

**T.C.**  
**İNÖNÜ ÜNİVERSİTESİ**  
**SOSYAL BİLİMLER ENSTİTÜSÜ**

**TÜRKİYE’NİN MAKROİKTİSADİ GÖSTERGELERİNİN**  
**ŞİMDİ TAHMİNİ**

DOKTORA TEZİ

DANIŞMAN  
**DOÇ. DR. VELİ YILANCI**

HAZIRLAYAN  
**HAKAN KARA**

**MALATYA-2018**

T.C.  
İNÖNÜ ÜNİVERSİTESİ  
SOSYAL BİLİMLERİ ENSTİTÜSÜ

**TÜRKİYE’NİN MAKROİKTİSADİ  
GÖSTERGELERİNİN ŞİMDİ TAHMİNİ**

DOKTORA TEZİ

DANIŞMAN  
**DOÇ. DR. VELİ YILANCI**

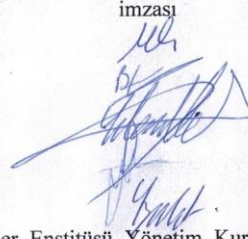
HAZIRLAYAN  
**HAKAN KARA**

Jürimiz 02.04.2018 tarihinde yapılan savunma sınavı sonucunda bu doktora tezini (oybirliği /oyçokluğu) ile başarılı bulunarak Ekonometri Anabilim, Ekonometri Bilim dalında doktora tezi olarak kabul edilmiştir.

Jüri Üyelerinin Unvan Ad Soyadı

imzası

1. Prof. Dr. Mehmet GÜNGÖR
2. Prof. Dr. Burak GÜRİŞ
3. Doç. Dr. Veli YILANCI
4. Doç. Dr. Fatma ZEREN
5. Doç. Dr. Yunus BULUT



İNönü Üniversitesi Sosyal Bilimler Enstitüsü Yönetim Kurulunun 05.04.2018 tarih ve 2018/15 sayılı kararıyla bu tezin kabulü onaylanmıştır.

Unvan Ad Soyad

Sosyal Bilimler Enstitüsü Müdürü

## ONUR SÖZÜ

Doç. Dr. Veli YILANCI'nın danışmanlığında doktora tezi olarak hazırladığım “TÜRKİYE’NİN MAKROİKTİSADİ SERİLERİNİN ŞİMDİ TAHMİNİ” başlıklı bu çalışmanın, bilimsel ahlak ve geleneklere aykırı düşecek bir yardıma başvurmaksızın tarafımdan yazıldığını ve yararlandığım bütün yapıtların hem metin içinde hem de kaynakçada yöntemine uygun biçimde gösterildiğini belirtir, bunu onurumla doğrularım.

Tarih:

Ad-Soyad:

İmza:

## **BİLDİRİM**

Doç. Dr. Veli YILANCI'nın danışmanlığında hazırladığım “TÜRKİYE’NİN MAKROİKTİSADİ SERİLERİNİN ŞİMDİ TAHMİNİ” başlıklı doktora tezimin tamamen kendi çalışmam olduğunu ve her alıntıya kaynak gösterdiğimi taahhüt eder, doktora tezimin kâğıt ve elektronik kopyalarının İnönü Üniversitesi Sosyal Bilimler Enstitüsü arşivlerinde aşağıda belirttiğim koşullarda saklanmasına izin verdiğimi onaylarım.

- Tezimin tamamı her yerden erişime açılabilir.
- Tezim sadece İnönü Üniversitesi yerleşkelerinden erişime açılabilir.
- Tezimin 3 yıl süreyle erişime açılmasını istemiyorum. Bu sürenin sonunda uzatma için başvuruda bulunmadığım takdirde, tezimin tamamı her yerden erişime açılabilir.

24.04.2018

Hakan KARA

## ÖNSÖZ

Tez çalışmam süresince bilgi ve öneri anlamında desteğini esirgemeyen değerli hocam Doç. Dr. Veli YILANCI'ya,

Çalışmalarım sırasında bilgi ve birikimi ile maddi ve manevi desteklerini hiçbir zaman esirgemeyen çok kıymetli hocam Prof. Dr. Mehmet GÜNGÖR'e ve değerli arkadaşım Dr. Esra GÖKÇE'ye,

Değerli Hocalarım Doç. Dr. Fatma ZEREN'e ve Prof. Dr. Burak GÜRİŞ'e,

Beni bu yaşa kadar büyütüp her zaman yanımda olan sevgili anne ve babama,

Çalışmalarım esnasında özveride bulunmak durumunda kalan kızım Betül Erva'ya ve oğlum Eyüp'e;

Bu süreçte sınırsız destekte ve fedakârlıkta bulunan çok sevdiğim eşim Leyla'ya,

Sonsuz teşekkür ederim.

## ÖZET

Gayri Safi Yurtiçi Hâsıla (GSYH ) ülkelerin ekonomik durumunu belirlemek için önemli bir değişkendir. Bu yüzden hükümetler ve merkez bankaları GSYH için doğru ve güncel değerlendirmeye ihtiyaç duyarlar. Bu çalışmada Türkiye'nin GSYH çeyreklik büyüme oranının öngörüsü yedi farklı şimdi tahmin yöntemi kullanılarak yapılmıştır. Bu sayede hangi yöntemin Türkiye için daha uygun olduğu tespit edilmeye çalışılmıştır. Böylece ülkemizde yayımlanan verilere uygun bir yöntem yoluyla doğru ve güvenilir tahminler üretilmiş olacaktır. Çalışmada kullanılan modellerden elde edilen öngörüler istatistiksel olarak karşılaştırılmış ve farklılıkları ortaya konmuştur.

**Anahtar Kelimeler:** Şimdiki Tahmin, Midas, Dinamik Faktör Analizi, Köprü Model.

## **ABSTRACT**

Gross Domestic Product's (GDP) is an important variable to determine the economic situation of the country therefore governments and central banks need to have an accurate and timely assessment of GDP. In this study seven different nowcasting models is applied in order to forecast Turkish GDP growth rate for the current quarter. Thus it has been tried to determine which method is more appropriate for Turkey. Therefore, accurate and reliable nowcast will be produced through a method appropriate to data set in our country. Nowcasting methods used in the study were compared statistically and their differences were revealed.

**Key words:** Nowcasting, Midas, Dynamic Factor Analysis, Bridge Models.

## İÇİNDEKİLER TABLOSU

ONUR SÖZÜ .....	i
BİLDİRİM.....	iii
ÖNSÖZ.....	iv
ÖZET.....	v
ABSTRACT.....	vi
Kısaltmalar .....	ix
Tablolar .....	x
Şekiller.....	xi
GİRİŞ .....	1
BÖLÜM 1 .....	2
1 ŞİMDİ-TAHMİN KAVRAMI VE DEĞERLENDİRME ÖLÇÜTLERİ.....	2
1.1 Şimdi Tahmin Nedir?.....	2
1.1.1 Neden Şimdi Tahmine İhtiyaç Duyulur ve Karşılaşılan Sorunlar .....	3
1.1.2 Şimdi Tahmin Modellerinin Doğruluğunu Etkileyen Olgular .....	4
1.2 Ekonomik Şimdi Tahmin Sorunları .....	5
1.3 Öngörü Doğruluğu .....	8
1.3.1 Diebold and Mariano (DM, 1995) Testi .....	9
1.4 Öngörü Performansı .....	10
1.4.1 Ortalama Mutlak Hata (MAE).....	10
1.4.2 Kök Ortalama Hata Kare (RMSE).....	11
1.4.3 Ortalama Hata (ME) .....	11
1.4.4 Ortalama Hata Kare (MSE) .....	11
1.4.5 Ortalama Mutlak Yüzde Hatası (MAPE).....	12
1.4.6 Theil Eşitsizlik Katsayısı .....	13

1.5	Farklı Öngörülerin Birleştirilmesi .....	14
1.5.1	İki Sapmasız Öngörünün Birleştirilmesi .....	15
1.5.2	k Sapmasız Öngörünün Birleştirilmesi.....	16
1.6	Öngörü Kapsama Testi .....	16
<b>BÖLÜM 2 .....</b>		<b>18</b>
<b>2</b>	<b>ŞİMDİ TAHMİN YÖNTEMLERİ.....</b>	<b>18</b>
2.1	Doğrudan Şimdi Tahmin.....	18
2.2	Toplulaştırılmamış Bilgilerin Kullanılmasıyla Dolaylı Şimdi Tahmin ....	19
2.3	Otoregresif Hareketli Ortalamalar (ARIMA) Yöntemi.....	20
2.4	Köprü Model Yöntemi .....	21
2.5	Dinamik Faktör Model Yöntemi .....	25
2.6	Karma Frekanslı Veri Örneklemi (MIDAS) Yöntemi.....	29
2.6.1	Temel MIDAS Yöntemi.....	30
2.6.2	Çok değişkenli MIDAS Yöntemi .....	32
2.6.3	Doğrusal Olmayan MIDAS Yöntemi.....	32
2.7	AR-MIDAS Yöntemi.....	33
2.8	Kısıtsız MIDAS (U-MIDAS) Yöntemi .....	34
2.9	Üç Aşamalı Regresyon Filtreleme (3PRF) Yöntemi .....	36
2.9.1	Karma Frekanslı 3PRF Yöntemi.....	38
<b>BÖLÜM 3 .....</b>		<b>40</b>
<b>3</b>	<b>VERİ VE UYGULAMA.....</b>	<b>40</b>
3.1	Şimdi Tahmin Yöntemleri İle İlgili Literatür Taraması .....	40
3.2	Türkiye İçin Uygulama .....	42
<b>SONUÇ.....</b>		<b>53</b>
<b>KAYNAKÇA .....</b>		<b>55</b>

## KISALTMALAR

<b>3PRF</b>	: 3 Geçişli Regresyon Filtre
<b>AIC</b>	: Akaike Bilgi Kriteri
<b>AR</b>	: Otoregresif Süreç
<b>ARIMA:</b>	: Otoregresif Hareketli Ortalamalar Süreci
<b>KM</b>	: Köprü Modeller
<b>DM</b>	: Diebold and Mariano
<b>EKK</b>	: En Küçük Kareler
<b>GSYH</b>	: Gayri Safi Yurt İçi Hasıla
<b>MA</b>	: Hareketli Ortalama
<b>MAD</b>	: Ortalama Mutlak Sapma
<b>MAE</b>	: Ortalama Mutlak Hata
<b>MAPE</b>	: Ortalama Mutlak Yüzde Hatası
<b>ME</b>	: Ortalama Hata
<b>MIDAS</b>	: Karma Frekanslı Veri Örnekleme
<b>MSE</b>	: Ortalama Hata Kare
<b>NLS</b>	: Doğrusal Olmayan En Küçük Kareler
<b>RMSE</b>	: Kök Ortalama Hata Kare
<b>SIC</b>	: Schwartz Bilgi Kriteri
<b>U-MIDAS</b>	: Kısıtsız Karma Frekanslı Veri Örnekleme
<b>VAR</b>	: Vektör Otoregresif

