır. Ancak tek denklem MIDAS yönteminde bağımlı değişkenin daima bağımsız değişken ve değişkenlerin

frekansından düşük olması gerekmektedir. MIDAS modelindeki bu zorunluluğu ortadan kaldırmak için Foroni ve diğerleri (2018) tarafından Kısıtsız Ters (*Reverse*) MIDAS (RU-MIDAS) ve Ters (*Reverse*) MIDAS (R-MIDAS) modelleri geliştirilmiştir. Geliştirilen bu modellerde bağımlı değişken, bağımsız değişken ve değişkenlerden daha yüksek frekansta olabilmektedir.

1.5.1. Kısıtsız Ters MIDAS (RU-MIDAS)

Foroni ve diğerleri (2018), yüksek frekanslı $x_t^{(m)}$ değişkeninin, aşağıda yer alan (78) numaralı denklemde gösterildiği gibi saklı yüksek frekanslı $y_t^{(m)}$ değişken ile birlikte otoregresif AR(p) süreci izlediğini varsayımlıdır.

$$x_t^{(m)} = \sum_{i=1}^p \beta_i x_{t-i/m}^{(m)} + \sum_{i=1}^p \alpha_i y_{t-i/m}^{(m)} + u_t^{(m)} \quad (78)$$

Yukarıdaki (78) numaralı denklemde β_i ve α_i sırasıyla yüksek frekanslı $x_t^{(m)}$ değişkeninin ve saklı yüksek frekanslı $y_t^{(m)}$ değişkeninin gecikme katsayılarını göstermektedir. Söz konusu denklem, aşağıdaki gibi yeniden yazılarak RU-MIDAS modeli oluşturulabilir.

$$x_{t,j}^{(m)} = \sum_{i=1}^p \beta_{i,j} x_{t-\frac{i}{m}j}^{(m)} + \sum_{i=1}^q \alpha_i y_{t-i} + u_{t,j} \quad (78)$$

(79) numaralı denklemde gösterilen RU-MIDAS modelinde $j = 1, 2, \dots, m$ yüksek frekanslı $x_t^{(m)}$ değişkeninin düşük frekanslı t zaman dilimin içerisindeki j 'nci yüksek frekanslı zaman dilimini ifade etmektedir. İlgili denklemde p ve q ; sırasıyla yüksek ve düşük frekanslı değişkenlerin optimal gecikme uzunluklarıdır.

Foroni ve diğerleri (2018), RU-MIDAS modeli doğrusal olduğu için EKK yöntemi ile kolaylıkla tahmin edilebileceğini ve modelde yer alan değişkenlerin gecikme uzunlukları standart bilgi kriterleri ile belirlenebileceğini belirtmişlerdir.

RU-MIDAS modelinde m farklı regresyon modeli elde edilebilmektedir. Modelde genel olarak $u_{t,j}$ hata terimleri arasında olası korelasyonun varlığından ötürü RU-MIDAS modelini sistem tahmin yöntemi ile tahmin edilebilir. Buradan hareketle Foroni ve diğerleri (2018), kukla değişkenler vasıtasıyla RU-MIDAS modelindeki m regresyon denklemini tek bir regresyon modeli olarak tahmin edilebileceğini önermişlerdir. Foroni ve diğerleri (2018), yüksek frekanslı değişkenin aylık, düşük

frekanslı değişkenin üçer aylık olduğu bir modelde RU-MIDAS modelini kukla değişkenlerle birlikte aşağıda yer alan (80) numaralı denklemle tek bir regresyon modelinde göstermişlerdir.

$$\begin{aligned}
x_t^{(3)} = & \alpha_1(1 - D_2 - D_3)y_{t-\frac{1}{3}} + \alpha_2 D_2 y_{t-\frac{2}{3}} + \alpha_3 D_3 y_{t-1} + \beta_{1,1}(1 - D_2 - D_3)x_{t-\frac{1}{3}}^{(3)} \\
& + \beta_{1,2} D_2 x_{t-\frac{1}{3}}^{(3)} + \beta_{1,3} D_3 x_{t-\frac{1}{3}}^{(3)} + \beta_{2,1}(1 - D_2 - D_3)x_{t-\frac{2}{3}}^{(3)} + \beta_{2,2} D_2 x_{t-\frac{2}{3}}^{(3)} \\
& + \beta_{2,3} D_3 x_{t-\frac{2}{3}}^{(3)} + \beta_{3,1}(1 - D_2 - D_3)x_{t-1}^{(3)} + \beta_{3,2} D_2 x_{t-1}^{(3)} + \beta_{3,3} D_3 x_{t-1}^{(3)} \\
& + u_t
\end{aligned} \tag{79}$$

Bu modelde yer alan D_2 ve D_3 kukla değişkenleri sırasıyla çeyrek dönemin 3. ve 1. aylarında 1 değerini almaktadır. Foroni ve diğerleri (2018), (80) numaralı regresyon modelinin değişen varyans ve otokorelasyon gibi sorunlardan ötürü genelleştirilmiş en küçük kareler yöntemi ile tahmin edilmesi gerektiğini önermişlerdir.

1.5.2. Ters MIDAS (R-MIDAS)

Bir önceki alt bölümde bahsedilen RU-MIDAS modelinde değişkenler arasında frekans oranı çok yüksek olduğu durumlarda söz konusu modelde tahmin edilmesi gereken parametre sayısı, fazla olacaktır. Bunun yanı sıra modelin gecikme uzunluğunun da bir hayli fazla olduğu durumlarda modelde tahmin edilmesi gereken parametre sayısının gözlem sayısından daha fazla olduğu durumlar ile karşılaşılabılır. RU-MIDAS modelinde frekans oranı veya uzun dönem gecikmeler neticesinde oluşabilecek Parametre sayısının olağanüstü bir biçimde arttışının önüne geçmek için Foroni ve diğerleri (2018), yüksek frekanslı değişkenin geçmiş değerlerini (81) numaralı model ile ağırlıklandırarak (82) numaralı denklemde yer alan Ters MIDAS (R-MIDAS) modelini önermişlerdir.

$$x_{t,j}^{(m)}(\theta_j) = W\left(L^{\frac{j}{m}}; \theta_j\right) x_{t,j}^{(m)} = \sum_{i=0}^p \omega_i(\theta_j) L^{\frac{i}{m}} x_{t,j}^{(m)} \tag{81}$$

$$x_{t,j}^{(m)} = \beta_1 \left\{ \sum_{i=0}^p \omega_i(\theta_j) L^{\frac{i}{m}} x_{t,j}^{(m)} \right\} + \sum_{i=1}^q \alpha_i y_{t-i} + x_{t,j}^{(m)} \tag{82}$$

R-MIDAS modelinde j ; 0 ile $m - 1$ arasında tam sayı değeri alan ve düşük frekanslı t zaman dilimi içerisinde hangi yüksek frekanslı zaman dilimi içerisinde bulunduğunu gösteren bir değerdir. Söz konusu j değerine göre R-MIDAS modelinin zaman indeksi aşağıdaki gibi olmaktadır.

$$t = 0 + \frac{j}{m}, 1 + \frac{j}{m}, 2 + \frac{j}{m}, \dots \quad (83)$$

R-MIDAS modelinde yüksek frekanslı deęişkenin aęırlıklandırılması MIDAS modelinde olduęu gibi belirli polinomlarla gerekleřtirilebilmektedir. Örneęin Foroni ve dięerleri (2018), aęırlıklandırma iřlemi için üstel almon polinomunu önermiřlerdir. Bu durumda R-MIDAS modelindeki yüksek frekanslı deęişkenin üstel aęırlıklandırma polinomu ařaęıdaki (84) numaralı model ile gösterilebilir.

$$\omega_j (\theta_1, \theta_2) = \left(\frac{e^{(\theta_1 j + \theta_2 j^2)}}{\sum_{j=1}^m e^{(\theta_1 j + \theta_2 j^2)}} \right) \quad (84)$$

Yukarıdaki denklemlerden de anlaşılacağı üzere R-MIDAS modeli doğrusal deęildir. Bu nedenle EKK yöntemi yerine doğrusal olmayan en küçük kareler (NLS) yöntemi ile tahmin edilebilir.

İKİNCİ BÖLÜM

2. İKTİSADİ DEĞİŞKENLERİN ÖNGÖRÜSÜ ÜZERİNE MIDAS LİTERATÜRÜ

Ekonomilerde GSYİH, enflasyon, işsizlik oranı, faiz oranı, döviz kurları gibi iktisadi ve finansal değişkenlerin öngörüsü; politika yapıcılar, girişimciler ve hane halkı başta olmak üzere birçok kesim açısından önem taşımaktadır. Ampirik literatürde söz konusu iktisadi ve finansal değişkenlerin öngörüsü için çoklu zaman serilerine dayalı bir çok alternatif model geliştirilmiştir. Ancak bu modellerde öngörüsü yapılmak istenilen ilgili değişkenin frekansı ile modelde yer alacak olan diğer değişkenlerin frekansları aynı düzeyde olma zorunluğu vardır. Halbu ki, daha önce de bahsedildiği gibi iktisadi ve finansal değişkenler aynı frekansta yayınlanmazlar. Literatürde çoklu bir modelde yer alması gereken değişkenler arasındaki frekans uyumsuzluğunu gidermek için çoğunlukla toplulaştırma işlemine başvurulduğu bir önceki bölümde belirtilmişti. Söz konusu bölümden de hatırlanacağı üzere toplulaştırma işlemi, yüksek frekanslı değişkende bilgi kaybına neden olabilmektedir. Bu bilgi kaybının yanı sıra iktisadi ve finansal değişkenlerin farklı gecikmelerle açıklanmaları ve yayınlanmaları da öngörü güvenliğinde sorun yaratabilmektedir. İktisadi ve finansal değişkenlerde yaşanan yayın gecikmeleri, değişkenlerin frekansları azaldıkça daha da fazla olmaktadır. Hemen hemen her ekonomide günlük finansal veriler o günün sonunda yayınlanırken, aylık frekansa sahip enflasyon oranı bir sonraki ay açıklanmaktadır. Üstelik bu yayın gecikmesi üçer aylık GSYİH’de daha fazla olmaktadır. Örneğin Türkiye ekonomisinde 2020 yılının 2. çeyreğine ait GSYİH değeri, bir sonraki çeyrek dönemin 2. ayının son işlem gününde açıklanacaktır.

İktisadi değişkenlerde görülen bu yayın gecikmelerinden dolayı geleneksel çoklu zaman serileri yönteminde yüksek frekanslı değişkenlere ait son gözlemler kullanılamamaktadır. Eğer mevcut veriler ile GSYİH büyüme oranının cari ve gelecekteki değerleri öngörülmek istenirse GSYİH için ulaşılabilecek son gözlem, bir ya da iki önceki döneme ait olacaktır. Diğer yandan cari çeyrek dönemde, GSYİH verisi yayınlanmasa dahi GSYİH’den daha yüksek frekansa sahip değişkenlere ait veriler yayınlanabilecektir. Her ne kadar yüksek frekanslı değişkenlere ait gözlemler mevcut olsa da bu gözlemler geleneksel çoklu zaman serileri yönteminde kullanılamayacaktır. Çünkü cari dönemin son zamanlarına ait birçok yüksek frekanslı değişkenin gözlemlerine bir sonraki çeyrek dönemde ulaşılabilecektir. Bu durumda bu gözlemler toplulaştırılarak düşük frekanslı değişkene dönüştürülemeyecektir. Böylelikle cari dönemdeki bilgilerden yoksun olarak GSYİH öngörüsü gerçekleştirilecektir. Oysaki MIDAS yönteminde farklı frekanslı değişkenlerin bir arada modele dahil edilebilmesinden ötürü yüksek frekanslı değişkenlerin en son gözlemleri

kullanılabilmektedir. Nitekim MIDAS yönteminin GSYİH büyüme oranı öngörüsü gerçekleştirilirken yüksek frekanslı değişkenlerin cari döneme ait gözlemlerinin kullanılabilmesine imkan tanınması, öngörü literatüründe “anlık tahmin” (“*nowcasting*”) teriminin doğmasına neden olmuştur. Anlık tahmin, herhangi bir değişkenin cari döneme ait değerinin öngörüsü için söz konusu değişkenden görece daha yüksek frekanslı değişken veya değişkenlerin cari dönem içerisindeki gözlemlerinden faydalanılmasıdır.

Tüm bu açıklamaların ardından yüksek frekanslı $x_t^{(m)}$ bağımsız değişkeninden faydalanılarak düşük frekanslı y_t bağımlı değişkeninin h dönem ilerisinin öngörüsü için MIDAS modeli (85) numaralı denklemde gösterilmiştir.

$$y_{t+h} = \beta_0 + \beta_1 W\left(L^{\frac{1}{m}}; \theta\right) x_{t-h}^{(m)} + u_t \quad (85)$$

Yukarıdaki modelde θ ; hiper parametre vektörünü, m ; düşük frekanslı t zaman dilimindeki yüksek frekanslı değişkenin gözlem sayısını, $L^{\frac{1}{m}}$ yüksek frekanslı değişken için gecikme işlemcisini ve $W\left(L^{\frac{1}{m}}; \theta\right) = \sum_{j=1}^q \omega_j(\theta) L^{\frac{j-1}{m}}$, yüksek frekanslı değişkenin ağırlıklandırma fonksiyonunu temsil etmektedir. Düşük frekanslı değişkenin üçer aylık yüksek frekanslı değişkenin ise aylık frekansta olduğu bir durumda yukarıdaki (85) numaralı model aşağıdaki şekilde yazılabilir.

$$y_{t+h} = \beta_0 + \beta_1 W\left(L^{\frac{1}{3}}; \theta\right) x_{t-h}^{(3)} + u_t \quad (86)$$

İlgili modelde yüksek frekanslı değişkenin gecikme uzunluğunun 12 dönem olarak belirlenmesi durumunda ağırlıklandırma fonksiyonu (87) numaralı modelde gösterildiği şekilde olacaktır.

$$W\left(L^{\frac{1}{3}}; \theta\right) = \sum_{j=1}^{12} \omega_j(\theta) L^{\frac{j-1}{3}} \quad (87)$$

Böylelikle düşük frekanslı y_t değişkeninin h dönem ilerisinin öngörü modeli, aşağıdaki gibi daha açık bir şekilde yazılabilecektir.

$$y_{t+h} = \beta_0 + \beta_1 \left[\omega_1(\theta) x_{t-h}^{(3)} + \omega_2(\theta) x_{t-h-1/3}^{(3)} + \omega_3(\theta) x_{t-h-2/3}^{(3)} + \omega_4(\theta) x_{t-h-1}^{(3)} + \dots \right. \\ \left. + \omega_{12}(\theta) x_{t-h-11/3}^{(3)} \right] + u_t \quad (88)$$

Bu modelin tahmini, düşük frekanslı y_t değişkeni için t dönemine kadar yüksek frekanslı $x_t^{(3)}$ değişkeni için ise $t - h$ dönemine kadar olan veriler kullanılarak gerçekleştirilebilmektedir (Clements ve Galvão, 2009: 1189).

2.1. Öngörü Üzerine MIDAS Literatürü

Literatürde MIDAS modellerinin dışında yüksek frekanslı değişkenlerdeki bilgilerden faydalanarak GSYİH büyüme oranı öngörüsü gerçekleştiren çalışmalar da bulunmaktadır. Bu çalışmaların büyük bir çoğunluğunda Köprü Modelleri ya da Faktör Modelleri ile öngörülerin gerçekleştirildiği görülmektedir. Köprü Modeli ile GSYİH büyüme oranı öngörüsü gerçekleştiren çalışmalara Euro bölgesi için Rünstler ve Sedillot (2003); Fransa, Almanya, İtalya ve Euro bölgesi için Baffigi ve diğerleri (2004); İtalya için Golinelli ve Parigi (2005); Kanada için Zheng ve Rossiter (2006) örnek olarak verilebilir. Bir diğer yöntem olan Faktör Modellerini kullanan çalışmalara ise Euro Bölgesi için Banbura ve Rünstler (2007), ABD için Giannone ve diğerleri (2008) ve Almanya için Schumacher ve Breitung (2008) örnek olarak gösterilebilir. Diğer yandan Nunes (2005), Stock ve Watson (1989, 1991)² tarafından önerilen tek endeksli rastlantısal değişkenler (*single-index coincident indicator*) modelini karma frekanslı duruma genişleterek Portekiz'in GSYİH büyüme oranını öngörmeye çalışmıştır. Tüm bu çalışmaların ortak özellikleri, GSYİH büyüme oranı öngörüsü için genel olarak aylık frekanslı değişkenlerin tercih edilmesidir. Bu çalışmalarda aylık frekanslı değişkenlerin tercih edilmesinin nedeni ele almış oldukları modellerin yeterince esnek olmamalarından dolayıdır. Çünkü daha yüksek frekanslı değişkenler ile çalışıldığında ele almış oldukları modellerde tahmin edilmesi gereken parametre sayısı bir hayli fazla olacaktır. Bunun sonucunda söz konusu modellerin tahmini neredeyse imkânsız hale gelebilecektir.

Nitekim Ghysels ve diğerleri (2004)'nin geliştirmiş oldukları MIDAS modeli ile yukarıda bahsedilen sorun ortadan kalkmış ve öngörü literatürüne yeni bir bakış açısı gelmiştir. MIDAS modelinin geliştirilmesinin ardından Tay (2006, 2007), Hogrefe (2008), Clements ve Galvão (2008) ve Clements ve Galvão (2009) çalışmalarında üçer aylık GSYİH büyüme oranı öngörüsünde yüksek frekanslı değişkenlerin orijinal frekanslarının kullanılmasının öngörü performansını artırıp artırmayacağı incelenmiştir. Bu çalışmalarda çoğunlukla MIDAS yönteminin öngörü performansının, geleneksel modellerin öngörü performanslarından daha iyi olduğu sonucu elde edilmiştir.

² Stock ve Watson (1989, 1991), iktisadi değişkenlerdeki ortak hareketliliğin (*comovements*), temelde gözlemlenemeyen tek bir değişken tarafından yakalanabileceği fikrini ortaya koyarak tek endeksli (*single-index*) modelini önermişlerdir. Stock ve Watson, bu model ile bazı öncü değişkenlerden (*leading variables*) faydalanarak ABD ekonomisinin sanayi üretimi, reel kişisel gelir, reel imalat ve ticaret satışları ve tarımdışı istihdam gibi rastlantısal değişkenlerin büyüme oranlarını öngörmeye çalışmışlardır. Analizler neticesinde öncü göstergeleri içeren modellerin, çalışmada ele alınan rastlantısal değişkenlerin büyüme oranlarına ilişkin yararlı öngörüler sağladığı belirlenmiştir.

Tay (2006, 2007), günlük frekansa sahip iktisadi değişkenlerin, daha düşük frekansa sahip iktisadi değişkenlerin tahminlerini iyileştirip iyileştirmeyeceğini incelemiştir. Bununla birlikte cari dönem içerisinde yüksek frekanslı güncel iktisadi verilerin yayınlanmasıyla düşük frekanslı iktisadi değişkenlerin tahminleri güncellenebilir mi sorusuna yanıt aramıştır. Bu kapsamda Tay (2006, 2007), S&P500 borsa endeksinin günlük hisse senedi getirilerinden faydalanarak ABD'nin üçer aylık GSYİH büyüme oranını öngörmeye çalışmıştır. Çalışmada 1964-2005 dönemi veri setiyle kayan pencereler altında 1990-2005 dönemi örneklem içi tahmin gerçekleştirilmiştir. Ardından elde edilen tahmin bulguları üçer aylık olarak toplulaştırılmış hisse senedi getirileriyle oluşturulan tahmin modelinin sonuçlarıyla kıyaslanmıştır. Bulgular hisse senedi getirilerinin özellikle son yıllarda reel üretim artışı için iyi bir öngörücü olduğunu ortaya koymuştur. Özellikle tahmin modelinde tüm değişkenleri aynı frekansa toplulaştırmanın optimal bir öncelik olmayacağı ve tahmin modelinde farklı frekansların yer almasının daha iyi tahminlere yol açabileceği tespit edilmiştir.

GSYİH verilerinin yayınlanması bir sonraki çeyrek dönemde gerçekleşmekle birlikte bu veriler zaman içinde bir dizi revizyona tabi tutulmaktadır. Bu nedenle Hogrefe (2008), 1985 – 2003 dönemi verilerinden yararlanarak aylık frekansa sahip iktisadi değişkenlerle birlikte ABD'nin GSYİH revizyonlarını öngörmeye çalışmıştır. Çalışmada GSYİH'nin oluşumu ile üretilen veri (*vintage*) arasındaki bilgiler dikkate alınarak MIDAS yaklaşımının yanı sıra enterpolasyon da göz önünde bulundurulmuştur. Elde edilen bulgular ile MIDAS yönteminin, GSYİH büyüme oranının ilk açıklanmasından ve yalnızca tek değişkenli bilgilere dayanan basit bir tahmin modelinden istatistiksel olarak anlamlı bir biçimde daha iyi bir performans gösterdiği tespit edilmiştir.

Daha sonraları, Clements ve Galvão (2008), iktisadi değişkenlerin genellikle AR özelliği taşımasından dolayı MIDAS modeline bağımlı değişkenin AR terimlerini ekleyerek MIDAS-AR modelini geliştirmişlerdir. Clements ve Galvão (2008), MIDAS-AR yöntemi ile sanayi üretimi, istihdam ve kapasite kullanımı gibi aylık frekanslı iktisadi değişkenleri kullanarak ABD'nin üçer aylık GSYİH büyümesinin kısa vadeli tahminlerini incelemişlerdir. Çalışmada MIDAS-AR yönteminin bulguları, aylık frekanslı değişkenleri kullanan iki farklı yaklaşımın bulgularıyla karşılaştırılmıştır. Bu yaklaşımlardan ilki, aşağıda (89) numaralı denklemde gösterilen Koenig ve diğerleri (2003) tarafından kullanılan bir regresyon modelidir.

$$y_t = \beta_0 + \sum_{j=0}^4 x_{t-j/3}^3 + u_t \quad (89)$$

Yukarıdaki modelde³ y_t ; üçer aylık frekanslı bağımlı değişkeni, x_t^3 ; aylık frekanslı bağımsız değişkeni ve u_t ; üçer aylık frekanslı hata terimini göstermektedir. Clements ve Galvão (2008), (89) numaralı denklemde yer alan modelin MIDAS yaklaşımına olan benzerliğinden yola çıkarak bu modeli karma frekanslı gecikmesi dağıtılmış (MF–DL) modeli olarak adlandırmışlardır. MIDAS-AR'ın bulgularının karşılaştırıldığı ikinci yöntem ise Köprü Modellerini andıran ve iki aşamadan oluşan gecikmesi dağıtılmış (ADL) modelidir. ADL modelinin ilk aşamasında otoregresif vektör (VAR) yöntemi ile eksik aylık gözlemler öngörülmektedir. Daha sonra ikinci aşamada ise aylık gözlemler üçer aylığa toplulaştırılarak ADL yöntemi ile üçer aylık GSYİH büyümesi tahmin edilmektedir. Uygulamada Koenig ve diğerleri (2003)'nin örneklem sonu üretilen verilerinin yerine gerçek zamanlı üretilen verilere dayandırılması yönündeki önerisi değerlendirilerek öngörüler gerçekleştirilmiştir. Bulgular neticesinde gerçek zamanlı üretilen verilerin, tahmin doğruluğunu artırdığı ancak temel sonuçları değiştirmedığı belirlenmiştir. Bu sonuçla birlikte MIDAS-AR modelinin, MF–DL ve ADL modellerine kıyasla daha iyi performans gösterdiği tespit edilmiştir.

Bu çalışmanın ardından yine Clements ve Galvão (2009), bu kez 1959 – 2003 dönemine ait Conference Board tarafından üretilen aylık frekansa sahip 10 farklı kompozit öncü göstergeleri kullanarak ABD'nin üçer aylık büyüme oranlarını bir yıl vadeye kadar öngörmeye çalışmışlardır. Öncü göstergelerin aylık frekansta olmalarından dolayı çalışmada MIDAS modeli tercih edilmiş ve MIDAS yaklaşımı, üçer aylık verilerin kullanıldığı otoregresif gecikmesi dağıtılmış (ADL) modeli ile karşılaştırılmıştır. Analiz bulguları neticesinde GSYİH öngörüsünde tüm öncü göstergelerin bir arada yer aldığı MIDAS modelinin sonuçlarının, öncü göstergelerin ayrı ayrı modellenerek oluşturulduğu U-MIDAS modellerinin öngörüsünden daha iyi sonuç verdiği belirlenmiştir. Bununla birlikte cari çeyrek döneme ait aylık verilerin kullanımının öngörüyle daha da geliştirdiği görülmüştür. Çalışmada ayrıca üretilen verilerin oluşturduğu örnek sonu yerine gerçek zamanlı üretilen veri kullanımının tahmin performansını geliştirdiği tespit edilmiştir. Bunun yanı sıra ilk yayınlanan veri genel olarak daha isabetli olarak tahmin edilse bile öncü göstergelerin öngörü kabiliyetinin ispatı ilk yayınlanan veriden ziyade nihai veriyi tahmin etmek amacı olduğunda daha güçlendiği anlaşılmıştır.

Beklenti anketleri, iktisadi aktörlerin beklentileri hakkında faydalı bilgiler sunmaktadır. Fakat beklenti anketleri nadiren yayınlanabildikleri için bu anketlerin sonuçları çabucak önemini kaybetmektedir. Bu kapsamda Ghysels ve Wright (2009), beklenti anketlerinin günlük tahminlerini oluşturmak için varlık fiyat verilerini kullanarak MIDAS ve Kalman Filtre yöntemlerini ayrı ayrı modellemişlerdir. Çalışmalarında, Ghysels ve Wright (2009)'ın amacı, ankete katılanların beklentilerinin yüksek frekanslı ölçütlerini elde etmektir. Ampirik çalışmada, 1990Q3 – 2005Q4

³ Koenig ve diğerleri (2003), bu model ile aylık frekanslı tarım dışı istihdam, sanayi üretimi ve reel perakende satış değişkenlerinden faydalanarak üçer aylık GSYH büyüme oranını öngörmeye çalışmışlardır. Söz konusu öngöründe yüksek frekanslı değişkenlerin, t çeyrek döneminin 3. ayında anlık (*snapshot*) 5 aylık geçmiş gözlemlerinden faydalanılmıştır.

dönemi içerisinde reel GSYH büyüme oranı, TÜFE enflasyonu, üç aylık hazine bonusu getirisi ve işsizlik oranının profesyonel tahminciler anketi (SPF) tarafından gerçekleştirilen öngörülerini kullanılmıştır. Çalışma sonucunda örneklem içi ve örneklem dışı bir tahmin uygulamasında hem MIDAS hem de Kalman Filtre yönteminin, rassal yürüyüş modelinden daha iyi performans gösterdiği belirlenmiştir.

MIDAS literatüründe kuşkusuz sadece GSYİH büyüme oranı öngörüsü üzerinde durulmamıştır. Armesto ve diğerleri (2010), ABD ekonomisi için üçer aylık GSYİH büyüme oranının öngörüsü yanı sıra aylık frekanslı enflasyon oranını, sanayi üretim artışını ve istihdam büyüme oranını öngörmeye çalışmışlardır. Bu öngörülerde GSYİH için bağımlı değişkenin gecikmeli değerleri ve istihdam artış oranı, modelin sağ tarafında bulunurken; aylık frekansa sahip değişkenlerin öngörü modellerinde bağımsız değişken olarak hem ilgili değişkenin gecikmeleri hem de günlük faiz oranları yer almıştır. Her bir değişkenin öngörüsünde, yüksek frekanslı değişkenin ortalama değerleri, basamak ağırlıklandırma ve MIDAS modelleri kullanılmıştır. Bu öngörülerde hem dönem içi hem de dönem sonu öngörüler gerçekleştirilmiştir. Burada dönem içi değerlerin öngörüsünde o dönem içerisinde ulaşılabilen yüksek frekanslı değişkenlerin gözlemlerinden yararlanılmıştır. Her iki öngörüde de hem kayan pencereler hem de ardışık örnekleme yöntemi kullanılmıştır. Kök ortalama kare öngörü hatası (RMSE) değerlerine göre çalışmada yer alan herhangi bir yöntemin diğer yöntemlere karşı her zaman bir üstünlükleri tespit edilememiştir.

Bir başka çalışmada Monteforte ve Moretti (2013), Euro bölgesinin aylık frekanslı enflasyon oranının cari ve bir dönem sonrası değerlerini öngörmeye çalışmışlardır. Söz konusu öngörüler için geliştirilmiş dinamik faktör modeli kullanılarak oluşturulan aylık frekanslı çekirdek enflasyon endeksini, günlük frekanslı değişkenler ile birleştirerek MIDAS modelini kullanmayı önermişlerdir. Analizlerde 1992 Mayıs – 2007 Eylül dönemine ait günlük frekanslı kısa ve uzun vadeli faiz oranları, getiri farkı, borsa endeksleri, emtia fiyatları ve döviz kurları öngörücü değişken olarak kullanılmıştır. Çalışmada MIDAS modelinin bulguları AR, ARMA ve VAR gibi geleneksel modellerle kıyaslanmıştır. Bu kıyaslama sonucunda modele günlük frekanslı değişkenlerin dahil edilmesinin öngörü hatalarını azalttığı ve böylelikle MIDAS modelinin, yalnızca aylık frekanslı değişkenlerle kurulan geleneksel modellerden daha iyi performans gösterdiği tespit edilmiştir. Çalışmada ayrıca enflasyon oranı öngörülerini, örneklemin her günü için günlük frekanslı değişkenlerin yeni açıklanan gözlemleriyle birlikte tekrarlanmıştır. Böylelikle aylık frekanslı dönemin her gününde aylık enflasyon oranları öngörüsü elde edilmiştir. Söz konusu bu öngörüler, Euro bölgesi uyumlaştırılmış tüketici fiyat endeksi (*harmonized index of consumer price* HICP) vadeli sözleşmelerinden (*future contracts*) çıkarılan piyasa beklentileriyle karşılaştırılmıştır. Bu karşılaştırma neticesinde MIDAS modeliyle günlük olarak tahmin edilen enflasyon oranı öngörülerinin, HICP vadeli sözleşmelerinden oluşturulan enflasyon beklentilerinden daha tutarlı ve daha az oynak olduğu belirlenmiştir.

Daha önce de belirtildiği gibi MIDAS modelinde belirli ağırlıklandırma polinomları kullanılarak tahmin edilmesi gereken parametre sayısı bir hayli azaltılabilmektedir. Ancak bağımsız değişken sayısının çok fazla sayıda olması durumunda parametre sayısı yeteri kadar düşürülemeyebilir. Bu bakımdan Frale ve Monteforte (2009), yüksek frekanslı göstergelerin çok sayıda gecikmeli değerlerinin yer aldığı Faktör MIDAS (FA-MIDAS) modelini önermişlerdir. Ampirik uygulamada, 1990 - 2009 dönemi verileri kullanılarak İtalya ekonomisinin GSYİH değerleri üçer aylık frekansta öngörülmesinin yanı sıra aylık frekans düzeyinde de öngörülmüştür. FA-MIDAS modelinin öngörü performansı, tek değişkenli (ADL) ve çok değişkenli (VAR) standart modellerle karşılaştırılmıştır. Sonuç olarak FA-MIDAS'ın, GSYİH için daha düzgün (*smoother*) aylık tahminler ürettiği ve GSYİH'nin daha uzun tahmin dönemlerinde etkili olduğu tespit edilmiştir.

Marcellino ve Schumacher (2010), Almanya'nın GSYİH büyüme oranının öngörüsü için aylık frekansa sahip çok fazla sayıda bağımsız değişkenden yararlanmaya çalışmışlardır. Değişken sayısının fazla olmasından dolayı modeldeki aşırı parametre sorununu çözmek için Faktör MIDAS yöntemini kullanmışlardır. Çalışmalarında temel, düzleştirilmiş ve kısıtsız üç farklı MIDAS yaklaşımını dengesiz veri (*ragged edge*) setlerini hesaba katabilecek üç alternatif faktör kestirimi yöntemi ile harmanlayarak dokuz farklı Faktör MIDAS yaklaşımını oluşturmuşlardır. Faktör kestirim yöntemlerinden ilki, tek taraflı parametrik olmayan dinamik temel bileşen analizinin (DPCA) faktör tahmincisidir. İkincisi, Stock ve Watson (2002) tarafından geliştirilen faktör tahmincisi tabanlı statik temel bileşen analizi (PCA) ile birleştirilen beklenti maksimizasyon (EM) algoritmasıdır. Üçüncüsü ise Doz ve diğerleri (2006)'nin Kalman Düzleştiricisine dayanan iki aşamalı parametrik Durum-Uzay faktörü tahmincisidir. Uygulamada 1992 - 2006 dönemi veri seti kullanılarak 111 farklı aylık frekanslı değişkenden faktör değişkenleri oluşturulmuştur. Oluşturulan söz konusu bu faktör değişkenleriyle GSYİH büyüme oranı öngörülmeye çalışılmıştır. Ampirik sonuçlarda faktör kestirim yöntemlerinin önemli ölçüde birbirleriyle farklılık göstermedikleri tespit edilmiştir. Bunun yanı sıra çalışmada Faktör MIDAS modeli, toplulaştırılmış verilere dayalı tek frekanslı faktör modeli ve Banbura ve Rünstler (2007)'in entegre Durum Uzay modeli ile kıyaslanmıştır. Çalışmada ele alınan tüm Faktör MIDAS modellerinin, toplulaştırılmış verilere dayanan üçer aylık faktör modellerinden daha iyi sonuçlar verdiği anlaşılmıştır. Durum Uzay yaklaşımı ile karşılaştırıldığında ise Faktör MIDAS modelinin üstünlüğünün daha az belirgin ve tahmin uzunluğuna bağlı olduğu saptanmıştır.

İktisadi değişkenler farklı frekansta yayınlandıkları gibi farklı gecikme zamanlarında da yayınlanmaktadır. Özellikle ekonominin genel durumunu gösteren GSYİH'nin cari dönemine ait verisine bir sonraki dönemde ulaşılabilir. GSYİH'de yaşanan söz konusu bu gecikme nedeniyle politika yapımcılarının ekonominin genel gidişatı hakkında bilgi edinmelerinde bir engel teşkil etmesi olası olacaktır. Bu engeli aşmak için Kuzin ve diğerleri (2013), ABD için 1982 - 2009 dönemi, İngiltere için 1980 - 2009 dönemi ve Japonya, Almanya, Fransa ve İtalya için 1991 - 2009

dönemi aylık frekanslı değişkenlerden faydalanarak bu ülkelerin üçer aylık GSYİH büyümesinin anlık tahminine odaklanılmışlardır. Uluslararası aylık istatistiklerin uyumlaştırılmaması nedeniyle ABD için 189, İngiltere için 60, Japonya için 71, Almanya için 111, Fransa için 167 ve İtalya için 150 adet aylık frekanslı göstere kullanılmıştır. Bu kadar çok sayıdaki değişkene ait üretilen veri setleri mevcut olmamasından dolayı gerçek zamanlı veri seti yerine nihai veri seti kullanılmıştır. Tüm ülkeler için kayan pencereler ile 2000 - 2007 ve 2008 - 2009 dönemleri GSYİH büyüme oranının anlık tahmini gerçekleştirilmiştir. Bu dönemlere ilave olarak İngiltere ve ABD için 1990 – 1999 döneminin GSYİH büyüme oranının anlık tahmini yapılmıştır. Alternatif tek göstergeli MIDAS modelleri ve büyük veri setlerine dayanan Faktör MIDAS yaklaşımları ile her bir ülkenin GSYİH büyüme oranının anlık tahmin öngörülleri gerçekleştirilmiş ve elde edilen öngörü sonuçları her ülke için ayrı ayrı havuzlanmıştır. Ortalama kare hatası (MSE) tahmin kriteri neticesinde tek göstergeli MIDAS modellerin anlık tahmini performansının zamanla önemli ölçüde değişiklik gösterdiği tespit edilmiştir. Genel olarak bu modellerin tahmin performansı, 1990 - 1999 ve 2000 - 2007 dönemleri arasında azaldığı ve 2008 - 2009 krizinde tekrar iyileştiği görülmüştür. Bu modellerin havuzlanmasıyla dönemler arasında görülen tahmin performans farklılıkları, tamamen olmasa da büyük ölçüde azaltılabilmektedir. Diğer yandan havuzlanmış faktör yaklaşımlarının, tek göstergeli MIDAS kombinasyonlarından daha iyi performans gösterdiği saptanmıştır.

Ferrara ve Marsilli (2013), 2008 - 2009 küresel ekonomik kriz döneminde dört ana Euro bölgesi ülkesi (Almanya, Fransa, İtalya ve İspanya) ve Euro bölgesinin tamamının GSYİH büyümesini öngörmek için aylık frekanslı petrol fiyatları, hisse senedi fiyatları ve getiri farkı gibi önemli finansal değişkenlerin öngörü gücünü değerlendirmişlerdir. Sıralanan bu bağımsız değişkenler GSYİH'den daha yüksek frekansa sahip olmalarından dolayı MIDAS yöntemi tercih edilmiştir. 1990Q1 – 2006Q4 dönemi boyunca örneklem içi analiz gerçekleştirilmiş ve ardından 2007Q1'den 2009Q4'e kadar olan kriz döneminde yarı gerçek zamanlı (*quasi-real-time*) bir analiz uygulanmıştır. Beş ekonominin her biri için, üç finansal değişken ile ayrı ayrı tek değişkenli MIDAS modelleriyle GSYİH'nin doğrudan çok adımlı öngörüsü yapılmıştır. Kök ortalama karekök hata tahmin (RMSFE) değerleriyle hisse senedi fiyatlarının, GSYİH tahminlerinin doğruluğunu artırmaya yardımcı olduğu, petrol fiyatlarının ve getiri farkının ise GSYİH tahminlerinde daha az bilgilendirici oldukları tespit edilmiştir. Ayrıca, Almanya için finansal değişkenlerin nitel verilere göre daha iyi bir tahmin performansı sunmadığı belirlenmiştir. Diğer ülkeler açısından nitel verilere göre sonuçların karışık olduğu ve tahmin ufku güçlü bir şekilde bağlı olduğu saptanmıştır.

Andreou ve diğerleri (2013), finansal varlık fiyatlarının, ekonominin gelecekteki durumu hakkında önemli bilgi içerdiğini vurgulayarak günlük frekanslı finansal veriler ile ABD'nin üçer aylık GSYİH büyüme oranını öngörmeye çalışmışlardır. Uygulamada günlük frekansta çok sayıda finansal verinin mevcut olmasından dolayı emtialar, kurumsal risk, özkaynaklar, sabit gelir ve döviz kuru gibi varlık sınıflarından 1000 civarında finansal zaman serisi kullanılmıştır. Bu kadar çok sayıda değişkenin modelde yer alması, tahmin edilmesi gereken parametre sayısını epey bir artıracığından

çalışmada faktör yaklaşımı kullanılmıştır. Faktör yaklaşımıyla finansal değişkenler birkaç faktör değişkene indirgenmiştir. Oluşturulan bu faktör değişkenlerle genişletilmiş gecikmesi dağıtılmış (ADL)-MIDAS modeliyle GSYİH büyüme oranı öngörüsü gerçekleştirilmiştir. Bunun yanı sıra daha dirençli ve doğru tahminler sağlamak amacıyla tek finansal değişkenin yer aldığı MIDAS modelleriyle GSYİH büyüme oranı öngörülmesi ve sonuçlar kombine edilmiştir. Üçer aylık GSYİH büyüme oranı öngörüsünde günlük frekansa sahip finansal değişkenlerin yanı sıra aylık ve üçer aylık frekansa sahip iktisadi veriler de kullanılmıştır. Bulgular neticesinde günlük finansal varlıklar veya faktörler yoluyla günlük finansal bilgileri kullanan MIDAS regresyon modellerinin ABD'nin üçer aylık reel GSYİH büyüme oranı öngörüsünü geliştirdiği tespit edilmiştir. Çalışmada ayrıca çeyrek dönem içerisinde yayınlanan günlük ve aylık frekanslı değişkenlerin öncü (*leads*) verilerine de yer verilmiştir. Hem aylık frekanslı iktisadi hem de günlük frekanslı finansal verilerdeki öncü (*leads*) verileri içeren MIDAS modelinin, sadece günlük frekanslı finansal öncü (*leads*) verilerini bulduran MIDAS modeliyle benzer öngörme performansına sahip olduğu belirlenmiştir. Bununla birlikte hem bağımsız değişkenlerin yüksek frekansta olmaları hem de günlük frekanslı finansal değişkenlerin geniş yatay kesitinden dolayı öncü (*leads*) verilerin yer aldığı MIDAS regresyon modellerinin, finansal değişkenlerdeki zengin veri çeşitliliğinden yararlanabildiği tespit edilmiştir.

Galvão (2013), ekonomik faaliyetlere ilişkin beklentilere göre belirlenen finansal değişkenler ışığında İngiltere ve ABD'nin reel GSYİH büyüme oranlarının bir çeyrek dönem ve bir yıl vadeli değerlerini öngörmeye çalışmıştır. Finansal değişkenlerin, GSYİH'den daha yüksek frekansta örneklenmeleri ve GSYİH'nin gelecekteki değeri üzerindeki etkilerinin uygulanan rejimle birlikte değişmesini dikkate alan Galvão, düzgün geçişli regresyon modelini MIDAS modeliyle harmanlayarak düzgün geçişli MIDAS (ST-MIDAS) yöntemini geliştirmiştir. ST-MIDAS modeli, yüksek bir frekansta bulunan gözlemlenebilir bir değişkenin boyutuna ve işaretine bağlı olan bir rejim değiştirme davranışı sergileyebilmektedir. Bu nedenle ST-MIDAS modeli, GSYİH için finansal değişkenlerin kestirim gücündeki asimetrisi yakalayabilmektedir. Çalışmada ST-MIDAS modelinin öngörü performansı simülasyon ile teste tabi tutulmuştur. Simülasyon sonucunda bazı koşullar altında doğrusal regresyon modelleri yerine ST-MIDAS modelinin kullanılması öngörü performansının iyileşmesinin beklendiği tespit edilmiştir. Söz konusu koşullar şu şekilde sıralanmaktadır; örneklem boyutunun, modelin doğrusal olmama derecesi, öngörücü değişkenin tahmin gücü ve değişkenler arasındaki frekans oranının fazla olmasıdır. Çalışmanın uygulama kısmında ABD'nin GSYİH büyüme oranını öngörmek için 5 yıllık hazine bonusu oranı ile 3 aylık bono oranı arasındaki getiri farkı, S&P500 endeksi ve kısa vadeli faiz oranları kullanılmıştır. İngiltere'nin GSYİH büyüme oranı öngörüsü için ise uzun vadeli hazine bonusu oranı ile 3 aylık hazine bonusu oranı arasındaki getiri farkından, FTSE100 endeksinden ve kısa vadeli faiz oranlarından faydalanılmıştır. ABD için 1970Q1 döneminden başlanılarak 1989Q4-2007Q3 dönemlerinde yayınlanmış olan üretilen veri seti kullanılarak 1989Q3-2007Q2 döneminin öngörüsü gerçekleştirilmiştir. Benzer işlem İngiltere için 1985Q1 döneminden başlanılarak gerekli üretilen veri setleriyle 1995Q3-2007Q2 döneminin öngörüsü yapılmıştır. Çalışmada finansal değişkenler

hem haftalık hem de günlük frekansta ST-MIDAS modellerinde yer almışlardır. Ancak haftalık frekans yerine günlük frekansın kullanılmasının öngörülerini geliştirmediği görülmüştür. Hem ABD hem de İngiltere GSYİH büyüme oranı öngörüsü için, tahmin doğruluğundaki anlamlı gelişmelerin, yüksek frekanslı verilerin kullanılmasından ziyade asimetrik dinamiklerin dahil edilmesinden kaynaklandığı savunulmuştur.