## **Tablolar**

Tablo 3-1: Uygulamada Kullanılan Değişkenler .....	42
Tablo 3-2: Kapsama Testi Karşılaştırma Sonuçları .....	49
Tablo 3-3: Kapsama Testi İkili Karşılaştırma Sonuçları .....	50
Tablo 3-4: Diebold-Mariano(DM) Test Sonuçları.....	51
Tablo 3-5: Öngörü Doğruluğu Değerlendirme Sonuçları.....	51

## Şekiller

Şekil 3-1: Bir Önceki Çeyreğe Göre GSYH'deki Büyüme Oranı .....	44
Şekil 3-2: AR(1) Modelinin Öngörü Değeri ve Gerçek GSYH Değeri .....	44
Şekil 3-3: Birinci Köprü Modeli(KM1) Öngörü Değeri ve Gerçek GSYH Değeri .....	45
Şekil 3-4: İkinci Köprü Modeli(KM2) Öngörü Değeri ve Gerçek GSYH Değeri.....	45
Şekil 3-5: Dinamik Faktör Modelin Öngörü Değeri ve Gerçek GSYH Değeri .....	46
Şekil 3-6: MIDAS Modelin Öngörü Değeri ve Gerçek GSYH Değeri.....	47
Şekil 3-7: U-MIDAS Modelin Öngörü Değeri ve Gerçek GSYH Değeri .....	47
Şekil 3-8: 3PRF Modelin Öngörü Değeri ve Gerçek GSYH Değeri .....	48
Şekil 3-9: Tüm Modellerin Öngörü Sonuçları ve Gerçek GSYH Çeyreklik Büyüme Oranı.....	49

## GİRİŞ

Ekonomik aktörler karar alacakları zaman gelecek hakkında buldukları öngörülerini en az hata ile yapmak isterler. Bir ülkede birçok iktisadi seri ile ilişkili ve karar vericilerin önemseydiği en önemli ekonomik göstergelerden biri olan GSYH'nin ne kadar doğru öngörüsü yapılabilirse alınacak kararlar ve atılacak adımlar o kadar isabetli olacaktır. Bu gerçeği göz önünde bulundurarak GSYH için hızlı ve doğru öngörüler nasıl elde edilebilir düşüncesiyle Türkiye'nin GSYH'nin şimdi-tahminini elde etmenin önemi artmaktadır. GSYH için çok farklı öngörü yöntemleri kullanılmaktadır. Fakat Türkiye için yapılan çalışmaların kısıtlı olması ve birçok modelin karşılaştırmalı olarak ele alan çalışmanın neredeyse olmaması bu alanda çalışma motivasyonunu doğurmuştur. Çalışmanın ilk bölümünde, şimdi-tahmin nedir, nelerden etkilenir ve elde edilen sonuçların hangi kıstaslara göre karşılaştırıldığı ele alınmaktadır. İkinci bölümde, literatürde Türkiye ve diğer ülkeler için yapılan bazı önemli çalışmalara yer verilmiştir. Üçüncü bölümde, farklı şimdi-tahmin yöntemleri ele alınmaktadır. Dördüncü bölümde, seçilmiş farklı şimdi-tahmin yöntemlerinin Türkiye için uygulaması yapılmış, hangi yöntemler ve hangi veri setleri ele alınırsa doğru ve güvenilir öngörü yapılabilir sorularının cevabı için karşılaştırmalı sonuçlara yer verilmektedir.

## BÖLÜM 1

### 1 ŞİMDİ-TAHMİN KAVRAMI VE DEĞERLENDİRME ÖLÇÜTLERİ

#### 1.1 Şimdi Tahmin<sup>1</sup> Nedir?

Bazı iktisadi kararlar henüz açıklanmamış cari ve gelecekteki verilerin kullanıldığı ekonomik durumların değerlendirilmesine dayanmaktadır. Birçok iktisadi seri ya gecikmeli yayınlanmakta ya da yayımlandıktan bir müddet sonra revize edilmektedir. İktisatçılar ekonominin şimdiki durumu ve yakın geçmişteki durumu için eksik bilgilere sahiptir. Sonuç olarak bugünü ve geleceği kestiren hava tahmincilerinden farklı olarak, iktisatçılar bugünü ve yakın geçmişi tahmin etmek zorundadır. Bugünü, yakın geleceği ve yakın geçmişi kestirim problemi şimdi tahmin olarak adlandırılır (Banbura vd., 2010).

Şimdi tahmin, ekonomideki cari durumu ve kısa vadedeki gelişmeleri, öngörü yöntemi olarak ifade edilir. Kısa vadeli tahmin dönemlerinde istatistiksel modellerin tahmin performansı cari göstergelerin dâhil edilmesi ile artar. Bu isabet oranı ve artırılmış öngörü performansı cari durum ve yakın gelecek ile alakalıdır. Bu özel öngörü modelleri genellikle şimdi tahmin modelleri olarak adlandırılır (Anderson ve Reijher, 2015:75-76).

Şimdi tahmin özellikle kayda değer bir gecikmeyle ve çeyreklik veriler gibi düşük frekanslı açıklanan önemli makro iktisadi değişkenlerle ilgilidir. Etkili bir şimdi tahmin aracının anahtar özelliklerinden biri, farklı gecikme tarihlerinde ve eşzamanlı açıklanmayan verileri daha güncel bilgilerle bir araya getirmektir. Örneğin, Türkiye İstatistik Kurumu (TÜİK), Gayri Safi Yurtiçi Hâsıla (GSYH) verisini çeyrek yıllık olarak hesaplamakta ve açıklamaktadır. Bu çeyrekte meydana gelen değişim ancak en erken yedi hafta sonra açıklanmaktadır. Hâlbuki bu zaman zarfında, enflasyon ve dış ticaret verileri gibi GSYH ile alakalı daha sık frekanslarla ve daha az gecikmeyle derlenip yayınlanan iktisadi veriler de vardır. Bu tarz veriler GSYH'nin öngörüsü için kullanılabilir.

---

<sup>1</sup> Şimdi tahmin meteorolojide gelecek 12 saat için kullanılan bir terimdir. Ekonomi literatürüne Giannone vd..(2008) tarafından kazandırılmıştır.

Şimdi tahmin yöntemi her ne kadar çoğu zaman GSYH'yi tahmin etmek için kullanılsa da önemli bir gecikme ile ve düşük frekanslı açıklanan başka değişkenlerin tahmini için de kullanılabilir. Genelde GSYH'nin tercih edilmesinin sebebi ekonominin geneli hakkında önemli bilgiler veren ciddi bir iktisadi değişken olmasıdır. Özellikle merkez bankalarında GSYH'nin şimdi tahmin yakından izlenmekte ve açıklanan son güncel verilerin ve bilgilerinin birleştirilmesiyle tahminlerini güncellemektedir. Bunlara ek olarak şimdi tahmin daha uzun vadeli ve büyük yapısal modellerin temelinde yürütülen öngörü süreçlerinin bir girdisi olarak da kullanılmaktadır (Banbura vd., 2010:2-3).

GSYH'nin şimdi tahmininde kullanılan GSYH ile ilgili değişkenler genellikle aylık veya daha sık açıklanan verilerdir. Farklı frekans ve eş zamanlı olmayan yayın tarihleri örneklemin sonunda eksik veriyle dengesiz panel üretmektedir. Bu problem genelde “düzensiz kesit” olarak adlandırılır (Forni ve Marcellino, 2013:1).

### **1.1.1 Neden Şimdi Tahmine İhtiyaç Duyulur ve Karşılaşılan Sorunlar**

Ekonomik değişkenlerin öngörüsü yapılırken istatistiksel modeller ve yapısal modeller<sup>2</sup> kullanılmaktadır. İstatistiksel modeller, buldukları öngörülerini niçin ürettikleri hakkında nadiren temel ekonomik sebepler sunarlar. Fakat öngörü hatalarını azaltmaya yardım etmektedir. Yapısal modellerse ekonominin işleyişini anlamak için bir çerçeve sağlamaktadır. Fakat istatistiksel modellerin iş anketlerindeki veriler gibi ekonomik dönüşüm hakkındaki daha güncel bilgi kaynaklarını doğrudan kullanarak şimdi tahminde yapısal modellere üstünlük sağlaması çok yüksek ihtimaldir. Örnek olarak, güncel finansal krizler süresince birkaç yapısal model ekonomik çıktıdaki ani daralmaları öngörebilmiştir. Buna karşın büyük hata payı olsa da iş anketlerinden elde edilen bilgilerin dâhil edildiği istatistiksel modeller genelde yapısal modellerden daha iyi öngörü üretmişlerdir (Bell vd, 2014:63).

Castle vd., (2013)'e göre ekonomik politika kararlarında kilit rol oynayan toplulaştırılmış ekonomik veriler için niçin şimdi tahmine ihtiyaç duyulmasının dört kullanışlı sebebi vardır ve her bir sebep aşağıda belirtilen benzer problemle eşleşir;

---

<sup>2</sup> Yapısal model: Hane halkı ve firmalar gibi ekonomik ajanlar tarafından alınan kararlardan yola çıkarak elde edilen davranışsal denklemler sistemidir.

İlk ve en önemlisi, ilgili toplulaştırılmış veriyi tahmin için gerekli toplulaştırılmamış değişkenlerin hepsinin eş zamanlı hazır olmamasıdır. Araştırmacılar güncellik ve doğruluk arasındaki en uygun görüşlerine dayanarak ön kestirimlerini ne zaman yayınlayacaklarına karar verirler. Bu ‘eksik veri problemi’ ile her zaman karşılaşılmaktadır. İkinci olarak, birçok ekonomik zaman serisinin kendisi, daha çok bilginin açıklanmasıyla ciddi düzeltme potansiyeline maruz kalan ön bilgi ve kestirimdir. Bundan dolayı bu seriler mevcut şartlar için mutlak, güvenilir ve doğru rehber değildir. Bazı araştırmacılar çoğu öncü ölçümlerin sapmalı kestiriciler olduğunu ve bazı revize edilmiş serilerin çoklu yapısal kırılmalardan etkilendiğini bulmuşlardır. Bu yüzden “ölçüm hatası sorunu” da yaygındır.