Yüksek frekanslı değişkenlerin öngörü kabiliyeti, konjonktür ya da piyasa koşullarındaki değişiklikler nedeniyle farklılık gösterebilmektedir. Bu nedenle, yüksek frekanslı verilerin öngörme yeteneğindeki zamansal değişime izin vermenin önemini vurgulayan Guérin ve Marcellino (2013), Galvão (2013)'nun ST-MIDAS modeline alternatif olarak Markov değişim (*Markov-switching*) MIDAS (MS-MIDAS) modelini geliştirmişlerdir. MS-MIDAS modeli, belirli bir rejimde olma olasılığının gerçek zamanlı olarak değerlendirilmesini ve öngörülmesini sağlamaktadır. Çalışmanın uygulama kısmında MS-MIDAS modeliyle 1959Q1-1997Q4 döneminden başlanarak ardışık örnekleme yöntemiyle 1959Q1-2009Q4 dönemine kadar ABD'nin üçer GSYİH büyüme oranı $h = \{0, 1/3, 2/3, 1\}$ dönemlerinde öngörülme çalışılmıştır. GSYİH büyüme oranı öngörüsünde ilk olarak getiri eğrisinin eğimi kullanılmıştır. Bunun için 10 yıllık Hazine tahvilindeki aylık getiriler ile 3 aylık Hazine bonosundaki aylık getiriler arasındaki fark, getiri eğrisinin aylık eğimi için bir gösterge olarak alınmıştır. Ayrıca GSYİH büyüme oranı öngörüsü için aylık frekanslı S&P500 endeksinin hisse senedi getirisi, Federal Fonları, Sanayi Üretimi ve Tedarik Yönetim Enstitüsü (*Institute of Supply Management ISM*) Üretimi göstergelerinden de faydalanılmıştır. Çalışmada GSYİH büyüme oranının öngörüsünün yanı sıra haftalık frekanslı Federal Fonlar ve S&P 500 endeksi ile aylık frekansa sahip sanayi üretim büyüme oranının da öngörüsü gerçekleştirilmiştir. Bu öngörüler için 1970:01 - 1997:12 döneminden başlanılarak ardışık örnekleme yöntemiyle 1970:01 - 2009:12 dönemine kadar haftalık frekansta $h = 0$ döneminden $h = 4$ dönemine kadar öngörülerde bulunulmuştur. Gerçekleştirilen analizler neticesinde MS-MIDAS modelinin sadece GSYİH büyüme oranı için iyi öngörü sonuçları vermediği aynı zamanda ekonominin durumu hakkında da önemli bilgiler sağladığı görülmüştür. Özellikle de yüksek frekanslı bilgi ile parametre değişimi (*switching*) kombinasyonunun, bu iki özelliğin her birini ayrı ayrı kullanımından daha iyi performans sergilediği belirlenmiştir. Üstelik ABD'de yaşanan Mortgage krizinin Aralık 2008'de Amerikan Ulusal Ekonomik Araştırma Bürosu (*National Bureau of Economic Research NBER*) tarafından açıklanmasından önce MS-MIDAS modelinin Şubat 2008 dönemine kadar ki verilerin kullanıldığı 2007 yılının 4. çeyreğinde ilk durgunluk sinyali verdiği görülmüştür. Ayrıca her iki uygulamada da standart MS modellerinin öngörü performansının, yüksek frekanslı bilgilerle geliştirilebildiği anlaşılmıştır. Bunun yanı sıra MS-MIDAS modellerinin, anlık tahmininin doğrusal ve doğrusal olmayan referans modellerinden daha iyi performans gösterdikleri tespit edilmiştir.

Schumacher (2016), anlık tahmin literatüründe kullanılan MIDAS ve Köprü Modellerinin öngörü performanslarını karşılaştırmıştır. Bu karşılaştırma için Euro bölgesinin üçer aylık GSYİH

büyüme oranının öngörüsünü kriter olarak kullanmıştır. Üçer aylık GSYİH büyüme oranının öngörüsü için sektörlere göre sanayi üretimi, anketler ve finansal verilerden oluşan 107 adet aylık frekanslı değişkenden faydalanılmıştır. Söz konusu çalışmada GSYİH verisi 1999Q1 – 2014Q4 dönemi ile sınırlıyken; aylık frekanslı değişkenlere ait 2015 yılının Nisan ayına kadar veri seti mevcuttur. Çalışmada MIDAS yönteminin doğrudan öngörü sağlaması ve Köprü Modellerinin ise doğrudan öngörü sağlamamasından yola çıkılarak döngüsel MIDAS (MIDAS-IT) modeli geliştirilmiştir.

$$y_t = \beta_0 + \beta_1 \sum_{j=0}^q \omega_j(\theta) L^{\frac{j}{m}} x_{t+w}^{(m)} + u_t \quad (90)$$

$$x_t^{(m)} = \alpha_0 + \alpha \left(L^{\frac{1}{3}} \right) x_{t-\frac{1}{3}}^{(m)} + u_t^m \quad (91)$$

Yukarıdaki denklemlerde w ; düşük frekanslı GSYİH değişkenin, yüksek frekanslı değişkenlere göre daha geç açıklanmasından dolayı aylık frekanslı bağımsız değişkenlerde meydana gelen öncü (*leads*) verileri temsil etmektedir. Buradaki öncü veriler, cari dönemde yüksek frekanslı $x_t^{(m)}$ değişkeninin açıklanan verileridir. MIDAS-IT modelinde MIDAS modelinin aksine doğrudan tahmin yapılmamaktadır. Öncelikle yüksek frekanslı değişken AR(1) modeli ile tahmin edilmekte ve bu tahmin değeriyle oluşturulan veriler MIDAS-IT modelinde kullanılmaktadır. Uygulamada, her bir çeyrek döneminin 3. ayının son gününde ulaşılabilen veri seti kullanılarak 2010Q1 – 2014Q4 dönemi kayan pencereler altında GSYİH büyüme oranı öngörülmüştür. Bu öngörülerde MIDAS ve MIDAS-IT modellerinin tahmin performansları Köprü Modelleri ile karşılaştırılmıştır. Bu karşılaştırma işleminde ortalama kare öngörü hatası (MSE) değerlerinden yararlanılmıştır. Elde edilen bulgularla MIDAS-IT'nin yinelemeli çok adımlı (*multi-step*) yaklaşımının, doğrudan öngörü sağlayan MIDAS modelinden daha iyi performans gösterdiği belirlenmiştir. Bununla birlikte MIDAS-IT'de öncü verinin kullanılıp kullanılmamasının öngörü performansından anlamlı bir fark yaratmadığı ve kısıtlanmamış veya üstel Almon gecikmeli polinomları olan MIDAS-IT modelinin daha iyi performans gösterdiği tespit edilmiştir. Analizlerde ayrıca 107 adet aylık frekanslı değişken sanayi, tüketici duyarlılığı anketi (*surveys on consumer sentiment*) ve finansal değişken gruplarına ayrılarak analizler tekrarlanmıştır. Sonuç olarak bu gruplar arasındaki tahmin performansları arasında büyük farkların oluşmamasından dolayı tüm göstergelerle gerçekleştirilen tahmin sonuçlarıyla uyumlu olduğu görülmüştür. Çalışmada genel olarak MIDAS ve MIDAS-IT'nin Köprü Modellerinden daha iyi performans gösterdiği anlaşılmıştır.

Ampirik literatürde tek denklemlerli MIDAS modellerinin yanı sıra farklı frekanslı değişkenlerin modele dahil edilebildiği alternatif karma frekanslı VAR (MF-VAR) modelleriyle ekonomik büyüme oranının nasıl öngörülebileceği ele alınmıştır. Bunun yanı sıra bu modeller vasıtasıyla üçer aylık frekansa

sahip ekonomik büyüme oranlarının aylık frekanstaki gözlemleri elde edilmeye çalışılmıştır. Bu kapsamda Kuzin ve diğerleri (2011), MIDAS yaklaşımını, karma frekanslı VAR (MF-VAR) modeliyle karşılaştırmışlardır. Çalışmada sanayi üretim istatistikleri, tüketici anketleri, finansal veriler, hammadde fiyat endeksleri ve araç kayıtları gibi 23 farklı aylık frekanslı değişken ile Euro bölgesinin GSYİH büyüme oranının anlık tahmini gerçekleştirilmeye çalışılmıştır. Düşük frekanslı değişkenlerin, yüksek frekanslı değişkenlerden daha geç yayınlanmalarından dolayı çalışmanın veri seti aylık değişkenler için 1992 yılının ilk ayından 2008'in altıncı ayına kadar bir dönemi kapsarken; üçer aylık GSYİH büyüme oranı verisi, 1992'nin ilk çeyreğinden 2008'in ilk çeyreğine kadar geçen süreyi kapsamaktadır. Uygulamada MIDAS ve MF-VAR modellerinin performansları, AR referans modeli ile kıyaslanmıştır. ortalama kare öngörü hatası (MSE) değerine göre hem MIDAS modelinin hem de MF-VAR modelinin referans modele göre daha iyi performans gösterdikleri belirlenmiştir. Ancak söz konusu iki modelin birbirlerine karşı tam üstünlükleri tespit edilememiştir. MF-VAR modelinin uzun dönemler için daha iyi performans gösterdiği belirlenirken; MIDAS modelinin ise kısa dönemler için daha iyi performans gösterdiği tespit edilmiştir.

Aylık değişkenlerin üçer aylık olarak toplulaştırılmaksızın öngörülleri ne kadar geliştirdiğini incelemek amacıyla Schorfheide ve Song (2015), aylık ve üçer aylık frekanslarda gözlemlenen iktisadi değişkenlerin yer aldığı karma frekanslı VAR (MF-VAR) modeli geliştirmişlerdir. Kuzin ve diğerleri (2011)'nden farklı olarak Schorfheide ve Song (2015)'un MF-VAR modeli, Durum Uzay modeli olarak gösterilebilmektedir. Durum Uzay modelindeki geçiş denklemleri yüksek frekanslı VAR modeli olarak oluşturulmaktadır. Ölçüm denklemleri ise düşük frekanslı değişkenin gözlemlenen serilerini yüksek frekansta gözlemlenemeyen aylık değişkenlerle ilişkilendirilmektedir. Ampirik uygulamada ABD ekonomisi için 3'ü üçer aylık frekansta 8'i aylık frekansta gözlemlenen toplam 11 iktisadi değişken ile çalışılmış ve MF-VAR modelinin öngörü sonuçları toplulaştırılmış değişkenlerin yer aldığı VAR modelinin öngörü sonuçları ile kıyaslanmıştır. Elde edilen bulgular neticesinde MF-VAR modelinin klasik VAR modelinden daha tutarlı tahminler ürettiği sonucuna ulaşılmıştır. MF-VAR modelinin tahminleri, federal açık piyasa komitesi toplantıları için yönetim kurulu personelleri tarafından hazırlanan yeşil kitap tahminleri (*Greenbook forecasts, prepared by the staff of the Board of Governors for the meetings of the Federal Open Market Committee.*) ile karşılaştırılmış ve kısa dönem öngörülerde MF-VAR modelinin büyüme oranı ve işsizlik oranı tahminlerinin *Greenbook* tahminleri kadar isabetli olduğu belirlenmiştir. Uzun dönemli öngörülerde ise MF-VAR modeli büyüme oranı için daha isabetli öngörülerde bulunurken; *Greenbook* işsizlik oranı tahminlerinde daha isabetli tahminler yaptığı anlaşılmıştır. Çalışmada ayrıca MF-VAR modeli ile aylık büyüme oranı tahminleri gerçekleştirilmiştir. Aylık GSYİH büyüme oranının üç aylık GSYİH büyümesine göre daha oynak olduğu ancak Stock ve Watson (2010)'nun⁴ tahmin etmiş oldukları aylık frekanslı büyüme oranından biraz az oynak olduğu bulgusuna ulaşılmıştır. Bununla

⁴ Stock ve Watson (2010), Kalman Filtre yöntemiyle GSYİH'nin bileşenlerinden yararlanarak ABD'nin üçer aylık frekanslı GSYİH'nin aylık frekanstaki verilerini tahmin etmişlerdir.

birlikte 2008-09 döneminde yaşanan durgunluk dönemi ele alınmış ve aylık bilgilerden dolayı MF-VAR modelinin, ekonomik durgunluğu toplulaştırılmış VAR modelinden gerçek zamanlı olarak daha yakından takip ettiği belirlenmiştir.

Hem Kuzin ve diğerleri (2011)'nin hem de Schorfheide ve Song (2015)'un geliştirmiş oldukları MF-VAR modelleri, sistemde bulunan en yüksek frekanslı değişkenin frekansına eşit olacak şekilde kurulmaktadır. Dolayısıyla düşük frekanslı değişkenin yüksek frekansta gözlemlenemeyen değerleri enterpolasyon veya Kalman Filtre yöntemleri ile oluşturulmaktadır. Öte yandan Mikosch ve Neuwirth (2015), sistemde bulunan en düşük frekanslı değişkenin frekansına eşdeğer olacak şekilde kurulan Ghysels'in MF-VAR modelini öngörü için geliştirmişlerdir. Ardından MF-VAR modelini MIDAS tipi doğrusal olmayan bir Almon gecikmeli polinom şeması ile genişleterek ABD'nin üçer aylık GSYİH büyüme oranını ve aylık frekanslı tüketici fiyat enflasyonunu ve kısa vadeli faiz oranını öngörmeye çalışmışlardır. Almon polinomu ile genişletilen MF-VAR modelinin tahmin performansı, standart üçer aylık frekanslı VAR modeli ve kısıtsız MF-VAR modelinin tahmin performansları ile karşılaştırılmıştır. Çalışmada ilk olarak sadece öngörüsü gerçekleştirilmek istenen değişkenlerle analizler yapılmıştır. Kök ortalama karekök hata kritik değeriyle MF-VAR modelinin, tahmin doğruluğunu önemli ölçüde iyileştirdiği saptanmıştır. Tahmin doğruluğundaki bu iyileşmenin modele daha fazla değişken katıldığında sürdürülüp sürdürülmeyeceğini test etmek için yukarıdaki üç değişkene ilave olarak MF-VAR modeline sanayi üretimi, yeni konut başlangıç sayısı ve S&P500 endeksinin aylık büyüme oranları dahil edilmiştir. Sonuç olarak MF-VAR modelinin Almon polinomu ile ağırlıklandırılmasının, öngörü performansında önemli ölçüde iyileşmelere yol açtığı gözlenmiştir. Bununla birlikte modele aylık frekanslı 6 değişken daha ilave edilerek Almon polinomlu MF-VAR modelinin tahmin performansının, standart üçer aylık frekanslı VAR modeli ve kısıtsız MF-VAR modelinin tahmin performanslarından daha iyi olduğu bir kez daha ispatlanmıştır. Üstelik MF-VAR modelinin Almon gecikme polinomu ile güçlendirilmesinin uzun gecikmeli spesifikasyonlar için belirgin bir avantaja sahip olduğu ortaya konulmuştur.

McCracken ve diğerleri (2015), değişkenlerin farklı frekanslarda yayınlanmasından ve spesifik yayın gecikmelerinden kaynaklanan öngörücülerin bilgi sorununu, en düşük ortak veri frekansında tahmin edilen karma frekanslı Bayesyen VAR modeliyle gidermeye çalışmışlardır. Bu sebeple ABD ekonomisinin GSYİH büyüme oranını yüksek frekanslı değişkenler ile öngörebilmek için Ghysels (2015)'in MF-VAR modelini kullanmışlardır. Ancak MF-VAR modeline çok sayıda değişken eklenmesi modelin boyutunu bir hayli büyütülmektedir. Bu durum parametre sayısının olağanüstü bir biçimde artmasına neden olmaktadır. Bu sorunu aşmak için McCracken ve diğerleri (2015), MF-VAR modelini Bayesyen yöntemleriyle tahmin etmişlerdir. MF-VAR modeliyle hem düşük frekanslı serinin öngörüsü hem de karma frekanslı seriler arasındaki nedensellik ilişkisi ortaya konulabilmektedir. Uygulamada ABD'nin üçer aylık GSYİH büyüme oranı öngörüsü için aylık, haftalık ve günlük frekansta örneklenen finansal ve iktisadi değişkenlerden yararlanılmıştır. Karma frekanslı Bayesyen VAR modelindeki tahmin edilmesi gereken parametre sayısı, eşit gecikme

düzeyine sahip standart VAR'ın parametre sayısından daha hızlı artacağından, analizlerde günlük ve haftalık frekansa sahip değişkenler aylık frekansa dönüştürülerek ele alınmıştır. Elde edilen bulgular ile verilerin karma frekanslı niteliğinin anlık tahmini için önemli olduğu, ancak çeyrek dönem içi bilgilerin tamamının tahmin doğruluğunu iyileştirmediği tespit edilmiştir. Bununla birlikte, çalışmada oluşturulan modelde ABD ekonomisinin GSYİH büyüme oranının anlık tahmininde alternatif yöntemlere göre daha güçlü olduğu belirlenmiştir. Modelin anlık tahminleri, profesyonel tahminciler anketi (SPF) tarafından gerçekleştirilen anlık tahmin doğruluğu ile karşılaştırıldığında Bayesyen VAR'ın %7 daha fazla kök ortalama karekök hata tahmine (RMSFE) sahip olduğu görülmüştür. Çalışmada ayrıca cari çeyrek dönem içinde açıklanan yüksek frekanslı değişkenin gözlem değerleriyle Bayesyen VAR modelinin öngörülerini tekrarlanmıştır. Bu tekrarlar sonucunda çeyrek dönemin ilk ayının sonundaki öngörü performansının faktör modeliyle aynı olduğu belirlenmiştir. Ancak çeyrek dönemin 2. ve 3. aylarında Bayesyen VAR modelin öngörü performansında önemli zaman farklılıkları (*time variation*) görülerek söz konusu Bayesyen VAR modelin öngörü performansı, faktör modelinden daha iyi olduğu anlaşılmıştır. 2008 yılında yaşanan resesyon sonrası dönemde Bayesyen VAR'ın, faktör modelinden daha iyi performans gösterdiği belirlenirken; SPF'nin anlık tahminleri 2000'den beri daha doğru olduğu tespit edilmiştir. Bayesyen VAR modeli ile gerçekleştirilen nedensellik analizinde para politikası şoklarının reel çıktı büyümesini en çok çeyrek döneminin 2. ayında etkilediği görülmüştür. Çalışmada böyle bir sonucun çıkması; çeyrek dönemin başlarında gerçekleşen şokların reel ekonomiye yayılması için daha fazla zamanı olması ya da yüksek frekanslı değişkenlerin marjinal öngörücü içeriğinin çeyrek dönemin 2. ayında en yüksek seviye ulaşması şeklinde yorumlanmıştır.

Ampirik literatürde yüksek frekanslı değişkendeki bilgilerle düşük frekanslı değişkenin öngörüsü MIDAS modellerinin yanı sıra Durum Uzay Modelleriyle de gerçekleştirilebilmektedir. Söz konusu bu model, Ölçüm ve Geçiş denklemlerinden Oluşmaktadır. Durum Uzay Modellerinde düşük frekanslı değişkenler “eksik gözlem” olarak ele alınır ve Kalman Filtre yöntemi ile eksik gözlemler tamamlanmaya çalışılır. Ancak Durum Uzay Modellerinin bazı deavantajları bulunmaktadır. Bunlardan ilki, Durum Uzay Modellerinin düşük frekanslı, eksik gözlem olarak nitelendirilen saklı düşük frekanslı ve yüksek frekanslı değişkenlerin her biri için doğrusal bir dinamik model belirlenmesinin gerektirmesidir. Bu nedenle Durum Uzay Modelleri oldukça karmaşık olabilir. İkinci deavantaj ise denklem sisteminin, ölçüm denklemi, geçiş dinamikleri ve hata süreçleri için çok sayıda parametre tahmininin zorunlu kılmasıdır. Eğer Durum Uzay Modeli, doğru bir şekilde belirlenir ve önsel parametreler bilinirse, Kalman Filtre yöntemi, MIDAS modellerinden daha iyi performans gösterebilir. Ancak Durum Uzay Modelinde parametre belirsizliği ve modelin yanlış belirlenmesi genellikle kaçınılmaz olmaktadır. Bunun neticesinde düşük frekanslı değişkenin öngörüsünde MIDAS ve Durum Uzay Modellerinin hangisinin daha iyi performans göstereceği belli olmayabilir (Bai ve diğerleri, 2013: 780-781). Bu kapsamda Bai ve diğerleri (2013), karma frekanslı değişkenlerin yer aldığı MIDAS ve Çarpımsal MIDAS Modelleri ile Kalman Filtre Yönteminin öngörü performanslarını karşılaştırmışlardır. Bu karşılaştırma için

ABD'nin üçer aylık GSYİH büyüme oranının öngörüsünü esas almışlardır. Bu öngörü için aylık frekansa sahip 9 farklı iktisadi ve finansal değişkenlerden ayrı ayrı yararlanılmıştır. Çalışmada 1959Q1 – 1978Q4 dönemi veri setinden başlanarak ardışık örnekleme yöntemiyle 1959Q1 – 2009Q1 dönemine kadar analizler tekrarlanmıştır. Tekrarlanan bu analizlerle her bir örnekleme dönemi için GSYİH büyüme oranının 1. çeyrekte 8. çeyreğe kadar olan öngörüsü gerçekleştirilmiştir. MIDAS Modellerinin ve Kalman Filtre yönteminin öngörü performansları Kök ortalama kare öngörü hatası (RMSE) ile karşılaştırılmıştır. Bu karşılaştırma sonucunda getiri farkı ve tüketici beklentileri öngörücü değişken olarak kullanıldığında MIDAS Modellerinin Kalman Filtre Yönteminden daha iyi öngörü performansı sergilediği anlaşılmıştır. Öte yandan kişisel gelir ve imalat sanayi üretiminden öngörücü değişken olarak faydalandığında Kalman Filtre Yönteminin öngörü performansının daha iyi olduğu görülmüştür. Analizlerde kullanılan diğer öngörücü değişkenlerde MIDAS Modellerinin ve Kalman Filtre Yönteminin öngörü açısından birbirlerine herhangi bir üstünlüğü tespit edilememiştir. Bu sonuçlarının yanı sıra, kısa dönemde MIDAS modelinin daha iyi performans gösterdiğini belirleyen Kuzin ve diğerleri (2011) ile benzer sonuçlara ulaşılmış ve orta dönem için ise Kalman Filtrenin en iyi öngörü performansı gösterdiği saptanmıştır.

Carriero ve diğerleri (2015), GSYİH büyümesinin hem nokta hem de yoğunluk anlık tahmini için stokastik oynaklığı Bayesyen karma frekans (*Bayesian mixed frequency with stochastic volatility* BMFSV) modelini geliştirmişlerdir. Geliştirmiş oldukları bu model, Bayesyen daraltımının kullanımını ve stokastik oynaklığı içermektedir. Böylelikle zaman serisi modellerinden kaynaklanan tahminlerin doğruluğu artmaktadır. Ayrıca Bayesyen karma frekans modeli, yoğunluk tahminlerinin doğruluğu için önemli bir özellik olan stokastik oynaklığa izin vermektedir. Başka bir ifade ile zamanla değişen regresyon katsayılarına izin verilmektedir. Bahsedilen çalışmada, geliştirilen BMFSV modeliyle ABD ekonomisi için aylık frekansta gözlemlenen istihdam ve sanayi üretimi gibi ekonomik göstergeler ve hisse senedi fiyatları ve faiz oranları gibi finansal göstergeler ile GSYH büyümesinin 1985'den 2011'e kadar olan gerçek zamanlı anlık tahminleri oluşturulmuştur. Çalışmada AR modellerinden üretilen Bayesyen karma frekans modelinin anlık tahminleri, ankete dayalı tahmin sonuçları ile kıyaslanmıştır. Bu karşılaştırma sonucunda GSYİH büyüme oranının nokta tahmini açısından BMFSV modelinin AR modellerinde önemli ölçüde iyileştiği, ankete dayalı tahminleriyle karşılaştırmalı olarak gerçekleştiği ve çeyrek içi bilgilerin yararlılığı hakkında daha fazla kanıt sağladığı tespit edilmiştir. Bununla birlikte modelin, stokastik oynaklık spesifikasyonunun oldukça güvenilir yoğunluk ve aralık tahminleri sağladığı belirlenmiştir.

MIDAS modellerinde bağımlı ve bağımsız değişkenler arasındaki frekans uyumsuzluğu fazla ise modelde parametre sayısının olağanüstü bir biçimde artmasını engellemesi için üstel Almon gibi gecikmesi dağıtılmış polinomlardan faydalanılmaktadır. Ancak bu tarz gecikmesi dağıtılmış polinomların doğrusal olmamaları nedeniyle, MIDAS regresyonları doğrusal olmayan en küçük kareler (NLS) yöntemi ile tahmin edilmektedirler. Fakat iktisadi değişkenler arasındaki frekans uyumsuzluğu, genellikle çok fazla olmamaktadır. Bu kapsamda Forni ve diğerleri (2015), MIDAS

modeli tahmininde NLS yöntemi gerektirmeyen ve en küçük kareler (EKK) yöntemi ile tahmin edilebilen kısıtsız MIDAS (U-MIDAS) modelini kullanmışlar ve bu modeli, üstel Almon gecikmesini temel alan MIDAS modeli ile karşılaştırmışlardır. Monte Carlo simülasyonu ile örneklem dışı anlık tahmin performansına bakıldığında değişkenler arasındaki frekans uyumsuzluğu küçük ise, yani aylık ile üç aylık frekanslı değişkenler kullanıldığında, U-MIDAS'ın üstel Almon Polinomu ile ağırlıklandırılan MIDAS modelinden daha iyi performans gösterdiği anlaşılmıştır. Ancak frekans uyumsuzluğu fazla ise üstel Almon polinomu ile ağırlıklandırılan MIDAS modelinin daha iyi sonuçlar verdiği görülmüştür. Çalışmanın ampirik kısmında aylık frekanslı değişkenler ile ABD ve Euro bölgesinin GSYİH büyüme oranları öngörüsüne odaklanılmıştır. ABD'nin GSYİH büyüme oranı öngörüsü için 1959 – 2011 dönemini kapsayan konferans kurulu (*Conference Board*) tarafından sağlanan aylık frekanslı kompozit öncü göstergelerin 10 bileşeninden yararlanılmıştır. Bu göstergeler ve ardışık örnekleme yaklaşımı ile 1985'in ilk çeyreğinden başlanılarak 2011'in ilk çeyreğine kadar ABD'nin GSYİH büyüme oranının anlık tahmini ve 4 çeyrek döneme kadar öngörüsü gerçekleştirilmiştir. Euro bölgesinin GSYİH büyüme oranı öngörüsü için 1996 – 2011 dönemini kapsayan aylık frekanslı değişkenlerden sektörlere göre tüketici ve üretici fiyat endeksleri, sektöre göre sektörel sanayi üretimi ve (deflete edilmiş) ciro endeksleri, işsizlik endeksleri, parasal büyüklükler, faiz oranları ve döviz kurları gibi göstergeler kullanılmıştır. Bu göstergeler ve ardışık örnekleme yaklaşımıyla Euro bölgesinin GSYİH büyüme oranının öngörüsü 2003'ün ilk çeyreğinden 2010'un ilk çeyreğine kadar gerçekleştirilmiştir. Çalışmada hem Euro bölgesi hem de ABD için örneklem dışı anlık tahmini ve kısa vadeli tahmin performanslarına bağlı olarak MIDAS ve U-MIDAS modelleri arasında herhangi bir fark gözlemlenmemiştir. Ancak uzun dönemli öngörülerde U-MIDAS modelinin daha iyi performans gösterdiği belirlenmiştir.

Barsoum ve Stankiewicz (2015), iktisadi verilerdeki konjonktürel dalgalanmaları hesaba katabilmek ve ayrıca öngörü performansını artırabilmek için Guérin ve Marcellino (2013)'nin Markov Değişim MIDAS (MS-MIDAS) modelini, Foroni ve diğerleri (2015)'nin kısıtsız MIDAS (U-MIDAS) modeli ile genişleterek MS-U-MIDAS modelini geliştirmişlerdir. Oluşturdukları MS-U-MIDAS modelini aylık frekansa sahip 156 adet iktisadi ve finansal göstergelerden oluşan büyük bir veri kümesi ile $h = \frac{1}{3}, \frac{2}{3}, 1, 2, 4$ dönemlerinde ABD'nin GSYİH büyümesinin öngörüsü için kullanmışlardır. Çalışmada kullanılan veri seti aylık değişkenler için 1958 Haziran – 2011 Eylül dönemini kapsarken; çeyrek GSYİH için 1959Q1-2011Q3 dönemini kapsamaktadır. Analizlerde çok fazla sayıdaki aylık frekanslı değişkenlerin sayısını azaltmak için faktör analizi yapılmıştır. Ancak değişken sayısını azaltırken söz konusu değişkenlerdeki mevcut bilgileri de verimli bir şekilde kullanabilmek için temel bileşen analizi (PCA) yöntemi tercih edilmiştir. Daha sonra oluşturulan bu faktör değişkenleri GSYİH büyümesini öngörmeye açıklayıcı değişken olarak kullanılmıştır. Çalışmada MS-U-MIDAS modelinin örneklem dışı tahmin performansı, alternatif modellerin performansları ile kıyaslanmıştır. Alternatif modeller şöyle sıralanmıştır; MS-MIDAS (-AR), MS-ADL-MIDAS, Markov-değişim gecikmesi dağıtılmış (MS-DL), Markov-değişim Otoregresif

Dağıtılmış Gecikme (MS-ADL) ve Markov-değişim olmayan bazı modeller: MIDAS ve U-MIDAS (otoregresif dinamikleri olan ve olmayan), Gecikmesi Dağıtılmış modeli (DL), Autoregressive Dağıtılmış Gecikme modeli (ADL), bir AR (2) ve rassal yürüyüş (RW) modelleridir. Bulgular neticesinde modellere her ne kadar otoregresif dinamiklerin eklenmesi, tüm tahmin dönemlerinde kök ortalama kare öngörü hatası (RMSE) açısından öngörme doğruluğunu iyileştirmede çok önemli katkı sağlamış olsa da, gerçek rejimin öngörüsünde böyle bir durumun söz konusu olmadığı görülmüştür. Çalışmada ayrıca rejim tahmin tutarlılığının (*accuracy of regime prediction*) bir ölçüsü olan quadratik olasılık skoruna (QPS) göre, modellere otoregresif dinamikler eklemenin, söz konusu modellerin rejim öngörme yeteneğini çoğu zaman olumsuz yönde etkilediği belirlenmiştir. Diebold ve Mariano (DM) testi ile de $h = 2$ ve $h = 4$ dönemlerinde hem öngörü performansı hem de rejim öngörü performansı açısından sonuçların anlamsız olduğu gözlemlenmiştir. Ancak $h = \{1/3, 2/3, 1\}$ kısa dönemleri için Diebold ve Mariano (DM) testinin oldukça anlamlı sonuçlar verdiği tespit edilmiştir. Bir bakıma buradan MIDAS tipi modellerin özellikle anlık tahmini için daha yararlı olduğu sonucu çıkartılabilmektedir. Elde edilen bulgular ile, MS-U-MIDAS sınıf modellerinin performansının kısıtlı alternatiflerine göre daha iyi performans gösterdiği belirlenmiştir. Böylelikle özellikle değişkenler arasındaki frekans oranı m küçük olduğunda MS-U-MIDAS modeli, birçok makroekonomik uygulama için MS-MIDAS modeline yararlı bir alternatif model olmaktadır. Çalışmada ayrıca oluşturulan faktör değişkenlerinin tek değişken olarak kullanıldığı MIDAS modellerinden elde edilen öngörü sonuçları kombine edilerek yeni öngörü sonuçları hesaplanmıştır. Hesaplanan bu öngörü sonuçları, genellikle tek faktör kullanan modellerin öngörü sonuçlarından daha tutarlı oldukları anlaşılmıştır. Kısaca özetlemek gerekirse çalışmada sunulan ve uygulanan modellerin, mevcut veri kümelerinin bilgi içeriğinin daha iyi kullanılmasına yardımcı olduğu ve bu nedenle birçok durumda ilgili değişkenlerin daha iyi tahminlerinin gerçekleştirilmesine aracılık ettikleri tespit edilmiştir.

Blasques ve diğerleri (2016), standart en yüksek olabilirlik yönteminden daha tutarlı bir öngörü performansı sağlamak amacıyla hedef değişkenlerin tahmininde dinamik faktör modelleri için karma frekanslı ağırlıklı en yüksek olabilirlik (WML) tahmin yöntemini geliştirmişlerdir. Blasques ve diğerleri (2016), geliştirmiş oldukları tahmin prosedürünü ABD ekonomisi için 1970-2009 dönemi verilerini kullanarak aylık frekansa sahip 13 değişken ve haftalık frekanslı 1 değişken ile GSYİH büyüme oranının öngörüsünü ve anlık tahmini iyileştirip iyileştiremediğini incelemişlerdir. Uygulamada ABD'nin GSYİH büyüme oranı öngörüsü için 3 farklı model üzerinde durulmuştur. Bu modellerden ilki öngörücü değişken olarak 4 farklı aylık frekanslı değişken içerirken; 2. model çalışmada kullanılan tüm aylık frekanslı değişkenleri içermektedir. Analizlerde kullanılan son modele ise, ilk modelde yer alan aylık frekanslı değişkenlere ilave olarak haftalık frekanslı 1 değişken eklenmiştir. Çalışmada sabit gözlemlili kayan pencereler ile 2000Q1-2009Q4 dönemi GSYİH'nin büyüme oranı değerlerinin anlık tahmini ve 1, 2 ve 4 çeyrek dönem sonrasının değerleri öngörülmüştür. Ortalama kare hatası kritik değerlerince, hemen hemen tüm durumlarda WML

yönteminin ABD GSYİH büyümesini öngörü ve anlık tahmini tutarlılığında anlamlı iyileştirmelere yol açabileceği kanısına varılmıştır.

Şen Doğan ve Midiliç (2016), Türkiye örneğinde günlük frekanslı finansal değişkenler ile üçer aylık GSYİH büyüme oranını öngörmeye çalışmışlardır. Çalışmada finansal değişkenlerin GSYİH'den daha yüksek frekansta bulunmalarından ötürü Ghysels ve diğerleri (2004) tarafından geliştirilen MIDAS yaklaşımı tercih edilmiştir. Uygulamada Andreou ve diğerleri (2013)'nin öngörü stratejisi izlenerek 2000Q2-2015Q1 dönemi verilerinden yararlanılmış ve 204 farklı finansal değişken ile Türkiye ekonomisinin GSYİH büyümesinin verileri öngörülme çalışılmıştır. Çok fazla sayıda finansal değişken olmasından dolayı bu finansal değişkenlerden 5 adet günlük frekanslı faktör değişkenleri oluşturulmuştur. Analizlerde finansal değişkenlerin yer aldığı gecikmesi dağıtılmış (ADL-MIDAS) model ile finansal değişkenler ve iktisadi faktörlerin bulunduğu Faktör Genişletilmiş Gecikmesi Dağıtılmış Karma Frekanslı Veri Örnekleme (*Factor Augmented Distributed Lag Mixed Data Sampling*, FADL-MIDAS) modeli kullanılmıştır. kök ortalama kare öngörü hatası (RMSE) kritik değeriyle her iki modelin öngörü performansı, toplulaştırılmış verilerle kurulan AR(1) referans modeliyle karşılaştırılmıştır. Elde edilen bulgularla günlük finansal verilerin kullanılmasının öngörü performansını geliştirdiği belirlenmiştir. Bunun yanı sıra MIDAS regresyon modelleri basit toplulaştırma yapısı kullanan modellere göre öngörü kazanımı sağladığı ve birçok durumda bu kazanımın önemli olduğu görülmüştür. Ancak ilgili çalışmada yüksek frekanslı değişkenlerin ağırlıklandırılmasında sadece geleneksel Almon Polinomu kullanılmıştır. Bu nedenle söz konusu çalışmada Türkiye ekonomisine ilişkin GSYİH büyüme oranı öngörüsünde yüksek frekanslı değişkenler için ağırlıklandırma polinomlarından hangisinin en uygun olduğuna dair herhangi bir analiz gerçekleştirilmemiştir.

Jiang ve diğerleri (2017), 2000 – 2016 dönemi verilerinden yararlanarak çok fazla sayıda aylık frekanslı iktisadi değişkenler ve günlük frekanslı finansal değişkenler ile Çin'in GSYİH büyüme oranını öngörmeye çalışmışlardır. Kullanılan değişkenlerin çok fazla sayıda olması ve değişkenlerin farklı frekanslarda olmaları nedeniyle çalışmada dinamik faktör modelleri ile MIDAS modeli bir arada kullanılmıştır. Uygulamada öncelikle 44 adet aylık değişken kendi aralarında dinamik faktör modeli ile 2 adet faktör modeline indirgenmiştir. Aynı şekilde 54 adet günlük finansal değişken dinamik faktör modeli vasıtasıyla 3 farklı faktör modeline dönüştürülmüştür. Daha sonra bu faktör değişkenleri MIDAS yöntemiyle Çin ekonomisinin üçer aylık GSYİH büyüme oranı tahmininde kullanılmıştır. Diebold ve Mariano (DM) testiyle MIDAS yöntemiyle gerçekleştirilen öngörülerin toplulaştırılmış değişkenler ile yapılan öngörülerden daha iyi öngörü sonuçları verdiği belirlenmiştir. Ayrıca çalışmada faktör değişkenlerinin kullanıldığı tahmin modellerinin, tek değişkenli tahmin modellerinden daha iyi bir sonuç verdiği görülmüştür. Bunun nedeni, iktisadi ve finansal bilgilerin tahmin prosedüründe etkin bir şekilde kullanılmasıdır. Dinamik faktör modeli (DFM), sayıca fazla iktisadi ve finansal değişkenden etkili bir şekilde bilgi elde edebilir ve bu nedenle DFM tarafından elde edilen faktörler, bireysel değişkenlerden daha fazla bilgi içerebilir. Dahası, MIDAS regresyonu,

yüksek frekanslı verilerde yer alan bilgilerden verimli bir şekilde faydalanabilir ve böylece daha isabetli GSYİH büyüme oranı tahminleri sağlanabilir. Çalışmada faktör değişkenleri kullanarak tahminleri kombinasyon yapmanın genel olarak tahmin doğruluğunu arttırdığı tespit edilmiştir.

Silverstovs (2017), 559 adet aylık frekanslı gösterge kullanarak İsviçre'nin üçer aylık GSYİH büyüme oranı tahminini gerçekleştirmiştir. Silverstovs (2017), ele aldığı modelinin çok fazla sayıda gösterge barındırmasından dolayı, Bai ve Ng (2008)'de önerilen hedef açıklayıcı değişken yaklaşımını Foroni ve diğerleri (2015) tarafından ortaya çıkarılan kısıtsız karma frekans verisi ile harmanlayarak MIDASSO yaklaşımını kullanmıştır. Uygulamada 2007Q1 – 2014Q1 dönemi, ardışık genişleyen pencere (*recursively expanding-window approach*) yaklaşımıyla sözde reel zamanlı GSYİH büyüme oranı öngörülmüştür. İlk olarak 2007 Mart ayının ilk işgününde 2001Q1-2006Q4 dönemi veri seti kullanılarak GSYİH büyüme oranının 2007 yılına ait ilk üç çeyreği için öngörüsü yapılmıştır. Öncü değişkenlerin tahmin performanslarını görmek adına bu öngörüler, 2007 yılı Nisan ve Mayıs aylarında yinelenmiştir. Ardından 2007 yılının Haziran ayının ilk işgününde 2001Q1-2007Q1 dönemi veri setiyle GSYİH büyüme oranının 2007Q2, 2007Q3 ve 2007Q4 öngörülmesi gerçekleştirilmiştir. Bu yolla çalışmada 2014 yılı Mayıs ayının ilk işgününe kadar GSYİH büyüme oranının öngörüsü yapılmıştır. Uygulamada yalnızca 2014 yılının ilk çeyreği için örneklem dışı öngörüsünde bulunulmuştur. Kök Ortalama Kare Öngörü Hatası (RMSFE) kriteriyle MIDASSO yönteminin öngörü sonuçları, 2. dereceden otoregresif model AR(2) referans modelinin öngörü bulgularıyla kıyaslanmıştır. Sonuç olarak MIDASSO modelinin, özellikle 2008 Mortgage ve Avrupa devlet borç krizleri döneminde, referans modelden daha tutarlı tahminler ürettiği belirlenmiştir.

literatürde hangi model ve spesifikasyon kullanılırsa kullanılsın düşük frekanslı iktisadi değişkenlerin daha iyi öngörüsünü elde edebilmek için modele çok fazla sayıda öngörücü değişkenin dâhil edilmesi gerektiği hususu üzerine de durulmuştur. Hatta bazı çalışmalarda modele dahil edilen öngörücü değişken sayısı, örneklem boyutunu aşmaktadır. Bu kapsamda Uematsu ve Tanaka (2017), 117 adet aylık frekanslı değişken ile birlikte ABD'nin üçer aylık frekanslı GSYİH büyüme oranını öngörmeye çalışmışlardır. Uematsu ve Tanaka (2017), öngörü regresyonuna 8 dönemlik gecikmeler ilave etmişlerdir. Ancak her bir değişkenin 8 döneme kadar gecikmesinin eklenmesi, öngörü modelinde tahmin edilmesi gereken parametre sayısını 1000'den daha fazla yapmaktadır. Diğer yandan uygulamada ele alınan değişkenlere ait veri seti 1959 – 2016 dönemini kapsamaktadır. Bu dönem aralığı, 1000'den fazla parametre tahmini için oldukça kısadır. Her ne kadar MIDAS modelinde yüksek frekanslı değişkenler için ağırlıklandırma parametreleri kullanılsa da böyle bir modelde tahmin edilmesi gereken parametre sayısı yine de bir hayli fazla olacaktır. Öte yandan, içbükey cezalandırılmış (*folded-concave penalized*) regresyon, dağıtılmış gecikme yapısını regresyon katsayılarına empoze etmeden MIDAS regresyon modelinin tahmin edilmesini sağlamaktadır. Cezalandırılmış regresyon yaklaşımı, regresyon katsayılarının kesikli (*sparse*) olarak tahmin edilmesine yol açabilmekte ve modeldeki değişken sayısı, gözlem sayısından çok daha büyük olsa bile rahatlıkla uygulanabilmektedir. Kesikli tahmin, bağımsız değişken sayısının alt üstel olarak

(*sub-exponentially*) farklılaştığı ultra yüksek boyutluluğa (*ultra high dimensionality*) izin vermektedir. Bu nedenle Uematsu ve Tanaka (2017), Ghysels ve diğerleri (2007)'nin aksine yüksek frekanslı değişkenin geçmiş değerlerinin ağırlıklandırma kalıplarının aksine cezalandırılan regresyon modelini kullanmışlardır. Uygulamada modelin 2000Q1 – 2016Q2 dönemi örneklem dışı tahmin performansı değerlendirilmiştir. Bahsedilen çalışmada cezalandırılmış (*penalized*) regresyon modelinin tahmin performansını ölçmek için iki farklı veri setinden yararlanılmıştır, bunlar sırasıyla tam veri seti ve yayın gecikmesi nedeniyle dengesiz veri (*ragged edge*) desenine sahip gerçek zamanlı bir veri setidir. Dengesiz veri (*ragged edge*) setinde aylık frekanslı değişkenlerin bazılarında son aylara ait gözlemlerin eksik olmasıdır. Ayrıca 2008 yılındaki Mortgage krizinden dolayı tüm örneklem gözlemi (2000Q1-2016Q1) ve iki alt örnekleme dönemi (2000Q1 – 2007Q4 ve 2008Q1 – 2016Q1) ele alınmıştır. Uygulamada cezalandırılmış regresyonun, Marcellino ve Schumacher (2010) tarafından önerilen faktör bazlı MIDAS (FA-MIDAS) regresyonundan daha iyi öngörü performansı gösterdiği tespit edilmiştir. Bunun yanı sıra tam veri seti ile cezalı hale getirilmiş MIDAS'ın çok kısa bir dönemde, özellikle istikrarsızlığın varlığında, nispeten uzun bir döneme sahip bir tahmin için 1.1 bir araç olmamasına rağmen, iyi bir tahmin performansına sahip olduğu belirlenmiştir. Gerçek zamanlı bir veri seti ile dengesiz veri (*ragged edge*) ve enterpolasyonun, cezalandırılmış regresyonun tahmin doğruluğu üzerindeki etkilerini ihmal edilebilir düzeyde olduğu tespit edilmiştir. Durum Uzayı en çok olabilirlik (ML) tahmincisi, daha zengin bilgiler içeren bir sistem denklemine dayanırken, cezalandırılmış regresyon tek bir denklem üzerine dayandığı için Durum Uzayı ML tahmincisinin cezalandırılan regresyondan daha yüksek tahmin performansına sahip olması beklenmektedir. Ancak Bai ve diğerleri (2013)'nin savundukları gibi, söz konusu beklenti model belirsizliklerinin mevcut olduğu durumlarda gerçekleşmeyecektir. Cezalandırılmış regresyon sonuçları, tahmin doğruluğu açısından Durum Uzayı ML tahmincisi ile rekabet edecek ölçüde bulunmuştur. Üstelik cezalandırılmış regresyonun tahmin değerlerini elde etmek Durum Uzay ML modelinden çok daha basit ve hızlı olmaktadır.

Yamak ve diğerleri (2018), Türkiye ekonomisinin GSYİH büyüme oranını öngörmek için getiri farklarından yararlanmışlardır. Bu öngörü için 3 farklı getiri farkı serisi kullanılmış olup söz konusu getiri farkı serileri, 12 ay vadeli faiz oranından sırasıyla 1 ay, 3 ay ve 6 ay vadeli faiz oranları çıkartılarak oluşturulmuştur. Çalışmada getiri farkları, 2010'nun ilk ayı ile 2017'nin 5. ayı arasındaki dönem kapsayan haftalık verilerden oluşurken; üçer aylık GSYİH büyüme oranı verisi ise 2010Q1 – 2016Q4 dönemini içeren üçer aylık verilerden oluşmaktadır. Uygulamada haftalık getiri farkı serisinden yararlanılarak GSYİH büyüme oranının 2017 yılının ilk üç çeyreği öngörülmüştür. Bunun yanı sıra haftalık frekansta olan getiri farkları aylık frekansa dönüştürülerek bahsi geçen döneme ait öngörüler tekrarlanmıştır. Almon ağırlıklandırma polinomunun kullanıldığı analizlerde belirli tahmin performans kriterlerine göre haftalık frekansta 12 vadeli faiz oranından 6 ay vadeli faiz oranının çıkartılmasıyla edilen getiri farkının en iyi tahmin performansı verdiği anlaşılmıştır. Öte yandan üstel Almon ağırlıklandırma Polinomunun kullanıldığı MIDAS modellerinde haftalık ve aylık frekanslarda oluşturulan getiri farklarının birbirlerine mutlak üstünlükleri görülmemiştir. İlgili

çalışmada, haftalık frekanslı getiri farkları aylık frekansta toplulaştırılarak uygulamalar gerçekleştirilmiş ancak söz konusu bu değişkenler GSYİH ile aynı frekansa toplulaştırılarak analizler tekrarlanmamıştır. Bu nedenle MIDAS modelinin, geleneksel yöntemlere göre daha iyi öngörü performansı sunup sunmadığı araştırılmamıştır.

Den Reijer ve Johansson (2019), aylık frekansa sahip 92 farklı değişken ile İsveç ekonomisinin üçer aylık GSYİH büyüme oranının sözde gerçek zamanlı anlık tahminini gerçekleştirmeye çalışmışlardır. Çok fazla sayıda öngörücü değişken olmasından dolayı Kuzin ve diğerleri (2013)'nde olduğu gibi faktör modelleri oluşturulmuştur. Faktör modellerinin yanı sıra tek değişkenli MIDAS, Faktor VAR modellerinden faydalanılmıştır. Her bir modelden elde edilen bulgular havuzlanmıştır. Uygulamada 1993 – 2014 dönemi veri seti kullanılarak kayan pencereler örneklemeyle 2003Q3 – 2014Q2 dönemi örnekleme dışı anlık tahmini gerçekleştirilmiştir. Bu anlık tahmin işlemi çeyrek dönemlerde her bir ayın sonuna denk gelen veri setleriyle ayrı ayrı yapılmıştır. Böylelikle 2003Q3-2014Q2 dönemi her çeyrek dönem için üç ardışık anlık tahmini oluşturulmuştur. Bunun yanı sıra öngörü dönemi 2008 kriz öncesi (2003Q3-2007Q4) ve sonrası (2008Q1-2014Q2) şeklinde iki alt gruba ayrılarak analizler tekrarlanmıştır. Analiz bulguları neticesinde tek göstergeli MIDAS modellerinin havuzlanmasının en iyi performansı gösterdiği belirlenmiştir. Ayrıca çeyrek dönem içerisinde daha fazla aylık bilginin kullanılması, daha doğru anlık tahmin sonuçları elde edilmesine neden olmuştur. Ancak en az bilgi durumunda, yani çeyrek dönem içerisindeki ilk ay bilgisiyle anlık tahmin yapıldığında faktör modellerinin, diğer modellere nazaran en kötü performansı sergilediği görülmüştür. Çalışmada ayrıca anlık tahmin performansının, örnekleme dışı anlık tahmin dönemi bulguları neticesinde kriz öncesi modellerin hiçbirinin referans modelinden anlamlı bir farklılık sergilemediği anlaşılmıştır. Buna karşılık, kriz sonrası dönemde tüm havuzlanmış modellerin, özellikle de tek göstergeli MIDAS modellerinin havuzlanması, diğer modellerden daha iyi performans gösterdiği tespit edilmiştir.

Öte yandan Xu ve diğerleri (2018), öngörü modeline olabildiğince çok fazla sayıda değişkenin katılmasının öngörü yeteneğini geliştireceği düşüncesi ile çok sayıda değişken ile ABD'nin GSYİH büyüme oranı tahminini gerçekleştirmişlerdir. Ancak çok fazla sayıda öngörücü değişkenin kullanılması tahmin edilmesi gereken parametre sayısını bir hayli arttırmaktadır. Bunun yanı sıra bu kadar çok sayıdaki bağımsız değişkenler arasında hangisinin veya hangilerinin GSYİH büyüme oranını en iyi şekilde öngörebileceği kolaylıkla kestirilememektedir. Üstelik MIDAS modeli ile kullanılan ağırlıklandırma yöntemleri, çok fazla sayıda değişken söz konusu olduğunda modelde tahmin edilmesi gereken parametre sayısını yeterince azaltamamaktadır. Bu nedenle uygulamada bireysel değişken seçim yöntemleri kullanmak yerine U-MIDAS modelini grup en az mutlak seçim ve daraltma işlemcisi (*least absolute shrinkage and selection operator* LASSO), grup düzgünleştirilmiş mutlak sapma (*smoothly clipped absolute deviation* SCAD) ve grup *minimax concave penalty* (MCP) gibi ceza esaslı modeller ile birleştirerek Grup Cezalandırılmış (*group penalized*) U-MIDAS (GP-U-MIDAS) modelini oluşturmuşlardır. Monte Carlo simülasyonu ile GP-

U-MIDAS modelinin, deęişken seçimi ve tahmin isabetlięi açısından P-U-MIDAS, FC-U-MIDAS, U-MIDAS ve düşük ve yüksek frekanslı (LF / HF-) EKK modellerinden daha iyi performans gösterdięi belirlenmiştir. Çalışmada ayrıca 1960-2017 dönemi GP-U-MIDAS modeli aylık frekanslı 17 adet iktisadi deęişken kullanılarak ABD'nin üçer aylık GSYİH büyüme oranının öngörüsü gerçekleştirilmiştir. Ampirik sonuçlar ile GP-U-MIDAS modelinin dięer rekabetçi modellerden daha iyi performans gösterdięi belirlenmiştir. Bununla birlikte özellikle politika yapıcılar için sanayi üretimi ve kişisel tüketim harcamalarının GP-U-MIDAS modeli tarafından ABD GSYİH büyüme oranını tahmin etmede kilit göstergeler olduęu tespit edilmiştir.

MIDAS yöntemi, yüksek frekanslı deęişkenlerin gecikmelerini ağırlıklandırma polinomları sayesinde modelde tahmin edilmesi gereken parametre sayısını azaltmaktadır. Ancak ele alınan MIDAS modelinde çok fazla sayıda yüksek frekanslı deęişkenin bulunması parametre sayısını yeteri kadar azaltamayabilir. Hatta bazı durumlarda tahmin edilmesi gereken parametre sayısı, gözlem sayısından fazla olabilir. Deęişken sayının çok fazla olması durumunda Mogliani (2019), yüksek frekanslı bir ortamda ilgili yüksek frekanslı öngörücülerin aynı anda tahmin edilmesi ve seçilmesi konusunu ele alan karma frekans regresyonlarının (MIDAS) modellenmesi ve öngörülmesi için farklı bir yaklaşım önermiştir. Bu yaklaşım, Almon gecikme polinomlarına, MIDAS regresyonlarına ve uyumlaştırılmış bir cezalandırılmış regresyon yaklaşımına, yani Grup Lasso objective fonksiyonuna dayanmaktadır. Uematsu ve Tanaka (2017)'dan farklı olarak, gecikmeler arasındaki yüksek korelasyon sorununun üstesinden gelmek için, gecikme ağırlıklandırma fonksiyonunun bireysel terimleri yerine tüm gecikme polinomu seviyesinde seçim yapılmaktadır. Mogliani (2019), cezalandırılmış MIDAS regresyonun tahmini için Bayesyen tekniklerden faydalanmış ve Bayesyen cezalandırılmış regresyonlar ve uyarlanabilir ceza kriteri hakkındaki en son literatürün ardından bazı şartlar altında her gecikme polinomuna farklı bir ceza süresi koyarak tahmin edilme özelliğinden yararlanan bir Bayesyen MIDAS Grup Uyumlaştırılmış En Az Mutlak Seçim ve Daraltma İşlemcisi (*Adaptive Group Least Absolute Shrinkage And Selection Operator, AGL*) modelini geliştirmiştir. Geliştirilen bu modelin öngörü tutarlılıęı Monte Carlo simülasyonu ile değerlendirilmiştir. Deęerlendirme sonucunda Bayesyen MIDAS AGL modelinin örneklem içi ve örneklem dışı öngörü performansının oldukça iyi olduęu bulunmuştur. Mogliani (2019), cezalandırılmış MIDAS modelini 1980Q1-2017Q4 dönemi verilerinden yararlanarak ABD'nin GSYİH büyüme oranını öngörüsü için kullanmıştır. Büyüme oranının öngörüsü için aylık, haftalık ve günlük frekanslarda örneklenen 42 adet reel ve finansal göstergedenden faydalanılmıştır. Tahminler, ardışık örnekleme yaklaşımı kullanılarak özyinelemeli olarak gerçekleştirilmiştir. Çalışmada, anlık tahmin 1 ve 4 çeyrek dönem sonrası öngörülerini olmak üzere üç farklı tahmin dönemi ele alınmıştır. Tahminler, basit bir rassal yürüyüş (RW) temsil eden AR(1) referans modeli ile karşılaştırılmıştır. Nokta tahminleri göreceli kök ortalama kare öngörü hatası (RMSE) oranları ile değerlendirilmiştir. Ayrıca, gözlemlenen tahmin farklılıklarının altında yatan örnek belirsizlięini hesaba katmak için Diebold ve Mariano (2002) ve West (1996) (DMW) testi sonuçları rapor edilmiştir. Sonuç olarak yüksek frekanslı reel iktisadi ve finansal öngörücülere sahip ABD'nin GSYİH büyüme oranı öngörme modeline

uygulandığında Bayesyen MIDAS AGL modelinin, Bayesyen Model Ortalama (*Bayesian Model Averaging*) ve en optimal şekilde birleştirilmiş tek değişkenli Bayesyen MIDAS modelleri gibi basit ve sofistike rakip modellere kıyasla anlık ve 1 çeyrek dönem sonrası tahminlerde daha üstün nokta ve yoğunluk tahminleri sağlayabildiği bulunmuştur.

Ankargren ve diğerleri (2019), durgun durum hakkındaki önsel bilgi ve stokastik bir oynaklık ile karma frekanslı Bayesyen VAR modeli geliştirmişlerdir. Bunun için çalışmada Villani (2009)⁵'nin durgun durum parametrelemesi, Schorfheide ve Song (2015)'un karma frekanslı verileri için Durum Uzay modelleme yaklaşımı ve Carriero ve diğerleri (2016)⁶'nin önerdiği ortak stokastik oynaklık modeliyle etkin bir şekilde birleştirilmiştir. Böylelikle karma frekanslı Bayesyen VAR modeli, koşulsuz ortalamanın farklı frekanslarda ölçülen verilerle açık bir şekilde modellenmesini sağlamaktadır. Ankargren ve diğerleri (2019), geliştirmiş oldukları bu modeli, ABD ekonomisi için aylık frekansta gözlemlenen 10 değişken ve üçer aylık frekansta gözlemlenen 3 değişken setinden oluşan 13 iktisadi değişken için gerçek zamanlı bir veri seti ile uygulamışlardır. Çalışmada Louzis (2019)⁷ tarafından önerilen önselliğin hiyerarşik formülasyonundan faydalanılarak sabit hata kovaryansı ve ortak stokastik oynaklık ile önsel normal ters Wishart modelleri; ve bu modellerin önsel durgun-durum ve önsel hiyerarşik normal-gamma durgun-durum modelleri olmak üzere 6 farklı model üzerinde çalışılmıştır. Referans modeli olarak da tüm değişkenlerin üçer aylık frekansta ele alındığı sabit hata kovaryansı için önsel normal ters Wishart ve önsel durgun durum modelleri kullanılmıştır. Ele alınan modellerin tahmin performanslarını değerlendirmek için 2005 Ocak'tan başlanarak ardışık örnekleme tahmin şeması kullanılmıştır. Her bir modelin tahmin yeteneği, kök ortalama kare hataları ile değerlendirilmiştir. Çalışmada sonuç olarak karma frekanslı verilerin kullanılmasının hem aylık hem de üç aylık değişkenler için tahmin performansını genellikle iyileştirdiği tespit edilmiştir. Üstelik durgun durum hakkında önsel bilginin kullanılmasının bu önsel bilgiyi içermeyen alternatif modellere karşı daha iyi performans gösterdiği görülmüştür. Çalışmada

⁵ Villani (2009), durgun durumda önsel bilgilendirici ile indirgenmiş ya da yapısal formda hem durağan hem de eş bütünleşmiş VAR modelleri için yöntemler geliştirmiştir. Söz konusu yöntemler ile İsveç için 1980Q1-2005Q4 dönemi veri seti kullanılarak durağan VAR modeliyle İsveç'in 7 iktisadi değişkeninin öngörü tutarlılığında önemli iyileşmelerin olduğu belirlenmiştir.

⁶ Carriero ve diğerleri (2016), koşullu oynaklıkların birlikte harekete ettiği (*comovement*) iki farklı model önermişlerdir. Bu modellerden 1.si, gözlemlenmeyen tek bir faktörün yanı sıra kendine özgü bir bileşen (*idiosyncratic component*) tarafından yönlendirilen koşullu oynaklıkları belirlemektedir. İkinci model ise, kendine özgü bir bileşen (*idiosyncratic component*) ortadan kaldırıldığı ve oynaklıktaki hareketlerin büyüklük sırasının değişkenler arasında orantılı olması için faktör yüklerinin tüm koşullu oynaklıklar için 1'e ayarlandığı stokastik oynaklık modelidir (Carriero ve diğerleri, 2016: 375-376). Çalışmada ABD iktisadi değişkenlerin öngörüsü için gerçekleştirilen uygulamada büyük veri kümesinde standart homoskedastik Bayesyen VAR modeli ile karşılaştırıldığında stokastik oynaklık modeli ile gerçek zamanlı nokta ve yoğunluk tahminlerinde sistematik iyileştirmeler sağlandığı anlaşılmıştır.

⁷ Louzis (2019), standart durgun durum (*steady-state*) VAR modelini genişleterek uyarlamalı hiyerarşik Önsel durgun durum (*steady-state prior*) yöntemi önermiştir. ABD'nin 14 iktisadi değişkeni için gerçekleştirilen uygulama ile söz konusu yöntemin, standart testlere göre 1 yıldan daha uzun vadelerde öngörülerde ortalama olarak daha tutarlı nokta ve yoğunluk tahminleri ürettiği gözlemlenmiştir.

ayrıca deęişen varyans içeren modeller genellikle sabit oynaklık modellerinden daha iyi performans gösterdikleri için stokastik oynaklığın genellikle tahminlerin doęruluęunu artırdığı belirlenmiştir.

Erdoędu (2020), aylık frekansa sahip vergi gelirlerinden faydalanarak üçer aylık GSYİH büyüme oranını öngörmeye çalışmıştır. Uygulamada 2006Q1 – 2018Q3 dönemi verileri kullanılarak 2016Q1-2018Q3 dönemi örneklem için GSYİH büyüme oranı öngörüsü gerçekleştirilmiştir. Bu öngörüler için MIDAS modelinin ağırlıklandırma fonksiyonlarından Almon, Beta ve üstel Almon polinomları tercih edilmiştir. Bu MIDAS ağırlıklandırma polinomlarının yanı sıra aylık vergi gelirlerinin üçer aylık olarak toplulaştırıldığı vergi gelirleri ile GSYİH büyüme oranı öngörüsü gerçekleştirilmiştir. Çalışmada kullanılan modellerin öngörü performansları kök hata kareleri ortalaması (RMSE), ortalama mutlak hata (MAE) ve Theil U1 deęerleri ile karşılaştırılmıştır. Bu karşılaştırma sonucunda üstel Almon polinomun kullanıldığı MIDAS modelinin dięer modellere göre daha iyi tahmin sonuçları verdiği tespit edilmiştir. Bununla birlikte Beta polinomlu U-MIDAS modeli ve toplulaştırılmış verilerin kullanıldığı EKK yöntemlerinin tahmin performansının pek iyi olmadığı anlaşılmıştır. Söz konusu çalışmada nominal GSYİH verileri kullanıldığı için reel GSYİH'daki büyüme oranı sonuçlarını tam yansıtmamaktadır. Bununla birlikte, aylık frekanslı vergi gelirleri, üçer aylık GSYİH verilerinden daha önce yayınlanmaktadır. Bu bakımdan içinde bulunan döneme ait GSYİH verisi olmazken bu dönem için vergi gelirlerine ait veriler bulunabilmektedir. Ancak çalışmada vergi gelirleri için örneklem dönemin sonu GSYİH ile aynı tutulmuştur. Böylelikle çalışmada MIDAS modeliyle vergi gelirleri için yeni verilerin olması durumunda GSYİH büyüme oranı öngörüsünü iyileştirip iyileştirmediği incelenmemiştir.

Ekinci ve Sakarya (2020), GSYİH'nin bileşenlerinden biri olan özel tüketim harcamalarının aylık tahminine yönelmişlerdir. İlgili deęişkene ait şimdi tahmini için aylık frekanslı gıda dışı perakende satışı, reel vergi geliri ve tüketim malı ithalat miktar endeksinden yararlanılmıştır. Ancak özel tüketim harcamaları üçer aylık frekansta olduğundan dolayı çalışmada yöntem olarak MIDAS modeli tercih edilmiştir. MIDAS modelinin tahmin performansını kıyaslamak için çalışmada yer alan aylık frekanslı deęişkenler, üçer aylık olarak toplulaştırılarak referans modeli kullanılmıştır. Uygulamada 2011Q1 – 2019Q3 döneminden yararlanılarak Kök ortalama kare öngörü hatası'na göre MIDAS modelinin klasik yöntemle göre daha iyi performans gösterdiği belirlenmiştir. Çalışmada ayrıca MIDAS modeline haftalık frekanslı kredi ve faiz deęişkenleri ve günlük frekanslı reel BİST hizmet endeksi deęişkenleri ilave edilmiştir. MIDAS modeline haftalık ve günlük frekanslı deęişkenlerin eklenmesi ile modelin öngörü performansının arttığı anlaşılmıştır. Bu çalışmada yüksek frekanslı deęişkenlerin yeni gözlem deęerlerinden faydalanılarak tüketim harcamalarının şimdi tahmin performansını iyileştirip iyileştirmediği araştırılmamıştır.

ÜÇÜNCÜ BÖLÜM

3. UYGULAMA: GSYİH TAHMİNİ

Çalışmanın bu bölümünde modellerde kullanılan veri seti tanıtılmış ve ardından MIDAS yöntemi ile Türkiye ekonomisinin reel Gayri Safi Yurtiçi Hasıla (GSYİH) büyüme oranının anlık olarak nasıl tahmin edileceği ayrıntılı olarak anlatılmıştır.

3.1. Veri Seti

Türkiye ekonomisine ilişkin üçer aylık frekanslı reel GSYİH büyüme oranının anlık tahmini için aylık frekansa sahip iktisadi değişkenlerden yararlanılmıştır. Aylık frekanslı iktisadi değişkenler sırasıyla reel kesim güven endeksi (GÜV), imalat sanayi kapasite kullanım oranı (KAP), sanayi üretim endeksi (SAN), tüketici fiyat endeksi (TÜFE), üretici fiyat endeksi (ÜFE), reel toplam ihracat (X) ve reel toplam ithalattan (M) oluşmaktadır.

Analizlerde kullanılan GSYİH verisi, Türkiye Cumhuriyet Merkez Bankası Elektronik Veri Dağıtım Sistemi (TCMB-EVDS)'nden zincirlenmiş hacim olarak alınmıştır. Aylık frekanslı değişkenlerden reel toplam ihracat ve ithalat serileri, Türkiye İstatistik Kurumu (TÜİK)'nden temin edilen toplam ihracat ve ithalat verilerinin sırasıyla ihracat ve ithalat birim değer endekslerine oranlanmalarının ardından 100 ile çarpılarak oluşturulmuştur. Çalışmada yer alan diğer aylık frekanslı değişkenler ise TCMB-EVDS'den alınmıştır.

Veri setleri temin edildikten sonra GSYİH verisi mevsimsel etkilerden arındırılmış ve ardından logaritmik 1. devresel farkı alınarak dönemlik GSYİH büyüme oranı hesaplanmıştır. GSYİH'de olduğu gibi çalışmada kullanılan aylık frekanslı açıklayıcı değişkenler de mevsimsel etkilerden arındırılarak logaritmik devresel farkları analizlerde kullanılmıştır.

Analizlerde kullanılan veri setleri 2020 haziran'ın son işlem gününde temin edilmiştir. Bu kapsamda her bir değişken için söz konusu tarihte ulaşılabilen tüm veri seti alınmıştır. Bu nedenle çalışmada yer alan değişkenlerin başlangıç gözlemleri benzer zaman dilimini oluştursa bile bu değişkenlere ait son gözlemler, farklı zaman noktalarını oluşturmaktadır. Söz gelimi GSYİH'ye ait veri seti, 2007'nin ilk çeyreğinden 2020'nin 1. çeyrek dönemine kadar olan dönemi kapsamaktadır. Öte yandan uygulamada kullanılacak olan aylık frekanslı değişkenlerin başlangıç noktaları 2007'nin Ocak ayıdır. Her ne kadar çalışmada kullanılan aylık frekanslı değişkenlerin başlangıç noktaları aynı

zaman dilimine denk gelse de iktisadi deęişkenlerin farklı gecikmelerle ilan edilmelerinden dolayı bu deęişkenlerin son gözlemleri farklı zamanlarda olmaktadır. Aylık frekanslı deęişkenlerin son gözlem deęerleri; Sanayi üretim endeksi, reel toplam ihracat ve reel toplam ithalat için 2020 yılının Nisan ayı, tüketici fiyat endeksi ve üretici fiyat endeksi için 2020'nin Mayıs ayı ve son olarak reel kesim güven endeksi ve imalat sanayi kapasite kullanım oranı için 2020'nin Haziran ayıdır.

Aşağıdaki Tablo 1'de aylık frekanslı deęişkenlere ait tanımlayıcı istatistikler sunulmuştur. Bahsi geçen tabloda aylık frekanslı deęişkenlerde reel toplam ihracat ve ithalat deęişkenleri hariç en yüksek ortalamanın 247.59 deęeriyle TÜFE deęişkenine ait olduęu gözlemlenmektedir. TÜFE deęişkenini 245.80 ortalama deęeriyle ÜFE deęişkeni, 103.04 ortalama deęeriyle de reel kesim güven endeksi takip etmektedir. En düşük ortalama deęerinin ise 76.04 ile kapasite kullanım oranına ait olduęu görülmektedir. Reel toplam ihracat ve ithalat deęişkenleri dışında ÜFE'nin 95.61 deęeriyle en yüksek standart sapmaya sahip olduęu ilgili tabloda göze çarpmaktadır. ÜFE'yi 88.32 standart sapmayla TÜFE deęişkeni, 19.63 standart sapmayla da sanayi üretim endeksi izlemektedir. Söz konusu tabloda ÜFE ve TÜFE deęişkenlerinin en yüksek deęerleri sırasıyla 482.02 ve 460.62 oldukları görülmektedir. Ancak reel kesim güven endeksi, kapasite kullanım oranı ve sanayi üretim endeksi deęişkenlerinin bu denli yüksek deęerler almadıkları ilgili tablodan anlaşılmaktadır. Söz konusu tablo en düşük deęerler açısından incelendiğinde TÜFE ve ÜFE'nin sırasıyla 135.84 ve 135.09 minimum deęerlerine sahip olduęu görülmektedir. Öte yandan reel kesim güven endeksi, kapasite kullanım oranı ve sanayi üretim endeksi deęişkenlerinin minimum deęerleri daha az olduęu bahsi geçen tabloda görülmektedir. İlgili tabloda Türkiye ekonomisinin dış ticaret açığı vermesinden dolayı reel toplam ithalatın, reel toplam ihracattan daha yüksek bir ortalama deęere sahip olduęu anlaşılmaktadır. Reel toplam ihracat, 26.2 milyar TL ile en yüksek deęerini ve 10.6 milyar TL ile de en düşük deęerini almaktadır. Reel toplam ithalatta ise en yüksek ve en düşük deęerler sırasıyla 37.7 milyar TL ve 15 Milyar TL olarak gerçekteleşmiştir. Tablo 1'de ayrıca reel toplam ihracat ve ithalatın standart sapmalarının sırasıyla 3.6 milyar TL ve 4.6 milyar TL olduęu göze çarpmaktadır.

Tablo 1: Aylık Frekanslı Deęişkenlerin Tanımlayıcı İstatistikleri

	Ortalama	Maksimum	Minimum	Standart Sapma
GÜV	103.04	121.00	52.60	11.19
KAP	76.04	84.10	60.80	4.25
TÜFE	247.59	460.62	135.84	88.32
ÜFE	245.80	482.02	135.09	95.61
SAN	89.38	129.99	50.45	19.63
X	17.6 (Milyar TL)	26.2 (Milyar TL)	10.6 (Milyar TL)	3.6 (Milyar TL)
M	26.8 (Milyar TL)	37.7 (Milyar TL)	15 (Milyar TL)	4.6 (Milyar TL)

Not: GÜV; reel kesim güven endeksini, KAP; imalat sanayi kapasite kullanım oranını, TÜFE; tüketici fiyat endeksini, ÜFE; üretici fiyat endeksini, SAN; sanayi üretim endeksini, X; reel toplam ihracatı ve M; reel toplam ithalatı temsil etmektedir.

Uygulamada MIDAS modelinin tahmin performansını kıyaslayabilmek için aylık frekanslı değişkenlerin üçer aylık frekanslarda toplulaştırılmış halleri de yukarıda bahsedilen veri kaynaklarından temin edilmiştir. İlgili değişkenlerin üçer aylık frekans dönemleri 2007'nin ilk çeyreğinden başlamaktadır. Bu değişkenlerin son gözlem değerleri ise reel kesim güven endeksi ve imalat sanayi kapasite kullanım oranı değişkenleri için 2020'nin 2. çeyreği, diğer toplulaştırılmış değişkenler için ise 2020'nin ilk çeyreği olmaktadır. Hem GSYİH hem de üçer aylık olarak toplulaştırılmış değişkenlerin tanımlayıcı istatistikleri aşağıdaki Tablo 2'de yer almaktadır. Bahsi geçen tabloda reel toplam ihracat ve ithalat değişkenlerinin dışındaki diğer toplulaştırılmış değişkenlerin tanımlayıcı istatistiklerinin orijinal frekanslarındaki tanımlayıcı istatistik değerleriyle hemen hemen aynı değerleri aldıkları gözden kaçmamaktadır. Bunun nedeni söz konusu değişkenler toplulaştırılırken üçer aylık dönem içerisindeki ortalama değerlerinin alınmasından dolayı olduğu belirtilebilir. Öte yandan reel toplam ihracat ve ithalat değişkenleri, üçer aylık dönem içerisindeki değerleri toplanmak suretiyle toplulaştırılmışlardır.

Bahsi geçen tabloda aylık frekanslı değişkenlerin toplulaştırılmasıyla oluşturulan üçer aylık frekanslı değişkenlerde GSYİH, reel toplam ihracat ve ithalat değişkenleri hariç en yüksek ortalamanın 244.95 ile TÜFE değişkenine ait olduğu anlaşılmaktadır. TÜFE değişkenini 242.88 ortalama değeriyle ÜFE değişkeni, 103.04 ortalama değeriyle de reel kesim güven endeksi takip etmektedir. En düşük ortalama değeri ise 76.04 ile kapasite kullanım oranına aittir. GSYİH, reel toplam ihracat ve ithalat değişkenleri dışında ÜFE'nin 93.01 ile en yüksek standart sapmaya sahip olduğu ilgili tabloda göze çarpmaktadır. ÜFE değişkenini 86.15 standart sapmayla TÜFE değişkeni, 19.21 standart sapmayla da sanayi üretim endeksi izlemektedir. En düşük standart sapma ise 4.15 ile kapasite kullanım oranındadır. Bahsi geçen tabloda ÜFE ve TÜFE değişkenlerinin sırasıyla 448.35 ve 465.25 değerleriyle en yüksek değerlere sahip oldukları görülmektedir. Ancak reel kesim güven endeksi, kapasite kullanım oranı ve sanayi üretim endeksi değişkenlerinde bu kadar yüksek değerlerin olmadığı Tablo 2'den anlaşılmaktadır. İlgili tablo en düşük değerler açısından incelendiğinde TÜFE ve ÜFE'nin sırasıyla 136.64 ve 136.38 minimum değerlerine sahip olduğu görülmektedir. Öte yandan reel kesim güven endeksi, kapasite kullanım oranı ve sanayi üretim endeksi değişkenlerinin minimum değerlerinin daha da düşük olduğu bahsi geçen tabloda görülmektedir.

İlgili tabloda orijinal frekanslarda (aylık frekans) olduğu gibi reel toplam ithalatın ortalama değerinin, reel toplam ihracatın ortalama değerinden daha büyük olduğu anlaşılmaktadır. Reel toplam ithalat ve ihracatın ortalama değerleri sırasıyla 80.4 milyar TL ve 53.1 milyar TL'dir. GSYİH'nin ortalama değeri ise ele alınan dönem içerisinde 342 milyar TL olarak gerçekleşmiştir. Bahsi geçen tabloda GSYİH'nin 478 milyar TL ile en yüksek değere sahip olduğu 214 milyar TL ile de en düşük değere sahip olduğu gözden kaçmamaktadır. Reel toplam ihracatta ise en yüksek ve en düşük değerler sırasıyla 75.8 milyar TL ve 37.2 Milyar TL olarak gerçekleşmiştir. Öte yandan reel toplam ithalatta en yüksek ve en düşük değerler sırasıyla 107 milyar TL ve 47.7 Milyar TL olmuştur.

Standart sapma açısından GSYİH, reel toplam ihracat ve ithalatın sırasıyla 73 milyar TL, 3.6 milyar TL ve 4.6 milyar TL değerlerini aldıkları Tablo 2’den anlaşılmaktadır.

Tablo 2 : Üçer Aylık Olarak Toplulaştırılmış Değişkenlerin ve GSYİH'ya İlişkin Tanımlayıcı İstatistikler

	Ortalama	Maksimum	Minimum	Standart Sapma
GÜV	103.04	116.73	58.73	10.79
KAP	76.04	82.93	61.87	4.15
TÜFE	244.95	448.35	136.64	86.15
ÜFE	242.88	465.25	136.38	93.01
SAN	89.46	126.84	53.29	19.21
X	53.1 (Milyar TL)	75.8 (Milyar TL)	37.2 (Milyar TL)	10.2 (Milyar TL)
M	80.4 (Milyar TL)	107 (Milyar TL)	47.7 (Milyar TL)	12.9 (Milyar TL)
GSYİH	342 (Milyar TL)	478 (Milyar TL)	214 (Milyar TL)	73 (Milyar TL)

Not: GÜV; reel kesim güven endeksini, KAP; imalat sanayi kapasite kullanım oranını, TÜFE; tüketici fiyat endeksini, ÜFE; üretici fiyat endeksini, SAN; sanayi üretim endeksini, X; reel toplam ihracatı ve M; reel toplam ithalattı temsil etmektedir.

3.2. Birim Kök Test Sonuçları

Modele dahil edilen değişkenlerin seviye değerlerinde durağan olmamaları durumunda sahte regresyon durumuyla karşılaşılabilir. Bu nedenle GSYİH'nin anlık tahmini gerçekleştirilmeden önce değişkenlerin seviye değerlerinde durağan olup olmadıkları birim kök testleriyle incelenmiştir. Eğer Uygulamada 2015 1. çeyrek – 2020 2. çeyrek dönemleri arasında GSYİH'nin anlık tahmini gerçekleştirileceği için çalışmada yer alan bütün değişkenlerin bu tarihler arasındaki durağan oldukları seviyeler araştırılmıştır. Her ne kadar değişkenlerin 5-6 yıllık birim kökleri analiz edilmiş olsa da burada sadece 2020'nin Haziran ayı ve 2. çeyrek dönemdeki birim kök test sonuçları sunulmuştur. Daha önceki dönemdeki birim kök test sonuçları Tez'in ek kısmında yer almaktadır.

Aşağıdaki Tablo 3'te 2020 Haziran ayında ulaşılabilen gözlem değerleriyle aylık frekanslı değişkenlerin Genişletilmiş Dickey Fuller (ADF), Philips Perron (PP) ve Kwiatkowski Phillips Schmidt Shin (KPSS) birim kök test sonuçları yer almaktadır. Söz konusu tabloda ADF birim kök testinin optimal gecikme uzunluğu Schwarz bilgi kriteri (SIC) ile belirlenmiştir. Tablo incelendiğinde ADF ve PP birim kök testlerinin hem sabitli hem de sabitli ve trendli modellerinde tüm aylık frekanslı değişkenlerin logaritmik 1. devresel farkında durağan oldukları anlaşılmaktadır. KPSS birim kök testinde ise %10 anlamlılıkla aylık frekanslı değişkenlerin her birinin, seviye değerlerinde durağan oldukları ilgili tabloda görülmektedir.

Tablo 3: Aylık Frekanslı Değişkenleri İçin Birim Kök Test Sonuçları

	ADF		PP		KPSS	
	Sabitli	Sabitli ve Trendli	Sabitli	Sabitli ve Trendli	Sabitli	Sabitli ve Trendli
$\Delta LGÜV$	-9.09*** (1)	-9.05*** (1)	-10.03*** [6]	-9.98*** [6]	0.04* [3]	0.04* [3]
$\Delta LKAP$	-11.72*** (0)	-11.69*** (0)	-11.69*** [2]	-11.66*** [2]	0.11* [3]	0.1* [3]
$\Delta LTÜFE$	-9.33*** (0)	-9.16*** (1)	-9.39*** [1]	-9.46*** [5]	0.6* [4]	0.14* [0]
$\Delta LÜFE$	-7.55*** (0)	-7.66*** (0)	-7.52*** [2]	-7.78*** [1]	0.36* [5]	0.07* [5]
$\Delta LSAN$	-23.92*** (0)	-23.9*** (0)	-25.24*** [4]	-25.17*** [4]	0.22* [7]	0.13* [7]
ΔLX	-25.14*** (0)	-25.18*** (0)	-28.77*** [7]	-28.82*** [7]	0.15* [2]	0.06* [2]
ΔLM	-20.74*** (0)	-20.72*** (0)	-21*** [3]	-20.98*** [3]	0.05* [0]	0.02* [0]

Not: ***, ** ve * sırasıyla %1, %5 ve %10 anlamlılık düzeylerinde serilerin durağan olduklarını ifade eder. ΔL , ilgili değişkenin logaritmik 1. devresel farkının alındığını belirtmektedir. ADF birim kök testi sonucundaki (), optimal gecikme uzunluklarını; PP ve KPSS birim kök test sonuçlarındaki [] ise bant genişliğini, GÜV; reel kesim güven endeksini, KAP; imalat sanayi kapasite kullanım oranını, TÜFE; tüketici fiyat endeksini, ÜFE; üretici fiyat endeksini, SAN; sanayi üretim endeksini, X; reel toplam ihracatı ve M; reel toplam ithalatı temsil etmektedir.

Çalışmada MIDAS modelinin anlık tahmin performansı, toplulaştırılmış değişkenlerin öngörü performansı ile karşılaştırılacaktır. Bu nedenle üçer aylık GSYİH değişkeninin durağanlığının yanı sıra aylık frekanslı değişkenlerin üçer aylık olarak toplulaştırılmış hallerinin de durağanlıkları incelenmiştir. Bahsi geçen incelemede aylık frekanslı değişkenlerde olduğu gibi ADF, PP ve KPSS birim kök testlerinden yararlanılmıştır. 2020'nin 2. çeyrek döneminde ulaşılabilen veri seti ile gerçekleştirilen birim kök test sonuçları Tablo 4'te özetlenmiştir. Söz konusu tabloya bakıldığında aylık frekanslı değişkenlerin birim kök test sonuçlarında olduğu gibi ADF ve PP birim kök testlerinin tüm değişkenlerin en az %10 anlamlılıkla logaritmik 1. devresel farklarında durağan oldukları anlaşılmaktadır. Diğer taraftan söz konusu değişkenler KPSS'nin sabitli ve sabitli ve trendli modellerinde en az %10 anlamlılıkla logaritmik 1. devresel farklarında durağan çıkmışlardır.

Tablo 4: Üçer Aylık Frekanslı Değişkenler için Birim Kök Test Sonuçları

	ADF		PP		KPSS	
	Sabitli	Sabitli ve Trendli	Sabitli	Sabitli ve Trendli	Sabitli	Sabitli ve Trendli
Δ LSYİH	-6.96*** (0)	-6.88*** (0)	-6.96*** [1]	-6.88*** [1]	0.13* [1]	0.12* [1]
Δ LGÜV	-4.94*** (0)	-4.87*** (0)	-4.77*** [3]	-4.69*** [3]	0.09* [3]	0.08* [3]
Δ LKAP	-3.13** (0)	-2.98 (0)	-3.13** [0]	-2.98 [0]	0.14* [1]	0.13* [1]
Δ TÜFE	-4.72*** (0)	-5.24*** (0)	-4.72*** [0]	-5.12*** [4]	0.51* [3]	0.16* [0]
Δ LÜFE	-4.79*** (0)	-4.95*** (0)	-4.79*** [2]	-4.97*** [1]	0.28* [3]	0.08* [2]
Δ LSAN	-6.39*** (0)	-6.32*** (0)	-6.41*** [3]	-6.35*** [3]	0.08* [2]	0.08* [2]
Δ LX	-10.29*** (0)	-10.19*** (0)	-10.73*** [5]	-10.61*** [5]	0.09* [9]	0.08* [8]
Δ LM	-5.15*** (0)	-5.1*** (0)	-5.13*** [3]	-5.08*** [3]	0.05* [1]	0.04* [1]

Not: ***, ** ve * sırasıyla %1, %5 ve %10 anlamlılık düzeylerinde serilerin durağan olduklarını ifade eder. Δ L, ilgili değişkenin logaritmik 1. devresel farkının alındığını belirtmektedir. ADF birim kök testi sonucundaki (), optimal gecikme uzunluklarını; PP ve KPSS birim kök test sonuçlarındaki [] ise bant genişliğini, GÜV; reel kesim güven endeksini, KAP; imalat sanayi kapasite kullanım oranını, TÜFE; tüketici fiyat endeksini, ÜFE; üretici fiyat endeksini, SAN; sanayi üretim endeksini, X; reel toplam ihracatı ve M; reel toplam ithalatı temsil etmektedir.