Üçüncüsü; şimdi tahmin için gerekli toplulaştırmada farklı veri bileşenlerinin farklı zaman dönemlerinde mevcut olmamasıdır. Böylece sistematik olmayan bir temelde eksik veri durumu ortaya çıkar. Sonuç olarak, uygun bir bilgi alt kümesi nadiren bulunur ve bu durum da şimdi tahmin için herhangi bir sistemi etkileyen ‘değişen veri tabanı’ problemine sebep olur. Dördüncüsü, ilgili değişkenlerin güncel değerleri olsa bile şimdi tahminler yine de üretilmelidir. Bunlar, şimdi tahminler ölçülen serilerden çok fazla sapma gösterdiğinde erken uyarı sinyali gibi davranarak anında değerlendirme yapmaya imkân tanıyacaktır. Bu durum şimdi tahmin modelinin veya yönteminin performansında oluşan herhangi bir bozulmanın anında hızlı bir düzeltme hareketinin gerçekleşmesini sağlayabilir veya güncel serilerle ilgili ölçme hatası sorununun uyarısı olabilir. Bu yüzden ‘kırılma sorunu’ daima herhangi bir şimdi tahminin doğruluğunun bozulması için bir tehdittir (Castle vd., 2013:71-72).

### **1.1.2 Şimdi Tahmin Modellerinin Doğruluğunu Etkileyen Olgular**

Kestirim temelli şimdi tahmin yöntemleri genellikle geçmişe yönelik uzun vadeli veriler kullanarak kestirim yapar. Bu yüzden her zaman yeni bir veriden etkilenmez veya özel durumları dikkate almaz. Bu durumda bu yöntemlerin belirli çeyreklerde doğruluğunu sorguladır. Sonuç olarak kullanılan şimdi tahmin modelinin gelişmeleri yeterince kapsamadığı özel durumlar vardır ve bu durumlarda araştırmacılar bu tarz modellere daha az ağırlık verirler (Bell vd., 2014:62).

### **1.1.2.1 Göstergelerin Kullanımı**

İş anketlerinde değişkenlerin genellikle nitel ölçülmesinden dolayı zorluklarla karşılaşılır. Örneğin araştırma için yapılan ankette işadamına firmasının üretiminin artıp artmadığı mı diye sorulur. Buradan hareketle üretimde artış veya azalış olduğu belirlenir fakat üretimin ne kadar değiştiği belirlenemez. Eğer üretimdeki değişim olumlu yönde çok az olmuş fakat ankete tabi tutulan kişi tarafından üretimde değişim olmadı veya azaldı cevabı verilirse sonuçlar yanıltıcı olur.

Eğer bir gösterge veri açıklama tarihinden ciddi saparsa belli bir göstergeye daha çok ağırlık veren bir model hedeflemek durumu ortaya çıkabilir.

### **1.1.2.2 Geçici ve Özel Durumlar**

Bazen bilginin diğer kaynakları modelin veya anket verisinin güncel olayları yakalamadığını gösterebilir. Ekonomik analiz yapacaklar bazen belirli bir endüstride çıktıyı etkileyen geçici olaylar hakkında bilgi alabilir. Bazen de olimpiyat oyunları gibi özel durumlar birden fazla endüstriyi etkileyebilir. Bu tarz olay türlerinin etkileri bilet satışları gibi bazı özel bilgi kaynakları kullanılarak öngörülme çalışılır.

### **1.1.2.3 İstikrarsız Katsayılar**

Çıktı dinamiklerindeki zamanla değişim şimdi tahmin modellerindeki katsayıların çok kısa dönem için çıktıdaki hareketin büyüklüğünü yakalamada başarısız olmasına yol açabilir (Bell vd., 2014:63). Örneğin ülkemizde meydana gelen 2001 krizindeki ekonomik daralma bu duruma iyi bir örnek olabilir.

## **1.2 Ekonomik Şimdi Tahmin Sorunları**

Belirli bir şimdi tahmin modelini ele almadan önce şimdi tahminin yeni bilgi akışı sonucu güncellenme sorunları şu şekilde tanımlanır. GSYH'nin yetkili makamlarsa açıklanan sayısal değeri GSYH'nin şimdi tahmininin yapıldığı çeyreğin bitiminden yaklaşık altı hafta sonra açıklanmaktadır. Bu arada GSYH, yüksek frekanslı ve daha güncel değişkenler kullanılarak kestirilebilir.

Sorunu daha biçimsel tanımlamak için belirli bir verinin açıklanma tarihi  $v$  olmak üzere  $v$  tarihinde kullanılabilir olan aylık ve çeyreklik verilerden oluşan veriler  $\Omega_v$  ile temsil edilsin.

t tarihindeki GSYH büyümesi  $y_t^Q$  ile gösterilsin.  $y_t^Q$ 'nin şimdi tahmin sorunu mevcut bilgi kümesi  $\Omega_v$  üzerine  $y_t^Q$ 'nin dikey izdüşümü olarak şu şekilde tanımlanır:

$$P[y_t^Q | \Omega_v] = E[y_t^Q | \Omega_v]$$

$E[. | \Omega_v]$  koşullu beklentiyi ifade etmektedir. Şimdi tahmini diğer öngörü uygulamalarından ayıran öğelerinden bir tanesi  $\Omega_v$  bilgi kümesinin yapısıdır.  $\Omega_v$ 'nin belirli bir özelliği genellikle “düzensiz kesit” olarak anılmaktadır. Bunun anlamı veriler aynı zamanda açıklanmadığından ve farklı gecikmelerle açıklandıklarından son mevcut gözlemin zamanı seriden seriye değişir. Şimdi tahminin diğer bir özelliği karma frekanslı seriler içermesidir. Yani aylık, haftalık, günlük v.b. serileri birlikte içerir.  $\Omega_v = \{x_i, x_{i,t_i}, t_i = 1, 2, \dots, T_{i,v}, i = 1, 2, \dots, n; y_{3k}^Q, 3k = 3, 6, 9, \dots, T_{Q,v}\}$   $T_{i,v}$  v tarihinde j tane serinin gözlemlendiği son dönemi temsil etmektedir. Veriler farklı tarihte açıklandığından  $T_{i,v}$  değişkenler boyunca aynı değildir. Bu yüzden veri yukarıda bahsedilen *düzensiz kesit* durumunu sergiler. Dolayısıyla şimdi tahmin sorunu,  $\Omega_v$  üzerine makul bir olasılık yapısı uygulamaya koyan ve mümkün oldukça geniş  $x_{i,t_i}$  tahmincilerini içeren bilgi setinden ilgili tüm bilgileri kullanan bir çerçevede analiz edilmelidir (Banbura vd., 2010:5).

Şimdi tahminin işleyişinin önemli bir özelliği ilgilenilen çeyreğin tek bir projeksiyonunu gerçekleştirmek yerine yeni veri geldikçe güncellenen tahminler üretmesidir. İlk şimdi tahminler, genellikle referans çeyrek hakkında çok az bilgi varken veya hiç bilgi yokken yapılmaktadır. İlk şimdi tahminler, veriler açıklandıkça revize edilir ve ilgili döneme ait bilgiler çoğaldıkça daha doğru bir projeksiyon gerçekleştirilir. Genellikle veri açıklanma tarihleri arasında birkaç gün veya daha az zaman bulunur ve bu zaman farkı zamanla da değişir. Sonuç olarak v yüksek frekanslı ve düzensiz aralığa sahiptir.

Banbura vd. (2010:5-7) ‘*Haber*’ şimdi tahmin neden ve nasıl güncellendiği ve şimdi tahminin revizyonunu anlamak için önemli bir kavramdır. Öncelikle, iki bilgi kümesi olan  $\Omega_v$  ve  $\Omega_{v+1}$  arasındaki fark ele alınmalıdır.  $v+1$  zamanında açıklanmış belli bir veri kümesi  $\{x_{j,T_{j,v+1}}, j \in \mathbb{J}_{v+1}\}$  olsun ve sonuçta bu bilgi kümesi genişlesin. İlave bir gözlem açıklandığında tüm  $j \in \mathbb{J}_{v+1}$  için  $T_{j,v+1} = T_{j,v} + 1$  dir. Yeni bilgi seti iki sebepten bir öncekinden farklıdır. İlki, daha yeni veriler içermektedir. İkincisi, eski veriler revize

edilmiş olabilir. Sonraki model veri revizyon probleminden soyutlanacaktır. Böylece  $\Omega_v \subseteq \Omega_{v+1}$  ve  $\Omega_v \setminus \Omega_{v+1} = \{x_{j,T,j,v+1}, j \in \mathbb{J}_{v+1}\}$  olacaktır.

Dikey izdüşümün özellikleri ve bilginin genişleyen karakteri dikkate alındığında yeni öngörüü şöyle ayrıştırılabilir:

$$E[y_t^Q | \Omega_{v+1}] = E[y_t^Q | \Omega_v] + E[y_t^Q | I_{v+1}] \quad (1.1)$$

Yeni öngörü = eski öngörü + revizyon

$I_{v+1}$ , elemanları  $\Omega_v$ 'nin tüm elemanlarına dikey olan  $\Omega_{v+1}$  bilgi setinin alt kümesidir.  $\Omega_v$  ve  $\Omega_{v+1}$ 'in yukarda tanımlanan farkları dikkate alındığında

$$I_{v+1,j} = x_{j,T,j,v+1} - E[x_{j,T,j,v+1} | \Omega_v] \quad (1.2)$$

eşitliği elde edilir.