3.3. GSYİH Büyüme Oranının Anlık Tahmini için Model Kurulumu

Daha önce de değinildiği gibi iktisadi değişkenler zamansal olarak farklı gecikmelerle yayınlanmaktadır. Bu gecikmelerden dolayı her bir iktisadi değişkenin son gözlemi aynı döneme denk gelmemektedir. Bu çalışmada kullanılan değişkenlerin ise birbirinden farklı yayın gecikmeleri bulunmaktadır. Örneğin GSYİH için t çeyrek dönemine ait gözlem değeri, $t + 1$ çeyrek döneminin 2. veya 3. ayının son resmi gününde açıklanmaktadır. Diğer taraftan çalışmada kullanılan aylık frekanslı değişkenlerin t çeyrek dönemindeki 1. ayına ait gözlem değerleri, reel kesim güven endeksi ve kapasite kullanım oranı için ilgili ayın son günlerinde; tüketici ve üretici fiyat endeksleri için bir sonraki ayın 3. gününde; sanayi üretim endeksi için t çeyrek döneminin 3. ayının ortalarında; toplam ihracat ve ithalat miktarları için izleyen ayın son resmi gününde ve son olarak ihracat ve ithalat birim değer endeksleri için ise t çeyrek döneminin 3. ayının son resmi gününde açıklanmaktadır. İhracat ve ithalat birim endekslerinin, toplam ihracat ve ithalat'tan daha sonra açıklanmasından dolayı reel toplam ihracat ve ithalat t çeyrek döneminin 1. aya ait gözlem değerleri, t çeyrek döneminin 3. ayının son resmi gününde hesaplanabilmektedir.⁸

Yukarıda bahsedilen yayın gecikmelerinden ötürü GSYİH büyüme oranının anlık tahmini için kullanılacak yüksek frekanslı değişkenlere ait ulaşılabilir son gözlem değerleri farklılık

⁸ <http://www3.tcmb.gov.tr/veriyaytakvim/takvim.php> ve <http://www.tuik.gov.tr/takvim/tkvim.zul>

gösterecektir. Örneğin t çeyrek döneminin 1. ayının ilk gününde GSYİH büyüme oranının anlık tahmini için GSYİH'ye ilişkin en son gözlem, $t - 2$ çeyrek dönemine ait olacaktır. Aylık frekanslı değişkenlerde ise son gözlem, reel kesim güven endeksi ve kapasite kullanım oranı için $t - 1$ çeyrek dönemindeki 3. aya ait gözlem değeri; üretici ve tüketici fiyat endeksleri için $t - 1$ çeyrek dönemin 2. ayına ait gözlem değerleri; sanayi üretim endeksi ve reel toplam ihracat ve ithalat için $t - 1$ çeyrek dönemin 1. ayına ait gözlem değerleri olacaktır. Söz konusu dönemde ay sonuna doğru yaklaşıırken aylık frekanslı değişkenlere ait yeni gözlem değerleri yayınlanacak ve bir sonraki ayda yani, t çeyrek döneminin 2. ayının ilk gününde ise GSYİH büyüme oranının anlık tahmininde aylık frekanslı değişkenler için birer yeni gözlem elde edilmiş olunacaktır. Son olarak t çeyrek döneminin 3. ayının ilk gününde ise GSYİH büyüme oranı öngörüsü için aylık frekanslı değişkenlerin yeni gözlemlerinin yanı sıra GSYİH içinde $t - 1$ çeyrek dönem verisi yayınlanmış olacaktır.

Aşağıdaki alt bölümlerde aylık frekanslı değişkenlerle GSYİH büyüme oranının anlık tahminin nasıl gerçekleştirildiği anlatılmıştır. Söz konusu bu anlık tahminler, 2015'in 1. çeyrek döneminden başlanılarak her bir çeyrek dönem için ayrı ayrı gerçekleştirilerek 2020'nin 2. çeyrek dönemine kadar sürdürülmüştür. Her bir dönemde anlık tahminler gerçekleştirilirken hem GSYİH hem de analizlerde yer alan aylık frekanslı tüm değişkenler o tarihte ulaşılabilir gözlem değerleriyle mevsimsellikten arındırılmışlardır. Ardından mevsimsellikten arındırılan değişkenler doğal logaritmik dönüşeme tabi tutularak 1. devresel farkları alınmıştır.

Analizlerde kurulmuş olan her bir model, MIDAS yaklaşımı altında tahmin edilmiştir. MIDAS modellerinde yüksek frekanslı değişkenlerin ağırlıklandırılmasında geleneksel Almon polinomu, üstel Almon polinomu, Beta, kısıtsız MIDAS (U-MIDAS) ve basamak ağırlıklı MIDAS yöntemleri ayrı ayrı uygulanmıştır. Bu yöntemlerden geleneksel Almon polinomu, kısıtsız MIDAS (U-MIDAS) ve basamak ağırlıklı MIDAS yöntemlerinde yüksek frekanslı değişkenler için maksimum gecikme uzunluğu, yüksek frekansta 12 dönem belirlenerek optimal gecikme uzunlukları Schwarz bilgi kriteri ile tespit edilmiştir. Üstel Almon polinomu ve Beta yöntemleri için herhangi bir maksimum gecikme uzunluğu belirlenmemiştir. Söz konusu yöntemlerde aylık frekanslı değişkenler için 3 aylık gecikme kullanılmıştır.

Çalışmada her bir aylık frekanslı değişken ayrı ayrı kullanılarak GSYİH büyüme oranının anlık tahmini gerçekleştirilmiştir. Öncelikle 2015 yılının Ocak ayının son gününde bulunduğu varsayılarak GSYİH'nin 2015 1. çeyrek büyüme oranının anlık tahmini yapılmıştır. Bu dönem için gerçekleştirilen öngörülerde değişkenlerin başlangıç gözlemleri GSYİH için 2007'nin ilk çeyreği, aylık frekanslı değişkenler için ise 2007 yılının ilk ayı olmak koşuluyla 2015 yılı Ocak ayında ulaşılabilen tüm veri setinden yararlanılmıştır.

$$\Delta LGSYİH_{2015:1|2014:3} = \beta_0 + \beta_1 W \left(L^{\frac{1}{3}}; \theta \right) \Delta LGUV_{2015:1/3|2014:7/3}^{(3)} + u_{2015:1|2014:3} \quad (92)$$

$$\Delta LGSY\dot{I}H_{2015:1|2014:3} = \beta_0 + \beta_1 W\left(L^{\frac{1}{3}}; \theta\right) \Delta LKAP_{2015:1/3|2014:7/3}^{(3)} + u_{2015:1|2014:3} \quad (93)$$

$$\Delta LGSY\dot{I}H_{2015:1|2014:3} = \beta_0 + \beta_1 W\left(L^{\frac{1}{3}}; \theta\right) \Delta LTUFE_{2015:1/3|2014:2}^{(3)} + u_{2015:1|2014:3} \quad (94)$$

$$\Delta LGSY\dot{I}H_{2015:1|2014:3} = \beta_0 + \beta_1 W\left(L^{\frac{1}{3}}; \theta\right) \Delta LUFEE_{2015:1/3|2014:2}^{(3)} + u_{2015:1|2014:3} \quad (95)$$

$$\Delta LGSY\dot{I}H_{2015:1|2014:3} = \beta_0 + \beta_1 W\left(L^{\frac{1}{3}}; \theta\right) \Delta LSAN_{2015:1/3|2014:5/3}^{(3)} + u_{2015:1|2014:3} \quad (96)$$

$$\Delta LGSY\dot{I}H_{2015:1|2014:3} = \beta_0 + \beta_1 W\left(L^{\frac{1}{3}}; \theta\right) \Delta LX_{2015:1/3|2014:5/3}^{(3)} + u_{2015:1|2014:3} \quad (97)$$

$$\Delta LGSY\dot{I}H_{2015:1|2014:3} = \beta_0 + \beta_1 W\left(L^{\frac{1}{3}}; \theta\right) \Delta LM_{2015:1/3|2014:5/3}^{(3)} + u_{2015:1|2014:3} \quad (98)$$

Yukarıdaki (92) – (98) numaralı MIDAS modellerinde her bir aylık frekanslı değişken ile GSYİH'nin 2015 1. çeyrek büyüme oranı öngörülmektedir. Söz konusu modellerde $W\left(L^{\frac{1}{3}}; \theta\right)$; ilgili yüksek frekanslı değişkenin ağırlıklandırma fonksiyonunu, ΔL ; değişkenlerin logaritmik devresel farkının alındığını ve $\Delta LGSY\dot{I}H_{2015:1|2014:3}$; 2015 yılının 1. çeyreğinde GSYİH için son gözlem olarak 2014'ün 3. çeyrek verisinin kullanıldığını ifade etmektedir. Modellerdeki aylık frekanslı değişkenlerin alt imlerindeki bilgiler, 2015'in Ocak ayında reel kesim güven endeksi ve kapasite kullanım oranı 2014'ün Temmuz ayına ait veriler; tüketici ve üretici fiyat endeksleri için 2014'ün Haziran ayına ait veriler ve sanayi üretim endeksi ve reel toplam ihracat ve ithalat için 2014'ün Mayıs ayına ait veriler son gözlem olarak ele alınmıştır. Bahsi geçen bu modellerde yüksek frekanslı değişkenlerin her biri geleneksel Almon polinomu, üstel Almon polinomu, Beta, kısıtsız MIDAS (U-MIDAS) ve basamak ağırlıklı MIDAS ile ağırlıklandırılarak parametre tahminleri yapılmıştır. Daha sonra ilgili modellerin tahmin edilen parametreleriyle GSYİH'nin 2015'in ilk çeyrek döneminin aylık tahmini aşağıdaki denklemler vasıtasıyla gerçekleştirilebilir.

$$\Delta \widehat{LGSY\dot{I}H}_{2015:1} = \hat{\beta}_0 + \hat{\beta}_1 W\left(L^{\frac{1}{3}}; \hat{\theta}\right) \Delta LGUV_{2015:1/3|2015:1/3}^{(3)} \quad (99)$$

$$\Delta \widehat{LGSY\dot{I}H}_{2015:1} = \hat{\beta}_0 + \hat{\beta}_1 W\left(L^{\frac{1}{3}}; \hat{\theta}\right) \Delta LKAP_{2015:1/3|2015:1/3}^{(3)} \quad (100)$$

$$\Delta \widehat{LGSY\dot{I}H}_{2015:1} = \hat{\beta}_0 + \hat{\beta}_1 W\left(L^{\frac{1}{3}}; \hat{\theta}\right) \Delta LTUFE_{2015:1/3|2014:4}^{(3)} \quad (101)$$

$$\Delta \widehat{LGSY\dot{I}H}_{2015:1} = \hat{\beta}_0 + \hat{\beta}_1 W \left(L^{\frac{1}{3}}; \hat{\theta} \right) \Delta LUF E_{2015:1/3|2014:4}^{(3)} \quad (102)$$

$$\Delta \widehat{LGSY\dot{I}H}_{2015:1} = \hat{\beta}_0 + \hat{\beta}_1 W \left(L^{\frac{1}{3}}; \hat{\theta} \right) \Delta L S A N_{2015:1/3|2014:11/3}^{(3)} \quad (103)$$

$$\Delta \widehat{LGSY\dot{I}H}_{2015:1} = \hat{\beta}_0 + \hat{\beta}_1 W \left(L^{\frac{1}{3}}; \hat{\theta} \right) \Delta L X_{2015:1/3|2014:11/3}^{(3)} \quad (104)$$

$$\Delta \widehat{LGSY\dot{I}H}_{2015:1} = \hat{\beta}_0 + \hat{\beta}_1 W \left(L^{\frac{1}{3}}; \hat{\theta} \right) \Delta L M_{2015:1/3|2014:11/3}^{(3)} \quad (105)$$

Yukarıdaki (99) – (105) numaralı denklemler ile GSYİH'nin 2015 1. çeyrek büyüme oranının anlık tahmini hesaplanmıştır. Söz konusu hesaplamalarda aylık frekanslı değişkenler için 2015'in Ocak ayında ulaşılabilen tüm veri seti kullanılmaktadır. Aylık frekanslı değişkenlerin bu dönemde ulaşılabilen en son gözlem değerleri şu şekildedir: Reel kesim güven endeksi ve kapasite kullanım oranı için 2015'in Ocak ayı, tüketici ve üretici fiyat endeksleri için 2014'ün Aralık ayı ve sanayi üretim endeksi ve reel toplam ihracat ve ithalat için 2014'ün Kasım ayıdır.

Söz konusu bu anlık tahminlerden sonra şimdi 2015'in Şubat ayının son gününde bulunduğu varsayılarak GSYİH 2015'in 1. çeyrek büyüme oranının anlık tahmini tekrarlanmıştır. Çeyrek dönemin 2. ayında gerçekleştirilen bu anlık tahminlerde GSYİH için yeni veri yayınlanmazken; aylık frekanslı değişkenlerin her biri için yeni gözlem değerleri yayınlanmıştır. Aylık frekanslı değişkenlerdeki yeni bilgilerden faydalanmak için yukarıdaki (92) - (98) numaralı MIDAS modeller yeniden düzenlenerek aşağıdaki (106) – (112) numaralı MIDAS modellerine ulaşılır. Bu yeni oluşturulan modellerde 2015'in Şubat ayında aylık frekanslı değişkenlerin en son gözlem değerleri olarak reel kesim güven endeksi ve kapasite kullanım oranı için 2014 Ağustos ayı, tüketici ve üretici fiyat endeksleri için 2014 Temmuz ayı ve sanayi üretim endeksi ve reel toplam ihracat ve ithalat için 2014 Haziran ayı verileri kullanılmıştır.

$$\Delta LGSY\dot{I}H_{2015:1|2014:3} = \beta_0 + \beta_1 W \left(L^{\frac{1}{3}}; \theta \right) \Delta L G U V_{2015:2/3|2014:8/3}^{(3)} + u_{2015:1|2014:3} \quad (106)$$

$$\Delta LGSY\dot{I}H_{2015:1|2014:3} = \beta_0 + \beta_1 W \left(L^{\frac{1}{3}}; \theta \right) \Delta L K A P_{2015:2/3|2014:8/3}^{(3)} + u_{2015:1|2014:3} \quad (107)$$

$$\Delta LGSY\dot{I}H_{2015:1|2014:3} = \beta_0 + \beta_1 W \left(L^{\frac{1}{3}}; \theta \right) \Delta L T U F E_{2015:2/3|2014:7/3}^{(3)} + u_{2015:1|2014:3} \quad (108)$$

$$\Delta LGSY\dot{I}H_{2015:1|2014:3} = \beta_0 + \beta_1 W \left(L^{\frac{1}{3}}; \theta \right) \Delta L U F E_{2015:2/3|2014:7/3}^{(3)} + u_{2015:1|2014:3} \quad (109)$$

$$\Delta LGSY\dot{I}H_{2015:1|2014:3} = \beta_0 + \beta_1 W\left(L^{\frac{1}{3}}; \theta\right) \Delta LSAN_{2015:2/3|2014:2}^{(3)} + u_{2015:1|2014:3} \quad (110)$$

$$\Delta LGSY\dot{I}H_{2015:1|2014:3} = \beta_0 + \beta_1 W\left(L^{\frac{1}{3}}; \theta\right) \Delta LX_{2015:2/3|2014:2}^{(3)} + u_{2015:1|2014:3} \quad (111)$$

$$\Delta LGSY\dot{I}H_{2015:1|2014:3} = \beta_0 + \beta_1 W\left(L^{\frac{1}{3}}; \theta\right) \Delta LM_{2015:2/3|2014:2}^{(3)} + u_{2015:1|2014:3} \quad (112)$$

Yukarıdaki (106) – (112) numaralı MIDAS modellerinde $W\left(L^{\frac{1}{3}}; \theta\right)$; ilgili yüksek frekanslı değişkenin ağırlıklandırma fonksiyonu, ΔL ; değişkenlerin logaritmik devresel farkının alındığını ve $\Delta LGSY\dot{I}H_{2015:1|2014:3}$; 2015 yılının 1. çeyreğinde GSYİH için son gözlem olarak 2014'ün 3. çeyrek verisinin kullanıldığı anlamına gelmektedir. Söz konusu U-MIDAS modellerinin tahmin edilmiş parametreleriyle GSYİH'nin 2015 yılı 1. çeyrek büyüme oranının anlık tahminleri hesaplanabilir. Bu anlık tahminlerde aşağıdaki (113) – (119) numaralı denklemlerden yararlanılmıştır. GSYİH'nin 2015 1. çeyrek büyüme oranı anlık tahmini yapılırken aylık frekanslı değişkenlerin 2015 Şubat ayında ulaşılabilen tüm veri setinden yararlanılmaktadır. Söz konusu dönemde aylık frekanslı değişkenlerin ulaşılabilir olduğu son gözlem değerleri şu şekildedir: reel kesim güven endeksi ve kapasite kullanım oranı için 2015'in Şubat ayı, tüketici ve üretici fiyat endeksleri için 2015'in Ocak ayı ve sanayi üretim endeksi ve reel toplam ihracat ve ithalat için 2014'ün Aralık ayıdır. İlgili modellerde 2015'in ilk ayında olduğu gibi yüksek frekanslı değişkenlerin her biri geleneksel Almon polinomu, üstel Almon polinomu, Beta, kısıtsız MIDAS (U-MIDAS) ve basamak ağırlıklı MIDAS ile ayrı ayrı ağırlıklandırılarak parametre tahminleri gerçekleştirilmiştir. Daha sonra ilgili modellerin tahmin edilmiş olan parametreleriyle GSYİH'nin 2015'in ilk çeyrek döneminin anlık tahmini aşağıdaki denklemler ile yapılmıştır.

$$\Delta \widehat{LGSY\dot{I}H}_{2015:1} = \hat{\beta}_0 + \hat{\beta}_1 W\left(L^{\frac{1}{3}}; \hat{\theta}\right) \Delta LGUV_{2015:2/3|2015:2/3}^{(3)} \quad (113)$$

$$\Delta \widehat{LGSY\dot{I}H}_{2015:1} = \hat{\beta}_0 + \hat{\beta}_1 W\left(L^{\frac{1}{3}}; \hat{\theta}\right) \Delta LKAP_{2015:2/3|2015:2/3}^{(3)} \quad (114)$$

$$\Delta \widehat{LGSY\dot{I}H}_{2015:1} = \hat{\beta}_0 + \hat{\beta}_1 W\left(L^{\frac{1}{3}}; \hat{\theta}\right) \Delta LTUFE_{2015:2/3|2015:1/3}^{(3)} \quad (115)$$

$$\Delta \widehat{LGSY\dot{I}H}_{2015:1} = \hat{\beta}_0 + \hat{\beta}_1 W\left(L^{\frac{1}{3}}; \hat{\theta}\right) \Delta LUFE_{2015:2/3|2015:1/3}^{(3)} \quad (116)$$

$$\Delta \widehat{LGSY\dot{I}H}_{2015:1} = \hat{\beta}_0 + \hat{\beta}_1 W\left(L^{\frac{1}{3}}; \hat{\theta}\right) \Delta LSAN_{2015:2/3|2014:4}^{(3)} \quad (117)$$

$$\Delta \widehat{LGSY\dot{I}H}_{2015:1} = \hat{\beta}_0 + \hat{\beta}_1 W\left(L^{\frac{1}{3}}; \hat{\theta}\right) \Delta LX_{2015:2/3|2014:4}^{(3)} \quad (118)$$

$$\Delta \widehat{LGSY\dot{I}H}_{2015:1} = \hat{\beta}_0 + \hat{\beta}_1 W\left(L^{\frac{1}{3}}; \hat{\theta}\right) \Delta LM_{2015:2/3|2014:4}^{(3)} \quad (119)$$

Şubat ayında gerçekleştirilen anlık tahminlerin ardından bu kez 2015'in Mart ayının son gününde bulunulduğu varsayılarak GSYİH'nin 2015 1. çeyrek büyüme oranının anlık tahmini son kez tekrarlanacaktır. Bu son anlık tahminlerde aşağıdaki (120) – (126) numaralı MIDAS modellerinden yararlanılmıştır. İlgili çeyrek dönemin son ayında gerçekleştirilen bu anlık tahminlerde GSYİH için 2014'ün son çeyrek verisi yayınlanmıştır. Bu sebeple aşağıdaki modellerde $\Delta LGSY\dot{I}H_{2015:1|2014:4}$; 2015'in ilk çeyreğinde GSYİH için 2014'ün son çeyrek verisinin kullanıldığını ifade etmektedir. GSYİH'deki yeni gözlemin yanı sıra aylık frekanslı değişkenlerde de yeni gözlemler yayınlanmıştır. Aylık frekanslı değişkenlerin kullanılan son gözlem değerleri şu şekildedir: Reel kesim güven endeksi ve kapasite kullanım oranı için 2014 Aralık ayı, tüketici ve üretici fiyat endeksleri için 2014 Kasım ayı ve sanayi üretim endeksi ve reel toplam ihracat ve ithalat için 2014 Ekim ayıdır.

$$\Delta LGSY\dot{I}H_{2015:1|2014:4} = \beta_0 + \beta_1 W\left(L^{\frac{1}{3}}; \theta\right) \Delta LGUV_{2015:1|2014:4}^{(3)} + u_{2015:1|2014:4} \quad (120)$$

$$\Delta LGSY\dot{I}H_{2015:1|2014:4} = \beta_0 + \beta_1 W\left(L^{\frac{1}{3}}; \theta\right) \Delta LKAP_{2015:1|2014:4}^{(3)} + u_{2015:1|2014:4} \quad (121)$$

$$\Delta LGSY\dot{I}H_{2015:1|2014:4} = \beta_0 + \beta_1 W\left(L^{\frac{1}{3}}; \theta\right) \Delta LTUFE_{2015:1|2014:11/3}^{(3)} + u_{2015:1|2014:4} \quad (122)$$

$$\Delta LGSY\dot{I}H_{2015:1|2014:4} = \beta_0 + \beta_1 W\left(L^{\frac{1}{3}}; \theta\right) \Delta LUFE_{2015:1|2014:11/3}^{(3)} + u_{2015:1|2014:4} \quad (123)$$

$$\Delta LGSY\dot{I}H_{2015:1|2014:4} = \beta_0 + \beta_1 W\left(L^{\frac{1}{3}}; \theta\right) \Delta LSAN_{2015:1|2014:10/3}^{(3)} + u_{2015:1|2014:4} \quad (124)$$

$$\Delta LGSY\dot{I}H_{2015:1|2014:4} = \beta_0 + \beta_1 W\left(L^{\frac{1}{3}}; \theta\right) \Delta LX_{2015:1|2014:10/3}^{(3)} + u_{2015:1|2014:4} \quad (125)$$

$$\Delta LGSY\dot{I}H_{2015:1|2014:4} = \beta_0 + \beta_1 W\left(L^{\frac{1}{3}}; \theta\right) \Delta LM_{2015:1|2014:10/3}^{(3)} + u_{2015:1|2014:4} \quad (126)$$

Yukarıdaki (120) – (126) numaralı MIDAS modellerinde $W\left(L^{\frac{1}{3}}; \theta\right)$; ilgili yüksek frekanslı değişkenin ağırlıklandırma fonksiyonu, ΔL ; değişkenlerin logaritmik devresel farkının alındığını ve

$\Delta LGSY\dot{I}H_{2015:1|2014:4}$; 2015 yılının 1. çeyreğinde GSYİH için son gözlem olarak 2014'ün 4. çeyrek verisinin kullanıldığı anlamına gelmektedir. Bahsi geçen bu modellerde 2015'in ilk çeyreği için son kez yüksek frekanslı değişkenler geleneksel Almon polinomu, üstel Almon polinomu, Beta, kısıtsız MIDAS (U-MIDAS) ve basamak ağırlıklı MIDAS ile parametre tahminleri elde edilmiştir. Daha sonra bahsi geçen bu U-MIDAS modellerinin parametreleri vasıtasıyla GSYİH'nin 2015 yılı 1. çeyrek büyüme oranının anlık tahminleri hesaplanmıştır.

$$\Delta \widehat{LGSY\dot{I}H}_{2015:1} = \hat{\beta}_0 + \hat{\beta}_1 W\left(L^{\frac{1}{3}}; \hat{\theta}\right) \Delta LGUV_{2015:1}^{(3)} \quad (127)$$

$$\Delta \widehat{LGSY\dot{I}H}_{2015:1} = \hat{\beta}_0 + \hat{\beta}_1 W\left(L^{\frac{1}{3}}; \hat{\theta}\right) \Delta LKAP_{2015:1}^{(3)} \quad (128)$$

$$\Delta \widehat{LGSY\dot{I}H}_{2015:1} = \hat{\beta}_0 + \hat{\beta}_1 W\left(L^{\frac{1}{3}}; \hat{\theta}\right) \Delta LTUFE_{2015:2/3}^{(3)} \quad (129)$$

$$\Delta \widehat{LGSY\dot{I}H}_{2015:1} = \hat{\beta}_0 + \hat{\beta}_1 W\left(L^{\frac{1}{3}}; \hat{\theta}\right) \Delta LUFE_{2015:2/3}^{(3)} \quad (130)$$

$$\Delta \widehat{LGSY\dot{I}H}_{2015:1} = \hat{\beta}_0 + \hat{\beta}_1 W\left(L^{\frac{1}{3}}; \hat{\theta}\right) \Delta LSAN_{2015:1/3}^{(3)} \quad (131)$$

$$\Delta \widehat{LGSY\dot{I}H}_{2015:1} = \hat{\beta}_0 + \hat{\beta}_1 W\left(L^{\frac{1}{3}}; \hat{\theta}\right) \Delta LX_{2015:1/3}^{(3)} \quad (132)$$

$$\Delta \widehat{LGSY\dot{I}H}_{2015:1} = \hat{\beta}_0 + \hat{\beta}_1 W\left(L^{\frac{1}{3}}; \hat{\theta}\right) \Delta LM_{2015:1/3}^{(3)} \quad (133)$$

Böylelikle ilgili çeyrek dönemde GSYİH büyüme oranı için 3 farklı horizonta her bir aylık frekanslı değişkenle hesaplanmış anlık tahmin değerleri elde edilmiştir. Ardından 2015'in 2. çeyrek dönemine geçilmiş ve benzer işlemler tekrarlanarak 2015'in 2. çeyreği için GSYİH'nin büyüme oranının 3 farklı horizonta anlık tahminleri oluşturulmuştur. Tüm bu işlemler 2020'nin 2. çeyreğinin son ayına kadar sürdürülerek, GSYİH için 2015 1. çeyrek 2020 2. çeyrek dönemleri arası anlık tahminler hesaplanmıştır.

3.4. MIDAS Modellerinin tahmin performanslarının Değerlendirilmesi

Çalışmada MIDAS modeliyle elde edilen GSYİH büyüme oranının anlık tahminleri, referans modelleriyle kıyaslanmıştır. Söz konusu referans modellerden kasıt aylık frekanslı değişkenlerin her birinin üçer aylık olarak toplulaştırılmış hallerinin GSYİH büyüme oranı öngörüsünde kullanılmasıdır. Uygulamada 2015'in ilk çeyreğinden başlanılarak 2020'nin 2. çeyrek dönemine

kadar GSYİH büyüme oranı öngörülere elde edilmiştir. Bahsi geçen bu öngörülerde her bir çeyrek dönemin son işlem gününde ulaşılabilen veri setinden faydalanılmıştır. Böylelikle bir önceki alt bölümdeki MIDAS modellerinde olduğu gibi 2015 1. çeyrek – 2020 2. çeyrek dönemleri arası GSYİH'nin büyüme oranı tahmin edilmiştir⁹.

Ardından çalışmada elde edilen tüm tahmin serilerinin, tahmin hata kriterleri hesaplanmıştır. Bu kriterler şu şekilde sıralanabilir; ortalama mutlak hata (MAE), ortalama mutlak yüzde hata (MAPE), ortalama kare öngörü hatası (MSE) kök ortalama kare öngörü hatası (RMSE) ve Hyndman ve Koehler (2006) tarafından geliştirilen mutlak ölçeklendirilmiş hata ortalaması (MASE). Söz konusu bu kriterlerin hesaplanmasında 2015 1. çeyrek - 2020 1. çeyrek dönemi için elde edilen öngörü değerlerinden yararlanılmıştır. 2020'nin 2. çeyrek öngörüsünün kullanılmamasının nedeni bu dönemin gerçekleşen büyüme oranının açıklanmamış olmasıdır.

Uygulamada bu kriterlerin hesaplanmasında RStudio programında Hamner ve diğerleri (2018)'nin oluşturmuş oldukları “Metrics” paketinden yararlanılmıştır. Aşağıdaki (141) – (145) numaralı denklemlerde bu kriterlerin nasıl hesaplandığı gösterilmiştir. Söz konusu bu denklemler, Frasco (2019) tarafından GitHub sitesine yüklenen “Metrics” paketi ile ilgili bilgilerden temin edilmiştir.

$$MAE = \frac{1}{21} \sum_{t=2015.1}^{2020.1} |\Delta LGSYİH_t - \Delta \widehat{LGSYİH}_t| \quad (134)$$

$$MAPE = \frac{1}{21} \sum_{t=2015.1}^{2020.1} \left| \frac{\Delta LGSYİH_t - \Delta \widehat{LGSYİH}_t}{\Delta LGSYİH_t} \right| \quad (135)$$

$$MASE = \left[\sum_{t=2015.1}^{2020.1} |\Delta LGSYİH_t - \Delta \widehat{LGSYİH}_t| \right] / \left[\frac{21}{20} |\Delta LGSYİH_t - \Delta LGSYİH_{t-1}| \right] \quad (136)$$

$$MSE = \frac{1}{21} \sum_{t=2015.1}^{2020.1} (\Delta LGSYİH_t - \Delta \widehat{LGSYİH}_t)^2 \quad (137)$$

$$RMSE = \sqrt{\frac{1}{21} \sum_{t=2015.1}^{2020.1} (\Delta LGSYİH_t - \Delta \widehat{LGSYİH}_t)^2} \quad (138)$$

⁹ Söz konusu bu tahminlerde toplulaştırılmış üçer aylık frekanslı değişkenlerin gecikmelerinden yararlanılmıştır. Uygulamada maksimum gecikme uzunluğu 4 kabul edilerek optimal gecikme uzunlukları, Schwarz bilgi kriteri ile belirlenmiştir.

Yukarıdaki eşitliklerde $\Delta LGSY\dot{I}H_t$; t döneminde gerçekleşen GSYİH büyüme oranını, $\widehat{\Delta LGSY\dot{I}H}_t$; t dönemi için GSYİH büyüme oranının anlık tahmin değerini, $t = 2015.1$; t döneminin 2015'in ilk çeyreğinden başladığını ve 2020.1; son dönemin 2020'nin ilk çeyreği olduğunu göstermektedir. Bahsi geçen denklemlerde tahmin dönemi, 21 çeyrek dönem içermektedir.

Analizlerde aylık frekanslı değişkenlerin yer aldığı MIDAS modelleri ile elde edilen tahmin kriterlerinin ilgili değişkenlerin üçer aylık olarak toplulaştırılmış halleriyle tahmin değerlerinin kriterlerine oranlanmıştır. Bu oranlama sonucu eğer 1'den küçük ise MIDAS modelinin yüksek frekanslı değişkenin toplulaştırılmasıyla oluşturulan tahmin modelinden daha iyi performans gösterdiği anlamına gelmektedir. Tam tersi durumda ise bu kez toplulaştırılmış değişken ile gerçekleştirilen tahmin modelinin daha iyi olduğu anlamına gelecektir.

DÖRDÜNCÜ BÖLÜM

4. BULGULAR

Çalışmanın bu bölümünde MIDAS modelleri ile elde edilen anlık tahminler, çeyrek dönemlerin 1., 2. ve 3. aylarına ayrılarak her biri ayrı ayrı grafiklerde gösterilmiştir. Söz konusu bu grafiklere toplulaştırılmış verilerin kullanıldığı geleneksel modelden elde edilen öngörü sonuçları ve gerçekleşen GSYİH büyüme oranı da eklenmiştir.¹⁰


4.1. GSYİH Büyüme Oranının Anlık Tahmin Bulguları

Aşağıdaki Grafik 1, 2 ve 3'te sırasıyla yüksek frekanslı reel kesim güven endeksi ile GSYİH büyüme oranının anlık tahminleri gösterilmiştir. Söz konusu bu grafiklerden ilki, çeyrek dönemin 1. aylarında elde edilen anlık tahmin bulguları; 2. ve 3. grafikte ise çeyrek dönemin sırasıyla 2. ve 3. aylarındaki anlık tahmin sonuçları yer almaktadır. Bu anlık tahminlerin yanı sıra her bir grafikte gerçekleşen GSYİH büyüme oranı ve üçer aylık olarak toplulaştırılmış reel kesim güven endeksi ile öngörü sonuçları da bulunmaktadır. Grafikler incelenecek olunursa her üçünde de anlık tahmin bulgularının ve toplulaştırılmış verilerle elde edilen öngörü sonuçlarının, gerçekleşen GSYİH büyüme oranının etrafında seyrettiği görülür. Ancak ne MIDAS modelinin ne de geleneksel modelin bulgularının, 2016'nın 3. çeyreğinde gerçekleşen ekonomik daralmayı ve aynı yılın 4. çeyreğindeki ekonomik büyümedeki ani sıçramayı öngöremedikleri ilgili grafiklerden anlaşılmaktadır. Bahsi geçen grafiklerde MIDAS modelinin bulgularının, toplulaştırılmış seri bulgularından daha fazla oynak olduğu gözlerden kaçmamaktadır. Ayrıca ilgili grafiklerde MIDAS modelinde kullanılan tüm ağırlıklandırma polinomların hemen hemen aynı seyri izledikleri dikkat çekmektedir. Ancak Grafik 2 ve 3'te üstel Almon modelinin bulgularının 2018'in 4. çeyreğinde diğer ağırlıklandırma polinomlarının sonuçlarından zıt yönlü olduğu görülmektedir. Bununla birlikte 3. grafikte 2018'in 4. çeyreğinden sonra U-MIDAS modelinin diğer modellerden daha fazla oynak olduğu gözlerden kaçmamaktadır. Son olarak her üç grafikte de hem MIDAS modelinin bulguları hem de


¹⁰ Çalışmada GSYİH büyüme oranının anlık tahminde haftalık frekanslı getiri farkı değişkenlerinden de yararlanılmıştır. Söz konusu bu getiri farkı değişkenleri, bankalarca açılan mevduatlara uygulanan ağırlıklı ortalama 12 ay vadeli faiz oranından sırasıyla 1, 3 ve 6 ay vadeli faiz oranlarının çıkartılmasıyla hesaplanmışlardır. Aylık frekanslı değişkenlerde olduğu gibi haftalık frekanslı getiri farkı değişkenleriyle de GSYİH büyüme oranının 2015 1. çeyrek 2020 2. çeyrek dönemleri arasında anlık tahminleri yapılmış ve elde edilen sonuçlar getiri farkı değişkenlerinin üçer ay olarak toplulaştırıldığı geleneksel modellerle karşılaştırılmıştır. Bu karşılaştırma sonucunda MIDAS modelinin, geleneksel modelden her zaman iyi tahmin performansı göstermediği görülmüştür. Ayrıca haftalık frekanslı değişkenlerin kullanılması GSYİH büyüme oranı anlık tahmini çok fazla iyileştiremediği de anlaşılmıştır. Bu nedenle çalışmada haftalık frekanslı getiri farkı değişkeninin kullanıldığı MIDAS modelleriyle ilgili bulgularına yer verilmemiştir.

toplulaştırılmış değişkenin bulguları, 2020'nin 2. çeyreğinde GSYİH'nin büyüme oranının negatif yönde olacağına işaret etmektedir. Bu negatif büyüme oranının en düşük değeri, -0.052 (-%5.2) ile çeyrek dönemin 1. aylarında gerçekleştirilen geleneksel Almon polinomuna aittir. Öte yandan Grafik 2'de çeyrek dönemin 2. aylarındaki üstel Almon polinom bulgularına göre 2020'nin 2. çeyreğinde 0.023 (%2.3)'lük bir büyüme oranının anlık tahmini görülmektedir.


Grafik 1: Reel Kesim Güven Endeksi ile GSYİH Büyüme Oranının Anlık Tahmini (1. Ay)



Grafik 2: Reel Kesim Güven Endeksi ile GSYİH Büyüme Oranının Anlık Tahmini (2. Ay)




Grafik 3: Reel Kesim Güven Endeksi ile GSYİH Büyüme Oranının Anlık Tahmini (3. Ay)




Daha önce de bahsedildiği gibi GSYİH büyüme oranının anlık tahmininde reel kesim güven endeksi yanında kapasite kullanım oranları da ayrıca kullanılmıştır. Yüksek frekanslı imalat sanayi kapasite kullanım oranıyla gerçekleştirilen MIDAS modellerinin anlık tahmin bulguları, gerçekleşen büyüme oranı ve toplulaştırılmış değişkenin kullanıldığı geleneksel modelin öngörü sonuçları aşağıdaki Grafik 4, 5 ve 6’da gösterilmiştir. Söz konusu grafiklerde imalat sanayi kapasite kullanım oranı bulgularının, reel kesim güven endeksi bulgularından daha az oynak oldukları anlaşılmaktadır. Fakat yüksek frekanslı imalat sanayinin kapasite kullanım oranının bağımsız değişken olarak kullanıldığı MIDAS modelleriyle elde edilen sonuçların, gerçekleşen büyüme oranını daha yakından takip ettiği her üç grafikte de görülmektedir. Böyle bir sonucun çıkmasında GSYİH içerisinde sanayinin önemli bir paya sahip olması ve imalat sanayinin kapasite kullanım oranının, sanayi üretimindeki gelişmelerin öncü göstergesi olması ifade edilebilir. Ancak yine de imalat sanayinin kapasite kullanım oranıyla 2016’nın 3. çeyreğindeki ekonomik daralmayı ve bu daralmadan dolayı 2016’nın 4. çeyreğindeki ani sıçrama öngörülemediği. Öte yandan bahsi geçen grafiklerde tüm model bulgularının birbirleriyle aynı seyirde gittikleri ve reel kesim güven endeksinde olduğu gibi 2020’nin 2. çeyreğinde bir ekonomik daralmanın olacağını öngördükleri gözlerden kaçmamaktadır. Her üç grafikte de söz konusu bu ekonomik daralmanın MIDAS modellerinde daha düşük olduğu ve en şiddetlisinin ise geleneksel Almon polinomuyla anlık olarak tahmin edildiği anlaşılmaktadır. Bu anlık tahminler, çeyrek dönemin 1., 2. ve 3. aylarında sırasıyla şu şekilde olmuştur: -0.114 (-%11.4), -0.171 (-%17.1) ve -0.169 (-%16.9). Bu denli yüksek oranda ekonomik daralmanın öngörülmesinde dünya genelinde yaşanan pandemi nedeniyle 2020’nin 2. çeyreğinde ekonomik faaliyetlerin neredeyse durma noktasına gelmesi gösterilebilir.


Grafik 4: İmalat Sanayi Kapasite Kullanım Oranı ile GSYİH Büyüme Oranının Anlık Tahmini (1. Ay)



Grafik 5: İmalat Sanayi Kapasite Kullanım Oranı ile GSYİH Büyüme Oranının Anlık Tahmini (2. Ay)




Grafik 6: İmalat Sanayi Kapasite Kullanım Oranı ile GSYİH Büyüme Oranının Anlık Tahmini (3. Ay)




Aşağıdaki Grafik 7, 8 ve 9’da sırasıyla çeyrek dönemin 1., 2. ve 3. aylarında gerçekleştirilen yüksek frekanslı TÜFE değişkeninin açıklayıcı değişken olarak kullanıldığı MIDAS modellerinden üretilen GSYİH büyüme oranının anlık tahmin bulguları bulunmaktadır. Bahsi geçen grafiklerde GSYİH büyüme oranının anlık tahmin bulgularının yanı sıra gerçekleşmiş olan GSYİH büyüme oranı ve toplulaştırılmış TÜFE değişkeninin bulunduğu geleneksel modelin öngörü sonuçları da gösterilmiştir. Her üç grafikte de bulguların, reel kesim güven endeksi ve imalat sanayi kapasite kullanım oranı bulgularından daha fazla oynak olduğu gözlerden kaçmamaktadır. Üstelik bu oynaklık MIDAS modellerinde daha fazla hissedilmektedir. Geleneksel Almon polinomun anlık tahmini her üç grafikte de 2018’in 4. çeyreğinde en düşük değerine ulaştığı görülmektedir. Reel kesim güven endeksi ve imalat sanayi kapasite kullanım oranında olduğu gibi TÜFE’nin de 2016 3. çeyrekteki daralmayı ve 2016 4. çeyrekteki ani sıçramayı öngöremediği Grafik 7, 8 ve 9’dan anlaşılmaktadır. Ancak çeyrek dönemin 3. aylarında uygulanan U-MIDAS ve Beta ağırlıklandırma Polinomunun 2016’nın 3. çeyreğinde GSYİH büyüme oranında yaşanmış olan daralmayı az da olsa anlık tahmin edebildikleri Grafik 9’da göze çarpmaktadır. Diğer yandan her üç grafikte de TÜFE değişkenin yer aldığı MIDAS modellerinin 2020’nin 2. çeyreğinde ekonomik büyümenin %0 ile %2 arasında gerçekleşeceği görülmektedir. Söz konusu bu ekonomik büyüme toplulaştırılmış TÜFE değişkeniyle de elde edilmiştir. Böyle bir sonucun çıkmasında pandemi döneminde her ne kadar ekonomik faaliyetler durma noktasına gelse de fiyatlar genel seviyesindeki artışın devam etmesine bağlanabilir.


Grafik 7: TÜFE ile GSYİH Büyüme Oranının Anlık Tahmini (1. Ay)



Grafik 8: TÜFE ile GSYİH Büyüme Oranının Anlık Tahmini (2. Ay)




Grafik 9: TÜFE ile GSYİH Büyüme Oranının Anlık Tahmini (3. Ay)




Yüksek frekanslı ÜFE değişkeninin yer aldığı MIDAS yaklaşımının çeyrek dönemin 1., 2. ve 3. aylarındaki anlık tahmin sonuçları sırasıyla Grafik 10, 11 ve 12’de sunulmuştur. Söz konusu bu grafiklerde daha önceki grafiklerde olduğu gibi gerçekleşen GSYİH büyüme oranı ve toplulaştırılmış ÜFE değişkeniyle elde edilen öngörü bulguları da yer almaktadır. Her üç grafikte de TÜFE değişkeninin yer aldığı MIDAS modellerinde olduğu gibi ÜFE değişkeni ile uygulanan anlık tahmin bulgularının da oynaklık sergilediği görülmektedir. Bahsi geçen grafiklerde çeyrek dönemin 2. aylarındaki basamak ağırlıklı MIDAS modelinin bulguları dışında diğer MIDAS modelinin anlık tahmin bulguları, 2017’nin ilk çeyreğine kadar hemen hemen aynı seyri izledikleri anlaşılmaktadır. Bu tarihten sonra MIDAS modelinin her bir ağırlıklandırma polinomu ile gerçekleştirilen anlık tahmin bulgularının birbirlerinden farklı sonuçlar verdikleri dikkat çekmektedir. Bu farklı sonuçlar, özellikle Grafik 10 ve 11’de geleneksel Almon polinomu ile ağırlıklandırılan MIDAS modelinde çoğunlukla daha düşük GSYİH büyüme oranı şeklinde olmuştur. Her iki grafikte de geleneksel Almon polinomuyla anlık tahmin değerlerinin 2017 ve 2018 4. çeyrek ve 2019 3. çeyrekte dip yaptığı görülmektedir. Grafik 12’de ise geleneksel Almon polinomunun bulgularının sıfır ortalamaya daha yakın olduğu gözlerden kaçmamaktadır. Öte yandan Grafik 11’de 2018’in 4. çeyreğinde Grafik 12’de ise 2018’in 3. çeyreğinde Beta ağırlıklandırma polinomun GSYİH büyüme oranını yüksek oranda anlık tahmin ettiği anlaşılmaktadır. Diğer taraftan aşağıdaki her üç grafikte de ne MIDAS modelinin ne de toplulaştırılmış geleneksel yöntemle uygulanan modelin GSYİH’da 2016’nın 3. çeyreğinde gerçekleşen daralmayı ve bu daralma neticesinde 2016’nın son çeyreğindeki GSYİH’deki yüksek oranlı büyüme oranı kestirilebilmiştir. Son olarak ÜFE değişkeninin yer aldığı MIDAS modellerinin genelinde 2020’nin 2. çeyreğinde GSYİH büyüme oranının pozitif yönde olacağı anlık olarak tahmin edilmiştir. Ancak bu pozitif yönlü büyüme oranı, TÜFE değişkeninin yer aldığı MIDAS modellerinin anlık tahminlerinde daha düşük oranlarda olmuştur. ÜFE değişkeninin yer aldığı MIDAS modeliyle 2020’nin 2. çeyreğinde bir GSYİH büyüme oranının anlık tahmin edilmesinde pandemi sürecinde petrol fiyatlarında görülen düşüşler öne sürülebilir. Çünkü petrol fiyatlarındaki düşüşler üretim maliyetlerinde azalmaya yol açacaktır. Ancak Türkiye ekonomisinde döviz kurunun yukarı yönlü hareket edeceği beklentisi, ÜFE’nin yer aldığı MIDAS modelinin anlık tahmin bulgularında GSYİH büyüme oranının çok yüksek oranda çıkmasını engellediği belirtilebilir.


Grafik 10: ÜFE ile GSYİH Büyüme Oranının Anlık Tahmini (1. Ay)



Grafik 11: ÜFE ile GSYİH Büyüme Oranının Anlık Tahmini (2. Ay)




Grafik 12: ÜFE ile GSYİH Büyüme Oranının Anlık Tahmini (3. Ay)




Yüksek frekanslı sanayi üretim endeksinin bağımsız değişken olarak kullanıldığı MIDAS modelinde çeyrek dönemin 1., 2. ve 3. aylarından uygulanan GSYİH büyüme oranının anlık tahmin sonuçları sırasıyla aşağıdaki Grafik 13, 14 ve 15'te yer almaktadır. Bahsi geçen grafiklerde toplulaştırılmış sanayi üretim endeksi ile gerçekleştirilen öngörü sonuçları ve gerçekleşen GSYİH büyüme oranları da bulunmaktadır. Her üç grafikte de toplulaştırılmış verilerle yapılan öngörü bulgularının çok fazla salınım göstermediği anlaşılmaktadır. Diğer taraftan MIDAS modelinin salınım gösterdiği ve bu salınımların gerçekleşen GSYİH büyüme oranını yakından takip ettiği söz konusu grafiklerden anlaşılmaktadır. Özellikle çeyrek dönemin 3. aylarında gerçekleştirilen sanayi üretim endeksinin yer aldığı MIDAS modellerinin, 2016'nın 3. çeyreğindeki ekonomik daralmayı ve 2016'nın 4. çeyreğindeki büyümedeki sıçramayı anlık tahmin ettikleri Grafik 15'te görülmektedir. Çeyrek dönemin ilk iki ayında ise MIDAS modeliyle 2016'nın 3. çeyreğindeki ekonomik daralma tam zamanında kestirilememiştir. Ekonomideki daralmanın çeyrek dönemin ilk iki ayında anlık olarak tahmin edilememesinin sebebi sanayi üretim endeksinin iki ay gecikme ile yayınlanmasından dolayı olduğu ileri sürülebilir. Çünkü çeyrek dönemin ilk iki ayında söz konusu U-MIDAS modelinde sanayi üretim endeksine ait ilgili dönemde veri bulunmamaktadır. Ancak 3. ayda çeyrek dönemin ilk ayına ait sanayi üretim endeksi verisi yayınlanmış olacaktır. Diğer taraftan bahsi geçen aylarda gerçekleştirilen MIDAS modellerinin 2016'nın 4. çeyreğindeki ekonomik büyümedeki sıçramayı anlık tahmin edebildiği Grafik 13 ve 14'ten anlaşılmaktadır. Tüm bunların yanı sıra basamak ağırlıklı MIDAS modeli hariç 2018'in 4. çeyreğindeki daralmanın her üç ayda da anlık olarak tahmin edildiği ilgili grafiklerde dikkat çekmektedir. Bu daralmanın her üç ayda da anlık olarak tahmin edilmesinde söz konusu daralmanın 2018'in ilk iki çeyreğinde de görülmesinden dolayı olduğu belirtilebilir. Grafik 13, 14 ve 15'te 2019'un 4. çeyreğinde MIDAS modelleriyle ekonomik daralmanın olacağı anlık tahmin edilmiş ancak söz konusu bu anlık tahminin gerçekleşmediği görülmektedir. Bahsi geçen grafiklerde çeyrek dönemin ilk iki ayında gerçekleştirilen MIDAS modeli anlık tahminlerinde 2020'nin 2. çeyreğinde %0 civarında bir ekonomik büyümenin olacağı ancak 3. aylarda uygulanan MIDAS modeli anlık tahminlerinde ise söz konusu dönemde ciddi bir ekonomik daralmanın olacağı gözlerden kaçmamaktadır. Bu ekonomik daralmanın en şiddetlisi geleneksel Almon ağırlıklandırma polinomun uygulandığı MIDAS modeliyle -0.135 (-%13.5) oranında anlık olarak tahmin edilmiştir.


Grafik 13: Sanayi Üretim Endeksi ile GSYİH Büyüme Oranının Anlık Tahmini (1. Ay)



Grafik 14: Sanayi Üretim Endeksi ile GSYİH Büyüme Oranının Anlık Tahmini (2. Ay)

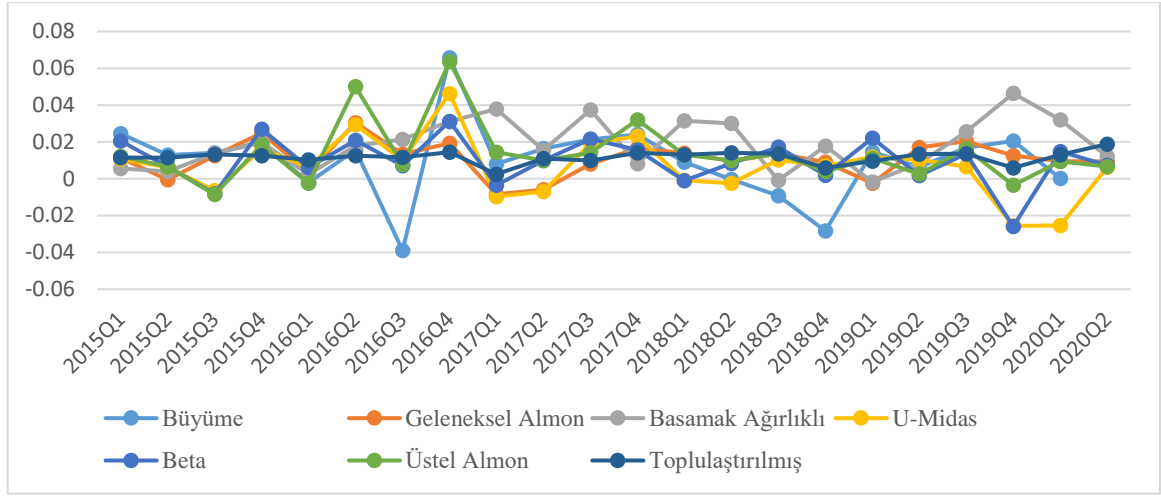


Grafik 15: Sanayi Üretim Endeksi ile GSYİH Büyüme Oranının Anlık Tahmini (3. Ay)




Aşağıdaki Grafik 16, 17 ve 18’te sırasıyla yüksek frekanslı reel toplam ihracatın bağımsız değişken olarak yer aldığı MIDAS modelinin çeyrek dönemin 1., 2. ve 3. aylarındaki anlık tahmin bulguları yer almaktadır. Bahsi geçen grafiklerde gerçekleşen GSYİH büyüme oranı ve toplulaştırılmış reel toplam ihracatın kullanıldığı geleneksel modelin öngörülleri de gösterilmiştir. Söz konusu grafiklerde toplulaştırılmış verilerle GSYİH büyüme oranının tahmininin çok dalgalı olmadığı ancak aylık frekanslı reel toplam ihracatıyla GSYİH büyüme oranının anlık tahmininin dalgalı bir seyir izlediği anlaşılmaktadır. Bu dalgalı seyrin her üç grafikten de 2015 1. çeyrek ve 2017 1. çeyrek arasında ve 2018’in 4. çeyreğinden sonra hissedilir olduğu görülmektedir. Özellikle çeyrek dönemin 3. ayında uygulanan MIDAS modellerinin anlık tahminleri, 2015 1. çeyrek ve 2017 1. çeyrek dönemleri arasında inişli çıkışlı bir seyir izlemektedir. Bu nedenle 2016’nın 3. çeyreğindeki ekonomik daralma MIDAS modelleriyle anlık tahmin edilebilmiştir. Ancak söz konusu MIDAS modelleri, 2015 3. çeyrek ve 2016 1. çeyrekte de ekonomik daralmanın olacağını anlık olarak tahmin etmişlerdir. 2016’nın 3. çeyreğinde yaşanan ekonomik daralmanın ardından 2016’nın 4. çeyreğindeki ekonomik sıçramanın MIDAS modeliyle anlık tahmin edildiği ilgili grafiklerden anlaşılmaktadır. Öte yandan 2017’nin 1. çeyreğinden sonra MIDAS modelinin anlık tahminlerinin çok fazla salınım göstermediği ve bu nedenle 2018’in 4. çeyreğindeki ekonomik daralmanın anlık tahmin edilmediği her üç grafikten de gözlenmektedir. Ancak MIDAS modeliyle 2019’un 4. çeyreğinde ekonomik daralma anlık tahmin edilmiş fakat bu söz konusu bu daralmanın gerçekleşmediği ilgili grafiklerde görülmektedir. Son olarak 2020’nin 2. çeyreğine ilişkin anlık tahmin sonuçları incelendiğinde çeyrek dönemin ilk iki ayında uygulanan MIDAS modelleriyle ekonomik büyümenin %0 civarında olacağı anlık olarak tahmin edildiği gözlerden kaçmamaktadır. Diğer taraftan çeyrek dönemin 3. aylarında uygulanan MIDAS modelleriyle 2020’nin 2. çeyreğinde ciddi bir ekonomik daralmanın olacağı anlaşılmaktadır. Böyle bir sonucun çıkmasında reel toplam ihracat verisinin iki ay gecikmeli olarak hesaplanmasının rolü büyüktür. Çünkü her ne kadar 2020’nin 2. çeyreğinde pandemi etkisi görülse de 2020’nin 2. çeyreğinin ilk ayına ait reel toplam ihracat verisine Haziran ayında ulaşılabilmektedir.


Grafik 16: Reel Toplam İhracat ile GSYİH Büyüme Oranının Anlık Tahmini (1. Ay)



Grafik 17: Reel Toplam İhracat ile GSYİH Büyüme Oranının Anlık Tahmini (2. Ay)

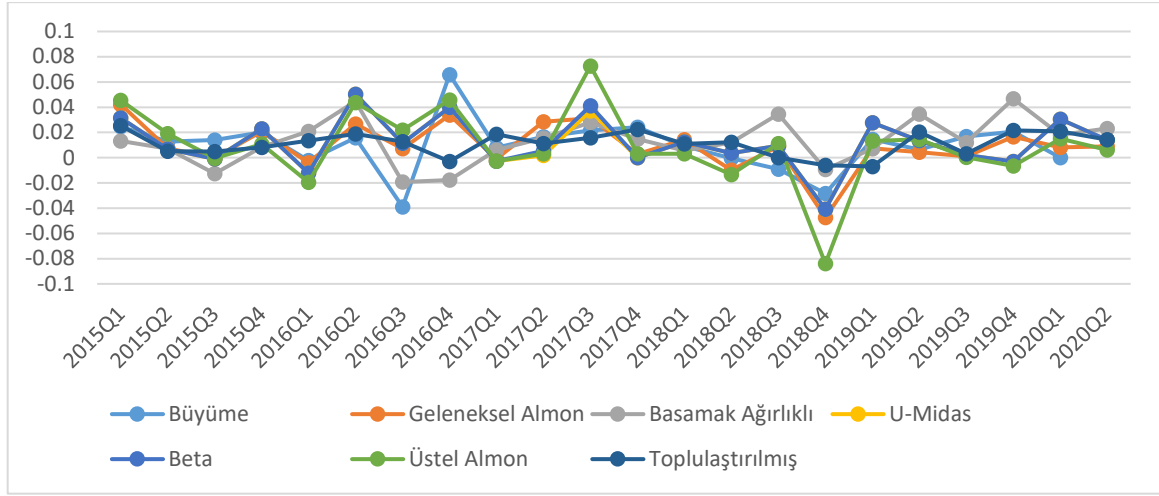


Grafik 18: Reel Toplam İhracat ile GSYİH Büyüme Oranının Anlık Tahmini (3. Ay)




Aylık frekanslı değişkenlerden en sonuncusu olan reel toplam ithalat ile GSYİH büyüme oranının anlık tahminleri Grafik 19, 20 ve 21’de sunulmuştur. Söz konusu grafiklerde sırasıyla çeyrek dönemin 1., 2. ve 3. aylarında uygulanan MIDAS modelinin anlık tahmin bulgularının yanı sıra gerçekleşen GSYİH büyüme oranını ve toplulaştırılmış verilerle elde edilen öngörü sonuçları da bulunmaktadır. Çalışmada kullanılan diğer aylık frekanslı değişkenlerin toplulaştırılmış verilerinin ekonomik büyüme oranı tahminlerinin çok fazla dalgalanma göstermediği daha önceki grafiklerde gözlemlenmiştir. Ancak toplulaştırılmış reel toplam ithalat ile GSYİH büyüme oranı tahmininin dalgalı seyir izlediği aşağıdaki Grafik 19, 20 ve 21’den anlaşılmaktadır. Söz konusu bu dalgalı seyir MIDAS modellerinin anlık tahminlerinde daha şiddetli olmaktadır. Diğer yandan çeyrek dönemin 3. aylarında uygulanan MIDAS modeliyle söz konusu ekonomik daralma anlık tahmin edilebilmiştir. Çeyrek dönemin ilk iki ayında da ilgili daralma MIDAS modeliyle anlık tahmin edilebilmiş ancak bu anlık tahmin çeyrek dönemin 3. ayındaki gibi tutarlı olmamıştır. Çeyrek dönemin 3. ayında ekonomik daralmanın daha tutarlı anlık tahmin edilmesinde reel toplam ithalat verisinin 2 ay gecikme ile hesaplanabilmesinin rol oynadığı ileri sürülebilir. Diğer taraftan 2016’nın 4. çeyreğindeki ani ekonomik büyümenin MIDAS modelleriyle anlık tahmin edildiği ilgili grafiklerden anlaşılmaktadır. Bu anlık tahmin çeyrek dönemin 3. ayında uygulanan MIDAS modellerinde daha tutarlı olmuştur. Bununla birlikte 2018 4. çeyrek döneminde yaşanan ekonomik daralmanın MIDAS modelleriyle anlık tahmin edilebildiği ilgili grafiklerde görülmektedir. Ancak daralmadaki bu anlık tahminler çeyrek dönemin ilk iki ayında uygulanan MIDAS modellerinde gerçeğinden daha fazla şiddetli olmuştur. Söz konusu grafiklerde 2020’nin 2. çeyrek ekonomik büyüme oranlarına bakıldığında çeyrek dönemin ilk iki ayında MIDAS modellerinin, ekonomik büyümenin %0 civarında olacağını çeyrek dönemin 3. aylarında ise ekonomik bir daralmanın olacağını anlık olarak tahmin ettikleri gözlerden kaçmamaktadır. Çeyrek dönemin 3. ayında ilk iki aydan farklı olarak ekonomik daralmanın anlık tahmin edilmesinde reel toplam ithalatın iki ay gecikme ile hesaplanabilmesi öne sürülebilir. Böylelikle 2020’nin 2. çeyreğinde yaşanan pandemi etkisi, 2020 Haziran ayında reel toplam ithalatla değişkeniyle MIDAS modelleriyle yansıtılabilmektedir.


Grafik 19: Reel Toplam İthalat ile GSYİH Büyüme Oranının Anlık Tahmini (1. Ay)



Grafik 20: Reel Toplam İthalat ile GSYİH Büyüme Oranının Anlık Tahmini (2. Ay)



Grafik 21: Reel Toplam İthalat ile GSYİH Büyüme Oranının Anlık Tahmini (3. Ay)



4. 2. MIDAS Modellerinin Tahmin Performanslarının Değerlendirilmesi

Çalışmanın bu alt bölümünde MIDAS modellerinin tahmin performansları, toplulaştırılmış değişkenlerle gerçekleştirilen geleneksel modellerin tahmin performanslarıyla karşılaştırılmıştır. Performans karşılaştırma işlemi için hem MIDAS modellerinin hem de toplulaştırılmış değişkenlerin kullanıldığı geleneksel modellerin tahmin hata kriterleri ayrı ayrı hesaplanmıştır. Bir önceki bölümden de hatırlanacağı üzere bu tahmin hata kriterleri şu şekildedir; ortalama mutlak hata (MAE), ortalama mutlak yüzde hata (MAPE), ortalama kare öngörü hatası (MSE), kök ortalama kare öngörü hatası (RMSE) ve mutlak ölçeklendirilmiş hata ortalaması (MASE). Ardından analizlerde kullanılan aylık frekanslı değişkenlerin her biri için MIDAS modellerinin tahmin hata kriterleri, ilgili aylık frekanslı değişkenin toplulaştırılmış halinin yer aldığı geleneksel modelin tahmin hata kriterlerine oranlanmıştır. Bu oranlama sonucunda elde edilen değerler her bir aylık frekanslı değişken için ayrı ayrı tablolar halinde sunulmuştur. Söz konusu bu değerlerin 1'den küçük olması MIDAS modelinin tahmin performansının daha iyi olduğu anlamına gelmektedir. Eğer bahsi geçen bu değerler, 1'den büyük ise bu kez geleneksel modelin tahmin performansının daha iyi olduğu sonucu çıkartılabilecektir.

Aşağıdaki 5-11 numaralı tablolarda aylık frekanslı açıklayıcı değişkenlerin kullanıldığı MIDAS modellerinin tahmin hata kriterleri ilgili aylık frekanslı değişkenin toplulaştırılmasıyla oluşturulan geleneksel modelin tahmin hata kriterlerine oranlanmış değerlerine yer verilmiştir. Bahsi geçen bu tablolarda sırasıyla reel kesim güven endeksi, imalat sanayi kapasite kullanım oranı, TÜFE, ÜFE, sanayi üretim endeksi, reel toplam ihracat ve reel toplam ithalat değişkenlerinin bulguları gösterilmektedir. Söz konusu bu tabloların her birinde 3 panel bulunmaktadır. Bu panellerde sırasıyla çeyrek dönemin 1., 2. ve 3. aylarında oluşturulan MIDAS yaklaşımlarının tahmin kriterlerinin sonuçları ayrı ayrı gösterilmiştir.

Bahsi geçen bu tablolar genel olarak incelendiğinde imalat sanayi kapasite kullanım oranı, TÜFE ve sanayi üretim endeksi açıklayıcı değişkenleri ile oluşturulan MIDAS yaklaşımlarının GSYİH büyüme oranı öngörüsünde geleneksel modele göre daha iyi performans sergiledikleri görülmektedir. Reel toplam ithalat açıklayıcı değişkenin yer aldığı MIDAS modellerinin tahmin performansları ise birkaç kez geleneksel modelin tahmin performansından daha iyi çıkmıştır. Ancak reel kesim güven endeksi, ÜFE ve reel toplam ihracat açıklayıcı değişkenlerinin bulunduğu MIDAS yaklaşımlarının geleneksel modellerden daha iyi performans gösteremedikleri anlaşılmaktadır.

Tablo 5: Reel Kesim Güven Endeksi ile Öngörü Performansı Karşılaştırılması

	Ağırlıklandırma Polinomu	MAE	MAPE	MASE	MSE	RMSE
1. ay	Geleneksel Almon	1.063	1.099	1.063	0.993	0.996
	Basamak Ağırlıklı	1.118	1.296	1.118	1.106	1.052
	U-MIDAS	1.34	1.798	1.34	1.188	1.09
	Beta	1.248	1.428	1.248	1.164	1.079
	Üstel Almon	1.265	1.438	1.265	1.191	1.091
2. ay	Geleneksel Almon	1.036	1.074	1.036	0.985	0.993
	Basamak Ağırlıklı	0.992	0.848	0.992	0.992	0.996
	U-MIDAS	1.417	1.769	1.417	1.29	1.136
	Beta	1.377	1.416	1.377	1.303	1.142
	Üstel Almon	1.172	1.104	1.172	1.232	1.11
3. ay	Geleneksel Almon	1.048	1.049	1.048	1.043	1.021
	Basamak Ağırlıklı	1.082	0.6	1.082	1.178	1.085
	U-MIDAS	1.488	1.848	1.488	1.593	1.262
	Beta	1.19	0.603	1.19	1.335	1.155
	Üstel Almon	1.235	0.61	1.235	1.453	1.205

Not: MAE; Ortalama Mutlak Hata'yı, MAPE; Ortalama Mutlak Yüzde Hata'yı, MASE; Mutlak Ölçeklendirilmiş Hata Ortalaması'nı, MSE; Ortalama Kare Öngörü Hatası'nı ve RMSE; Kök Ortalama Kare Öngörü Hatası'nı temsil etmektedir. MIDAS yaklaşımın tahmin performans kriterleri, toplulaştırılmış değişkenle gerçekleştirilen modelin tahmin performans kriterine oranlamıştır.

Reel kesim güven endeksinin açıklayıcı değişken olarak kullanıldığı MIDAS yaklaşımın tahmin performansının çok iyi olmadığı Tablo 5'ten anlaşılmaktadır. Söz konusu tabloda çeyrek dönemin 2. aylarında basamak ağırlık MIDAS modellerinin daha iyi performans gösterdiği görülmektedir. Bununla birlikte ilgili tabloda MAPE'nin çeyrek dönemin 3. ayında basamak ağırlıklı, Beta ve üstel Almon modellerinde, MSE ve RMSE'de çeyrek dönemin 1. ve 2. aylarında geleneksel Almon modellerinde MIDAS yaklaşımın iyi performans gösterdiği gözlerden kaçmamaktadır. Öte yandan Tablo 6, 7 ve 9'da imalat sanayi kapasite kullanım oranı, TÜFE ve sanayi üretim endeksi açıklayıcı değişkenlerinin yer aldığı MIDAS modellerinin bahsi geçen bu değişkenlerin toplulaştırılmış hallerinden çoğunlukla daha iyi tahmin performans kriteri sundukları anlaşılmaktadır. Özellikle de imalat sanayi kapasite kullanım oranı ve TÜFE için çeyrek dönemin 3. döneminde hemen hemen her tahmin kriterinde MIDAS modelinin geleneksel modele göre daha iyi performans sergilemiştir. Tablo 9'da ise sanayi üretim endeksinin çeyrek dönemin her bir ayında genellikle geleneksel modelden daha iyi performans sergilediği anlaşılmaktadır.

Tablo 6: İmalat Sanayi Kapasite Kullanım Oranı ile Öngörü Performansı Karşılaştırılması

	Ağırlıklandırma Polinomu	MAE	MAPE	MASE	MSE	RMSE
1. ay	Geleneksel Almon	1.04	0.894	1.04	1.022	1.011
	Basamak Ağırlıklı	0.946	0.892	0.946	0.85	0.922
	U-MIDAS	0.959	1.074	0.959	0.852	0.923
	Beta	1.068	0.93	1.068	1.108	1.053
	Üstel Almon	0.953	1.073	0.953	0.849	0.921
2. ay	Geleneksel Almon	1.031	1.004	1.031	0.774	0.88
	Basamak Ağırlıklı	1.061	0.62	1.061	1.027	1.014
	U-MIDAS	1.032	1.013	1.032	0.77	0.877
	Beta	0.983	1.155	0.983	0.819	0.905
	Üstel Almon	0.988	1.113	0.988	0.836	0.914
3. ay	Geleneksel Almon	0.978	0.838	0.978	0.712	0.844
	Basamak Ağırlıklı	0.93	0.96	0.93	0.856	0.925
	U-MIDAS	0.917	0.855	0.917	0.696	0.834
	Beta	0.984	0.584	0.984	0.993	0.996
	Üstel Almon	1.018	0.822	1.018	0.93	0.964

Not: MAE; Ortalama Mutlak Hata'yı, MAPE; Ortalama Mutlak Yüzde Hata'yı, MASE; Mutlak Ölçeklendirilmiş Hata Ortalaması'nı, MSE; Ortalama Kare Öngörü Hatası'nı ve RMSE; Kök Ortalama Kare Öngörü Hatası'nı temsil etmektedir. MIDAS yaklaşımın tahmin performans kriterleri, toplulaştırılmış değişkenle gerçekleştirilen modelin tahmin performans kriterine oranlamıştır.

Tablo 7: TÜFE ile Öngörü Performansı Karşılaştırılması

	Ağırlıklandırma Polinomu	MAE	MAPE	MASE	MSE	RMSE
1. ay	Geleneksel Almon	1.308	0.687	1.308	1.412	1.188
	Basamak Ağırlıklı	0.798	1.031	0.798	0.733	0.856
	U-MIDAS	0.748	0.792	0.748	0.651	0.807
	Beta	0.973	0.952	0.973	1.028	1.014
	Üstel Almon	0.841	0.521	0.841	0.773	0.879
2. ay	Geleneksel Almon	1.232	0.43	1.232	1.216	1.103
	Basamak Ağırlıklı	1.046	0.259	1.046	0.981	0.99
	U-MIDAS	0.84	0.459	0.84	0.622	0.788
	Beta	0.912	0.483	0.912	0.751	0.867
	Üstel Almon	0.861	0.453	0.861	0.636	0.797
3. ay	Geleneksel Almon	1.148	0.655	1.148	1.271	1.128
	Basamak Ağırlıklı	0.884	1.054	0.884	0.841	0.917
	U-MIDAS	0.775	0.74	0.775	0.578	0.76
	Beta	0.842	0.913	0.842	0.745	0.863
	Üstel Almon	0.807	0.424	0.807	0.578	0.76

Not: MAE; Ortalama Mutlak Hata'yı, MAPE; Ortalama Mutlak Yüzde Hata'yı, MASE; Mutlak Ölçeklendirilmiş Hata Ortalaması'nı, MSE; Ortalama Kare Öngörü Hatası'nı ve RMSE; Kök Ortalama Kare Öngörü Hatası'nı temsil etmektedir. MIDAS yaklaşımın tahmin performans kriterleri, toplulaştırılmış değişkenle gerçekleştirilen modelin tahmin performans kriterine oranlamıştır.

Tablo 8 incelendiğinde ÜFE açıklayıcı değişkeninin yer aldığı MIDAS yaklaşımlarının çoğunlukla geleneksel modellere göre daha iyi performans sergileyemediği görülmektedir. Özellikle

çeyrek dönemin 3. ayında gerçekleştirilen MIDAS modellerinin hiçbiri geleneksel yöntemden daha iyi performans gösterememiştir. Çeyrek dönemin ilk iki ayında ise MIDAS yaklaşımının bazı ağırlıklandırma polinomlarının daha iyi performans gösterdikleri ilgili tablodan anlaşılmaktadır. Örneğin çeyrek dönemin 2. ayında U-MIDAS modelinin tahmin performansı geleneksel modelin tahmin performansından daha iyi olduğu açıkça görülmektedir. Bunun yanı sıra çeyrek dönemin ilk iki ayında da MAPE kriterince MIDAS modelinin her bir ağırlıklandırma polinomu, geleneksel yöntemden daha düşük tahmin kriterleri elde edilebilmiştir.

Tablo 8: ÜFE ile Öngörü Performansı Karşılaştırılması

	Ağırlıklandırma Polinomu	MAE	MAPE	MASE	MSE	RMSE
1. ay	Geleneksel Almon	1.515	0.903	1.515	2.248	1.499
	Basamak Ağırlıklı	0.91	0.836	0.91	0.883	0.94
	U-MIDAS	1.177	0.763	1.177	1.503	1.226
	Beta	1.359	1.27	1.359	1.554	1.246
	Üstel Almon	1.209	0.706	1.209	1.518	1.232
2. ay	Geleneksel Almon	1.367	0.689	1.367	1.919	1.385
	Basamak Ağırlıklı	1.311	0.679	1.311	1.422	1.192
	U-MIDAS	0.852	0.416	0.852	0.908	0.953
	Beta	1.131	0.526	1.131	1.902	1.379
	Üstel Almon	0.969	0.357	0.969	1.287	1.135
3. ay	Geleneksel Almon	1.396	1.272	1.396	1.714	1.309
	Basamak Ağırlıklı	1.188	1.079	1.188	1.401	1.184
	U-MIDAS	1.196	1.209	1.196	1.311	1.145
	Beta	1.164	1.063	1.164	1.555	1.247
	Üstel Almon	1.196	1.209	1.196	1.311	1.145

Not: MAE; Ortalama Mutlak Hata'yı, MAPE; Ortalama Mutlak Yüzde Hata'yı, MASE; Mutlak Ölçeklendirilmiş Hata Ortalaması'nı, MSE; Ortalama Kare Öngörü Hatası'nı ve RMSE; Kök Ortalama Kare Öngörü Hatası'nı temsil etmektedir. MIDAS yaklaşımın tahmin performans kriterleri, toplulaştırılmış değişkenle gerçekleştirilen modelin tahmin performans kriterine oranlamıştır.

Tablo 10'da reel toplam ihracat ile MIDAS modelinin, GSYİH büyüme oranının tahmin performansını çok fazla iyileştirmediği görülmektedir. Özellikle çeyrek dönemin 2. ve 3. aylarında uygulanan geleneksel Almon ve basamak ağırlık MIDAS yaklaşımlarının tüm tahmin kriterlerince geleneksel modele göre daha kötü tahmin performansı sergilediği ilgili tablodan göze çarpmaktadır. Ancak çeyrek dönemin 2. ayında MAPE tahmin hata kriterine ve çeyrek dönemin 3. ayında MAPE, MSE ve RMSE tahmin hata kriterlerine göre U-MIDAS Beta ve üstel Almon ağırlıklandırma polinomlarının kullanıldığı MIDAS yaklaşımlarının, geleneksel modelden daha iyi performanslarının olduğu bahsi geçen tablodan anlaşılmaktadır. Çeyrek dönemin ilk ayında ise her bir tahmin hata kriterinde üstel Almon ağırlıklandırma polinomu ile MIDAS yaklaşımının performansının daha iyi çıktığı Tablo 10'da tespit edilmektedir. Diğer taraftan reel toplam ihracat yerine reel toplam ithalatın açıklayıcı değişken olarak kullanılmasının MIDAS yaklaşımın öngörü performansını biraz iyileştirdiği Tablo 11'den anlaşılmaktadır. Bilhassa da çeyrek dönemin 3. ayında

MIDAS yaklaşımı çoğunlukla geleneksel modelden daha iyi performans sergilemiştir (MAPE tahmin hata kriteri ve basamak ağırlıklı MIDAS yaklaşımında MAE ve MASE kriterleri hariç). Çeyrek dönemin ilk iki aylarında ise MIDAS modelinin çeyrek dönemin 3. ayında olduğu gibi tahmin performansı çok iyi olmamıştır.

Tablo 9: Sanayi Üretim Endeksi ile Öngörü Performansı Karşılaştırılması

	Ağırlıklandırma Polinomu	MAE	MAPE	MASE	MSE	RMSE
1. ay	Geleneksel Almon	1.019	0.826	1.019	0.837	0.915
	Basamak Ağırlıklı	1.043	0.968	1.043	0.963	0.982
	U-MIDAS	0.853	0.696	0.853	0.71	0.842
	Beta	1.046	1.743	1.046	0.954	0.977
	Üstel Almon	0.805	0.733	0.805	0.687	0.829
2. ay	Geleneksel Almon	1.088	2.208	1.088	1.123	1.06
	Basamak Ağırlıklı	1.071	0.921	1.071	1.337	1.156
	U-MIDAS	0.848	0.804	0.848	0.705	0.839
	Beta	1.019	1.217	1.019	0.866	0.931
	Üstel Almon	1.001	0.964	1.001	0.906	0.952
3. ay	Geleneksel Almon	0.927	1.554	0.927	0.65	0.806
	Basamak Ağırlıklı	1.172	1.091	1.172	1.362	1.167
	U-MIDAS	0.961	1.356	0.961	0.66	0.812
	Beta	0.835	1.272	0.835	0.468	0.684
	Üstel Almon	0.838	1.273	0.838	0.47	0.685

Not: MAE; Ortalama Mutlak Hata'yı, MAPE; Ortalama Mutlak Yüzde Hata'yı, MASE; Mutlak Ölçeklendirilmiş Hata Ortalaması'nı, MSE; Ortalama Kare Öngörü Hatası'nı ve RMSE; Kök Ortalama Kare Öngörü Hatası'nı temsil etmektedir. MIDAS yaklaşımın tahmin performans kriterleri, toplulaştırılmış değişkenle gerçekleştirilen modelin tahmin performans kriterine oranlamıştır.

Tablo 10: Reel Toplam İhracat ile Öngörü Performansı Karşılaştırılması

	Ağırlıklandırma Polinomu	MAE	MAPE	MASE	MSE	RMSE
1. ay	Geleneksel Almon	1.155	0.767	1.155	1.108	1.053
	Basamak Ağırlıklı	1.324	2.188	1.324	1.5	1.225
	U-MIDAS	1.153	1.36	1.153	1.115	1.056
	Beta	1.075	0.982	1.075	1.032	1.016
	Üstel Almon	0.914	0.726	0.914	0.81	0.9
2. ay	Geleneksel Almon	1.211	1.183	1.211	1.212	1.101
	Basamak Ağırlıklı	1.13	0.983	1.13	1.422	1.193
	U-MIDAS	1.384	0.717	1.384	1.39	1.179
	Beta	1.073	0.909	1.073	1.072	1.035
	Üstel Almon	1.147	0.884	1.147	1.316	1.147
3. ay	Geleneksel Almon	1.21	1.068	1.21	1.24	1.114
	Basamak Ağırlıklı	1.499	1.049	1.499	2.029	1.424
	U-MIDAS	1.038	0.868	1.038	0.97	0.985
	Beta	1.043	0.906	1.043	0.92	0.959
	Üstel Almon	1.059	0.908	1.059	0.966	0.983

Not: MAE; Ortalama Mutlak Hata'yı, MAPE; Ortalama Mutlak Yüzde Hata'yı, MASE; Mutlak Ölçeklendirilmiş Hata Ortalaması'nı, MSE; Ortalama Kare Öngörü Hatası'nı ve RMSE; Kök Ortalama Kare Öngörü Hatası'nı temsil etmektedir. MIDAS yaklaşımın tahmin performans kriterleri, toplulaştırılmış değişkenle gerçekleştirilen modelin tahmin performans kriterine oranlamıştır.

Tablo 11: Reel Toplam İthalat ile Öngörü Performansı Karşılaştırılması

	Ağırlıklandırma Polinomu	MAE	MAPE	MASE	MSE	RMSE
1. ay	Geleneksel Almon	0.873	0.479	0.873	0.571	0.756
	Basamak Ağırlıklı	1.267	0.955	1.267	1.396	1.181
	U-MIDAS	1.113	1.21	1.113	0.83	0.911
	Beta	1.115	1.209	1.115	0.836	0.914
	Üstel Almon	1.409	0.848	1.409	1.411	1.188
2. ay	Geleneksel Almon	1.089	1.63	1.089	0.951	0.975
	Basamak Ağırlıklı	1.095	1.633	1.095	1.165	1.079
	U-MIDAS	1.217	1.206	1.217	1.049	1.024
	Beta	1.055	0.782	1.055	0.976	0.988
	Üstel Almon	1.072	0.911	1.072	0.953	0.976
3. ay	Geleneksel Almon	0.944	1.427	0.944	0.672	0.819
	Basamak Ağırlıklı	1.033	1.456	1.033	0.948	0.974
	U-MIDAS	0.795	1.466	0.795	0.413	0.642
	Beta	0.807	1.475	0.807	0.469	0.685
	Üstel Almon	0.843	1.476	0.843	0.486	0.697

Not: MAE; Ortalama Mutlak Hata'yı, MAPE; Ortalama Mutlak Yüzde Hata'yı, MASE; Mutlak Ölçeklendirilmiş Hata Ortalaması'nı, MSE; Ortalama Kare Öngörü Hatası'nı ve RMSE; Kök Ortalama Kare Öngörü Hatası'nı temsil etmektedir. MIDAS yaklaşımın tahmin performans kriterleri, toplulaştırılmış değişkenle gerçekleştirilen modelin tahmin performans kriterine oranlamıştır.

4. 3. Tahmin Hata Kriterleriyle En İyi Tahmin Modellerinin Belirlenmesi

Çalışmanın bu alt bölümünde ise hem MIDAS modellerinin hem de toplulaştırılmış değişkenlerin yer aldığı geleneksel modellerin tahmin hata kriterleri, en küçükten en büyüğe doğru sıralanmıştır. Bu sıralama sonucunda her tahmin hata kriterinde en küçük değeri alan onar model Tablo 12’de gösterilmiştir. Bahsi geçen tablo incelenecek olunursa toplulaştırılmış değişkenlerin kullanıldığı modellerin hiçbirinin yer almadığı görülür. Tabloda ayrıca yüksek frekanslı reel toplam ihracat ve reel kesim güven endeksinin yer aldığı MIDAS modellerinin de bulunmadığı dikkat çekmektedir. Bunun yanı sıra yüksek frekanslı ÜFE değişkeninin ise sadece çeyrek dönemin 2. aylarında üstel Almon ağırlıklandırma polinomuyla uygulanan MIDAS modelinin ilgili tabloda yer aldığı görülmektedir.

Bahsi geçen tablo genel olarak incelendiğinde yüksek frekanslı kapasite kullanım oranının yer aldığı MIDAS modellerinin en iyi tahmin performansına sahip olduğu anlaşılmaktadır. Böyle bir sonucun çıkmasında kapasite kullanım oranının, çalışmada kullanılan diğer aylık frekanslı değişkenlere göre zaman itibariyle daha erken açıklanması gösterilebilir. Çünkü erken açıklanan kapasite kullanım oranıyla cari dönemde GSYİH ile ilgili bilgilere çok önceden ulaşılacaktır. Kapasite kullanım oranı için çeyrek dönemin 3. aylarında uygulanan U-MIDAS modeli, MAPE kriteri dışında diğer tüm tahmin hata kriterlerine göre en iyi modeller arasında yer almaktadır. İlgili tabloda ayrıca yüksek frekanslı TÜFE, sanayi üretim endeksi ve reel toplam ithalatın kullanıldığı MIDAS modellerinin de yer aldığı görülmektedir. Ancak bu modeller genel itibariyle kapasite kullanım oranı kadar iyi bir tahmin performansı sergileyememişlerdir. Bunun nedeni olarak söz konusu bu değişkenlere ait verilere 1 – 2 ay geç ulaşılabilmesi öne sürülebilir.

Söz konusu tabloda MAE ve MASE kriterlerinde birebir aynı sonuçların elde edildiği görülmektedir. Bahsi geçen bu kriterlere göre yüksek frekanslı kapasite kullanım oranının açıklayıcı değişken olarak yer aldığı MIDAS modellerinin en iyi tahmin performansına sahip olduğu da gözlerden kaçmamaktadır. Özellikle de kapasite kullanım oranıyla çeyrek dönemin 3. aylarında uygulanan U-MIDAS ve basamak ağırlıklı MIDAS modelleri en iyi tahmin performansı sergilemişlerdir. İlgili tabloda MSE ve RMSE kriterlerine göre en iyi tahmin performansına sahip modellerin aynı olduğu ancak bu modellerin farklı sıralarda yer aldıkları dikkati çekmektedir. Söz konusu bu kriterlerde çeyrek dönemin 3. ayında uygulanan ve yüksek frekanslı reel ithalatın bağımsız değişken olarak yer aldığı U-MIDAS modelinin en iyi tahmin performansa sahip olduğu görülmektedir. Bu modeli, çeyrek dönemin 3. aylarında uygulanan kapasite kullanım oranının bağımsız değişken olarak kullanıldığı U-MIDAS modeli ve sanayi üretim endeksinin bağımsız değişken olarak kullanıldığı beta ve üstel Almon ağırlıklı MIDAS modelleri takip etmektedir. Öte yandan MAPE kriteriyle de diğer kriterlerden tamamen farklı sonuçlara ulaşıldığı Tablo 12’de dikkat çekmektedir. Söz konusu kritere göre yüksek frekanslı TÜFE değişkeninin kullanıldığı MIDAS modelleri en iyi tahmin performansına sahiptir. Bahsi geçen kritere göre TÜFE değişkeninin haricinde

kapasite kullanım oranı ve ÜFE değişkenlerinin yer aldığı MIDAS modellerinin de iyi tahmin performansı sergiledikleri ilgili tabloda görülmektedir.

Bahsi geçen tabloda MIDAS yaklaşımının tüm ağırlıklandırma polinomları tabloda yer aldığı Dikkati çekmektedir. Bununla birlikte anlık tahmin açısından U-MIDAS'ın diğer ağırlıklandırma polinomların uygulandığı MIDAS yaklaşımlarından daha iyi performans sergilediği ilgili tablodan çıkartılabilir. Ayrıca söz konusu tabloda çeyrek dönemin 3. aylarında gerçekleştirilen MIDAS yaklaşımlarının çeyrek dönemin ilk iki ayında gerçekleştirilen MIDAS yaklaşımlarından daha iyi tahmin performansına sahip oldukları anlaşılmaktadır. Böylelikle çeyrek dönem içerisinde yüksek frekanslı değişkenlerden daha fazla bilgi kullanılmasıyla daha tutarlı tahminlere ulaşılabileceği sonucuna varılabilir.