$I_{v+1} = (I_{v+1,1} \dots I_{v+1,j_{v+1}})'$ ,  $j_{v+1} \mathbb{J}_{v+1}$ 'deki elemanların sayısını temsil etmektedir. Böylece şimdi tahminde bir değişikliğe neden olan tek unsur veri açıklamanın beklenmedik parçası olan '*haber*' olarak adlandırılan  $I_{v+1}$ 'dir. '*haber*' kavramı önemlidir çünkü şimdi tahminin güncelleme sürecini anlamakta önemli olan şimdi tahminin ilanı değil, bu ilan ile önceki ilan arasındaki farktır. Özellikle açıklanan rakamların model tarafından tam olarak tahmin edildiği beklenmedik durumlarda şimdi tahmin revize edilmeyecektir. Diğer taraftan örneğin sanayi üretiminde olumsuz '*haber*'in GSYH'nin öngörüsünü aşağı revize ettirmesi gerektiği sezgisel olarak beklenmektedir. Aşağıda bunun nasıl nicelleştirileceği gösterilmiştir. '*haber*' standart Wold<sup>3</sup> öngörü hatası değildir. Çünkü veri bulunabilirliği örüntüsü zamanla değişmektedir ve '*haber*' yeni verilerin yayımlanma sırasına bağlıdır (Banbura vd., 2010:5-7)..

Koşullu beklentinin özelliklerinden denklem (1.1) aşağıdaki gibi geliştirilebilir:

$$E[y_t^Q | I_{v+1}] = E[y_t^Q I'_{v+1}] E[I_{v+1} I'_{v+1}]^{-1} I_{v+1} \quad (1.3)$$

Denklem (1.3) daha genişletmek ve anlamlı model tabanlı *haber* bileşeni çıkarmak için, verilerin dinamik ilişkilerini birlikte hesaba katan bir modele ihtiyaç

<sup>3</sup> Wold Teoremi her kovaryans durağan zaman serisinin deterministik ve stokastik olmak üzere iki ayrı zaman serisinin toplamı şeklinde yazılabileceğini söyler.

duyulmaktadır. Böyle bir model olduğunda ve veriler Gauss dağılımlı kabul edildiğinde model,  $b_{j,t,v+1}$  katsayıların bulunabileceği şöyle bir modele dönüşür:

$$\underbrace{E[y_t^Q | \Omega_{v+1}]}_{\text{Yeni öngörü}} = \underbrace{E[y_t^Q | \Omega_v]}_{\text{eski öngörü}} + \sum_{j \in \mathbb{J}_{v+1}} b_{j,t,v+1} \underbrace{(x_{j,T_{j,v+1}} - E[x_{j,T_{j,v+1}} | \Omega_v])}_{\text{haber}} \quad (1.4)$$

Diğer bir ifadeyle, öngörü revizyonu açıklanan değişkenlerden *haber*in ağırlıklı toplamı gibi ifade edilebilir:

$$\underbrace{E[y_t^Q | \Omega_{v+1}] - E[y_t^Q | \Omega_v]}_{\text{Öngörü revizyonu}} = \sum_{j \in \mathbb{J}_{v+1}} b_{j,t,v+1} \underbrace{(x_{j,T_{j,v+1}} - E[x_{j,T_{j,v+1}} | \Omega_v])}_{\text{haber}} \quad (1.5)$$

Dolaysıyla öngörü revizyonunun büyüklüğü *haber*in boyutuna ve *haber*in ilgili ağırlık  $b_{j,t,v+1}$  ile ölçülen hedef değişken ile olan ilişkisine bağlıdır.

Denklem (1.5)'in analizi, öngörü revizyonunun kaynaklarını tekrar tekil kestiricilere dönüştürmeyi sağlamaktadır. Birkaç değişkenin eş zamanlı açıklandığı durumda, sonuçta bulunan öngörü revizyonunu tekil serilerdeki *haber*den gelen katkılara ayırtırmak mümkündür. Böylece girdilerin beklenmedik gelişmeleriyle ilişki içindeki hedefin revizyonunun yorumlanmasına izin verilir. Bu ayırtırma öngörünün her yeni veri açıklanmasından daha az sıklıkla güncellendiği durumlarda da yararlıdır (Banbura vd., 2010:6-7).

### 1.3 Öngörü Doğruluğu

Öngörü doğruluğu testleri model bazlı veya model bazlı olmayan şeklinde iki başlık altında incelenebilir. Model bazlı testler ekonometrik modellerin parametrik, belirli bir veri örneğinden kestirildiğini ve öngörü doğruluğunu test etmek için hem verinin hem de modelin uygun olduğunu varsaymaktadır. Bu tür testler, tahmini modelin deterministik ve stokastik simülasyonlarına dayanan büyük makroekonomik modeller için geliştirilmiştir. Model bazlı olmayan testler için araştırmacının elinde bulunan bilgilerin yalnızca öngörülerin kümesinden ve öngörü gerçek değerlerinden oluştuğu varsayılmaktadır. Ayrıca, rakip modellerden iki veya daha fazla öngörü kümesine gerçek değerlerle birlikte sahip olduğu ve öngörülerin göreceli doğruluğunun belirlenmek istendiği kabul edilmektedir (Mariano, 2004:284-286).

### 1.3.1 Diebold and Mariano (DM, 1995) Testi

Diebold ve Mariano (1995) model bazlı olmayan bir test önermişlerdir. Önerilen testin sıfır hipotezi iki öngörü arasında fark yoktur şeklinde kurulmaktadır. Önerilen test için kayıp fonksiyonu karesel veya simetrik olmak zorunda değildir. Ek olarak da öngörü hataları Gauss olmayan dağılıma, sıfırdan farklı bir ortalamaya, ardışık bağımlılığa ve eşzamanlı korelasyona sahip olabilmektedir.

$\{y_t\}_{t=1}^T$  zaman serisinin  $\{\hat{y}_{it}\}_{t=1}^T$  ve  $\{\hat{y}_{jt}\}_{t=1}^T$  diye iki öngörüsü olsun. Bunların öngörü hataları da sırasıyla  $e_{it} = y_t - \hat{y}_{it}$  olmak üzere  $\{e_{it}\}_{t=1}^T$  ve  $\{e_{jt}\}_{t=1}^T$  olsun.  $t$  zamanında  $i$ . öngörü ile ilişkili kayıp, serinin gerçek değeri  $y_t$ , ile tahmini değeri,  $\hat{y}_{it}$ , nin bir fonksiyonu,  $g(y_t, \hat{y}_{it})$ , ile gösterilmektedir. Kayıp fonksiyonu  $g(y_t, \hat{y}_{it}) = g(e_{it})$  şeklinde hataların doğrudan bir fonksiyonudur. Önerilen testin sıfır ve alternatif hipotezi aşağıdaki gibidir. Tüm  $t$  ler için;

$$H_0: E[g(e_{it})] = E[g(e_{jt})] \text{ ya da } E[d_t] = 0, d_t = [g(e_{it}) - g(e_{jt})]' \text{ dir.}$$

$$H_1: E[d_t] \neq 0$$

Diebold ve Mariano (1995) kayıp farkları serisinin örneklem yolu  $\{d_t\}_{t=1}^T$  olduğunu kabul etmektedir. Eğer kayıp farklılıkları serisi kovaryans durağan ve kısa hafızalı ise örneklem ortalamasının asimtotik dağılımı standart yolla çıkarılabilir.

$$\sqrt{T} (\bar{d} - \mu) \xrightarrow{d} N(0, 2\pi f_d(0))$$

$$\bar{d} = \frac{1}{T} \sum_{t=1}^T [g(e_{it}) - g(e_{jt})]$$

$$f_d(0) = \frac{1}{2\pi} \sum_{\tau=-\infty}^{\infty} \gamma_d(\tau)$$

kayıp fonksiyonunun sıfır frekansında spektral yoğunluğudur.

$\gamma_d(\tau) = E[(d_t - \mu)(d_{t-\tau} - \mu)]$  kayıp farklılıklarının  $\tau$ . dereceden otokovaryansıdır,  $\mu$  kayıp farklılıklarının ana kitle ortalamasıdır.

Diebold and Mariano (1995) büyük örneklerde  $\bar{d}$  nin  $\mu$  ortalama ve  $2\pi f_d(0)$  varyansla  $N(0,1)$  normal dağılıma yaklaşıcağını iddia etmektedir. Böylece test istatistiği

$$DM = \frac{\bar{d}}{\sqrt{\frac{2\pi \hat{f}_d(0)}{T}}}$$

$\hat{f}_d(0)$ ,  $f_d(0)$  'nin tutarlı tahmincisidir.  $f_d(0)$ 'nin tutarlı tahmincisi mevcut örneklem otokovaryanslarının ağırlıklı toplamlarının alınmasıyla elde edilmektedir:

$$2\pi \hat{f}_d(0) = \sum_{\tau=-(T-1)}^{T-1} 1\left(\frac{\tau}{S(T)}\right) \hat{\gamma}_d(\tau)$$

$\hat{\gamma}_d(\tau) = \frac{1}{T} \sum_{t=|\tau|+1}^T (d_t - \bar{d})(d_{t-|\tau|} - \bar{d})$ ,  $1\left(\frac{\tau}{S(T)}\right)$  gecikme penceresi ve  $S(T)$  kesme(truncation) gecikmesidir.

DM test istatistiği mutlak değerce standart birim Gauss dağılım kritik değerini aşarsa sıfır hipotezi reddedilmektedir. Böylece iki öngörü arasında fark olduğu sonucuna ulaşılmaktadır.

## 1.4 Öngörü Performansı

Öngörü hatalarının geçmişteki sicili, model hatası ve hatalı öznel düzenlemelerin katkısı da dâhil olmak üzere tüm hata kaynaklarını içerir. Dolayısıyla geçmişteki öngörü performansı, öngörü belirsizliğinin ölçüsü için uygun bir temel oluşturmaktadır. Öngörü performansını ölçen yöntemlerden bazıları şunlardır:

### 1.4.1 Ortalama Mutlak Hata (MAE)

Ortalama mutlak hata, tahmin hatalarının mutlak değerlerinin ortalamasıdır. Öngörü hatalarının maliyeti öngörü hatasının mutlak boyutu ile orantılı olduğunda uygun olmaktadır. Bu kritere ortalama mutlak sapma (MAD) da denir. Bu ölçüt, ölçeklendirmeye duyarlıdır, bu nedenle, farklı ölçeklerle ölçülmüş veri kümelerindeki öngörme başarısını karşılaştırmak için kullanılmamalıdır.

$$MAD = \frac{1}{n} \sum_{t=1}^n |e_t|$$

#### 1.4.2 Kök Ortalama Hata Kare (RMSE)

Öngörü hatalarının karesel değerlerinin ortalamasının kareköküdür. Bu ölçüt, örtük olarak büyük öngörü hatalarına küçüklerden daha çok ağırlık verir. Bir hatanın maliyetinin o hatanın karesi kadar arttığı durumlarda uygundur. "Karesel kayıp fonksiyonu" en popüler kullanım şeklidir. Bu ölçüt, ölçeklemeye ve aykırı değerlere karşı duyarlıdır (Kennedy, 2008:334).