Tablo 12: Tahmin Hata Kriteri En Düşük Değer Alan Modeller

Kriter	Bağımsız Değişken	Horizon	Ağırlıklandırma Polinomu	Değer
Ortalama Mutlak Hata (MAE)	Δ LKAP	3. ay	U-MIDAS	0.01124
	Δ LKAP	3. ay	Basamak Ağırlıklı	0.01139
	Δ LKAP	1. ay	Basamak Ağırlıklı	0.01159
	Δ LKAP	1. ay	Üstel Almon	0.01168
	Δ LTÜFE	1. ay	U-MIDAS	0.01169
	Δ LM	3. ay	U-MIDAS	0.01171
	Δ LKAP	1. ay	U-MIDAS	0.01174
	Δ LSAN	1. ay	Üstel Almon	0.01186
	Δ LM	3. ay	Beta	0.01189
Ortalama Mutlak Yüzde Hata (MAPE)	Δ LKAP	3. ay	Geleneksel Almon	0.01198
	Δ LTÜFE	2. ay	Basamak Ağırlıklı	1.47812
	Δ LTÜFE	3. ay	Üstel Almon	2.41894
	Δ LTÜFE	2. ay	Geleneksel Almon	2.45373
	Δ LTÜFE	2. ay	Üstel Almon	2.58357
	Δ LTÜFE	2. ay	U-MIDAS	2.61747
	Δ LÜFE	2. ay	Üstel Almon	2.67671
	Δ LKAP	3. ay	Beta	2.73389
	Δ LTÜFE	2. ay	Beta	2.75551
Mutlak Ölçeklendirilmiş Hata Ortalaması (MASE)	Δ LKAP	2. ay	Basamak Ağırlıklı	2.90353
	Δ LTÜFE	1. ay	Üstel Almon	2.96867
	Δ LKAP	3. ay	U-MIDAS	0.52267
	Δ LKAP	3. ay	Basamak Ağırlıklı	0.52971
	Δ LKAP	1. ay	Basamak Ağırlıklı	0.53919
	Δ LKAP	1. ay	Üstel Almon	0.54313
	Δ LTÜFE	1. ay	U-MIDAS	0.54375
	Δ LM	3. ay	U-MIDAS	0.54449
	Δ LKAP	1. ay	U-MIDAS	0.54622
Ortalama Kare Öngörü Hatası (MSE)	Δ LSAN	1. ay	Üstel Almon	0.55165
	Δ LM	3. ay	Beta	0.553
	Δ LKAP	3. ay	Geleneksel Almon	0.55735
	Δ LM	3. ay	U-MIDAS	0.0002
	Δ LKAP	3. ay	U-MIDAS	0.00023
	Δ LSAN	3. ay	Beta	0.00023
	Δ LSAN	3. ay	Üstel Almon	0.00023
	Δ LM	3. ay	Beta	0.00023
	Δ LM	3. ay	Üstel Almon	0.00023
Ortalama Kare Öngörü Hatası (RMSE)	Δ LKAP	3. ay	Geleneksel Almon	0.00024
	Δ LKAP	2. ay	Geleneksel Almon	0.00026
	Δ LKAP	2. ay	U-MIDAS	0.00026
	Δ LKAP	2. ay	Beta	0.00027
	Δ LM	3. ay	U-MIDAS	0.01413
	Δ LSAN	3. ay	Beta	0.01501
	Δ LSAN	3. ay	Üstel Almon	0.01503
	Δ LM	3. ay	Beta	0.01507
	Δ LKAP	3. ay	U-MIDAS	0.01526
Δ LM	3. ay	Üstel Almon	0.01533	
Ortalama Kare Öngörü Hatası (RMSE)	Δ LKAP	3. ay	Geleneksel Almon	0.01543
	Δ LKAP	2. ay	U-MIDAS	0.01605
	Δ LKAP	2. ay	Geleneksel Almon	0.01609
	Δ LKAP	2. ay	Beta	0.01655

Not: Δ L, ilgili değişkenin logaritmik 1. devresel farkının alındığını belirtmektedir. KAP; imalat sanayi kapasite kullanım oranını, TÜFE; tüketici fiyat endeksini, ÜFE; üretici fiyat endeksini, SAN; sanayi üretim endeksini ve M; reel toplam ithalattı temsil etmektedir.

SONUÇ ve ÖNERİLER

Modern ekonomilerde tüketici, üretici, yatırımcı, politika yapıcıları ve uygulayıcıları gibi tüm iktisadi aktörler buldukları konuma ilişkin kararlar almadan önce iktisadi ve finansal değişkenlerin gelecekte nasıl bir seyir takip edeceklerini öngörmek isterler. Uygulamalı literatürde bu değişkenlerin öngörüsüne ilişkin tek değişkenli (*univariate*) ve çok değişkenli (*multivariate*) öngörü modelleri kullanılmaktadır. Bilindiği üzere geleneksel zaman serilerinde çok değişkenli modeller kullanıldığında modelde yer alan tüm değişkenlerin aynı frekansta olmaları gerekmektedir. Ancak iktisadi ve finansal değişkenler, aynı frekanslarda yayınlanmazlar. Literatürde söz konusu bu frekans farklılığını ortadan kaldırmak için çoğunlukla toplulaştırma işlemine başvurulmaktadır. Toplulaştırma işlemiyle modelde yer alan yüksek frekanslı değişken veya değişkenler modeldeki düşük frekanslı değişkenin frekansına dönüştürülmektedir. Fakat toplulaştırılmış değişkenlerin kullanılması, model tahminlerinin istatistiksel olarak sapmalı ve tutarsız olmasına yol açması olasıdır. Bununla birlikte toplulaştırma işlemi, yüksek frekanslı değişkendeki bilgilerin ortadan kaybolmasına neden olabilecektir.

Yukarıda değinilen toplulaştırma işleminin olumsuz yönleriyle birlikte çok değişkenli modellerin bir başka sorunu daha bulunmaktadır. Bu sorun, iktisadi ve finansal değişkenlerin farklı gecikmelerle açıklanmasıdır. Eğer çok değişkenli modellerde yer alan değişkenler farklı frekanslarda açıklanıyorsa söz konusu bu sorun, daha da ciddi olabilecektir. Çünkü bir değişkenin frekans seviyesi ne kadar düşükse o değişkenle ilgili bilgilerin derlenip, raporlanması ve yayınlanması daha fazla zaman alabilecektir. Bahsedilen yayın gecikmesi özellikle üçer aylık frekanslarda açıklanan GSYİH'de daha fazla görülmektedir. Örneğin Türkiye ekonomisinde cari döneme ait GSYİH verisi, bir sonraki çeyrek dönemin 2. veya 3. ayların son işlem günlerinde açıklanmaktadır. Ancak daha yüksek frekanslı değişkenlerde bu kadar yayın gecikmesi çoğunlukla yaşanmamaktadır. Hatta belli bir frekans seviyesinde verilerin açıklanması anlık olabilmektedir.

Bahsi geçen bu yayın gecikmelerinden dolayı geleneksel çok değişkenli öngörü modellerinde yüksek frekanslı değişkenlerin son gözlemlerinin kullanılamamasına neden olmaktadır. Eğer geleneksel çok değişkenli öngörü modelleriyle Türkiye ekonomisinin GSYİH büyüme oranı öngörüsü gerçekleştirilmek isteniliyorsa, GSYİH için ulaşılabilecek son gözlem değeri, ya bir önceki çeyrek dönem öncesine ya da iki çeyrek dönem öncesine ait olacaktır. Her ne kadar cari dönemde GSYİH verisi açıklanmış olmasa da yüksek frekanslı değişkenlerle ilgili verilere ulaşılabilecektir. Ancak cari dönemdeki yüksek frekanslı değişkene ait tüm verilere ulaşmak mümkün olmayacaktır. Bu nedenle cari dönemde yüksek frekanslı değişken toplulaştırılamayacaktır. Böylelikle cari

dönemdeki yüksek frekanslı bilgilerden yoksun bir şekilde GSYİH büyüme oranı öngörüsü gerçekleştirilecektir.

Zamansal toplulaştırma işleminin yukarıda bahsedilen bu olumsuz yönleri ve ayrıca değişkenlerin farklı zaman gecikmeleriyle açıklanması 2000'li yılların başlarından beri ilgili literatürde değinilmiş ve çözüm odaklı bir yöntem Ghysels ve diğerleri (2004) tarafından sunulmuştur. Ghysels ve diğerleri (2004)'nin sunmuş oldukları yöntem Karma Frekanslı Veri Örnekleme (*Mixed Data Sampling*, MIDAS) modeli olarak adlandırılmaktadır. Söz konusu bu model, bağımlı değişkenin düşük frekanslı olduğu, bağımsız değişken veya değişkenlerin daha yüksek frekanslı olduğu tek denklemlilikli bir yaklaşımdır. Böylelikle MIDAS yaklaşımıyla çok değişkenli bir modelde yüksek frekanslı değişken veya değişkenler toplulaştırma işlemine tabi tutulmadan daha düşük frekanslı değişkenlerle aynı modelde kullanılabilir. Bunun yanı sıra MIDAS modeliyle cari dönemdeki yüksek frekanslı bilgilerinden de faydalanılarak düşük frekanslı bir değişkenin daha tutarlı bir öngörüsü elde edilebilir. MIDAS modelinin ardından literatürde MIDAS modelinin çeşitli uzantıları da geliştirilmiştir. Hem MIDAS modeli hem de MIDAS modelinin uzantılarıyla öngörü literatüründe özellikle ekonomilerin GSYİH büyüme oranlarının anlık tahminlerine yoğunlaşmıştır.

MIDAS modelinin yeni yeni kullanılmaya başlanıldığı ilk zamanlarda çoğunlukla ABD ekonomisinin GSYİH büyüme oranının anlık tahmini ve öngörüsü üzerine durulmuştur. Daha sonralarda ise MIDAS yaklaşımıyla ABD dışındaki ülke ekonomilerinin GSYİH büyüme oranlarının anlık tahmini ve öngörüsü üzerine de uygulamalı çalışmaların gerçekleştirildiği görülmektedir. Söz konusu bu ülkeler arasında Türkiye ekonomisinin de yer aldığı dikkat çekmektedir. Ancak Türkiye ekonomisinin GSYİH büyüme oranı üzerine yapılan çalışmalarda genellikle örneklem sonu anlık tahminlerine yoğunlaşıldığı ve yok denilecek kadar az sayıda çalışmada ise örneklem içi anlık tahminlerin yapıldığı gözlemlenmektedir. Bu çalışmada ise MIDAS yaklaşımıyla Türkiye ekonomisinin üçer aylık frekanslı GSYİH büyüme oranının anlık tahmininin belirli bir zaman periyodunda gerçek zamanlı olarak uygulanmasına odaklanılmıştır. Üçer aylık frekanslı GSYİH büyüme oranının anlık tahmininde yedi farklı aylık frekanslı değişkenden faydalanılmıştır. Söz konusu bu değişkenler şunlardır: reel kesim güven endeksi, imalat sanayi kapasite kullanım oranı, sanayi üretim endeksi, tüketici fiyat endeksi, üretici fiyat endeksi, reel toplam ihracat ve reel toplam ithalat. Sıralanan bu aylık frekanslı değişkenlerin her biri için ayrı ayrı MIDAS modelleri kurularak, GSYİH büyüme oranının anlık tahminleri yapılmıştır.

Bahsi geçen bu anlık tahminlerin gerçekleştirilmesi için 2020 yılının Haziran ayının son işlem gününde elde edilebilen veri setlerinden yararlanılmış ve analizlerde yer alan değişkenlerin başlangıç noktaları 2007 yılı olmaktadır. Söz konusu bu başlangıç noktası, üçer ay frekanslı GSYİH için 2007'nin ilk çeyreği olurken; aylık frekanslı değişkenler için ise 2007'nin Ocak ayıdır. Ancak daha önce de bahsedildiği gibi iktisadi ve finansal değişkenlerin farklı gecikmelerle açıklanmasından

dolayı analizlerde yer alan değişkenlerin son gözlemleri aynı döneme denk gelmemektedir. Çalışmada üçer aylık frekanslı GSYİH'nin son gözlemi, 2020'nin ilk çeyrek dönemine aitken; aylık frekanslı değişkenlerin son gözlemleri ise sanayi üretim endeksi, reel toplam ihracat ve reel toplam ithalat için 2020'nin Nisan ayına, tüketici fiyat endeksi ve üretici fiyat endeksi için 2020'nin Mayıs ayına, reel kesim güven endeksi ve imalat sanayi kapasite kullanım oranı için 2020'nin Haziran ayına aittir.

Uygulamada 2015 yılı 1. çeyrek 2020 yılı 2. çeyrek dönemleri arasında her ayın son işlem gününde ulaşılabilen veri setleriyle GSYİH büyüme oranının anlık tahmini, gerçek zamanlı olarak gerçekleştirilmiştir. Bahsi geçen bu anlık tahminlerde, GSYİH mevsimsel etkilerden arındırıldıktan sonra logaritmik 1. devresel farkı alınarak dönemlik GSYİH büyüme oranı serisi oluşturulmuştur. GSYİH değişkeninde olduğu gibi aylık frekanslı değişkenler de mevsimsellikten arındırılarak logaritmik 1. devresel farkları alınmıştır. Söz konusu dönüşüm işlemi, anlık tahminlerin gerçekleştirildiği her dönemde ulaşılabilen veri setleriyle her zaman tekrarlanmıştır. Tüm bu işlemlerin ardından analizlerde kullanılacak olan tüm değişkenler ADF, PP ve KPSS birim kök testlerine tabi tutulmuşlar ve değişkenlerin logaritmik 1. devresel farklarının seviyelerinde durağan oldukları gözlemlenmiştir.

Çalışmada öncelikle 2015'in ocak ayının son işlem gününde bulunulduğu varsayılarak GSYİH büyüme oranının 2015 yılının 1. çeyrek dönemine ait anlık tahmini, MIDAS modelleriyle aylık frekanslı değişkenlerin her biriyle ayrı ayrı uygulanmıştır. Ardından 2015'in Şubat ve Mart aylarının son işlem günlerinde ulaşılabilen veri setleriyle GSYİH büyüme oranının 2015 yılının 1. çeyrek dönem anlık tahmini tekrarlanmıştır. Böylelikle çeyrek dönemin her üç ayı içinde GSYİH büyüme oranının 2015 yılı 1. çeyrek dönem anlık tahmini hesaplanmıştır. Söz konusu bu işlem, 2020'nin haziran ayına kadar sürdürülmüş ve 2015 yılı 1. çeyrek 2020 yılı 2. çeyrek dönemleri için GSYİH büyüme oranının anlık tahmin serileri oluşturulmuştur.

Oluşturulan bu MIDAS modellerinde yüksek frekanslı değişkenler, geleneksel Almon polinomu, üstel Almon polinomu, Beta, kısıtsız MIDAS (U-MIDAS) ve basamak ağırlıklı MIDAS ile ağırlıklandırılmıştır. Bahsi geçen bu ağırlıklandırma yöntemlerinden geleneksel Almon polinomu, U-MIDAS ve basamak ağırlıklı MIDAS için aylık frekanslı değişkenlerin maksimum gecikme uzunluğu yüksek frekansta 12 dönem olarak belirlenmiş ve optimal gecikme uzunlukları Schwarz bilgi kriteri ile tespit edilmiştir. Diğer ağırlıklandırma yöntemleri olan üstel Almon polinomu, Beta için ise herhangi bir maksimum gecikme uzunluğu belirlenmemiş olup bu değişkenlerin gecikme uzunlukları, 3 aylık gecikme olarak tercih edilmiştir.

Analizlerde MIDAS modelinin anlık tahmin performansını karşılaştırabilmek için aylık frekanslı değişkenlerin üçer aylık frekansta toplulaştırıldığı geleneksel yöntemle de GSYİH büyüme oranının öngörüsü yapılmıştır. Bu öngörülerde ilk olarak 2015'in ilk çeyreğinin son işlem gününde

bulunulduğu varsayılmıştır. İlgili dönemde aylık frekanslı değişkenler, üçer aylık frekansta toplulaştırıldıktan sonra her biriyle ayrı ayrı geleneksel modeller oluşturularak GSYİH büyüme oranının 2015 1. çeyrek dönemine ait büyüme oranı öngörülmüştür. Ardından 2015'in 2. çeyreğinin son işlem gününde benzer işlemler tekrarlanarak GSYİH büyüme oranının 2015'in 2. çeyrek dönem büyüme oranı öngörülmüştür. Söz konusu bu işlem 2020'nin 2. çeyreğine kadar sürdürülmüştür. Dolayısıyla toplulaştırılmış değişkenlerin kullanıldığı geleneksel modelle de 2015 yılı 1. çeyrek 2020 yılı 2. çeyrek dönemleri arasında GSYİH büyüme oranının öngörüsü elde edilmiştir. Yapılan bu öngörülerde üçer aylık frekanslı değişkenlerin gecikmelerinden yararlanılmıştır. Analizlerde maksimum gecikme uzunluğu 4 dönem kabul edilmiş ve optimal gecikme uzunluğu, Schwarz bilgi kriteriyle belirlenmiştir.

Uygulamada GSYİH büyüme oranının anlık tahminleri ve öngörü serileri oluşturulduktan sonra söz konusu anlık tahminlerin ve serilerin tahmin hata kriterleri hesaplanmıştır. Böylelikle MIDAS modelinin anlık tahmin performansı, geleneksel modelin öngörü performansı ile karşılaştırılmıştır. Çalışmada kullanılan tahmin hata kriterleri, ortalama mutlak hata (MAE), ortalama mutlak yüzde hata (MAPE), ortalama kare öngörü hatası (MSE) kök ortalama kare öngörü hatası (RMSE) ve mutlak ölçeklendirilmiş hata ortalaması (MASE)'dir.

Çalışmada genel olarak MIDAS modelinin anlık tahmin bulguları, toplulaştırılmış değişkenlerin yer aldığı geleneksel modelin öngörü sonuçlarından daha tutarlı olduğu ve gerçekleşen GSYİH büyüme oranını daha yakından takip ettiği tespit edilmiştir. Özellikle aylık frekanslı imalat sanayi kapasite kullanım oranının yer aldığı MIDAS modellerinin en iyi tahmin performansına sahip olduğu belirlenmiştir. Bunun nedeni olarak sanayi sektörünün, GSYİH içerisinde önemli bir paya sahip olması ve imalat sanayinin kapasite kullanım oranının, sanayi üretimindeki gelişmelerin öncü göstergesi olması gösterilebilir. Ayrıca kapasite kullanım oranının içinde bulunan aya ait verisinin o ayın son işlem günlerinde açıklanması da söz konusu bu değişkenin MIDAS modeliyle anlık tahmin performansını arttırdığı ifade edilebilir. Kapasite kullanım oranında olduğu gibi aylık frekanslı sanayi üretim endeksi, TÜFE ve reel toplam ithalat değişkenlerinin yer aldığı MIDAS modellerinin de çeyrek dönemin 3. aylarında iyi bir tahmin performansı sergilediği belirlenmiştir. Böyle bir sonucun çeyrek dönemin 3. aylarında elde edilme nedeni olarak söz konusu bu değişkenlerin 2 ay gecikmeli olarak açıklanması gösterilebilir. Çünkü cari dönemde bahsi geçen bu değişkenlerin o döneme ait ilk aydaki verilerine ilgili çeyrek dönemin son ayında ulaşılabilecektir.

Ayrıca çalışmanın analizlerinde yüksek frekanslı değişkenlerin ağırlıklandırılması için kullanılan polinomlar arasında U-MIDAS'ın diğerlerine göre biraz daha iyi performans sergilediği belirlenmiştir. Bununla birlikte çeyrek dönemin 3. aylarında uygulanan MIDAS modellerinin çeyrek dönemin ilk iki ayında uygulanan MIDAS modellerinden daha iyi performans sergilediği de saptanmıştır. Bu nedenle cari dönemde ne kadar çok yüksek frekanslı değişken bilgisi kullanılırsa o kadar tutarlı bir GSYİH büyüme oranı anlık tahminine ulaşılabileceği sonucuna varılabilir.

Uygulamada kullanılan hemen hemen her modelde 2020'nin 2. çeyreğinde Türkiye ekonomisinin GSYİH'de dönemlik bir daralmanın olacağı belirlenmiştir. Bu daralmanın MIDAS modellerinde daha şiddetli olabileceği anlık olarak tahmin edilmiştir. Böyle bir ekonomik daralmanın anlık tahmin edilmesinde 2019'un sonlarında başlayan ve 2020'nin 2. çeyreğinin başlarında ise neredeyse tüm dünya üzerinde etkisini gösteren pandemi dolayısıyla 2020 yılının 2. çeyreğinde ekonomik faaliyetlerin neredeyse durma noktasına gelmesi gösterilebilir. Söz konusu bu ekonomik daralma reel kesim güven endeksi ve imalat sanayi kapasite kullanım oranının yer aldığı MIDAS modellerinde çeyrek dönemin her üç ayında da ulaşılmıştır. Sanayi üretim endeksi, reel toplam ithalat ve reel toplam ihracat değişkenlerinin kullanıldığı MIDAS modellerinin ise çeyrek dönemin 3. aylarında uygulandıklarında bir ekonomik daralmanın anlık olarak tahmin edildiği görülmüştür. Söz konusu bu değişkenlerle ekonomik daralmanın 3. ayda anlık olarak tahmin edilmesinde bahsi geçen değişkenlerin gözlemlerine 2 ay gecikmeyle ulaşılabilmesi olduğu belirtilebilir. Öte yandan TÜFE ve ÜFE değişkenlerinin yer aldığı MIDAS modellerinde 2020'nin 2. çeyreğinde pozitif ekonomik büyümenin olacağı anlık olarak tahmin edilmiş ancak bu ekonomik büyüme oranının %2.5'i aşamadığı da belirlenmiştir.

Bu çalışmada, MIDAS modelleriyle aylık frekanslı değişkenler kullanılarak Türkiye ekonomisinin üçer ay frekanslı GSYİH büyüme oranı anlık tahminlerine odaklanılmıştır. Söz konusu bu anlık tahminler, aylık değişkenlerin üçer ay olarak toplulaştırılmış hallerinin bulunduğu geleneksel modellerin GSYİH büyüme oranı öngörülerıyla kıyaslanmıştır. Bu kıyaslama sonucunda MIDAS modellerinin genel olarak geleneksel modelden daha iyi performans sergilediği gözlemlenmiştir. Daha sonra yapılacak olan çalışmalarda öngörü literatürde son zamanlarda cezalandırılmış regresyon yaklaşımlarıyla MIDAS modellerinin bir arada kullanılmasından yola çıkılarak öngörü modeline olabildiğince çok sayıda yüksek frekanslı değişkenler dahil edilerek üçer aylık frekanslı GSYİH büyüme oranının daha tutarlı bir anlık tahmini elde edilmeye çalışılabilir.

YARARLANILAN KAYNAKLAR

- Almon, Shirley (1965), "The Distributed Lag Between Capital Appropriations and Expenditures", **Econometrica: Journal of the Econometric Society**, 33 (1), 178-196.
- Andersen, Torben G. vd. (2005), "Roughing it up: Including Jump Components in the Measurement, Modeling, and Forecasting of Return Volatility", **National Bureau of Economic Research**, Working Paper 11775, <https://www.nber.org/papers/w11775.pdf>, (25.02.2020),
- Andreou, Elena vd. (2010a), "Regression Models with Mixed Sampling Frequencies", **Journal of Econometrics**, 158 (2), 246-261.
- _____ (2010b). "Forecasting with Mixed-Frequency Data.", In the Oxford Handbook of Economic Forecasting.
- _____ (2013), "Should Macroeconomic Forecasters Use Daily Financial Data and How", **Journal of Business & Economic Statistics**, 31 (2), 240-251.
- Ankargren, Sebastian vd. (2019), "A Flexible Mixed-Frequency Vector Autoregression with a Steady-State Prior", **arXiv Preprint arXiv:1911.09151**, <https://arxiv.org/pdf/1911.09151.pdf> (18.11.2019)
- Antony, Jürgen ve Klarl, Torben (2016), "An EM-Algorithm for Maximum Likelihood Estimation of Vector Autoregressions with Mixed Frequency Data." https://www.wiwi.uni-augsburg.de/de/vwl/ei_vwl/Daten/Antony.pdf (13.12.2017)
- Armesto, Michelle vd. (2010), "Forecasting with Mixed Frequencies", **Federal Reserve Bank of St. Louis Review**, 92 (6), 521-36.
- Baffigi, Alberto vd. (2004), "Bridge Models to Forecast the EURO Area GDP." **International Journal of Forecasting**, 20 (3), 447-460.
- Bai, Jushan ve Ng, Serena (2002), "Determining the Number of Factors in Approximate Factor Models", **Econometrica**, 70 (1), 191-221.
- _____ (2008), "Forecasting Economic Time Series Using Targeted Predictors", **Journal of Econometrics**, 146 (2), 304-317.
- Bai, Jennie vd. (2013), "State Space Models and MIDAS Regressions", **Econometric Reviews**, 32 (8), 779-813.
- Banbura, Marta ve Rünstler, Gerhard (2007), "A Look into the Factor Model Black Box: Publication Lags and the Role of Hard and Soft Data in Forecasting GDP." **European Central Bank**, Working Paper No: 751.

- Barsoum, Fady ve Sandra Stankiewicz (2015), "Forecasting GDP Growth Using Mixed-Frequency Models with Switching Regimes" **International Journal of Forecasting**, 31(1), 33-50.
- Blasques, Francisco vd (2016), "Weighted Maximum Likelihood for Dynamic Factor Analysis and Forecasting with Mixed Frequency Data." **Journal of Econometrics**, 193(2), 405-417.
- Boivin, Jean ve Ng, Serena (2005), "Understanding and Comparing Factor-Based Forecasts", **National Bureau of Economic Research**, Working Paper No: 11285.
- Carriero, Andrea vd. (2015), "Realtime Nowcasting with a Bayesian Mixed Frequency Model with Stochastic Volatility", **Journal of the Royal Statistical Society: Series A (Statistics in Society)**, 178 (4), 837-862.
- _____ (2016), "Common Drifting Volatility in Large Bayesian VARs", **Journal of Business & Economic Statistics**, 34 (3), 375-390.
- Clements, Michael P. and Galvão Ana Beatriz (2008), "Macroeconomic Forecasting with Mixed-Frequency Data: Forecasting Output Growth in the United States", **Journal of Business & Economic Statistics**, 26 (4), 546-554.
- _____ (2009), "Forecasting US Output Growth Using Leading Indicators: An Appraisal Using MIDAS Models", **Journal of Applied Econometrics**, 24 (8), 1057-1217.
- Corsi, Fulvio (2004), "A Simple Long Memory Model of Realized Volatility." **University of Southern Switzerland**, 1-26, <https://www.realvol.com/HVOLPaper.pdf> , (25.02.2020).
- Den Reijer, Ard ve Johansson, Andreas (2019), "Nowcasting Swedish GDP with a Large and Unbalanced Data Set." **Empirical Economics**, 57(4), 1351-1373.
- Dickey, David A. ve Fuller, Wayne A. (1981), "Likelihood Ratio Statistics for Autoregressive Time Series with a Unit Root." **Econometrica: journal of the Econometric Society**, 49(4), 1057-1072.
- Diebold, Francis X. ve Mariano, Robert S. (2002), "Comparing Predictive Accuracy." **Journal of Business & economic Statistics**, 20(1), 134-144.
- Doz, Catherine, vd. (2006), "A Quasi–Maximum Likelihood Approach for Large, Approximate Dynamic Factor Models." **European Central Bank**, Working Paper No: 674.
- Ekinci, Aykut ve Sakarya, Burçhan (2020), "Özel Tüketim Talebinin Yüksek Frekans ve Şimdi Tahmin ile Modellenmesi." **Bankacılar Dergisi**, 113, 3-16.
- Erdoğan, Hamza (2020), "Türkiye'nin GSYİH Büyümesinin Karışık Veri Örnekleme (MIDAS) Yöntemi ile Öngörüsü", **Iğdır Üniversitesi Sosyal Bilimler Enstitüsü Dergisi**, 22, 519-541.
- Ferrara, Laurent ve Marsilli, Clément (2013), "Financial Variables as Leading Indicators of GDP Growth: Evidence from A MIDAS Approach During the Great Recession", **Applied Economics Letters**, 20 (3), 233-237.

- Foroni, Claudia vd. (2015), "Unrestricted Mixed Data Sampling (MIDAS): MIDAS Regressions with Unrestricted Lag Polynomials", **Journal of the Royal Statistical Society: Series A (Statistics in Society)**, 178 (1), 57-82.
- _____ (2018), "Using Low Frequency Information for Predicting High Frequency Variables." **International Journal of Forecasting**, 34(4), 774-787.
- Forsberg, Lars ve Ghysels, Eric (2007), "Why Do Absolute Returns Predict Volatility So Well?", **Journal of Financial Econometrics**, 5 (1), 31-67.
- Frale, Cecilia ve Libero Monteforte (2009), "FaMIDAS A Mixed Frequency Factor Model with MIDAS Structure", **Bank of Italy Temi di Discussione (Working Paper)** No, 788.
- Frasco, Michael (2019), "Metrics", **GitHub**, <https://github.com/mfrasco/Metrics> (24.07.2020).
- Galvão, Ana Beatriz (2013), "Changes in Predictive Ability with Mixed Frequency Data", **International Journal of Forecasting**, 29 (3), 395-410.
- Ghysels, Eric vd. (2004), "The MIDAS Touch: Mixed Data Sampling Regression Models", **Finance**, 1-31.
- _____ (2005), "There is a Risk-Return Trade-off After All", **Journal of Financial Economics**, 76 (3), 509-548.
- _____ (2007), "MIDAS Regressions: Further Results and New Directions", **Econometric Reviews**, 26 (1), 53-90.
- Ghysels, Eric ve Wright, Jonathan H. (2009) "Forecasting Professional Forecasters" **Journal of Business & Economic Statistics**, 27(4), 504-516.
- Ghysels, Eric (2016) "Macroeconomics and the Reality of Mixed Frequency Data" **Journal of Econometrics**, 193(2), 294-314.
- Ghysels, Eric vd. (2016a), "Testing For Granger Causality With Mixed Frequency Data". **Journal of Econometrics**, 192(1), 207-230.
- _____ (2016b), "Mixed Frequency Data Sampling Regression Models: the R Package MIDASr.", **Journal of Statistical Software**, 1-35.
- Ghysels, Eric (2017), "MIDAS Matlab Toolbox", <https://www.mathworks.com/matlabcentral/fileexchange/45150-MIDAS-matlab-toolbox> (15.09.2018).
- Giannone, Domenico vd. (2008), "Nowcasting: The Real-Time Informational Content of Macroeconomic Data", **Journal of Monetary Economics**, 55 (4), 665-676.
- Golinelli, Roberto ve Parigi, Giuseppe (2005) "Short-Run Italian GDP Forecasting and Real-Time Data"

- Götz, Thomas B. vd. (2016), "Testing for Granger Causality in Large Mixed-Frequency VARs." **Journal of Econometrics**, 193(2), 418-432.
- Granger, Clive William John (1988), "Aggregation of Time Series Variables: A Survey", **Institute for Empirical Macroeconomics Federal Reserve Bank of Minneapolis Discussion Paper**, 1, 1-25. <https://www.minneapolisfed.org/research/DP/DP1.pdf> (04.03.2020).
- Granger, Clive William John ve Pierre L. Siklos (1995), "Systematic Sampling, Temporal Aggregation, Seasonal Adjustment, and Cointegration Theory and Evidence", **Journal of Econometrics**, 66 (1-2), 357-369.
- Guérin, Pierre ve Massimiliano Marcellino (2013) "Markov-Switching MIDAS Models." **Journal of Business & Economic Statistics**, 31(1), 45-56.
- Hamner, Ben vd. (2018), "Metrics: Evaluation Metrics for Machine Learning", <https://cran.r-project.org/web/packages/Metrics/Metrics.pdf> (24.07.2020).
- Harvey, Andrew C. (1989), Forecasting, **Structural Time Series Models and the Kalman Filter**, Cambridge University Press, New York.
- Hogrefe, Jens (2008), "Forecasting data Revisions of GDP: a Mixed Frequency Approach", **AStA Advances in Statistical Analysis**, 92 (3), 271-296.
- Hyndman, Rob J. ve Koehler Anne B. (2006), "Another Look at Measures of Forecast Accuracy." **International Journal of Forecasting**, 22 (4), 679-688.
- Jiang, Yu vd. (2017), "Forecasting China's GDP Growth Using Dynamic Factors and Mixed-Frequency Data", **Economic Modelling**, 66, 132-138.
- Koenig, Evan F. vd. (2003), "The Use and Abuse of Real-Time Data in Economic Forecasting", **Review of Economics and Statistics**, 85 (3), 618-628.
- Kuzin, Vladimir vd. (2011), "MIDAS vs. Mixed-Frequency VAR: Nowcasting GDP in the Euro Area", **International Journal of Forecasting**, 27 (2), 529-542.
- _____ (2013), "Pooling Versus Model Selection for Nowcasting GDP With Many Predictors: Empirical Evidence for Six Industrialized Countries", **Journal of Applied Econometrics**, 28 (3), 392-411.
- Kwiatkowski, Denis vd. (1992) "Testing the Null Hypothesis of Stationarity Against the Alternative of a Unit Root." **Journal of Econometrics** 54(1-3), 159-178.
- Louzis, Dimitrios P. (2019), "Steady-State Modeling and Macroeconomic Forecasting Quality", **Journal of Applied Econometrics**, 34 (2), 285-314.
- Marcellino, Massimiliano (1999), "Some Consequences of Temporal Aggregation In Empirical Analysis", **Journal of Business & Economic Statistics**, 17 (1), 129-136.

- Marcellino, Massimiliano ve Schumacher, Christian (2010), "Factor MIDAS for Nowcasting and Forecasting with Ragged-Edge Data: A Model Comparison for German GDP", **Oxford Bulletin of Economics and Statistics**, 72 (4), 518-550.
- Mariano, Roberto S. ve Murasawa, Yasutomo (2003), "A New Coincident Index of Business Cycles Based on Monthly and Quarterly Series." **Journal of applied Econometrics**, 18(4), 427-443.
- _____ (2010), "A Coincident Index, Common Factors, and Monthly Real GDP." **Oxford Bulletin of Economics and Statistics**, 72(1), 27-46.
- Marsilli, Clément (2014), **Mixed-Frequency Modeling and Economic Forecasting**. Yayınlanmış Doktora Tezi, Université de Franche-Comté.
- Mikosch, Heiner ve Neuwirth, Stefan (2015), "Real-Time Forecasting with a MIDAS VAR.", **BOFIT Discussion Papers**.
- Mogliani, Matteo (2019), "Bayesian MIDAS Penalized Regressions: Estimation, Selection, and Prediction." **Banque De France Working Paper**, 713, 1-33, <https://entreprises.banque-france.fr/sites/default/files/medias/documents/wp-713.pdf> (03.03.2020).
- Monteforte, Libero ve Moretti, Gianluca (2013), "Real-Time Forecasts of Inflation: The Role of Financial Variables", **Journal of Forecasting**, 32 (1), 51-61.
- Nijman, Theo E., ve Palm, Franz C. (1990). "Predictive Accuracy Gain from Disaggregate Sampling in ARIMA Models." **Journal of Business & Economic Statistics**, 8 (4), 405-415.
- Nunes, Luis C. (2005), "Nowcasting Quarterly GDP Growth in a Monthly Coincident Indicator Model." **Journal of Forecasting**, 24(9), 575-592.
- Phillips, Peter CB ve Perron, Pierre (1998), "Testing for a Unit Root in Time Series Regression." **Biometrika**, 75(2), 335-346.
- Rünstler, Gerhard ve Sédillot, Franck (2003), "Short-Term Estimates of Euro Area Real GDP by Means of Monthly Data", No. 276. ECB working paper.
- Schorfheide, Frank ve Song, Dongho (2015), "Real-Time Forecasting with a Mixed-Frequency VAR", **Journal of Business & Economic Statistics**, 33 (3), 366-380.
- Schumacher, Christian ve Breitung, Jörg (2008), "Real-Time Forecasting of German GDP Based on a Large Factor Model with Monthly and Quarterly Data." **International Journal of Forecasting**, 24(3), 386-398.
- Schumacher, Christian (2016), "A Comparison of MIDAS and Bridge Equations", **International Journal of Forecasting**, 32 (2), 257-270.
- Silverstovs, Boriss (2017), "Short-Term Forecasting with Mixed-Frequency Data: a MIDASSO Approach", **Applied Economics**, 49 (14), 1326-1343.

- Stock, James H. ve Watson, Mark W. (1989), "New Indexes of Coincident and Leading Economic Indicators." **NBER Macroeconomics Annual**, 4, 351-394.
- _____ (1991), "A Probability Model of the Coincident Economic Indicators", Kajal Lahiri ve Geoffrey H. Moore (Ed.), **In Leading Economic Indicators: New Approaches and Forecasting Records** 1. Baskı içinde (63-89), Cambridge University Press, ABD.
- _____ (2002), "Macroeconomic Forecasting Using Diffusion Indexes." **Journal of Business & Economic Statistics**, 20 (2), 147-162.
- _____ (2010), "Distribution of Quarterly Values of GDP/GDI Across Months Within the Quarter." Research Memorandum https://www.princeton.edu/~mwatson/mgdp_gdi/Monthly_GDP_GDI_Sept19.pdf (15.07.2020).
- Şen Doğan, Bahar ve Midiliç, Murat (2016), "Forecasting Turkish Real GDP Growth in a Data Rich Environment", **Research and Monetary Policy Department, Central Bank of the Republic of Turkey**, 16 (12), 1-45.
- Tay, Anthony S. (2006), "Mixing Frequencies: Stock Returns as A Predictor of Real Output Growth", **Singapore Management University Working Paper**, 34, 1-30. https://ink.library.smu.edu.sg/soe_research/949/
- _____ (2007) "Financial Variables as Predictors of Real Output Growth", **Singapore Management University Working Paper**, 14, 1-29. http://ink.library.smu.edu.sg/soe_research/1058/
- TCMB (2020), "Elektronik Veri Dağıtım Sistemi", <https://evds2.tcmb.gov.tr> (30.06.2020).
- _____ (2020), "Veri Yayınlama Takvimi", <http://www3.tcmb.gov.tr/veriyaytakvim/takvim.php> (30.06.2020).
- TÜİK (2020), "Konularına Göre İstatistikler" <http://www.tuik.gov.tr/UstMenu.do?metod=kategorist> (30.06.2020).
- _____ (2020), "Ulusal Veri Yayınlama Takvimi", <http://www.tuik.gov.tr/takvim/tkvim.zul#tbl> (30.06.2020).
- Uematsu, Yoshimasa ve Tanaka, Shinya (2017), "Macroeconomic Forecasting and Variable Selection with a Very Large Number of Predictors: A Penalized Regression Approach" **Available at SSRN 2927876**.
- Villani, Mattias (2009). "Steady-State Priors for Vector Autoregressions", **Journal of Applied Econometrics**, 24(4), 630-650.
- Wei, William WS. (1982), "Comment: The Effects of Systematic Sampling and Temporal Aggregation on Causality—A Cautionary Note." **Journal of the American Statistical Association**, 77(378), 316-319.

- West, Kenneth D. (1996), "Asymptotic Inference About Predictive Ability." **Econometrica: Journal of the Econometric Society**, 64(5), 1067-1084.
- Xu, Qifa vd. (2018), "Group Penalized Unrestricted Mixed Data Sampling Model with Application to Forecasting US GDP Growth" **Economic Modelling**, 75, 221-236.
- Yamak, Nebiye vd. (2018), "Farklı Frekanslı Veriler Altında Ekonomik Büyüme Oranının Tahmini." **Ekonomi Bilimleri Dergisi**, 10 (1), 34-49.
- Zheng, Isabel Yi ve Rossiter, James (2006), "Using Monthly Indicators to Predict Quarterly GDP." **Bank of Canada**, Working Paper No. 2006-26.





EKLER

Ek 1: Birim Kök Test Sonuçları

Tablo 13: Aylık Frekanslı Reel Kesim Güven Endeksi için Birim Kök Test Sonuçları

Dönem	ADF			KPSS			PP			ADF			PP			KPSS		
	sabitli	trendli	sabitli	trendli	sabitli	trendli	sabitli	trendli	Dönem	sabitli	trendli	sabitli	trendli	sabitli	trendli	sabitli	trendli	sabitli
2015m01	-6.01***	-6.03	-5.91***	-5.91***	0.11***	0.07***	0.11***	0.07***	2017m10	-7.87***	-7.88***	-7.81***	-7.81***	-7.81***	-7.81***	0.11***	0.11***	0.06***
2015m02	-6.05	-6.03	-5.96***	-5.94***	0.11***	0.07***	0.11***	0.07***	2017m11	-7.87***	-7.85***	-7.82***	-7.82***	-7.82***	-7.82***	0.09***	0.09***	0.06***
2015m03	-5.85***	-5.88***	-5.76***	-5.74***	0.09***	0.08***	0.09***	0.08***	2017m12	-7.92***	-7.91***	-7.83***	-7.83***	-7.83***	-7.83***	0.09***	0.09***	0.06***
2015m04	-6.24***	-6.23	-6.16***	-6.14***	0.1***	0.08***	0.1***	0.08***	2018m01	-8.02***	-8.01***	-7.94***	-7.94***	-7.94***	-7.94***	0.1***	0.1***	0.06***
2015m05	-6.34***	-6.31	-6.25***	-6.22***	0.1***	0.07***	0.1***	0.07***	2018m02	-8.02***	-8.01***	-7.94***	-7.94***	-7.94***	-7.94***	0.09***	0.09***	0.06***
2015m06	-6.35***	-6.32	-6.31***	-6.28***	0.09***	0.07***	0.09***	0.07***	2018m03	-7.89***	-7.88***	-7.79***	-7.79***	-7.79***	-7.79***	0.09***	0.09***	0.06***
2015m07	-6.4***	-6.38	-6.36***	-6.34***	0.09***	0.07***	0.09***	0.07***	2018m04	-7.95***	-7.93***	-7.84***	-7.84***	-7.84***	-7.84***	0.09***	0.09***	0.06***
2015m08	-6.43***	-6.41	-6.39***	-6.37***	0.1***	0.07***	0.1***	0.07***	2018m05	-7.9***	-7.88***	-7.79***	-7.79***	-7.79***	-7.79***	0.08***	0.08***	0.06***
2015m09	-6.48***	-6.44	-6.43***	-6.4***	0.09***	0.07***	0.09***	0.07***	2018m06	-7.93***	-7.9***	-7.82***	-7.82***	-7.82***	-7.82***	0.08***	0.08***	0.06***
2015m10	-6.37***	-6.34	-6.33***	-6.3***	0.09***	0.07***	0.09***	0.07***	2018m07	-8.25***	-8.22***	-8.17***	-8.17***	-8.17***	-8.17***	0.07***	0.07***	0.06***
2015m11	-6.43***	-6.43	-6.38***	-6.39***	0.1***	0.07***	0.1***	0.07***	2018m08	-7.98***	-7.95***	-7.87***	-7.87***	-7.87***	-7.87***	0.07***	0.07***	0.06***
2015m12	-6.73***	-6.72	-6.68***	-6.66***	0.1***	0.07***	0.1***	0.07***	2018m09	-7.94***	-7.9***	-7.81***	-7.81***	-7.81***	-7.81***	0.07***	0.07***	0.07***
2016m01	-6.78***	-6.77	-6.72***	-6.72***	0.1***	0.07***	0.1***	0.07***	2018m10	-8.14***	-8.11***	-8.03***	-8.03***	-8.03***	-8.03***	0.07***	0.07***	0.07***
2016m02	-6.85***	-6.83	-6.8***	-6.78***	0.1***	0.07***	0.1***	0.07***	2018m11	-8.24***	-8.21***	-8.13***	-8.13***	-8.13***	-8.13***	0.07***	0.07***	0.06***
2016m03	-6.79***	-6.77	-6.75***	-6.72***	0.09***	0.07***	0.09***	0.07***	2018m12	-8.31***	-8.29***	-8.22***	-8.22***	-8.22***	-8.22***	0.07***	0.07***	0.06***
2016m04	-6.85***	-6.82	-6.8***	-6.78***	0.09***	0.07***	0.09***	0.07***	2019m01	-8.35***	-8.32***	-8.24***	-8.24***	-8.24***	-8.24***	0.07***	0.07***	0.06***
2016m05	-6.86***	-6.83	-6.82***	-6.79***	0.09***	0.07***	0.09***	0.07***	2019m02	-8.4***	-8.37***	-8.31***	-8.31***	-8.31***	-8.31***	0.07***	0.07***	0.06***
2016m06	-6.91***	-6.89	-6.86***	-6.84***	0.09***	0.07***	0.09***	0.07***	2019m03	-8.45***	-8.43***	-8.34***	-8.34***	-8.34***	-8.34***	0.07***	0.07***	0.06***
2016m07	-6.93***	-6.91	-6.88***	-6.86***	0.09***	0.07***	0.09***	0.07***	2019m04	-8.46***	-8.44***	-8.35***	-8.35***	-8.35***	-8.35***	0.07***	0.07***	0.06***
2016m08	-6.98***	-6.96	-6.94***	-6.91***	0.09***	0.07***	0.09***	0.07***	2019m05	-8.5***	-8.47***	-8.38***	-8.38***	-8.38***	-8.38***	0.07***	0.07***	0.06***
2016m09	-7.15***	-7.14	-7.1***	-7.1***	0.09***	0.06***	0.09***	0.06***	2019m06	-8.6***	-8.58***	-8.5***	-8.5***	-8.5***	-8.5***	0.07***	0.07***	0.06***
2016m10	-7.2***	-7.18	-7.14***	-7.13***	0.09***	0.06***	0.09***	0.06***	2019m07	-8.69***	-8.66***	-8.62***	-8.62***	-8.62***	-8.62***	0.07***	0.07***	0.06***
2016m11	-7.27***	-7.26	-7.22***	-7.21***	0.1***	0.06***	0.1***	0.06***	2019m08	-8.66***	-8.64***	-8.57***	-8.57***	-8.57***	-8.57***	0.07***	0.07***	0.06***
2016m12	-7.34***	-7.31	-7.3***	-7.28***	0.09***	0.06***	0.09***	0.06***	2019m09	-8.76***	-8.74***	-8.69***	-8.69***	-8.69***	-8.69***	0.07***	0.07***	0.06***
2017m01	-7.32***	-7.29	-7.28***	-7.25***	0.08***	0.07***	0.08***	0.07***	2019m10	-8.73***	-8.72***	-8.64***	-8.64***	-8.64***	-8.64***	0.07***	0.07***	0.05***
2017m02	-7.36***	-7.36	-7.4***	-7.4***	0.09***	0.06***	0.09***	0.06***	2019m11	-9.12***	-9.1***	-9.07***	-9.07***	-9.07***	-9.07***	0.07***	0.07***	0.05***
2017m03	-7.55***	-7.53	-7.51***	-7.49***	0.09***	0.06***	0.09***	0.06***	2019m12	-9.12***	-9.11***	-9.13***	-9.13***	-9.13***	-9.13***	0.07***	0.07***	0.05***
2017m04	-7.6***	-7.58	-7.56***	-7.55***	0.09***	0.06***	0.09***	0.06***	2020m01	-9.19***	-9.18***	-9.19***	-9.19***	-9.19***	-9.19***	0.07***	0.07***	0.05***
2017m05	-7.52***	-7.49	-7.48***	-7.45***	0.08***	0.06***	0.08***	0.06***	2020m02	-9.24***	-9.22***	-9.24***	-9.24***	-9.24***	-9.24***	0.07***	0.07***	0.05***
2017m06	-7.54***	-7.54	-7.5***	-7.5***	0.09***	0.06***	0.09***	0.06***	2020m03	-9.21***	-9.2***	-9.25***	-9.25***	-9.25***	-9.25***	0.05***	0.05***	0.05***
2017m07	-7.75***	-7.73	-7.67***	-7.66***	0.09***	0.06***	0.09***	0.06***	2020m04	-6.09***	-6.05***	-5.98***	-5.98***	-5.98***	-5.98***	0.12***	0.12***	0.08***
2017m08	-7.77***	-7.77	-7.74***	-7.74***	0.1***	0.06***	0.1***	0.06***	2020m05	-11.09***	-11.06***	-11.06***	-11.06***	-11.06***	-11.06***	0.07***	0.07***	0.07***
2017m09	-7.86***	-7.86	-7.83***	-7.83***	0.1***	0.06***	0.1***	0.06***	2020m06	-9.09***	-9.05***	-9.98***	-9.98***	-9.98***	-9.98***	0.04***	0.04***	0.04***

Not: İlgili değişken, mevsimsellikten arındırılarak doğal logaritmik farkı alınmıştır. ***, **, * ve srasıyla %1, %5 ve %10 anlamlılık düzeylerinde serilerin durağan olduklarını ifade eder. AL, ilgili değişkenin logaritmik 1. devresel farkının alındığı belirtilmektedir. ADF birim kök testi sonucundaki () , optimal gecikme uzunluklarını; PP ve KPSS birim kök test sonuçlarındaki [] ise bant genişliğini göstermektedir.