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (e_t)^2}$$

Çoğu çalışmada MAD ile RMSE birlikte rapor edilmesine rağmen, bu iki yöntem arasındaki seçim kayıp fonksiyonunun yapısına bağlıdır. Seçim, kayıp fonksiyonunun karesel hataya dayanan mı yoksa mutlak hataya dayanan mı olmasına göre yapılmalıdır (Kennedy, 2008:340).

#### 1.4.3 Ortalama Hata (ME)

Ortalama öngörü hata, öngörü hatasının beklenen değerinin bir kestirimidir ve sıfır olması umulmaktadır; yani, öngörü tekniği sapmasız öngörüler üretir.

$$ME = \frac{1}{n} \sum_{t=1}^n e_t$$

Ortalama öngörü hatası sıfırdan kayda değer ölçüde farklılaşıyorsa, bu durum öngörüdeki sapmaya işaret etmektedir. Öngörü tekniği kullanılırken ortalama öngörü hatası sıfırdan uzaklaşırsa bu, temel alınan zaman serilerinin yapısının bir şekilde değiştiğinin, tahmin tekniğinin bu değişikliği izlemediğinin ve sapmalı öngörüler ürettiğinin bir göstergesidir.

#### 1.4.4 Ortalama Hata Kare (MSE)

MAD ve MSE öngörü hatasındaki varyansı ölçmektedir. Öngörü hatalarında değişkenliğin az olmasını istenmektedir.

$$MSE = \frac{1}{n} \sum_{t=1}^n (e_t)^2$$

MSE, tek adımlı tahmin hatalarının varyansının doğrudan bir tahminicisidir:

$$\hat{\sigma}_e^2 = MSE = \frac{1}{n} \sum_{t=1}^n (e_t)^2$$

Öngörü hataları normal olarak dağıtılsa MAD, öngörü hatalarının standart sapması ile ilişkilidir:

$$\hat{\sigma}_e^2 = \sqrt{\frac{\pi}{2}} MAD \cong 1.25MAD$$

ME, MSE ve MAD öngörü doğruluğu ölçeğe bağlı ölçümleridir, yani değerleri orijinal ölçüm birimleri cinsinden ifade edilir. Ayrıca, ölçeğe bağlı doğruluk ölçümleri, farklı zaman serileri boyunca ya da farklı zaman aralıklarındaki tek bir öngörü tekniğinin karşılaştırılmasına imkân vermez. Bunu başarmak için nispi öngörü hata ölçüsüne ihtiyaç vardır (Montgomery vd., 2015:66).

#### 1.4.5 Ortalama Mutlak Yüzde Hatası (MAPE)

Ortalama mutlak yüzde hatası için ilk olarak nispi yüzde hata şu şekilde hesaplanmaktadır:

$$RE_t = \frac{(y_t - \hat{y}_t)}{y_t} * 100 = \frac{e_t}{y_t} * 100$$

Buradan ise ortalama mutlak yüzde hatası;

$$MAPE = \frac{1}{n} \sum_{t=1}^n |RE_t|$$

şeklinde elde edilmektedir.

MAPE yüzdellik hataların mutlak değerlerinin ortalamasıdır. Ölçü biriminden bağımsız olma avantajına sahiptir. Öngörü hatasının maliyeti, hatanın sayısal büyüklüğünden ziyade hata yüzdesiyle yakından alakalı olduğunda daha uygundur. Bu ölçütle ilgili önemli bir sorun sıfır değerini alabilmesidir. Bu durumda MAPE tanımsız olmaktadır. İkinci bir sorun, pozitif hatalara negatif hatalara kıyasla daha ağır bir ceza koymasındır çünkü belirli bir tahmin için yüzdellik hesaplama tabanı fazla tahminde az tahminde olduğundan daha düşüktür (Kennedy, 2008:340).

MAPE orijinal deęeri küçük olduęunda asimetri ve istikrarsızlık sorunu için eleştirilmektedir. MAPE, doğruluk ölçütü olarak dört sorundan etkilenir: (1) Orijinal serinin deęeri küçük olduęunda büyük yüzde hataları oluşur; (2) Aykırı deęerler ampirik çalışmalardaki karşılaştırmaları zorlaştırır; (3) MAPE'ler, rassal yürüyüş gibi saf modellerle doğrudan karşılaştırılmaz; (4) Gerçek deęerin üzerindeki eşit hata, daha büyük bir mutlak yüzde hataya neden olur (Woschnagg ve Cipan, 2004:14).

#### 1.4.6 Theil Eşitsizlik Katsayısı

RMSE ölçü biriminden ve deęişkenin ortalamasından etkilenmektedir. Farklı ölçü birimleri ile ölçülen deęişkenlerin öngörülerinin doğruluęu kıyaslanmak istenildięinde RMSE sorunlu olabilmektedir. Bu sorunları aşmak için Theil eşitsizlięi kullanılabilir. Standartlaştırılmış köklü ortalama hata kare fikri, farklı deęişkenler arasındaki karşılaştırmayı kolaylaştırmaktır.

$$U_1 = \frac{\sqrt{\frac{1}{n} \sum_{t=1}^n (\hat{y}_t - y_t)^2}}{\sqrt{\frac{1}{n} \sum_{t=1}^n (\hat{y}_t)^2 + \frac{1}{n} \sum_{t=1}^n (y_t)^2}}$$

Denklem yakından incelendięinde paydaki ifadenin RMSE, paydadaki ifadelerinde gerçek deęerin ve öngörü deęerlerinin kare ortalamalarının karekökü olduęu görülmektedir. Theil eşitsizlik katsayısı, ölçekten bağımsızdır ve sıfır ile bir arasında deęer alır. Theil katsayısı sıfıra eşitse, mükemmel bir uyum sağlanmıştır (Woschnagg ve Cipan, 2004:14).

Gelecekteki öngörülerin belirsizlięinin bir ölçüsünü geçmişteki öngörü performansına dayandırmak, başka bir öngörü sorunu doğurmaktadır. Sorun öngörülerin dağılım ölçüsü ile alakalıdır. Ancak Theil eşitsizlik katsayısı da nokta öngörüsü gibi yapısal kırılmalar nedeniyle öngörü başarısızlıklarının benzer zorluklarına tabidir. Geçmişteki performanstan geleceęi öngörme, istikrarlı bir temel ortamı varsaymaktadır ve bu yapı deęiştiiğinde öngörü için zorluklar ortaya çıkmaktadır (Mariano ve Tse, 2008:14-15).

## 1.5 Farklı Öngörülerin Birleştirilmesi

Literatürde, "en iyi" öngörü yönteminin, her biri farklı bir teknikle üretilen çeşitli tahminlerin ağırlıklı ortalaması olarak oluşturulan "birleştirilmiş" öngörü olduğu konusunda genel kabul bulunmaktadır. Farklı öngörü yöntemlerinin dayandığı ilkeler birbirinden yeterince farklıysa birleştirilmiş öngörü her öngörü tekniğinden daha üstün olmaktadır. Çünkü farklı öngörülerdeki hatalar birbirini yok etme eğiliminde olacaktır. Model belirleme sorunları bağlamında, bu iyi öngörülerin tek bir favori model kurmaktan kaynaklanmadığını, aksine çeşitli makul modellerin sonuçlarını birleştirmekten geldiği öne sürülmektedir. Birleştirilmiş öngörme için ağırlıkları bulmanın bir yolu, gerçek değerlerin tüm rakip öngörüler üzerine regrese edilmesidir. Bu regresyona kesme terimi de dâhil edilir çünkü kesme teriminin dâhil edilmesi öngörüdeki her hangi bir sapmayı azaltacaktır. Çoğu uygulamada örnekleme değişkenliğinin, birleştirmenin avantajı ile dengelendiğine dair önemli kanıtlar vardır. Sonuç olarak, araştırmacılar genelde eşit ağırlıklar benimsemektedirler ya da gerçek değerlerin tüm rakip öngörüler üzerine regrese edilmesinden elde edilen ağırlıkları eşitlik yönünde küçültmektedirler.

Tahmin hatasından kaynaklanan kayıpların asimetrik olduğu ve nadiren RMSE gibi genel kriterlerinin doğruluğuna uyduğu şaşırtıcı değildir. Bazı araştırmacılar tahminlerin son kullanımları temelinde değerlendirilmesi gerektiğini vurgulamıştır.

Bazı yazarlar çeşitli tahmin yöntemlerinin görece doğruluğunun verilerin niteliğine bağlı olduğunu ve tahmin yönteminin seçilmesinin bunu dikkate alması gerektiğini belirtmektedir. Veri setinin: gözlem sayısı, değişim katsayısı, eğimin varlığı, uç değerlerin varlığı, son güncel gözlemlerin genel eğilim karşısındaki eğilimi ve otokorelasyon katsayısının büyüklüğü gibi özellikleri tahmin yönteminin seçilmesinin de dikkate alınması gereken etkenlerdir (Kennedy, 2008:340).

Yapılan çalışmalar göstermiştir ki birden fazla rakip öngörü sonucu varsa bunların sonuçlarının performansını tek tek değerlendirmeye çalışmak yerine eldeki öngörü sonuçlarını birleştirmek daha faydalı olabilmektedir. Eldeki öngörü sonuçlarının her biri, diğerleri tarafından kapsanmayan değerli bilgiler içerebilir; bu bilgiler, neden birleştirmenin ilgi çekici olabileceğini açıklamaktadır. Bunları birleştirmenin bir yolu

basitce aritmetik ortalamayı almaktır. Bununla birlikte, bu yol çok özel bir durumda yani yalnızca tüm tahminler sapmasız, bağımsız ve özdeş dağılmışsa idealdir.