Tablo 14: Aylık Frekanslı İmalat Sanayi Kapasite Kullanım Oranı için Birim Kök Test Sonuçları

Dönem	ADF			PP			KPSS			ADF			PP			KPSS		
	sabitli	trendli	sabitli	trendli	sabitli	trendli	sabitli	trendli	Dönem	sabitli	trendli	sabitli	trendli	sabitli	trendli	sabitli	trendli	
2015m01	-8.23***	-8.26***	-8.42***	-8.43***	0.13***	0.08***	-10.03***	-10.11***	2017m10	-10.03***	-10.11***	-10.26***	-10.29***	0.15***	0.06***	0.15***	0.06***	
2015m02	-8.21***	-8.26***	-8.41***	-8.44***	0.14***	0.07***	-10.09***	-10.17***	2017m11	-10.09***	-10.17***	-10.31***	-10.37***	0.16***	0.06***	0.16***	0.06***	
2015m03	-8.33***	-8.36***	-8.51***	-8.53***	0.14***	0.07***	-10.18***	-10.24***	2017m12	-10.18***	-10.24***	-10.41***	-10.43***	0.15***	0.06***	0.15***	0.06***	
2015m04	-8.32***	-8.39***	-8.54***	-8.58***	0.15***	0.07***	-10.23***	-10.3***	2018m01	-10.23***	-10.3***	-10.46***	-10.48***	0.15***	0.06***	0.15***	0.06***	
2015m05	-8.41***	-8.48***	-8.62***	-8.66***	0.16***	0.07***	-10.27***	-10.34***	2018m02	-10.27***	-10.34***	-10.5***	-10.54***	0.15***	0.06***	0.15***	0.06***	
2015m06	-8.47***	-8.51***	-8.65***	-8.68***	0.15***	0.07***	-10.31***	-10.38***	2018m03	-10.31***	-10.38***	-10.54***	-10.58***	0.15***	0.06***	0.15***	0.06***	
2015m07	-8.52***	-8.59***	-8.71***	-8.76***	0.15***	0.07***	-10.29***	-10.32***	2018m04	-10.29***	-10.32***	-10.53***	-10.54***	0.13***	0.07***	0.13***	0.07***	
2015m08	-8.57***	-8.59***	-8.77***	-8.78***	0.13***	0.07***	-10.42***	-10.45***	2018m05	-10.42***	-10.45***	-10.65***	-10.66***	0.13***	0.07***	0.13***	0.07***	
2015m09	-8.75***	-8.81***	-8.94***	-8.98***	0.15***	0.07***	-10.46***	-10.5***	2018m06	-10.46***	-10.5***	-10.69***	-10.71***	0.13***	0.07***	0.13***	0.07***	
2015m10	-8.9***	-8.94***	-9.09***	-9.11***	0.14***	0.07***	-10.56***	-10.58***	2018m07	-10.56***	-10.58***	-10.79***	-10.79***	0.12***	0.07***	0.12***	0.07***	
2015m11	-8.96***	-9.02***	-9.15***	-9.19***	0.15***	0.07***	-10.62***	-10.65***	2018m08	-10.62***	-10.65***	-10.85***	-10.86***	0.13***	0.07***	0.13***	0.07***	
2015m12	-9.02***	-9.08***	-9.21***	-9.25***	0.15***	0.07***	-10.68***	-10.68***	2018m09	-10.68***	-10.68***	-10.92***	-10.91***	0.11***	0.07***	0.11***	0.07***	
2016m01	-9.06***	-9.13***	-9.25***	-9.3***	0.16***	0.07***	-10.65***	-10.64***	2018m10	-10.65***	-10.64***	-10.89***	-10.87***	0.11***	0.08***	0.11***	0.08***	
2016m02	-9.14***	-9.21***	-9.33***	-9.38***	0.16***	0.07***	-10.63***	-10.6***	2018m11	-10.63***	-10.6***	-10.88***	-10.86***	0.11***	0.08***	0.11***	0.08***	
2016m03	-9.17***	-9.24***	-9.36***	-9.42***	0.16***	0.06***	-10.76***	-10.75***	2018m12	-10.76***	-10.75***	-11***	-10.98***	0.11***	0.08***	0.11***	0.08***	
2016m04	-9.22***	-9.27***	-9.42***	-9.45***	0.14***	0.07***	-10.75***	-10.74***	2019m01	-10.75***	-10.74***	-10.97***	-10.93***	0.11***	0.07***	0.11***	0.07***	
2016m05	-9.29***	-9.34***	-9.48***	-9.51***	0.14***	0.07***	-10.83***	-10.82***	2019m02	-10.83***	-10.82***	-11.04***	-11.03***	0.11***	0.07***	0.11***	0.07***	
2016m06	-9.33***	-9.38***	-9.52***	-9.55***	0.14***	0.07***	-10.85***	-10.85***	2019m03	-10.85***	-10.85***	-11.07***	-11.07***	0.11***	0.07***	0.11***	0.07***	
2016m07	-9.37***	-9.41***	-9.56***	-9.59***	0.14***	0.07***	-10.88***	-10.88***	2019m04	-10.88***	-10.88***	-11.1***	-11.1***	0.11***	0.07***	0.11***	0.07***	
2016m08	-9.3***	-9.33***	-9.5***	-9.51***	0.13***	0.07***	-10.91***	-10.92***	2019m05	-10.91***	-10.92***	-11.14***	-11.14***	0.11***	0.07***	0.11***	0.07***	
2016m09	-9.43***	-9.49***	-9.66***	-9.67***	0.14***	0.07***	-10.95***	-10.96***	2019m06	-10.95***	-10.96***	-11.18***	-11.18***	0.11***	0.07***	0.11***	0.07***	
2016m10	-9.52***	-9.57***	-9.73***	-9.75***	0.14***	0.07***	-10.98***	-10.99***	2019m07	-10.98***	-10.99***	-11.21***	-11.21***	0.11***	0.07***	0.11***	0.07***	
2016m11	-9.57***	-9.62***	-9.78***	-9.8***	0.14***	0.07***	-11.01***	-11.02***	2019m08	-11.01***	-11.02***	-11.24***	-11.24***	0.11***	0.07***	0.11***	0.07***	
2016m12	-9.61***	-9.66***	-9.82***	-9.84***	0.14***	0.07***	-11.04***	-11.05***	2019m09	-11.04***	-11.05***	-11.27***	-11.27***	0.11***	0.07***	0.11***	0.07***	
2017m01	-9.66***	-9.72***	-9.88***	-9.89***	0.14***	0.06***	-11.09***	-11.1***	2019m10	-11.09***	-11.1***	-11.32***	-11.32***	0.11***	0.07***	0.11***	0.07***	
2017m02	-9.71***	-9.77***	-9.92***	-9.95***	0.15***	0.06***	-11.13***	-11.14***	2019m11	-11.13***	-11.14***	-11.36***	-11.36***	0.11***	0.07***	0.11***	0.07***	
2017m03	-9.75***	-9.82***	-9.97***	-10***	0.15***	0.06***	-11.12***	-11.15***	2019m12	-11.12***	-11.15***	-11.36***	-11.38***	0.12***	0.06***	0.12***	0.06***	
2017m04	-9.79***	-9.86***	-10.01***	-10.04***	0.15***	0.06***	-11.19***	-11.21***	2020m01	-11.19***	-11.21***	-11.42***	-11.43***	0.11***	0.07***	0.11***	0.07***	
2017m05	-9.84***	-9.9***	-10.05***	-10.08***	0.15***	0.06***	-11.25***	-11.27***	2020m02	-11.25***	-11.27***	-11.49***	-11.49***	0.11***	0.06***	0.11***	0.06***	
2017m06	-9.87***	-9.93***	-10.09***	-10.11***	0.15***	0.06***	-11.33***	-11.34***	2020m03	-11.33***	-11.34***	-11.56***	-11.56***	0.11***	0.07***	0.11***	0.07***	
2017m07	-9.93***	-9.98***	-10.15***	-10.16***	0.14***	0.06***	-11.33***	-11.34***	2020m04	-11.33***	-11.34***	-11.56***	-11.56***	0.11***	0.07***	0.11***	0.07***	
2017m08	-9.95***	-10.01***	-10.17***	-10.19***	0.14***	0.06***	-11.88***	-11.87***	2020m05	-11.88***	-11.87***	-11.93***	-11.93***	0.14***	0.12***	0.14***	0.12***	
2017m09	-10.01***	-10.07***	-10.23***	-10.25***	0.14***	0.06***	-11.72***	-11.69***	2020m06	-11.72***	-11.69***	-11.69***	-11.66***	0.11***	0.13***	0.11***	0.13***	

Not: İlgili değişken, mevsimsellikten arındırılarak doğal logaritmik farkı alınmıştır. ***, **, * ve ' sırasıyla %1, %5 ve %10 anlamlılık düzeylerinde serilerin durağan olduklarını ifade eder. ΔL_t, ilgili değişkenin logaritmik ΔL_t devresel farkının alındığını belirtmektedir. ADF birim kök testi sonucundaki () , optimal gecikme uzunluklarını; PP ve KPSS birim kök test sonuçlarındaki [] ise bant genişliğini göstermektedir.

Tablo 15: Aylık Frekanslı TÜFE için Birim Kök Test Sonuçları

Dönem	ADF			PP			KPSS			ADF			PP			KPSS						
	sabitli	trendli	sabitli	trendli	sabitli	trendli	sabitli	trendli	sabitli	trendli	sabitli	trendli	sabitli	trendli	sabitli	trendli	sabitli	trendli				
2015m01	-8.53***	(0)	-8.5***	(2)	-8.5***	(2)	0.05***	(2)	0.04***	(2)	0.05***	(2)	-9.55***	(0)	-9.52***	(0)	-9.73***	(16)	0.08***	(10)	0.05***	(10)
2015m02	-8.58***	(0)	-8.58***	(2)	-8.57***	(2)	0.05***	(3)	0.04***	(3)	0.05***	(3)	-9.56***	(0)	-9.55***	(0)	-9.64***	(16)	0.1***	(10)	0.06***	(11)
2015m03	-8.84***	(0)	-8.83***	(0)	-8.82***	(2)	0.05***	(3)	0.04***	(2)	0.05***	(3)	-9.52***	(0)	-9.55***	(0)	-9.44***	(15)	0.14***	(10)	0.07***	(10)
2015m04	-8.86***	(0)	-8.83***	(0)	-8.82***	(2)	0.04***	(2)	0.03***	(2)	0.04***	(2)	-9.5***	(0)	-9.52***	(0)	-9.37***	(14)	0.15***	(9)	0.08***	(10)
2015m05	-8.72***	(0)	-8.68***	(0)	-8.68***	(2)	0.04***	(2)	0.04***	(2)	0.04***	(2)	-9.55***	(0)	-9.53***	(0)	-9.53***	(16)	0.11***	(10)	0.06***	(11)
2015m06	-8.78***	(0)	-8.74***	(0)	-8.74***	(2)	0.04***	(6)	0.04***	(6)	0.04***	(6)	-9.77***	(0)	-9.77***	(0)	-9.78***	(15)	0.13***	(10)	0.07***	(11)
2015m07	-8.89***	(0)	-8.85***	(0)	-8.79***	(10)	0.04***	(8)	0.04***	(8)	0.04***	(8)	-9.78***	(0)	-9.79***	(0)	-9.76***	(15)	0.14***	(9)	0.07***	(10)
2015m08	-8.84***	(0)	-8.8***	(0)	-8.75***	(11)	0.04***	(8)	0.04***	(8)	0.04***	(8)	-9.69***	(0)	-9.72***	(0)	-9.54***	(14)	0.18***	(9)	0.08***	(10)
2015m09	-8.89***	(0)	-8.86***	(0)	-8.85***	(11)	0.04***	(8)	0.04***	(8)	0.04***	(8)	-9.51***	(0)	-9.59***	(0)	-9.27***	(14)	0.24***	(9)	0.09***	(10)
2015m10	-9.06***	(0)	-9.02***	(0)	-9.01***	(10)	0.04***	(8)	0.04***	(8)	0.04***	(8)	-8.34***	(0)	-8.53***	(0)	-8.3***	(8)	0.37***	(4)	0.13***	(6)
2015m11	-9.15***	(0)	-9.11***	(0)	-9.1***	(10)	0.04***	(8)	0.04***	(8)	0.04***	(8)	-9.2***	(0)	-9.39***	(0)	-9.17***	(9)	0.37***	(3)	0.13***	(5)
2015m12	-9.09***	(0)	-9.05***	(0)	-9.03***	(10)	0.04***	(7)	0.04***	(7)	0.04***	(7)	-8.76***	(0)	-9.06***	(0)	-8.84***	(4)	0.57***	(1)	0.17***	(2)
2016m01	-9.18***	(0)	-9.14***	(0)	-9.13***	(10)	0.04***	(7)	0.04***	(8)	0.04***	(7)	-5.26***	(0)	-5.69***	(0)	-5.39***	(3)	0.52***	(6)	0.19***	(5)
2016m02	-9.2***	(0)	-9.15***	(0)	-9.09***	(10)	0.04***	(7)	0.04***	(7)	0.04***	(7)	-8.23***	(0)	-8.66***	(0)	-8.32***	(3)	0.874***	(3)	0.53***	(6)
2016m03	-9.31***	(0)	-9.26***	(0)	-9.26***	(10)	0.04***	(7)	0.04***	(8)	0.04***	(7)	-4.47***	(2)	-4.9***	(2)	-8.34***	(1)	0.495***	(6)	0.2***	(5)
2016m04	-9.14***	(0)	-9.11***	(0)	-9.05***	(11)	0.04***	(8)	0.04***	(8)	0.04***	(8)	-8.37***	(0)	-8.3***	(1)	-8.28***	(3)	0.44***	(4)	0.14***	(1)
2016m05	-9.16***	(0)	-9.15***	(0)	-9.07***	(11)	0.05***	(8)	0.04***	(8)	0.05***	(8)	-8.51***	(0)	-8.68***	(0)	-8.45***	(3)	0.41***	(3)	0.12***	(1)
2016m06	-9.25***	(0)	-9.24***	(0)	-9.17***	(10)	0.05***	(7)	0.04***	(7)	0.05***	(7)	-8.52***	(0)	-8.68***	(0)	-8.45***	(3)	0.39***	(3)	0.11***	(1)
2016m07	-9.25***	(0)	-9.22***	(0)	-9.26***	(12)	0.04***	(8)	0.03***	(8)	0.04***	(8)	-8.57***	(0)	-8.45***	(1)	-8.45***	(4)	0.43***	(3)	0.12***	(1)
2016m08	-9.06***	(0)	-9.02***	(0)	-9.05***	(13)	0.04***	(10)	0.04***	(10)	0.04***	(10)	-8.59***	(0)	-8.81***	(0)	-8.48***	(4)	0.47***	(3)	0.13***	(1)
2016m09	-9.35***	(0)	-9.31***	(0)	-9.73***	(14)	0.04***	(10)	0.04***	(10)	0.04***	(10)	-8.66***	(0)	-8.91***	(0)	-8.56***	(4)	0.51***	(3)	0.14***	(1)
2016m10	-9.42***	(0)	-9.38***	(0)	-9.82***	(14)	0.05***	(11)	0.04***	(11)	0.05***	(11)	-8.84***	(0)	-8.64***	(1)	-8.77***	(3)	0.5***	(3)	0.13***	(1)
2016m11	-9.4***	(0)	-9.38***	(0)	-9.9***	(15)	0.05***	(11)	0.04***	(11)	0.05***	(11)	-8.8***	(0)	-8.67***	(1)	-8.72***	(3)	0.53***	(3)	0.17***	(0)
2016m12	-9.46***	(0)	-9.43***	(0)	-10.02***	(15)	0.05***	(11)	0.04***	(11)	0.05***	(11)	-8.95***	(0)	-8.84***	(1)	-8.87***	(2)	0.53***	(3)	0.16***	(0)
2017m01	-9.14***	(0)	-9.09***	(0)	-9.61***	(18)	0.07***	(13)	0.06***	(13)	0.07***	(13)	-8.88***	(0)	-8.85***	(1)	-8.8***	(2)	0.54***	(3)	0.16***	(0)
2017m02	-9.32***	(0)	-9.28***	(0)	-9.92***	(18)	0.07***	(12)	0.06***	(12)	0.07***	(12)	-8.98***	(0)	-9.24***	(0)	-8.91***	(3)	0.55***	(3)	0.16***	(0)
2017m03	-9.21***	(0)	-9.19***	(0)	-9.34***	(16)	0.08***	(11)	0.06***	(10)	0.08***	(11)	-9.17***	(0)	-8.9***	(1)	-9.23***	(1)	0.52***	(4)	0.15***	(0)
2017m04	-9.27***	(0)	-9.25***	(0)	-9.3***	(15)	0.08***	(9)	0.06***	(10)	0.08***	(9)	-9.1***	(0)	-8.96***	(1)	-9.01***	(2)	0.55***	(4)	0.15***	(0)
2017m05	-9.36***	(0)	-9.34***	(0)	-9.4***	(14)	0.08***	(9)	0.05***	(9)	0.08***	(9)	-9.15***	(0)	-8.99***	(1)	-9.19***	(1)	0.56***	(4)	0.15***	(0)
2017m06	-9.39***	(0)	-9.37***	(0)	-9.43***	(14)	0.08***	(9)	0.06***	(10)	0.08***	(9)	-9.17***	(0)	-9.05***	(1)	-9.24***	(1)	0.58***	(4)	0.12***	(1)
2017m07	-9.37***	(0)	-9.34***	(0)	-9.55***	(15)	0.07***	(10)	0.05***	(10)	0.07***	(10)	-9.22***	(0)	-9.08***	(1)	-9.29***	(1)	0.58***	(4)	0.11***	(1)
2017m08	-9.41***	(0)	-9.37***	(0)	-9.61***	(15)	0.07***	(10)	0.05***	(10)	0.07***	(10)	-9.29***	(0)	-9.09***	(1)	-9.35***	(1)	0.56***	(4)	0.14***	(0)
2017m09	-9.54***	(0)	-9.51***	(0)	-9.74***	(15)	0.07***	(10)	0.05***	(10)	0.07***	(10)	-9.33***	(0)	-9.1***	(1)	-9.39***	(1)	0.6***	(4)	0.14***	(0)

Not: İlgili değişken, mevsimsellikten arındırılarak doğal logaritmik farkı alınmıştır. ***, ** ve * sırasıyla %1, %5 ve %10 anlamlılık düzeylerinde serilerin durağan olduklarını ifade eder. ΔL, ilgili değişkenin logaritmik farkıdır. I. devresel farkın alındığını belirtmektedir. ADF birim kök testi sonucundaki () ise bant genişliğini göstermektedir.

Tablo 16: Aylık Frekanslı ÜFE için Birim Kök Test Sonuçları

Dönem	ADF			PP			KPSS			ADF			PP			KPSS						
	sabitli	trendli	trendli	sabitli	trendli	trendli	sabitli	trendli	trendli	sabitli	trendli	trendli	sabitli	trendli	trendli	sabitli	trendli	trendli				
2015m01	-7.35***	(0)	-7.31***	(0)	-7.43***	(3)	-7.36***	(3)	0.04***	(5)	0.04***	(5)	-7.94***	(0)	-7.92***	(0)	-8.02***	(4)	0.07***	(5)	0.04***	(5)
2015m02	-7.2***	(0)	-7.19***	(0)	-7.27***	(3)	-7.25***	(3)	0.05***	(5)	0.05***	(5)	-7.98***	(0)	-7.96***	(0)	-8.07***	(4)	0.07***	(5)	0.04***	(5)
2015m03	-7.42***	(0)	-7.4***	(0)	-7.47***	(3)	-7.45***	(3)	0.05***	(5)	0.05***	(5)	-7.65***	(0)	-7.68***	(0)	-7.79***	(4)	0.11***	(5)	0.06***	(5)
2015m04	-7.5***	(0)	-7.48***	(0)	-7.55***	(3)	-7.53***	(3)	0.05***	(5)	0.04***	(4)	-7.78***	(0)	-7.8***	(0)	-7.9***	(4)	0.12***	(5)	0.06***	(5)
2015m05	-7.48***	(0)	-7.45***	(0)	-7.49***	(2)	-7.45***	(2)	0.04***	(4)	0.04***	(4)	-7.85***	(0)	-7.86***	(0)	-7.95***	(4)	0.11***	(5)	0.06***	(5)
2015m06	-7.4***	(0)	-7.37***	(0)	-7.45***	(3)	-7.42***	(3)	0.04***	(4)	0.04***	(4)	-7.89***	(0)	-7.94***	(0)	-8.01***	(5)	0.15***	(6)	0.06***	(6)
2015m07	-7.53***	(0)	-7.49***	(0)	-7.59***	(5)	-7.55***	(5)	0.04***	(4)	0.04***	(4)	-8.06***	(0)	-8.11***	(0)	-8.17***	(5)	0.16***	(6)	0.07***	(6)
2015m08	-7.56***	(0)	-7.52***	(0)	-7.66***	(4)	-7.62***	(4)	0.04***	(4)	0.04***	(4)	-7.89***	(0)	-7.98***	(0)	-8.05***	(5)	0.2***	(6)	0.08***	(6)
2015m09	-7.68***	(0)	-7.64***	(0)	-7.74***	(5)	-7.7***	(5)	0.04***	(4)	0.04***	(4)	-7.35***	(0)	-7.51***	(0)	-7.6***	(5)	0.27***	(6)	0.1***	(6)
2015m10	-7.73***	(0)	-7.69***	(0)	-7.79***	(5)	-7.75***	(5)	0.04***	(4)	0.04***	(4)	-6.93***	(0)	-7.16***	(0)	-7.28***	(6)	0.33***	(6)	0.12***	(6)
2015m11	-7.78***	(0)	-7.74***	(0)	-7.84***	(5)	-7.8***	(5)	0.04***	(4)	0.04***	(4)	-7.1***	(0)	-7.33***	(0)	-7.45***	(6)	0.34***	(7)	0.12***	(6)
2015m12	-7.75***	(0)	-7.7***	(0)	-7.79***	(5)	-7.75***	(5)	0.04***	(4)	0.04***	(4)	-5.76***	(0)	-6.17***	(0)	-6.76***	(7)	0.43***	(7)	0.15***	(7)
2016m01	-7.77***	(0)	-7.74***	(0)	-7.82***	(5)	-7.79***	(5)	0.04***	(4)	0.04***	(4)	-3.32***	(0)	-3.79***	(0)	-3.95***	(6)	0.5***	(7)	0.18***	(7)
2016m02	-7.66***	(0)	-7.65***	(0)	-7.73***	(5)	-7.7***	(5)	0.05***	(5)	0.04***	(4)	-6.78***	(0)	-7.17***	(0)	-7.35***	(6)	0.5***	(7)	0.18***	(7)
2016m03	-7.67***	(0)	-7.68***	(0)	-7.75***	(5)	-7.74***	(5)	0.06***	(5)	0.05***	(5)	-6.86***	(0)	-4.62***	(2)	-6.81***	(4)	0.46***	(7)	0.16***	(6)
2016m04	-7.8***	(0)	-7.81***	(0)	-7.88***	(5)	-7.87***	(5)	0.07***	(5)	0.05***	(5)	-6.67***	(0)	-6.78***	(0)	-6.66***	(2)	0.4***	(6)	0.13***	(5)
2016m05	-7.88***	(0)	-7.9***	(0)	-7.98***	(5)	-7.97***	(5)	0.07***	(6)	0.05***	(5)	-7***	(0)	-7.24***	(1)	-7.31***	(1)	0.38***	(6)	0.12***	(4)
2016m06	-7.9***	(0)	-7.9***	(0)	-7.98***	(5)	-7.96***	(5)	0.06***	(5)	0.04***	(4)	-6.97***	(0)	-7.08***	(0)	-6.85***	(3)	0.34***	(6)	0.1***	(5)
2016m07	-7.99***	(0)	-7.98***	(0)	-8.06***	(5)	-8.04***	(5)	0.05***	(5)	0.04***	(4)	-7.25***	(0)	-7.44***	(0)	-7.14***	(3)	0.38***	(6)	0.11***	(5)
2016m08	-8.05***	(0)	-8.04***	(0)	-8.12***	(5)	-8.1***	(5)	0.05***	(5)	0.04***	(4)	-7.29***	(0)	-7.55***	(0)	-7.17***	(3)	0.46***	(6)	0.12***	(5)
2016m09	-8.07***	(0)	-8.07***	(0)	-8.15***	(5)	-8.13***	(5)	0.06***	(5)	0.04***	(4)	-7.25***	(0)	-7.58***	(0)	-7.19***	(3)	0.5***	(6)	0.13***	(5)
2016m10	-8.08***	(0)	-8.09***	(0)	-8.15***	(5)	-8.14***	(5)	0.07***	(5)	0.04***	(4)	-7.29***	(0)	-7.75***	(0)	-7.39***	(3)	0.5***	(6)	0.13***	(5)
2016m11	-8.13***	(0)	-8.15***	(0)	-8.21***	(5)	-8.2***	(5)	0.07***	(5)	0.04***	(4)	-7.46***	(0)	-7.62***	(0)	-7.35***	(3)	0.43***	(6)	0.11***	(4)
2016m12	-7.98***	(0)	-7.95***	(0)	-8.09***	(4)	-8.06***	(4)	0.04***	(4)	0.04***	(4)	-7.33***	(0)	-7.43***	(0)	-7.21***	(3)	0.39***	(5)	0.09***	(4)
2017m01	-7.38***	(0)	-7.34***	(0)	-7.45***	(4)	-7.42***	(4)	0.04***	(4)	0.04***	(4)	-7.28***	(0)	-7.37***	(0)	-7.26***	(2)	0.34***	(5)	0.08***	(4)
2017m02	-7.14***	(0)	-7.13***	(0)	-7.24***	(4)	-7.23***	(4)	0.06***	(5)	0.05***	(5)	-7.45***	(0)	-7.53***	(0)	-7.37***	(3)	0.3***	(6)	0.07***	(5)
2017m03	-7.35***	(0)	-7.32***	(0)	-7.41***	(4)	-7.4***	(4)	0.07***	(5)	0.05***	(5)	-7.5***	(0)	-7.59***	(0)	-7.46***	(4)	0.3***	(6)	0.07***	(5)
2017m04	-7.48***	(0)	-7.46***	(0)	-7.56***	(4)	-7.54***	(4)	0.07***	(5)	0.05***	(5)	-7.52***	(0)	-7.63***	(0)	-7.42***	(3)	0.31***	(6)	0.07***	(5)
2017m05	-7.61***	(0)	-7.59***	(0)	-7.69***	(4)	-7.68***	(4)	0.07***	(5)	0.05***	(5)	-7.4***	(0)	-7.55***	(0)	-7.37***	(2)	0.37***	(5)	0.08***	(5)
2017m06	-7.63***	(0)	-7.59***	(0)	-7.71***	(4)	-7.68***	(4)	0.06***	(5)	0.04***	(4)	-7.48***	(0)	-7.62***	(0)	-7.45***	(2)	0.37***	(5)	0.07***	(5)
2017m07	-7.64***	(0)	-7.61***	(0)	-7.72***	(4)	-7.69***	(4)	0.05***	(5)	0.04***	(4)	-7.5***	(0)	-7.65***	(0)	-7.47***	(2)	0.38***	(5)	0.07***	(5)
2017m08	-7.74***	(0)	-7.71***	(0)	-7.82***	(4)	-7.8***	(4)	0.06***	(5)	0.04***	(4)	-7.55***	(0)	-7.66***	(0)	-7.5***	(2)	0.37***	(5)	0.07***	(5)
2017m09	-7.84***	(0)	-7.82***	(0)	-7.93***	(4)	-7.92***	(4)	0.06***	(5)	0.04***	(4)	-7.55***	(0)	-7.66***	(0)	-7.52***	(2)	0.36***	(5)	0.07***	(5)

Not: İlgili değişken, mevsimsellikten arındırılarak doğal logaritmik farkı alınmıştır. ***, ** ve * sırasıyla %1, %5 ve %10 anlamlılık düzeylerinde serilerin durağan oluklarını ifade eder. AL, ilgili değişkenin logaritmik I. devresel farkının alındığını belirtmektedir. ADF birim kök testi sonucundaki () , optimal gecikme uzunluklarını; PP ve KPSS birim kök test sonuçlarındaki [] ise bant genişliğini göstermektedir.

Tablo 17: Aylık Frekanslı Sanayi Üretim Endeksi için Birim Kök Test Sonuçları

Dönem	ADF			PP			KPSS			Dönem	ADF			PP			KPSS			
	sabitli	trendli	sabitli	trendli	sabitli	trendli	sabitli	trendli	sabitli		trendli	sabitli	trendli	sabitli	trendli	sabitli	trendli	sabitli	trendli	
2015m01	-19.81***	(0)	-19.79***	(0)	-20.35***	[2]	-20.21***	[1]	0.14***	[13]	0.08***	[14]	-27.73***	[3]	-28.24***	[4]	0.11***	[8]	0.06***	[9]
2015m02	-19.81***	(0)	-19.84***	(0)	-20.15***	[1]	-20.23***	[1]	0.16***	[14]	0.08***	[16]	-28.23***	[3]	-28.76***	[4]	0.11***	[9]	0.06***	[9]
2015m03	-19.98***	(0)	-19.97***	(0)	-20.57***	[2]	-20.42***	[1]	0.13***	[13]	0.09***	[14]	-28.28***	[3]	-28.86***	[4]	0.12***	[9]	0.06***	[9]
2015m04	-20.07***	(0)	-20.03***	(0)	-20.68***	[2]	-20.47***	[1]	0.13***	[13]	0.09***	[14]	-28.38***	[3]	-29.***	[4]	0.11***	[9]	0.06***	[10]
2015m05	-20.17***	(0)	-20.16***	(0)	-20.87***	[2]	-20.97***	[2]	0.15***	[13]	0.08***	[14]	-28.46***	[3]	-29.03***	[4]	0.1***	[9]	0.06***	[9]
2015m06	-20.21***	(0)	-20.23***	(0)	-20.91***	[2]	-20.72***	[1]	0.16***	[13]	0.08***	[15]	-28.53***	[3]	-29.15***	[4]	0.12***	[9]	0.05***	[9]
2015m07	-20.25***	(0)	-20.24***	(0)	-21.04***	[2]	-20.75***	[1]	0.11***	[6]	0.07***	[7]	-28.74***	[3]	-29.35***	[4]	0.1***	[9]	0.06***	[9]
2015m08	-20.36***	(0)	-20.37***	(0)	-20.83***	[1]	-20.37***	[0]	0.13***	[6]	0.06***	[7]	-28.83***	[3]	-29.37***	[4]	0.1***	[9]	0.06***	[9]
2015m09	-21.04***	(0)	-21.01***	(0)	-21.53***	[1]	-21.01***	[0]	0.1***	[6]	0.06***	[7]	-28.86***	[3]	-29.33***	[4]	0.09***	[9]	0.06***	[9]
2015m10	-20.97***	(0)	-20.98***	(0)	-21.47***	[1]	-21.55***	[1]	0.17***	[8]	0.06***	[9]	-28.98***	[3]	-29.44***	[4]	0.1***	[8]	0.06***	[9]
2015m11	-21.62***	(0)	-21.58***	(0)	-22.18***	[1]	-22.18***	[1]	0.09***	[6]	0.09***	[7]	-28.47***	[2]	-28.42***	[2]	0.07***	[6]	0.07***	[6]
2015m12	-22.55***	(0)	-22.54***	(0)	-23.55***	[2]	-22.54***	[0]	0.16***	[6]	0.06***	[7]	-29.14***	[3]	-29.49***	[4]	0.11***	[8]	0.05***	[9]
2016m01	-23.35***	(0)	-23.38***	(0)	-24.41***	[2]	-23.38***	[0]	0.11***	[6]	0.06***	[6]	-29.99***	[3]	-29.95***	[3]	0.07***	[6]	0.07***	[6]
2016m02	-23.43***	(0)	-23.45***	(0)	-24.14***	[1]	-23.45***	[0]	0.13***	[5]	0.06***	[6]	-31.82***	[2]	-31.46***	[3]	0.1***	[9]	0.05***	[9]
2016m03	-23.48***	(0)	-23.45***	(0)	-24.16***	[1]	-23.45***	[0]	0.09***	[4]	0.06***	[4]	-32.1***	[3]	-32.44***	[4]	0.07***	[8]	0.06***	[8]
2016m04	-23.68***	(0)	-23.68***	(0)	-24.91***	[2]	-24.46***	[1]	0.1***	[11]	0.04***	[2]	-32.38***	[4]	-32.33***	[4]	0.07***	[8]	0.07***	[8]
2016m05	-23.84***	(0)	-23.86***	(0)	-25.07***	[2]	-23.86***	[0]	0.03***	[0]	0.04***	[1]	-31.65***	[3]	-31.54***	[3]	0.07***	[6]	0.07***	[6]
2016m06	-23.84***	(0)	-23.82***	(0)	-25.18***	[2]	-24.64***	[1]	0.03***	[0]	0.05***	[1]	-31.91***	[3]	-31.8***	[3]	0.06***	[6]	0.06***	[6]
2016m07	-23.94***	(0)	-23.92***	(0)	-25.29***	[2]	-24.73***	[1]	0.09***	[11]	0.04***	[1]	-32.14***	[3]	-32.05***	[3]	0.06***	[5]	0.06***	[5]
2016m08	-24.06***	(0)	-24.04***	(0)	-25.43***	[2]	-24.85***	[1]	0.08***	[11]	0.04***	[2]	-32.07***	[3]	-31.97***	[3]	0.06***	[5]	0.06***	[5]
2016m09	-22.7***	(0)	-22.6***	(0)	-23.78***	[2]	-23.7***	[2]	0.07***	[2]	0.07***	[2]	-32.11***	[3]	-32.03***	[3]	0.06***	[5]	0.06***	[5]
2016m10	-23.38***	(0)	-23.3***	(0)	-24.31***	[1]	-23.3***	[0]	0.1***	[3]	0.05***	[4]	-31.92***	[3]	-31.87***	[3]	0.06***	[5]	0.05***	[5]
2016m11	-24.34***	(0)	-24.25***	(0)	-24.34***	[0]	-24.25***	[0]	0.08***	[3]	0.08***	[3]	-30.23***	[1]	-30.12***	[1]	0.08***	[4]	0.07***	[4]
2016m12	-25.55***	(0)	-25.46***	(0)	-25.55***	[0]	-25.46***	[0]	0.17***	[0.67]	0.06***	[7]	-32.46***	[2]	-32.36***	[2]	0.06***	[5]	0.05***	[5]
2017m01	-25.31***	(0)	-25.28***	(0)	-27.18***	[2]	-26.81***	[3]	0.17***	[0.67]	0.06***	[7]	-33.24***	[2]	-33.12***	[2]	0.08***	[6]	0.08***	[6]
2017m02	-25.41***	(0)	-25.36***	(0)	-26.94***	[3]	-27.02***	[3]	0.09***	[8]	0.06***	[8]	-34.01***	[2]	-33.9***	[2]	0.07***	[8]	0.05***	[8]
2017m03	-25.56***	(0)	-25.51***	(0)	-27.12***	[3]	-27.22***	[3]	0.1***	[8]	0.06***	[9]	-33.74***	[3]	-33.66***	[3]	0.06***	[7]	0.06***	[7]
2017m04	-25.67***	(0)	-25.63***	(0)	-27.8***	[2]	-27.43***	[3]	0.1***	[9]	0.07***	[9]	-34.1***	[3]	-34.33***	[4]	0.06***	[7]	0.06***	[7]
2017m05	-25.89***	(0)	-25.85***	(0)	-27.96***	[2]	-27.65***	[3]	0.1***	[8]	0.06***	[8]	-34.39***	[4]	-34.32***	[4]	0.06***	[8]	0.06***	[8]
2017m06	-26.11***	(0)	-26.08***	(0)	-28.17***	[2]	-27.83***	[3]	0.1***	[8]	0.06***	[8]	-34.54***	[3]	-34.48***	[3]	0.06***	[8]	0.06***	[9]
2017m07	-26.05***	(0)	-26.03***	(0)	-28.19***	[2]	-27.89***	[3]	0.1***	[8]	0.06***	[8]	-34.46***	[3]	-34.43***	[3]	0.06***	[8]	0.05***	[8]
2017m08	-26.07***	(0)	-26***	(0)	-27.99***	[2]	-27.6***	[3]	0.08***	[8]	0.07***	[8]	-34.52***	[3]	-34.44***	[3]	0.07***	[7]	0.07***	[7]
2017m09	-26.2***	(0)	-26.15***	(0)	-28.42***	[2]	-28.1***	[3]	0.12***	[8]	0.06***	[9]	-25.24***	[4]	-25.17***	[4]	0.22***	[7]	0.13***	[7]

Not: İlgili değişken, mevsimsellikten arındırılarak doğal logaritmik farkı alınmıştır. ***, ** ve * sırasıyla %1, %5 ve %10 anlamlılık düzeylerinde serilerin duruşan olduklarını ifade eder. AL, ilgili değişkenin logaritmik 1. devresel farkının alındığını belirtmektedir. ADF birim kök testi sonucundaki () optimal gecikme uzunluğundaki [] ise bant genişliğini göstermektedir.