Öngörülerin doğruluğunu iyileştirmek için önemli farklılıklar gösteren ve farklı bilgi kaynaklarından türetilen öngörüler birleştirilmelidir. Armstrong (2001)'a göre mümkünse, beş veya daha fazla öngörü yönteminin sonucu kullanılmalıdır. Öngörülerini birleştirmek için biçimsel yöntemler kullanılmalıdır. Tekil öngörülerde yanlış hesaplamalar, veri hataları veya yanlış anlaşılmalardan dolayı büyük hatalar olabilmektedir. Eğer beş veya daha fazla yöntemden elde edilen öngörü varsa en düşük ve en yüksek değer atılarak kalan öngörüler birleştirilirse arzu edilen düzeltilmiş bir ortalama elde edilebilir. Alan bilgisi veya hangi yöntemin en doğru olması gerektiğine dair güçlü bilgi varsa öngörülerini birleştirirken farklı ağırlıklar kullanılabilir. Özellikle durum hakkında ve hangi yöntemin en doğru olduğu konusunda kararsız olduğunda ve büyük hatalar önlenmek istendiğinde tahminleri birleştirmek yararlıdır. Özgün tekil öngörü hataları ile karşılaştırıldığında öngörülerini birleştirme hataları azaltır. Armstrong (2001), 30 ampirik karşılaştırmada eşit ağırlıklı birleştirilmiş öngörüler için tahmin hatalarındaki azalmanın %3 ila 24 arasında değişmekte ve ortalamasının da % 12.5 olduğunu belirtmiştir. İdeal koşullar altında, birleştirilmiş öngörüler bazen en doğru bileşenlerinden daha doğrudur (Armstrong, 2001:417).

### 1.5.1 İki Sapmasız Öngörünün Birleştirilmesi

$y_t, t \in Z$ , koşullu olmayan ortalaması  $\mu$  olan durağan tek değişkenli zaman serisi olduğu olsun. Kolaylık olması için, çalışmaların çoğu, bir adım ötesini öngören iki öngörüyle bir araya getirmeye odaklanmaktadır. H adım ötesini öngören iki modelin birleştirilme durumu da benzer şekilde yapılabilmektedir.  $\hat{y}_{t+1,t}^1$  ve  $\hat{y}_{t+1,t}^2$  belirli bir ekonomik zaman serisi  $y_{t+1}$  için t zamanında yapılmış alternatif iki öngörüsü olsun. Öngörü hatası aşağıdaki gibi elde edilir:

$$\hat{e}_{t+1,t}^j = y_{t+1} - \hat{y}_{t+1,t}^j, j=1,2.$$

İlk olarak, aşağıdaki gibi birleştirilen iki sapmasız öngörüye sahip olduğu kabul edilsin.

$$\hat{y}_{t+1,t}^c = \alpha \hat{y}_{t+1,t}^1 + (1 - \alpha) \hat{y}_{t+1,t}^2$$

Ağırlıklar toplamı 1 olduğundan, bileşik tahmin mutlaka sapmasızdır. Birleştirilmiş öngörü hatası da aynı durumu sağlamaktadır.

$$\hat{e}_{t+1,t}^c = \alpha \hat{e}_{t+1,t}^1 - (1 - \alpha) \hat{e}_{t+1,t}^2$$

Birleştirmede kullanacak ağırlıklar, belli kısıtlar altında birleştirilmiş öngörü hatalarının varyansını,  $\sigma_c^2$ , minimum yapan değerler olarak seçilmektedir.

### 1.5.2 k Sapmasız Öngörünün Birleştirilmesi

Daha önce elde edilen sonuçlar ikiden fazla öngörünün birleştirilmesi için de genişletilebilir. Tek değişkenli zaman serisi  $y_{t+1}$ , k öngörünün birleşimi ile de öngörülebilir,  $(\hat{y}_{t+1,t}^j, j=1,2,\dots,k \text{ ve } t=1,2,\dots,T)$ . İki öngörü birleşiminde olduğu gibi k öngörü birleşiminde de öngörülerin sapmasız olduğu varsayılmaktadır.

$$\hat{\mathbf{y}}'_{t+1,t} = (\hat{y}_{t+1,t}^1, \hat{y}_{t+1,t}^2, \dots, \hat{y}_{t+1,t}^k)$$

$$\mathbf{u}' = (1, 1, \dots, 1)$$

$$\mathbf{e}_{t+1,t} = y_{t+1} \mathbf{u} - \hat{\mathbf{y}}'_{t+1,t}, E(\mathbf{e}_{t+1,t} \mathbf{e}'_{t+1,t}) = \Sigma,$$

Birleşik öngörü, tekil tahminlerin ağırlıklı ortalaması olarak yazılabilir:  $\hat{y}_{t+1,t}^c = \alpha' \hat{\mathbf{y}}_{t+1,t}$ , ağırlıklar toplamı,  $\alpha' \mathbf{u}$ , bire eşittir. Birleştirilmiş öngörü hatalarının varyansı :  $\text{Var}(\alpha' \mathbf{e}_{t+1,t}) = \alpha' \Sigma \alpha$  dır.

Yine iki öngörüü birleştirmede olduğu gibi değişik kısıtlar altında birleştirme için verilecek ağırlıklar birleştirilmiş öngörü hatalarının varyansını en küçük yapacak değerler olarak belirlenir (Charpin ve Mazzi, 2016:372-375).

### 1.6 Öngörü Kapsama Testi

Eğer öngörülerden biri, diğerinin içerdiği bilgileri içeriyorsa birden fazla öngörü elde edildiğinde bunları birleştirip daha isabetli öngörü elde etmek kullanışlı olmayabilir. Öngörü kapsama testleri, rakip öngörülerin etkin bir şekilde birleştirilerek tekil öngörülere üstün bir öngörü üretilip üretilmeyeceğini değerlendirmeye çalışır. Diğer bir ifadeyle öngörü kapsama testleri farklı öngörülerini birleştirmenin faydalı olup olmadığını test etmektedir. Chong ve Hendry (1986) öngörü hatalarından birinin diğer öngörü üzerine regrese edilen aşağıdaki modeli önermişlerdir:

$$e_{t+k}^1 = y_{t+k} - \hat{y}_{t+k}^1 = \beta \hat{y}_{t+k}^2 + \varepsilon_{t+k}$$

burada  $\hat{y}_{t+k}^1$  ve  $\hat{y}_{t+k}^2$ , sırasıyla  $y_{t+k}$  orijinal serisinin k aşama sonraki iki öngörüsüdür.

Model, sıradan ek küçük kareler yöntemi ile tahmin edilir ve  $\beta$  için elde edilen t-istatistiği kullanılarak sıfır hipotezi  $H_0 : \beta = 0$ , yani öngörü için kullanılan ikinci model birinci modele ek bilgi sağlamamaktadır, test edilir. Eğer sıfır hipotezi belirli bir anlamlılık düzeyinde reddedilirse birinci modelin ikinci modeli kapsadığına dair yeterli bilgi olmadığı sonucuna ulaşılmaktadır. Bu da iki öngörü modelini birleştirerek yeni öngörü hesaplanmasının faydalı olacağı ve böylece öngörü doğruluğunun artacağı anlamına gelmektedir. Eğer sıfır hipotezi belirli bir anlamlılık düzeyinde reddedilemez ise birinci modelin ikinci modeli kapsadığı sonucuna ulaşılmaktadır. Bu da iki öngörü modelini birleştirerek yeni öngörülerin hesaplanmasının faydalı olmayacağı yani birleştirmenin öngörü doğruluğunu artırmayacağı anlamına gelmektedir.

Timmermann (2006), her hangi bir öngörü modelinin, örneğin birinci öngörü modelinin, diğer n modeli kapsama testini göstermek için Chong ve Hendry (1986)'nın daha genişletilmiş halini aşağıdaki gibi ifade etmektedir:

$$y_{t+h} - \hat{y}_{t+h,t}^1 = \beta_0 + \sum_{i=2}^n \beta_i \hat{y}_{t+h,t}^i + e_{t+h,t}$$

Öngörü kapsama testi  $H_0: \beta_2 = \beta_3 = \dots = \beta_n = 0$  sıfır hipotezinin test edilmesine dayanmaktadır.

## BÖLÜM 2

### 2 ŞİMDİ TAHMİN YÖNTEMLERİ

Yöntemlere geçmeden önce kullanılacak notasyonları tanımlanacaktır. Şimdi tahminde bulunmak için çok farklı yöntemlerin olmasının sebebi öngörü için faydalı, kullanılabilir veri setinin genişliği ve bu veri seti ile öngörülecek değişkenin ilişkisinin farklı yollarla modellenmesidir (Bell vd., 2014:58). Hangi yöntemin daha uygun olduğu kullanılabilir veri kümesine ve ülkelere göre önemi değişebilen resmi veriler ile diğer indikatörlerin güncelliğine bağlıdır (Bell vd., 2014:61).

Öngörüsü yapılacak olan değişken  $y_{t_q}$  ile gösterilirken burada  $t_q=1,2,\dots,T_q$  çeyrekleri ifade etmektedir ve  $T_q$  şimdi tahminin yapıldığı çeyreği temsil etmektedir. Aylık frekanslarla ölçülen GSYH  $y_{t_m}=y_{t_q}$  şeklinde gösterilir ve  $t_m=3t_q$  ile ilişkilidir. Böylece öngörüsü yapılacak olan değişken  $t_m=3,6,9,\dots,T_m$  iken  $T_m=3T_q$  ayında gözlemlenir. Aylık olarak açıklanan indikatörler  $z_{t_m}$  ile gösterilir.  $t_m=1,2,\dots,T_m$  ve indikatör sayısı  $n$  dir. Her  $t_m$  ayı için  $t_m \times n$  dışsal açıklayıcı değişken matrisi  $\mathbf{Z}_{t_q}^1=(\mathbf{z}_{t_m},\dots,\mathbf{z}_1)$  ile ifade edilir, burada  $\mathbf{z}_{t_m}=(z_{1,t_m},\dots,z_{n,t_m})'$  belli bir periyottaki gözlemlerin vektörüdür. Bu açıklamalardan sonra şimdi tahmin yöntemleri ele alınabilir.

#### 2.1 Doğrudan Şimdi Tahmin

Öngörüsü yapılacak olan değişken ( $y_{t_q}$ ) şimdi tahmin etmekte en az tercih edilen yaklaşım sadece kendi geçmiş değerlerin  $\mathbf{Y}_{T_q-1}^1=y_{T_q-1},\dots,y_1$  kullanılmasıdır:

$$\hat{Y}_{(T_q|T_q-1)}=f(\mathbf{Y}_{T_q-1}^1) \quad (3.1)$$

Castle vd., (2013)'e göre çeyreklik değişkenlerin tahmini için bir otoregresyon tanımlanması, düşük frekansların sınırlı bilgisini kullanan bir tahmin çalışmasıdır. Sadece kendi geçmiş değerleri kullanıldığı için ilan edilen iki bağımlı değişken arasında tahmini geliştirme imkânı yoktur. Denklem (3.1) aylık indikatörler ile genişletilirse kestirimi geliştirme imkânı daha mümkün olabilir. Bu tarz veri setleri; sanayi üretimi, finansal göstergeler ve faiz oranları gibi daha yüksek frekanslı somut verileri veya

güven endeksleri ve iş anketleri gibi soyut verileri de içerebilir. Birçok araştırmacı bu şekildeki verilerin öngörüsü yapılacak değişken ile ilişkili olduğunu bulmuşlardır.

Genişletilmiş modelde,  $y_{t_q}$  'nün tahmini aylık  $\mathbf{Z}_{t_m}$  gösterge kümesine dayanır.  $\mathbf{Z}_{t_m}$  'nin bir alt kümesi  $T_q$  'den önce faraza  $T_q - v$  tarihinde örnek bazı veri setlerinin yayımlanmasıyla kullanılabilir. Burada  $3T_m \leq T_q - v \leq 3(T_{m+1})$  ve  $v$  bir açıklayıcı değişkenin bağımlı değişkenden önce açıklanan aylarının maksimum sayısını göstermektedir. Aylık indikatörler değişik gecikmelerle farklı zamanlarda açıklandıklarından  $(z_{1,T_m}, \dots, z_{n,T_m})'$  açıklanmayan değişkenler için sıfır girdi ile temsil edilmektedir. Sonuç olarak  $\mathbf{Z}_{T_m}^1$  örneklem sonuna doğru “düzensiz kesit” li olacaktır. İlk bağımsız değişken kestirimi açıklanmadan tahminler yayımlanır. Bu yüzden  $y_{T_m}$  tahmini sadece  $T_q$  ile eş zamanlı değil tüm mevcut bilgilere bağlıdır. Yeni aylık veri akışının genişletilmesinin anlamı zaman geçtikçe  $v$ 'nin sifira yakınsamasıdır ve her  $T_q - v$  aşamasında yeni genişletilmiş model, mevcut tüm bilgilere göre koşullu olarak aşağıdaki gibi formüle edilebilmektedir.

$$\hat{Y}_{(T_q|T_q-v)} = f(\mathbf{Y}_{T_q-1}^1, \mathbf{Z}_{T_q-v}^1) \quad (3.2)$$

## 2.2 Toplulaştırılmamış Bilgilerin Kullanılmasıyla Dolaylı Şimdi Tahmin

Toplulaştırılmış  $y_{t_q}$ ,  $y_{t_q} = \sum_{i=1}^{N_T} w_i y_{i,t_q}$  şeklinde tanımlanan  $N_T$  tane toplulaştırılmamış bileşenlerin ağırlıklandırılmış toplamı olarak tanımlanır, burada ağırlıklardaki değişim önemlidir. Bu nedenle bağımlı değişkenin şimdi tahmini tekil şimdi tahminlerin ağırlıklandırılmış toplamı gibi yapılması mümkündür.  $N_T - J_T$  tane toplulaştırılmamış değişken,  $v^* \geq v$  iken sadece  $T-v^*$  gecikmeye kadar biliniyorken  $T_q$  zamanında  $N_T$  değişkenden  $J_T$  tanesinin eş zamanlı kullanılabilir olduğu varsayalım. Daha sonra toplulaştırılmamış düzeydeki tüm mevcut bilgiler kullanılarak bilinmeyen toplulaştırılmamış değişkenler  $J_T + 1, \dots, N_T$  ile şimdi tahmin şu şekilde yapılabilir:

$$\tilde{Y}_{(i,T_q|T_q-v)} = f(\mathbf{y}_{T_q-v^*}^1, \mathbf{Z}_{T_q-v}^1) \quad (3.3)$$

Burada,  $\tilde{Y}_{(i,T_q|T_q-v)}$  koşullu şimdi tahmin ve  $y_{i,t_q}^1$  i.bileşen için geçmiş gözlemlerdir.

Bilinen ve şimdi tahmini yapılan toplulaştırılmamış değişkenlerin bileşimi aşağıda gösterildiği gibi toplulaştırılmış bağımlı değişkenin tahminini üretir (Castle vd., 2013:9):

$$\tilde{Y}_{(T_q|T_q)} = \sum_{i=1}^{J_T} w_i y_{i,T_q} + \sum_{i=J_T+1}^{N_T} w_i \tilde{Y}_{(i,T|T_q-v)} \quad (3.4)$$

### 2.3 Otoregresif Hareketli Ortalamalar (ARIMA) Yöntemi

Zaman serisi öngörü analizi için en sık kullanılan tekniklerden biri ARIMA model kurma sürecidir. Box ve Jenkins yaklaşımı olarak da bilinen bu teknik, Box ve Jenkins (1976) tarafından geliştirilmiştir. Bu yüzden Box Jenkins yaklaşımı ve ARIMA süreci aynı anlamlarda kullanılmaktadır. Box Jenkins yaklaşımı tek değişkenli zaman serisi analizlerinde ve ön raporlamada sıklıkla kullanılmaktadır (Sevüktekin ve Çınar, 2014). ARIMA modeli, otoregresif (AR) model ve hareketli ortalamalar (MA) modelinin birleşiminden oluşan ARMA modelinin özel bir halidir. ARIMA modeli zaman serileri durağan ve eksik veri yoksa kullanılabilir (Ediger ve Akar, 2007). ARIMA sürecinin anlaşılabilmesi için AR ve MA süreçlerinin işleyişlerinin bilinmesi gerekmektedir. AR(p) modelinin ana fikri durağan bir seri olan  $x_t$  serisinin şu anki değerini,  $x_{t-1}$ ,  $x_{t-2}$ , ...,  $x_{t-p}$  şeklindeki  $p$  tane geçmiş değerinin doğrusal bir fonksiyonu olarak modelleyebilmektir. Burada  $p$ ,  $x_t$  serisinin şu anki değerinin tahmini için gerek duyulan kaç adım geçmişe gidilmesi gerektiğini belirten değerdir.  $q$  mertebeli hareketli ortalamalar modeli MA(q) şeklinde gösterilir. MA(q) modeli beyaz gürültülü süreç olan  $w_t$ ,  $q$  gecikmeye kadar gözlemlenmiş veri yapısının doğrusal birleşiminden oluşur (Kumar ve Jain, 2010).

Bir zaman serisi  $\{x_t; t=0, \pm 1, \pm 2, \dots\}$  şeklinde olsun. Bu zaman serisi için kovaryans durağanlık varsayımı altında ARMA(p,q) modeli aşağıda gösterildiği şekildedir (Shumway ve Stoffer, 2006):

$$x_t = \phi_1 x_{t-1} + \dots + \phi_p x_{t-p} + w_t + \theta_1 w_{t-1} + \dots + \theta_q w_{t-q}. \quad (3.5)$$

Burada  $\phi_p \neq 0$ ,  $\theta_q \neq 0$  ve  $\sigma_w^2 > 0$ 'dır.  $p$  ve  $q$  parametreleri otoregresif ve hareketli ortalama mertebeleridir. Eğer  $x_t$  serisinin ortalaması sıfır olmayan ortalama  $\mu$ 'ye eşitse (3.5) numaralı model şu şekilde yazılır (Shumway ve Stoffer, 2006):

$$x_t = \mu + \phi_1 x_{t-1} + \dots + \phi_p x_{t-p} + w_t + \theta_1 w_{t-1} + \dots + \theta_q w_{t-q} \quad (3.6)$$

Aksi belirtilmedikçe,  $\{w_t; t=0, \pm 1, \pm 2, \dots\}$  serisi Gaussian beyaz gürültülü seridir.

Zaman serisinin kovaryans durağan olmadığı tespit edilirse serinin farkı alınarak durağanlaştırılır. Durağanlaştırılan seri kullanılarak ARMA(p,q) modeli oluşturulur farkı alınıp durağanlaştırılan seri kullanılarak oluşturulan bu model ARIMA(p,d,q) modeli olarak adlandırılır. ARIMA modelindeki d, serinin kaç kere farkı alınarak durağanlaştığını gösteren fark mertebesidir.

ARIMA model kurma süreci üç aşamadan oluşmaktadır. Bunlardan ilki tanımlama aşamasıdır. Bu aşamada verilerin sabit varyanslılık durumunun sağlanması için dönüştürme işlemi yapılır ve veri setinin durağanlık koşulunu sağlaması için fark alma işlemi gerçekleştirilir. Zaman serisi bu gerekli koşulları sağladıktan sonra uygun modelin seçimine geçilir. Eğer kurulacak model önceden biliniyorsa öngörü model denklemleri yinelemeli şekilde yapılabilir. Ancak uygulamada genelde model önceden bilinmez bu yüzden zaman serisi verisinin kendisinden çıkarsama yapılır. Modeldeki p, q ve d mertebelerinin belirlenmesi önemli bir konudur. Otokorelasyon fonksiyonu ve kısmi otokorelasyon fonksiyonu p ve q mertebelerinin belirlenmesinde kullanılabilir. Ancak p ve q mertebelerini belirlemenin daha objektif yolu Akaike bilgi kriteri (AIC) ve Schwartz bilgi kriteri (SIC) gibi bilgi kriterlerini kullanmaktır. İkinci aşama tahmin ve test yapma aşamasıdır. Eğer zaman serisi örneğinden ARMA sürecinin izlendiği sonucuna varıldıysa ARMA katsayıları ( $\phi$  ve  $\theta$ ) koşulsuz en küçük kareler, koşullu en küçük kareler veya en çok olabilirlik gibi yöntemlerle tahmin edilebilir (Brockwell ve Davis, 2002; Shumway ve Stoffer, 2006). En çok olabilirlik tekniği ARMA katsayılarının hesaplanmasında etkin bir tekniktir (Kumar ve Jain, 2010). Tahmin edilen modele tanı testleri yapılarak model kontrol edilir. Son aşamada ise ikinci aşamada belirlenen en iyi model önraporlama ve kontrol amacıyla kullanılabilir (Enders, 2010).