Tablo 18: Aylık Frekanslı Reel Toplam İhracat için Birim Kök Test Sonuçları

Dönem	ADF			PP			KPSS			ADF			PP			KPSS				
	sabitli	trendli	sabitli	trendli	sabitli	trendli	sabitli	trendli	sabitli	trendli	sabitli	trendli	sabitli	trendli	sabitli	trendli	sabitli	trendli		
2015m01	-11.35***	(1)	-11.28***	(1)	-28.34***	[13]	-27.98***	[13]	0.5*[93]	0.5*[93]	-10.2***	(2)	-10.17***	(2)	-44.7***	[24]	-44.73***	[24]	0.06*[9]	0.06*[9]
2015m02	-11.48***	(1)	-11.42***	(1)	-28.6***	[12]	-28.37***	[12]	0.5*[94]	0.5*[94]	-10.14***	(2)	-10.1***	(2)	-49.3***	[27]	-48.27***	[27]	0.08*[12]	0.05*[12]
2015m03	-11.5***	(1)	-11.44***	(1)	-28.68***	[12]	-28.55***	[12]	0.5*[95]	0.5*[95]	-10.18***	(2)	-10.14***	(2)	-49.09***	[26]	-48.01***	[26]	0.06*[14]	0.06*[14]
2015m04	-11.6***	(1)	-11.54***	(1)	-29.03***	[12]	-28.88***	[12]	0.5*[96]	0.5*[96]	-10.31***	(2)	-10.26***	(2)	-50.36***	[28]	-49.94***	[28]	0.06*[13]	0.06*[13]
2015m05	-11.61***	(1)	-11.55***	(1)	-29.55***	[13]	-29.15***	[13]	0.5*[97]	0.5*[97]	-10.34***	(2)	-10.3***	(2)	-50.31***	[27]	-49.64***	[27]	0.07*[13]	0.06*[13]
2015m06	-11.87***	(1)	-11.81***	(1)	-29.44***	[12]	-29.21***	[12]	0.5*[98]	0.5*[98]	-10.42***	(2)	-10.38***	(2)	-49.68***	[26]	-48.78***	[26]	0.07*[13]	0.06*[13]
2015m07	-11.77***	(1)	-11.71***	(1)	-27.45***	[10]	-27.14***	[10]	0.18*[17]	0.1*[17]	-10.43***	(2)	-10.39***	(2)	-49.69***	[26]	-47.96***	[25]	0.08*[13]	0.06*[13]
2015m08	-11.84***	(1)	-11.79***	(1)	-30.23***	[15]	-29.66***	[15]	0.18*[30]	0.13*[30]	-10.52***	(2)	-10.48***	(2)	-48.58***	[24]	-47.78***	[24]	0.06*[13]	0.06*[13]
2015m09	-11.97***	(1)	-11.92***	(1)	-30.81***	[15]	-30.39***	[15]	0.19*[22]	0.1*[23]	-10.57***	(2)	-10.55***	(2)	-48.84***	[24]	-48.01***	[24]	0.06*[12]	0.05*[12]
2015m10	-11.96***	(1)	-11.9***	(1)	-32.62***	[16]	-32.26***	[17]	0.13*[24]	0.11*[24]	-10.62***	(2)	-10.57***	(2)	-49.1***	[24]	-48.25***	[24]	0.06*[12]	0.05*[12]
2015m11	-12.03***	(1)	-11.96***	(1)	-33.26***	[17]	-33.29***	[18]	0.13*[21]	0.1*[22]	-10.68***	(2)	-10.64***	(2)	-47.21***	[23]	-46.26***	[23]	0.08*[12]	0.05*[12]
2015m12	-11.91***	(1)	-11.84***	(1)	-33.6***	[16]	-33.38***	[16]	0.07*[14]	0.07*[14]	-10.73***	(2)	-10.68***	(2)	-51.16***	[25]	-50.44***	[25]	0.05*[12]	0.05*[12]
2016m01	-11.94***	(1)	-11.88***	(1)	-33.71***	[16]	-33.51***	[16]	0.08*[15]	0.07*[15]	-10.78***	(2)	-10.74***	(2)	-50.52***	[24]	-49.76***	[24]	0.07*[11]	0.05*[11]
2016m02	-12.04***	(1)	-11.98***	(1)	-37.12***	[20]	-35.96***	[19]	0.09*[17]	0.08*[17]	-10.76***	(2)	-10.72***	(2)	-48.55***	[23]	-48.38***	[23]	0.05*[10]	0.05*[10]
2016m03	-21.56***	(0)	-21.48***	(0)	-38.04***	[30]	-36.8***	[30]	0.18*[23]	0.09*[23]	-10.6***	(2)	-10.57***	(2)	-44.57***	[19]	-44.83***	[19]	0.05*[10]	0.05*[10]
2016m04	-9.38***	(2)	-9.33***	(2)	-38.25***	[22]	-37.68***	[22]	0.06*[13]	0.06*[13]	-10.64***	(2)	-10.62***	(2)	-44.83***	[19]	-46***	[20]	0.05*[10]	0.04*[10]
2016m05	-9.38***	(2)	-9.33***	(2)	-39.83***	[24]	-39.48***	[24]	0.07*[12]	0.06*[12]	-10.89***	(2)	-10.86***	(2)	-49.3***	[22]	-49.11***	[22]	0.05*[9]	0.04*[9]
2016m06	-9.54***	(2)	-9.49***	(2)	-39.42***	[22]	-38.85***	[22]	0.07*[12]	0.06*[12]	-10.91***	(2)	-10.88***	(2)	-49.67***	[22]	-49.47***	[22]	0.04*[8]	0.04*[8]
2016m07	-9.65***	(2)	-9.61***	(2)	-39.08***	[23]	-38.4***	[23]	0.08*[12]	0.06*[12]	-10.97***	(2)	-10.93***	(2)	-49.31***	[21]	-49.11***	[21]	0.04*[7]	0.04*[7]
2016m08	-9.81***	(2)	-9.76***	(2)	-37.91***	[20]	-37.57***	[20]	0.06*[9]	0.06*[9]	-10.99***	(2)	-10.96***	(2)	-49.7***	[21]	-49.29***	[21]	0.04*[8]	0.04*[8]
2016m09	-9.65***	(2)	-9.61***	(2)	-34.28***	[18]	-33.83***	[18]	0.11*[4]	0.05*[4]	-11.03***	(2)	-10.99***	(2)	-50.26***	[22]	-50.07***	[22]	0.04*[8]	0.04*[8]
2016m10	-9.87***	(2)	-9.83***	(2)	-40.14***	[23]	-39.45***	[23]	0.05*[8]	0.05*[8]	-11.02***	(2)	-10.99***	(2)	-47.27***	[20]	-47.65***	[20]	0.05*[7]	0.05*[7]
2016m11	-9.81***	(2)	-9.77***	(2)	-44.68***	[26]	-43.97***	[26]	0.09*[8]	0.05*[8]	-11.08***	(2)	-11.04***	(2)	-45.61***	[19]	-44.54***	[19]	0.1*[6]	0.04*[6]
2016m12	-9.92***	(2)	-9.87***	(2)	-43.2***	[23]	-42.65***	[23]	0.06*[9]	0.05*[9]	-11.3***	(2)	-11.26***	(2)	-52.39***	[22]	-51.38***	[22]	0.04*[8]	0.04*[8]
2017m01	-9.69***	(2)	-9.63***	(2)	-46.33***	[27]	-46.04***	[27]	0.05*[8]	0.05*[9]	-11.48***	(2)	-11.44***	(2)	-54.79***	[22]	-54.45***	[22]	0.04*[8]	0.03*[8]
2017m02	-9.69***	(2)	-9.65***	(2)	-46.41***	[27]	-46.1***	[27]	0.06*[9]	0.05*[9]	-11.54***	(2)	-11.49***	(2)	-54.38***	[23]	-54.31***	[23]	0.04*[8]	0.04*[8]
2017m03	-9.85***	(2)	-9.81***	(2)	-48.01***	[29]	-47.52***	[29]	0.06*[9]	0.05*[9]	-11.64***	(2)	-11.61***	(2)	-54.21***	[23]	-56.08***	[24]	0.04*[8]	0.04*[8]
2017m04	-9.92***	(2)	-9.88***	(2)	-49.41***	[32]	-48.76***	[32]	0.06*[10]	0.05*[10]	-11.66***	(2)	-11.63***	(2)	-58.03***	[25]	-57.96***	[25]	0.04*[8]	0.03*[8]
2017m05	-9.96***	(2)	-9.92***	(2)	-44.23***	[24]	-44.05***	[24]	0.06*[9]	0.06*[9]	-11.7***	(2)	-11.67***	(2)	-59.16***	[26]	-58.81***	[26]	0.04*[8]	0.03*[8]
2017m06	-10.01***	(2)	-9.97***	(2)	-44.48***	[24]	-44.34***	[24]	0.06*[9]	0.05*[9]	-11.76***	(2)	-11.73***	(2)	-58.99***	[26]	-58.91***	[26]	0.04*[8]	0.03*[8]
2017m07	-10.02***	(2)	-9.99***	(2)	-44.84***	[24]	-44.71***	[24]	0.05*[9]	0.05*[9]	-11.79***	(2)	-11.76***	(2)	-61.17***	[27]	-60.8***	[27]	0.04*[8]	0.03*[8]
2017m08	-10.1***	(2)	-10.07***	(2)	-45.62***	[24]	-45.38***	[24]	0.05*[9]	0.05*[9]	-11.32***	(2)	-11.28***	(2)	-45.21***	[18]	-44.28***	[18]	0.1*[6]	0.04*[6]
2017m09	-10.17***	(2)	-10.14***	(2)	-44.82***	[23]	-44.38***	[23]	0.05*[8]	0.04*[8]	-25.14***	(0)	-25.18***	(0)	-28.77***	[7]	-28.82***	[7]	0.15*[2]	0.06*[2]

Not: İlgili değişken, mevsimsellikten arındırılarak doğal logaritmik farkı alınmıştır. ***, ** ve * sırasıyla %1, %5 ve %10 anlamlılık düzeylerinde serilerin duruşan oluklarını ifade eder. AL, ilgili değişkenin logaritmik farkının alındığını belirtmektedir. ADF birim kök testi sonucundaki () , optimal gecikme uzumluklarını; PP ve KPSS birim kök testi sonucundaki [] ise bant genişliğini göstermektedir.

Tablo 19: Aylık Frekanslı Reel Toplam İthalat için Birim Kök Test Sonuçları

Dönem	ADF			PP			KPSS			Dönem	ADF			PP			KPSS							
	sabitli	trendli	trendli	sabitli	trendli	trendli	sabitli	trendli	trendli		sabitli	trendli	trendli	sabitli	trendli	trendli	sabitli	trendli	trendli					
2015m01	-14.04	(0)	-14.00	-13.97	[4]	-13.95	[4]	0.07	[4]	0.05	[4]	-20.69	(0)	-20.63	(0)	-21.44	[4]	-21.42	[4]	0.04	[1]	0.03	[1]	
2015m02	-14.21	(0)	-14.17	(0)	-14.16	[4]	-14.13	[4]	0.07	[4]	0.05	[3]	-20.74	(0)	-20.68	(0)	-21.49	[4]	-21.48	[4]	0.02	[0]	0.03	[1]
2015m03	-14.36	(0)	-14.29	(0)	-14.39	[4]	-14.33	[4]	0.06	[3]	0.05	[3]	-20.83	(0)	-20.78	(0)	-21.54	[4]	-21.55	[4]	0.04	[1]	0.03	[1]
2015m04	-14.57	(0)	-14.50	(0)	-14.63	[4]	-14.57	[4]	0.06	[3]	0.05	[3]	-20.73	(0)	-20.67	(0)	-21.53	[4]	-21.72	[3]	0.04	[3]	0.04	[3]
2015m05	-14.63	(0)	-14.57	(0)	-14.7	[4]	-14.65	[4]	0.06	[3]	0.05	[3]	-20.85	(0)	-20.79	(0)	-21.65	[4]	-21.83	[3]	0.04	[3]	0.04	[3]
2015m06	-14.68	(0)	-14.61	(0)	-14.74	[4]	-14.68	[4]	0.06	[3]	0.05	[3]	-20.68	(0)	-20.64	(0)	-21.76	[3]	-21.76	[3]	0.06	[2]	0.04	[3]
2015m07	-14.56	(0)	-14.48	(0)	-14.63	[4]	-14.56	[4]	0.03	[0]	0.03	[0]	-20.94	(0)	-20.89	(0)	-21.88	[4]	-22.08	[3]	0.03	[1]	0.03	[2]
2015m08	-14.76	(0)	-14.69	(0)	-15.02	[3]	-14.95	[3]	0.04	[1]	0.04	[1]	-20.81	(0)	-12.13	(1)	-21.82	[4]	-21.97	[3]	0.03	[2]	0.03	[2]
2015m09	-14.89	(0)	-14.82	(0)	-15.15	[3]	-15.08	[3]	0.05	[1]	0.05	[1]	-20.89	(0)	-20.82	(0)	-22.12	[3]	-22.05	[3]	0.03	[2]	0.03	[2]
2015m10	-14.97	(0)	-14.9	(0)	-15.12	[4]	-15.04	[4]	0.05	[1]	0.05	[1]	-20.99	(0)	-20.92	(0)	-22	[4]	-22.15	[3]	0.03	[2]	0.03	[2]
2015m11	-15.02	(0)	-14.95	(0)	-15.15	[4]	-15.08	[4]	0.05	[1]	0.05	[1]	-20.86	(0)	-20.78	(0)	-21.75	[5]	-21.66	[5]	0.04	[2]	0.04	[2]
2015m12	-15.1	(0)	-15.02	(0)	-15.24	[4]	-15.17	[4]	0.05	[1]	0.04	[1]	-21.02	(0)	-20.95	(0)	-21.82	[5]	-21.74	[5]	0.04	[2]	0.04	[2]
2016m01	-15.73	(0)	-15.65	(0)	-15.9	[4]	-15.82	[4]	0.05	[1]	0.05	[1]	-20.57	(0)	-20.53	(0)	-20.71	[5]	-20.67	[5]	0.11	[3]	0.07	[3]
2016m02	-16.55	(0)	-16.47	(0)	-16.92	[4]	-16.84	[4]	0.02	[0]	0.02	[0]	-21.11	(0)	-21.06	(0)	-21.31	[5]	-21.28	[5]	0.05	[1]	0.04	[1]
2016m03	-16.6	(0)	-16.52	(0)	-16.98	[4]	-16.9	[4]	0.02	[0]	0.02	[0]	-21.4	(0)	-21.36	(0)	-21.47	[5]	-21.48	[5]	0.1	[3]	0.06	[3]
2016m04	-16.61	(0)	-16.54	(0)	-16.95	[4]	-16.88	[4]	0.06	[2]	0.04	[2]	-21.52	(0)	-21.49	(0)	-21.54	[5]	-21.57	[5]	0.09	[3]	0.06	[3]
2016m05	-16.69	(0)	-16.64	(0)	-16.98	[4]	-16.94	[4]	0.05	[1]	0.04	[1]	-21.54	(0)	-21.52	(0)	-21.3	[6]	-21.38	[6]	0.12	[4]	0.07	[3]
2016m06	-16.73	(0)	-16.66	(0)	-17.39	[3]	-17.32	[3]	0.05	[2]	0.05	[2]	-21.73	(0)	-21.7	(0)	-21.75	[5]	-21.79	[5]	0.07	[4]	0.05	[4]
2016m07	-16.79	(0)	-16.71	(0)	-17.52	[3]	-17.45	[3]	0.05	[3]	0.05	[3]	-21.71	(0)	-21.66	(0)	-21.79	[5]	-21.79	[5]	0.06	[4]	0.05	[3]
2016m08	-16.51	(0)	-16.46	(0)	-17.15	[4]	-17.11	[4]	0.05	[1]	0.03	[1]	-21.79	(0)	-21.74	(0)	-21.87	[5]	-21.87	[5]	0.07	[4]	0.05	[3]
2016m09	-11.05	(1)	-10.99	(1)	-17.13	[4]	-17.04	[4]	0.07	[2]	0.06	[2]	-21.9	(0)	-21.84	(0)	-21.94	[5]	-21.91	[5]	0.05	[4]	0.04	[4]
2016m10	-11.5	(1)	-11.44	(1)	-18.91	[4]	-18.82	[4]	0.04	[3]	0.04	[3]	-22.03	(0)	-21.97	(0)	-22.11	[5]	-22.1	[5]	0.07	[3]	0.05	[3]
2016m11	-11.55	(1)	-11.5	(1)	-19.77	[3]	-19.68	[3]	0.05	[4]	0.05	[4]	-21.55	(0)	-21.54	(0)	-21.75	[5]	-21.81	[5]	0.13	[3]	0.06	[3]
2016m12	-18.92	(0)	-18.84	(0)	-19.79	[4]	-19.71	[3]	0.04	[4]	0.04	[4]	-21.78	(0)	-21.73	(0)	-22.15	[5]	-22.16	[5]	0.05	[2]	0.04	[2]
2017m01	-19.08	(0)	-19	(0)	-19.96	[4]	-19.88	[4]	0.04	[3]	0.04	[3]	-22	(0)	-21.94	(0)	-22.46	[5]	-22.48	[4]	0.07	[2]	0.04	[2]
2017m02	-19.15	(0)	-19.07	(0)	-20.25	[3]	-20.17	[3]	0.04	[3]	0.04	[3]	-22.09	(0)	-22.02	(0)	-22.48	[4]	-22.45	[4]	0.04	[1]	0.03	[1]
2017m03	-19.23	(0)	-19.15	(0)	-20.33	[3]	-20.24	[3]	0.04	[3]	0.04	[3]	-22.12	(0)	-22.05	(0)	-22.44	[4]	-22.38	[4]	0.03	[1]	0.03	[1]
2017m04	-19.3	(0)	-19.23	(1)	-20.4	[3]	-20.31	[3]	0.04	[4]	0.04	[4]	-22.14	(0)	-22.07	(0)	-22.39	[4]	-22.32	[4]	0.04	[2]	0.03	[2]
2017m05	-19.52	(0)	-19.44	(0)	-20.41	[4]	-20.33	[4]	0.04	[3]	0.04	[3]	-22.19	(0)	-22.12	(0)	-22.4	[4]	-22.33	[4]	0.04	[2]	0.03	[2]
2017m06	-19.7	(0)	-19.62	(0)	-20.55	[4]	-20.47	[4]	0.04	[2]	0.04	[2]	-22.21	(0)	-22.14	(0)	-22.3	[5]	-22.22	[5]	0.03	[2]	0.03	[2]
2017m07	-19.79	(0)	-19.73	(0)	-20.51	[4]	-20.45	[4]	0.05	[2]	0.04	[2]	-22.34	(0)	-22.27	(0)	-22.51	[4]	-22.44	[4]	0.03	[1]	0.03	[1]
2017m08	-19.97	(0)	-19.91	(0)	-20.76	[4]	-20.7	[4]	0.04	[3]	0.04	[3]	-22.27	(0)	-22.2	(0)	-22.52	[4]	-22.45	[4]	0.03	[1]	0.03	[1]
2017m09	-20.44	(0)	-20.38	(0)	-21.17	[4]	-21.15	[4]	0.02	[0]	0.03	[1]	-20.74	(0)	-20.72	(0)	-21	[3]	-20.98	[3]	0.05	[0]	0.02	[0]

Not: İlgili değişken, mevsimsellikten arındırılarak doğal logaritmik farkı alınmıştır. ***, ** ve * sırasıyla %1, %5 ve %10 anlamlılık düzeylerinde serilerin durağan olduklarını ifade eder. ΔL, ilgili değişkenin logaritmik

1. devresel farkının alındığını belirtmektedir. ADF birim kök testi sonucundaki () , optimal gecikme uzunluğundaki [] ise bant genişliğini göstermektedir.

Tablo 20: Üçer Aylık Frekanslı GSYİH ve Reel Kesim Güven Endeksi için Birim Kök Test Sonuçları

GSYİH		Reel Kesim Güven Endeksi											
		ADF			PP			KPSS					
Dönem	sabitli	trendli	sabitli	trendli	sabitli	trendli	Dönem	sabitli	trendli	sabitli	trendli		
2015Q1	-4.75*** (0)	-4.81*** [1]	-4.74*** [1]	0.29 [0]	0.09* [2]	-4.47*** [2]	2015Q1	-3.34*** (3)	-3.3* (3)	-4.47*** [2]	-4.37*** [2]	0.09* [2]	0.07* [2]
2015Q2	-4.71*** (0)	-4.82*** [1]	-4.7*** [1]	0.32 [0]	0.08* [2]	-4.55*** [2]	2015Q2	-3.39*** (3)	-3.36* (3)	-4.55*** [2]	-4.46*** [2]	0.09* [2]	0.07* [2]
2015Q3	-4.78*** (0)	-4.84*** [1]	-4.78*** [1]	0.31 [0]	0.09* [2]	-4.63*** [2]	2015Q3	-3.18*** (7)	-3.41* (3)	-4.63*** [2]	-4.54*** [2]	0.08* [2]	0.07* [2]
2015Q4	-4.94*** (0)	-4.97*** [1]	-4.93*** [1]	0.29 [0]	0.1 [2]	-4.68*** [2]	2015Q4	-3.28*** (7)	-4.55*** (7)	-4.68*** [2]	-4.58*** [3]	0.09* [2]	0.07* [2]
2016Q1	-4.99*** (0)	-5.1*** (0)	-4.98*** [1]	0.32 [0]	0.09* [2]	-4.75*** [2]	2016Q1	-3.31*** (7)	-4.6*** (7)	-4.75*** [2]	-4.66*** [3]	0.09* [2]	0.07* [2]
2016Q2	-5.13*** (0)	-5.15*** [0]	-5.13*** [1]	0.28* [0]	0.1 [2]	-4.83*** [3]	2016Q2	-3.12*** (2)	-5.08*** (7)	-4.83*** [3]	-4.74*** [3]	0.08* [2]	0.07* [2]
2016Q3	-5.28*** (0)	-5.3*** (0)	-5.27*** [1]	0.27 [0]	0.1 [2]	-4.91*** [3]	2016Q3	-3.16*** (2)	-3.15(2)	-4.91*** [3]	-4.83*** [3]	0.08* [2]	0.06* [2]
2016Q4	-5.09*** (0)	-4.95*** (0)	-5.08*** [1]	0.19 [0]	0.13* [1]	-5*** [2]	2016Q4	-3.21*** (2)	-3.19(2)	-5*** [2]	-4.9*** [3]	0.08* [2]	0.06* [2]
2017Q1	-5.89*** (0)	-5.93*** (0)	-5.88*** [1]	0.22 [2]	0.1 [3]	-5.05*** [3]	2017Q1	-3.26*** (2)	-3.24* (2)	-5.05*** [3]	-4.97*** [3]	0.08* [2]	0.06* [2]
2017Q2	-6.35*** (0)	-6.37*** (0)	-6.35*** [1]	0.21 [2]	0.1 [3]	-5.12*** [3]	2017Q2	-3.88*** (7)	-5.13*** (7)	-5.12*** [3]	-5.04*** [3]	0.08* [2]	0.06* [2]
2017Q3	-6.48*** (0)	-6.52*** (0)	-6.48*** [0]	0.21 [2]	0.1 [3]	-5.16*** [3]	2017Q3	-3.97*** (7)	-3.36* (2)	-5.16*** [3]	-5.1*** [3]	0.08* [2]	0.06* [2]
2017Q4	-6.49*** (0)	-6.54*** (0)	-6.5*** [1]	0.22 [1]	0.1 [3]	-5.26*** [3]	2017Q4	-4.15*** (7)	-4.9*** (7)	-5.26*** [3]	-5.19*** [3]	0.08* [2]	0.06* [2]
2018Q1	-6.42*** (0)	-6.5*** (0)	-6.43*** [1]	0.23 [1]	0.1 [3]	-5.32*** [3]	2018Q1	-4.23*** (7)	-4.82*** (7)	-5.32*** [3]	-5.25*** [3]	0.08* [2]	0.06* [2]
2018Q2	-6.51*** (0)	-6.58*** (0)	-6.51*** [1]	0.23 [1]	0.1 [3]	-5.35*** [3]	2018Q2	-3.52*** (2)	-3.49* (2)	-5.35*** [3]	-5.25*** [3]	0.07* [2]	0.06* [2]
2018Q3	-6.64*** (0)	-6.67*** (0)	-6.64*** [1]	0.21 [1]	0.1 [3]	-5.42*** [3]	2018Q3	-5.36*** (0)	-5.27*** (0)	-5.42*** [3]	-5.2*** [3]	0.06* [2]	0.06* [2]
2018Q4	-6.56*** (0)	-6.51*** (0)	-6.56*** [1]	0.18 [1]	0.11* [2]	-5.44*** [3]	2018Q4	-5.47*** (0)	-5.4*** (0)	-5.42*** [3]	-5.34*** [3]	0.06* [2]	0.06* [2]
2019Q1	-6.3*** (0)	-6.19*** (0)	-6.29*** [1]	0.15* [0]	0.13* [1]	-5.54*** [3]	2019Q1	-5.54*** (0)	-5.48*** (0)	-5.48*** [3]	-5.41*** [3]	0.06* [2]	0.06* [2]
2019Q2	-6.7*** (0)	-6.62*** (0)	-6.7*** [1]	0.15 [1]	0.13* [1]	-5.48*** [3]	2019Q2	-5.6*** (0)	-5.54*** (0)	-5.48*** [3]	-5.47*** [3]	0.06* [2]	0.06* [2]
2019Q3	-6.75*** (0)	-6.67*** (0)	-6.75*** [1]	0.15* [0]	0.13* [0]	-5.59*** [3]	2019Q3	-5.65*** (0)	-5.59*** (0)	-5.59*** [3]	-5.52*** [3]	0.06* [2]	0.05* [2]
2019Q4	-6.83*** (0)	-6.76*** (0)	-6.83*** [1]	0.14 [1]	0.12* [1]	-5.59*** [3]	2019Q4	-5.65*** (0)	-5.6*** (0)	-5.59*** [3]	-5.53*** [3]	0.06* [2]	0.05* [2]
2020Q1	-6.86*** (0)	-6.8*** (0)	-6.86*** [1]	0.14 [1]	0.11* [1]	-5.74*** [3]	2020Q1	-5.8*** (0)	-5.72*** (0)	-5.74*** [3]	-5.66*** [3]	0.06* [2]	0.05* [2]
2020Q2	-6.96*** (0)	-6.88*** (0)	-6.96*** [1]	0.13 [1]	0.12* [1]	-4.77*** [3]	2020Q2	-4.94*** (0)	-4.87*** (0)	-4.77*** [3]	-4.69*** [3]	0.09* [3]	0.08* [3]

Not: Her iki değişken mevsimsellikten arındırılarak doğal logaritmik farkları alınmıştır. ***, ** ve * sırasıyla %0.1, %5 ve %10 anlamlılık düzeylerinde serilerin durağan olduklarını ifade eder. ΔL, ilgili değişkenin logaritmik 1. devresel farkının alındığını belirtmektedir. ADF birim kök testi sonucundaki (), optimal gecikme uzunluğundaki [] ise bant genişliğini göstermektedir.

Tablo 21: Üçer Aylık Frekanslı İmalat Sanayi Kapasite Kullanım Oranı ve TÜFE için Birim Kök Test Sonuçları

Dönem	İmalat Sanayi Kapasite Kullanım Oranı						TÜFE					
	ADF			PP			ADF			PP		
	sabitli	trendli	KPSS	sabitli	trendli	KPSS	sabitli	trendli	KPSS	sabitli	trendli	KPSS
2015Q1	-7.28*** (7)	-2.87(6)	0.16* [1]	-3.4** [0]	-3.5* [1]	0.16* [1]	0.08 [1]	-5.45*** (3)	-5.35*** (3)	-6.97*** [23]	-6.8*** [23]	0.32* [20]
2015Q2	-7.21*** (7)	-2.99(6)	0.18* [1]	-3.42* [0]	-3.55* [1]	0.18* [1]	0.08 [1]	-5.48*** (3)	-5.39*** (3)	-6.82* [24]	-6.9*** [26]	0.4* [21]
2015Q3	-3.4** (6)	-2.99(6)	0.17* [1]	-3.54* [0]	-3.64** [1]	0.17* [1]	0.08 [1]	-5.35*** (3)	-5.2*** (3)	-8.14*** [31]	-7.81*** [31]	0.41* [27]
2015Q4	-3.44** (6)	-7.02*** (7)	0.15* [2]	-3.59* [0]	-3.7* [1]	0.15* [2]	0.08 [1]	-5.45*** (3)	-4.38*** (5)	-8.63*** [30]	-8.67*** [32]	0.38* [26]
2016Q1	-8.02*** (7)	-7.19*** (7)	0.16* [2]	-3.63* [0]	-3.76 [1]	0.16* [2]	0.08 [1]	-5.56*** (3)	-4.54*** (5)	-8.57 [28]	-8.29*** [28]	0.35* [25]
2016Q2	-3.7*** (0)	-3.24* (6)	0.15* [2]	-3.7*** [0]	-3.8 [1]	0.15* [2]	0.08 [1]	-5.69*** (3)	-4.66*** (5)	-8.95*** [29]	-8.77*** [30]	0.36* [26]
2016Q3	-3.77*** (0)	-3.77*** (0)	0.14* [2]	-3.77*** [0]	-3.85** [1]	0.14* [2]	0.08 [1]	-5.78*** (3)	-5.71*** (3)	-7.86*** [24]	-8.45*** [27]	0.44* [22]
2016Q4	-3.83*** (0)	-3.86*** (0)	0.15* [2]	-3.83*** [0]	-3.93 [1]	0.15* [2]	0.08 [1]	-6.06*** (3)	-5.94*** (3)	-8.96*** [25]	-8.77*** [26]	0.35* [24]
2017Q1	-8.57*** (7)	-3.9*** (0)	0.15* [2]	-3.85*** [0]	-3.98** [1]	0.15* [2]	0.07 [1]	-6.08*** (3)	-5.96*** (3)	-9.77*** [28]	-9.63*** [30]	0.38* [27]
2017Q2	-8.77*** (7)	-3.95*** (0)	0.15* [2]	-3.91*** [0]	-4.03* [1]	0.15* [2]	0.07 [1]	-5.86*** (3)	-4.31*** (5)	-5.39*** [16]	-5.44*** [15]	0.24* [16]
2017Q3	-9*** (7)	-8.05*** (7)	0.15* [2]	-3.96*** [0]	-4.08 [1]	0.15* [2]	0.07 [1]	-5.72*** (3)	-5.64*** (3)	-6.1*** [13]	-6.32*** [14]	0.25* [13]
2017Q4	-9.11*** (7)	-8.19*** (7)	0.16* [2]	-4.01*** [0]	-4.14 [1]	0.16* [2]	0.07 [1]	-6.17*** (3)	-6.17*** (3)	-6.62 [15]	-6.91*** [16]	0.23* [14]
2018Q1	-9.38*** (7)	-8.42*** (7)	0.16* [2]	-4.06*** [0]	-4.18** [1]	0.16* [2]	0.07 [1]	-5.95*** (0)	-5.63*** (3)	-5.98*** [8]	-6.13*** [9]	0.23* [8]
2018Q2	-4.19*** (6)	-4.07*** (0)	0.14* [2]	-4.09*** [0]	-4.15* [1]	0.14* [2]	0.08 [1]	-6.08*** (0)	-6.13*** (0)	-6.16*** [8]	-6.41*** [10]	0.23* [8]
2018Q3	-4.26*** (6)	-3.82*** (6)	0.13* [2]	-4.16*** [0]	-4.23 [1]	0.13* [2]	0.08 [1]	-5.61*** (0)	-5.85*** (0)	-5.5 [4]	-5.73*** [6]	0.34* [4]
2018Q4	-4.07*** (0)	-4*** (0)	0.11* [2]	-4.07*** [0]	-4*** [0]	0.11* [2]	0.08 [2]	-3.09*** (0)	-3.56*** (0)	-3*** [1]	-3.56*** [0]	0.44* [2]
2019Q1	-4.36*** (0)	-4.34*** (0)	0.11* [2]	-4.36*** [0]	-4.34*** [0]	0.11* [2]	0.08 [2]	2.34(6)	-3.74*** (0)	-3.04*** [1]	-3.74*** [0]	0.47* [3]
2019Q2	-4.41*** (0)	-4.4*** (0)	0.11* [2]	-4.41*** [0]	-4.4* [0]	0.11* [2]	0.07 [2]	-4.48*** (0)	-4.79*** (0)	-4.34*** [4]	-4.47*** [6]	0.43* [2]
2019Q3	-4.45*** (0)	-4.45*** (0)	0.11* [2]	-4.45*** [0]	-4.45*** [0]	0.11* [2]	0.07 [2]	-4.65*** (0)	-5.15*** (0)	-4.64*** [1]	-5.02*** [4]	0.49* [2]
2019Q4	-4.48*** (0)	-4.48*** (0)	0.12* [2]	-4.48*** [0]	-4.48*** [0]	0.12* [2]	0.07 [2]	-4.79*** (0)	-5.3*** (0)	-4.79*** [0]	-5.19*** [4]	0.48* [3]
2020Q1	-4.55*** (0)	-4.54*** (0)	0.11* [2]	-4.55*** [0]	-4.61 [1]	0.11* [2]	0.07 [2]	-4.7*** (0)	-5.17*** (0)	-4.69*** [1]	-5.04*** [4]	0.48* [3]
2020Q2	-3.13*** (0)	-2.98(0)	0.14* [1]	-3.13*** [0]	-2.98[0]	0.14* [1]	0.13 [1]	-4.72*** (0)	-5.24*** (0)	-4.72*** [0]	-5.12*** [4]	0.51* [3]

Not: Her iki değişken mevsimsellikten arındırılarak doğal logaritmik farkları alınmıştır. *** ve ** sırasıyla %1, %5 ve %10 anlamlılık düzeylerinde serilerin durağan olduklarını ifade eder. ΔL, ilgili değişkenin logaritmik 1. devresel farkının alındığını belirtmektedir. ADF birim kök testi sonucundaki (), optimal gecikme uzunluklarını; PP ve KPSS birim kök test sonuçlarındaki [] ise bant genişliğini göstermektedir.

Tablo 22: Üçer Aylık Frekanslı ÜFE ve Sanayi Üretim Endeksi için Birim Kök Test Sonuçları

ÜFE		Sanayi Üretim Endeksi								
Dönem	ADF		PP		ADF		PP		KPSS	
	sabitli	trendli	sabitli	trendli	sabitli	trendli	sabitli	trendli	sabitli	trendli
2015Q1	-3.82***	-3.76**	-3.61***	-3.55**	-3.65***	-3.63**	-3.56**	-3.47**	0.25*[0]	0.08*[2]
2015Q2	-3.77**	-3.76**	-3.63**	-3.65**	-3.7**	-3.69**	-3.58**	-3.53**	0.25*[0]	0.08*[2]
2015Q3	-4.16***	-4.11**	-3.97***	-3.87**	-3.78**	-3.81**	-3.68**	-3.61**	0.26*[0]	0.08*[2]
2015Q4	-4.33***	-4.28**	-4.18**	-4.11**	-3.97**	-3.94**	-3.88**	-3.79**	0.17*[1]	0.08*[2]
2016Q1	-4.3**	-4.27**	-4.11**	-4.08**	-3.93**	-4.02**	-3.93**	-3.86**	0.28*[0]	0.07*[2]
2016Q2	-4.22***	-4.27**	-4.02***	-4.04**	-4.31***	-4.32***	-4.32***	-4.22**	0.24*[0]	0.08*[2]
2016Q3	-4.42**	-4.48**	-4.22**	-4.3**	-4.4**	-4.4**	-4.42**	-4.31**	0.17*[1]	0.08*[2]
2016Q4	-4.41**	-4.48**	-4.23**	-4.29**	-3.89**	-3.87**	-3.89**	-3.76**	0.13*[1]	0.1*[2]
2017Q1	-4.53**	-4.51**	-4.3**	-4.27**	-4.72**	-4.72**	-4.72**	-4.62**	0.15*[3]	0.08*[4]
2017Q2	-3.54**	-3.46**	-3.31**	-3.24**	-5.53***	-5.52**	-5.51***	-5.49**	0.14*[3]	0.09*[4]
2017Q3	-4.6**	-4.53**	-4.4**	-4.32**	-5.63**	-5.59**	-5.61**	-5.57**	0.13*[3]	0.09*[4]
2017Q4	-4.68**	-4.62**	-4.49**	-4.42**	-5.73**	-5.77**	-5.76**	-5.78**	0.16*[1]	0.07*[3]
2018Q1	-4.72**	-4.69**	-4.69**	-4.65**	-5.72**	-5.8**	-5.75**	-5.8**	0.18*[1]	0.07*[2]
2018Q2	-4.53**	-4.54**	-4.51**	-4.52**	-5.72**	-5.74**	-5.74**	-5.74**	0.16*[1]	0.07*[2]
2018Q3	-4.21**	-4.35**	-4.26**	-4.4**	-5.96***	-5.92**	-5.8**	-5.93**	0.11*[2]	0.08*[3]
2018Q4	-2.07**	-2.45**	-2.11**	-2.51**	-5.72**	-5.63**	-5.78**	-5.69**	0.11*[1]	0.1*[1]
2019Q1	-3.15**	-3.56**	-3.18**	-3.6**	-6.1**	-6.03**	-6.13**	-6.07**	0.1*[1]	0.1*[1]
2019Q2	-3.94**	-4.56**	-3.91**	-3.64**	-6.15**	-6.08**	-6.19**	-6.13**	0.1*[1]	0.1*[1]
2019Q3	-4.3**	-4.67**	-4.33**	-4.65**	-6.23**	-6.17**	-6.27**	-6.19**	0.09*[2]	0.08*[2]
2019Q4	-4.55**	-4.7**	-4.55**	-4.7**	-6.33**	-6.26**	-6.35**	-6.28**	0.09*[2]	0.08*[2]
2020Q1	-4.61**	-4.69**	-4.61**	-4.71**	-6.39**	-6.32**	-6.41**	-6.35**	0.08*[2]	0.08*[2]
2020Q2	-4.79**	-4.95**	-4.79**	-4.97**						

Not: Her iki değişken mevsimsellikten arındırılarak doğal logaritmik farkları alınmıştır. ***, ** ve * sırasıyla %0.1, %5 ve %10 anlamlılık düzeylerinde serilerin durağan olduklarını ifade eder. ΔL, ilgili değişkenin logaritmik 1. devresel farkının alındığını belirtmektedir. ADF birim kök testi sonucundaki (), optimal gecikme uzunluklarını; PP ve KPSS birim kök test sonuçlarındaki [] ise bant genişliğini göstermektedir.

Tablo 23: Üçer Aylık Frekanslı Reel Toplam İhracat ve İthalat için Birim Kök Test Sonuçları

Dönem	Reel Toplam İhracat						Reel Toplam İthalat					
	ADF			PP			ADF			PP		
	sabitli	trendli	KPSS	sabitli	trendli	KPSS	sabitli	trendli	KPSS	sabitli	trendli	KPSS
2015Q1	-8.2***	-8.06***	0.08* [4]	-7.89***	-7.76***	0.08* [4]	-3.23***	-3.21(1)	0.07* [3]	-3.55***	-3.44* [6]	0.08* [2]
2015Q2	-8.31***	-8.18***	0.08* [4]	-8***	-7.89***	0.08* [4]	-3.43***	-6.04***	0.07* [3]	-3.82***	-3.73* [5]	0.07* [2]
2015Q3	-8.46***	-8.32***	0.08* [4]	-8.15***	-8.03***	0.08* [4]	-4.15***	-6.26***	0.07* [3]	-3.97***	-3.88* [6]	0.07* [3]
2015Q4	-8.48***	-8.35***	0.08* [4]	-8.18***	-8.06***	0.09* [4]	-4.14***	-6.61***	0.07* [3]	-3.95***	-3.86* [6]	0.07* [3]
2016Q1	-8.58***	-8.43***	0.07* [5]	-8.35***	-8.21***	0.07* [5]	-3.98***	-6.49***	0.06* [2]	-3.75***	-3.68* [6]	0.06* [2]
2016Q2	-8.82***	-8.69***	0.07* [5]	-8.56***	-8.44***	0.07* [5]	-4.2***	-7.22***	0.07* [3]	-3.96***	-3.88* [7]	0.07* [3]
2016Q3	-8.97***	-8.84***	0.07* [5]	-8.7***	-8.59***	0.07* [5]	-4.17***	-7.4***	0.06* [3]	-3.95***	-3.88* [6]	0.06* [3]
2016Q4	-8.85***	-8.73***	0.11* [5]	-8.64***	-8.52***	0.08* [5]	-2.12(8)	-7.34***	0.06* [3]	-3.78***	-3.73* [6]	0.06* [3]
2017Q1	-9.58***	-9.41***	0.08* [6]	-9.22***	-9.14***	0.08* [6]	-4.45***	-6.55***	0.06* [3]	-4.23***	-4.15* [6]	0.06* [3]
2017Q2	-9.71***	-9.6***	0.08* [6]	-9.47***	-9.37***	0.08* [6]	-4.62***	-7.07***	0.06* [3]	-4.43***	-4.36* [6]	0.06* [3]
2017Q3	-9.77***	-9.68***	0.08* [6]	-9.5***	-9.43***	0.08* [6]	-4.62***	-7.3***	0.06* [3]	-4.41***	-4.34* [6]	0.06* [3]
2017Q4	-9.78***	-9.68***	0.08* [7]	-9.53***	-9.45***	0.08* [7]	-4.52***	-6***	0.07* [2]	-4.35***	-4.26* [5]	0.07* [2]
2018Q1	-9.89***	-9.78***	0.08* [7]	-9.66***	-9.58***	0.08* [7]	-4.88***	-4.84***	0.07* [3]	-4.71***	-4.65* [5]	0.07* [3]
2018Q2	-9.98***	-9.86***	0.08* [7]	-9.74***	-9.63***	0.08* [7]	-4.91***	-4.87***	0.05* [3]	-4.73***	-4.67* [5]	0.05* [3]
2018Q3	-10.05***	-9.93***	0.08* [6]	-9.79***	-9.68***	0.08* [6]	-4.77***	-4.7***	0.05* [3]	-4.48***	-4.43* [5]	0.05* [3]
2018Q4	-10.04***	-9.93***	0.08* [7]	-10.11***	-10.03***	0.08* [7]	-4.3***	-4.27***	0.08* [2]	-4.08***	-4.24* [3]	0.08* [2]
2019Q1	-10.09***	-10.03***	0.08* [7]	-10.17***	-10.16***	0.08* [7]	-4.17***	-4.22***	0.19* [0]	-4.17***	-4.27* [2]	0.19* [0]
2019Q2	-10.21***	-10.13***	0.08* [8]	-10.35***	-10.62***	0.08* [8]	-4.71***	-4.67***	0.08* [2]	-4.43***	-4.37* [5]	0.08* [2]
2019Q3	-10.24***	-10.14***	0.08* [9]	-10.73***	-11.04***	0.08* [9]	-4.95***	-4.97***	0.12* [1]	-4.82***	-4.83* [4]	0.12* [1]
2019Q4	-10.42***	-10.34***	0.09* [10]	-10.87***	-11.26***	0.09* [10]	-5.11***	-5.06***	0.07* [2]	-4.97***	-4.91* [4]	0.07* [2]
2020Q1	-10.61***	-10.53***	0.08* [10]	-11.07***	-11.49***	0.08* [10]	-5.08***	-5.02***	0.05* [1]	-5.06***	-5***	0.05* [1]
2020Q2	-10.29***	-10.19***	0.09* [9]	-10.73***	-10.61***	0.09* [9]	-5.15***	-5.1***	0.05* [1]	-5.13***	-5.08* [3]	0.05* [1]

Not: Her iki değişken mevsimsellikten arındırılarak doğal logaritmik farkları alınmıştır. ***, ** ve * sırasıyla %0.1, %5 ve %10 anlamlılık düzeylerinde serilerin durağan olduklarını ifade eder. ΔL, ilgili değişkenin logaritmik 1. devresel farkının alındığını belirtmektedir. ADF birim kök testi sonucundaki (), optimal gecikme uzunluklarını; PP ve KPSS birim kök test sonuçlarındaki [] ise bant genişliğini göstermektedir.

ÖZGEÇMİŞ

Serkan SAMUT, 21.05.1987 tarihinde Diyarbakır İli Yenişehir İlçesi'nde doğdu. 2001 yılında Sühandan Kürklü İlköğretim Okulu'nu; 2004 yılında Yunus Emre Lisesi'ni; 2010 yılında Gazi Üniversitesi – İktisadi ve İdari Bilimler Fakültesi, Ekonometri Bölümü'nü; 2016 yılında da Karadeniz Teknik Üniversitesi – Sosyal Bilimler Enstitüsü, Ekonometri Anabilim Dalı'nda yüksek lisans programını bitirdi. 2016 yılında Karadeniz Teknik Üniversitesi – Sosyal Bilimler Enstitüsü, Ekonometri Anabilim Dalı'nda doktora programına başladı. Halen Karadeniz Teknik Üniversitesi - İktisadi ve İdari Bilimler Fakültesi'nde araştırma görevlisi olarak çalışmaktadır.

SAMUT, bekar olup, İngilizce bilmektedir.