## 2.4 Köprü Model Yöntemi

Öngörüler için ekonomik bir yorum sağlamak adına sıkça kullanılan bir başka alternatif köprü modelleri (KM) kurmaktır. Köprü modelleri esasen karma frekanslı veri örnekleme (MIDAS) doğrusal regresyon modelleridir. Bu doğrusal regresyonlar aylık

değişkenleri üç aylık değişkenlere bağlar yani "köprü" kurar. Bu bağlamda MIDAS yaklaşımının kısıtsız versiyonudur. Bazı köprü modelleri kullanılan verilerin daha basit şekilde yorumlanmasına olanak sağlar (Lamprou, 2015:87).

MIDAS regresyonları ve yine ileride değinilecek olan faktör modelleri cimri ancak geniş bilgi seti ile karma frekanslı verileri ve “düzensiz kesit” veri setlerini birleştirmenin kısıtlayıcı yöntemleridir. Öte yandan, sonuçlarının yorumlanması zordur: MIDAS katsayılarının gecikmeli dağılımı geçicidir ve ortak faktörler net, daha doğrusu benzersiz, bir şekilde tanımlanamayabilir. Temel bileşenler yöntemi orijinal verilerin bir dönüşümü olup, hedef seriler ve dışsal değişkenler arasındaki bağlantının temeli hakkında ek bir bilgi içermemektedir. Bu nedenlerden dolayı, biraz daha az kısıtlayıcı bir yaklaşım, toplulaştırılmış ölçümler ve açıklayıcı değişkenler kümesi arasında doğrudan bir 'köprü' oluşturan denklemlere dayanmaktadır. Köprü denklemleri, esas olarak, yorumlanabilirlikleri nedeniyle tercih edilir (Castle vd., 2013:15).

Köprü modelleri yüksek frekanslı göstergeleri kullanarak daha düşük frekanslı göstergeleri tahmin etmede kullanılır. Eğer aylık göstergeler yalnızca projeksiyon periyodu boyunca elde edilebiliyorsa, çeyreklik bağımlı değişken tahminleri iki adımda elde edilir. İlk olarak, aylık göstergeler, tek değişkenli zaman serisi modelleri temel alınarak çeyreğin geri kalanında tahmin edilmektedir. Daha sonra çeyreklik değerlerini elde etmek için bir araya toplanmıştır. İkincisi, toplanan değerler, çeyreklik bağımlı değişken tahminlerini elde etmeyi sağlayan köprü denkleminde bağımsız değişken olarak kullanılır. Çeyreklik  $x_{j,t}$  değerini elde etmek için aylık göstergelerin kayıp gözlemlerini öngörmeye gecikme süresinin bilgi ölçütlerine (SIC, AIC vb.) dayandığı otoregresif modellerin kullanılması yaygın bir uygulamadır (Forni ve Marcellino, 2012:5).

Bir köprü modeli oluşturmadan önce, göstergelerin seçilmesi hayati bir adımdır. Öncelikle, aylık göstergeler zamanında güncellenmelidir. İkincisi, göstergeler güvenilir olmalıdır; yani ilk yayımlandıktan sonra önemli ölçüde gözden geçirilmemelidir. Alternatif olarak, gerçek zamanlı veriler kullanılabilir, yani yalnızca öngörü vadesinde bulunan bilgiler (ilk kestirimler veya nihai veriler) öngörüü hesaplamak için kullanılır. Son olarak, göstergeler KM'nin bağımlı değişkeni ile ilişkili olmalıdır (Wohlrabe, 2008:24).

Köprü modelinde yer alan aylık göstergelerin seçimi genelde özel bir yöntemle ve bilgi ölçütleri veya RMSE performansı gibi farklı örneklem içi veya örneklem dışı ölçütlere dayanır. Bazı araştırmacılar ise Bayesian model ortalamayı esas alan ve deneysel olarak oldukça iyi performans gösteren alternatif bir yöntem kullanmayı önermektedirler (Foroni ve Marcellino, 2013:4).

Köprü denklemi, aylık açıklayıcı değişkenlerin ( $X_t$ ) çeyreklik ortalaması ile çeyreklik ( $Y_t$ ) arasındaki ilişki kurar.  $p$  açıklayıcı değişken için gecikmesi dağıtılmış otoregresif köprü modelinin genel gösterimi aşağıdaki gibidir.

$$y_t = \mu + \sum_{i=1}^n \theta_i y_{t-i} + \sum_{j=1}^p \sum_{i=1}^k \delta_{j,i} x_{j,t-i}^q + \vartheta_t$$

$n$ , otoregresif parametrelerin sayısıdır,  $p$  açıklayıcı değişkenlerin sayısıdır ve  $k$  açıklayıcı değişkenlerin gecikme sayısıdır.  $\mu$  sabit terim,  $x_{j,t-i}^q$   $j$ . toplulaştırılmış çeyreklik açıklayıcı değişken ve  $\vartheta_t$  bağımsız ve özdeş dağılım gösteren hata terimidir. Açıklayıcı değişkenler ve bunların gecikmeleri ile otoregresif parametreler otomatik seçim prosedüründen seçilmiştir. Otomatik seçim süreci tarafından seçilen değişkenler, örneklemin belirli zaman aralığına karşı duyarlı olabilir.

Köprü modelleri, aylık olarak kullanılmak üzere tasarlanmıştır. İmalat faaliyetinin, tüm iş döngüsünün bir öncüsü olarak alakası göz önüne alındığında sanayi üretimi endeksi, muhtemelen en önemli ve en yaygın olarak analiz edilen yüksek frekanslı göstergedir.

Köprü modelleri, belirli bir zaman aralığında en küçük karelerle (EKK) tahmin edilmektedir. Çeşitli kalıntı tanı testleri, belirgin bir özellik hatası olup olmadığını ortaya koymaktadır. Bazı modellerde, değişen varyansı sorununa karşı Newey-West HAC tahmini uygulanabilmektedir (Antipa vd., 2012:869-870).

KM'nin altında yatan yapı standart bir makroekonomik model olmadığından KM davranışsal ilişkilerle ilgilenmemektedir: spesifik açıklayıcı göstergelerin dahil edilmesi nedensel bir ilişkiye dayanmamaktadır. Fakat bağımlı değişkene ilişkin zamanında güncellenmiş bilgileri somutlaştıran basit istatistiksel gerçeğe dayanmaktadır. Bundan

---

<sup>4</sup> q:değişkenin çeyreklik olduğunu ifade etmektedir.

dolayı prensip olarak köprü modellerinde bütün regressörler kümesi (gecikmeli içsel ve açıklayıcı göstergeler) tahmin periyodu boyunca bilinmelidir. Bunlar mevcut durumun tahminini sağlayan bir araç: saf bir öngörü yerine, bir 'şimdi tahmin' olarak düşünülebilir. Fakat genellikle ilgilenilen dönem içinde sadece göstergelerin birkaç değeri bilinir ve bu durum KM kestirimlerini öngörü olarak yorumlamaya izin verir. KM'nin öngörü vadesi bir veya en fazla iki dönem sonrasıdır (Baffigi vd., 2004:449).

Köprü modeller regresyon tabanlı yaklaşımlardır. Regresyon tabanlı yaklaşımlar bağımlı değişken ile yakın ilişkisi olan küçük bir gösterge değişkenler kümesi üzerine odaklanmaktadır. Yorumlanması basit ve kolay olduğundan caziptir. Benimsenen yaklaşım, şimdi tahmin yapabilmek için kullanılan modellerin politika yapıcılara ve istatistikçi olmayan diğer kişilere güven verecek şekilde tasarlanmasıdır. Bu, dışsal değişkenlerde uzun gecikmelerle karar verme süreci olarak görülmektedir. Çünkü bir göstergenin altı aya kadar veya daha öncesi başka bir değişken tarafından keskin bir şekilde etkilendiği bir durumu savunmak zordur (Mitchell, 2009:61-62).

Tahmin hatasının en aza indirgenmesi, basit ve karmaşık modeller arasında bir tercihi gerektirir. Basit ARIMA modelleri, parametre belirsizliğini azaltır, ancak sınırlı bir bilgi setine sahiptir. Böylece değişkenlerin öngörüsündeki yaklaşım hatası büyük olabilir. Birçok parametreye sahip vektör otoregresif (VAR) modelleri daha çok parametre belirsizliğine sahiptir. Buna karşın daha çok bilgi içermesi ve öngörü hatasında azalma sağlaması bir avantajdır (Golinelli ve Parigi, 2007:83).

KM yaklaşımında, bilgi seti geçmiş gözlemlere (ARIMA-VAR-VECM vakalarında olduğu gibi) ve bazı göstergelere dayanmaktadır. Bunlar, öngörü vadesinde en azından kısmen mevcut olmalı ve kıstas modellerine (ARIMA-VAR-VECM) göre öngörü hatasında bir azalmaya olanak sağlamalıdır. Gösterge değişkenler, öngörü vadesi süresince yoksa kestirilecek parametre sayısındaki önemli artışla tek değişkenli tekniklerle tahmin edilebilir (Baffigi vd., 2004:449).

KM denklemlerindeki değişkenler durağan olmalıdır, eğer durağan olmayan değişken varsa durağanlaştırmak için gerektiği kadar fark alınır. Ayrıca, kısa vade için tek değişkenli doğrusal olmayan modellerden gelen öngörü performansı, genellikle daha iyi değildir. Bu nedenle basit doğrusal modeller dikkate alınmaktadır. KM modelin bağımsız değişken sayısı ve gecikme uzunluğu büyük sayılar seçilirse bu durum

bağımsız değişken sayısının fazla olmasına sebep olacaktır. Öngörü modellerinde cimrilik prensibine ait bilinen yararların akılda tutulması ve denklemleri en fazla iki açıklayıcı değişken ile sınırlandırılması önerilmektedir (Mitchell, 2009:61-62).

## 2.5 Dinamik Faktör Model Yöntemi

Bağımsız değişkenlere göre veri açıklanma sıklığı daha az olan bağımlı değişkenlerin öngörüsü için kullanılan köprü modeller bir veya birkaç değişkeni kullanmaktadır. Daha fazla değişkenin kullanımının öngörünün doğruluğunu arttıracığı düşüncesiyle Giannone vd. (2008) farklı zamanlarda ve farklı gecikmelerle yayımlanan çok sayıda veri seti kullanıldığında ortaya çıkan birkaç temel sorunu çözen bir öngörü modeli önermişlerdir. Model aylık veriler açıklandıkça çeyreklik olan bağımlı değişkenin şimdi tahmin değerini güncellemektedir. Önerilen yaklaşım, bağımlı değişkenin şimdi tahmininin yanı sıra modelde kullanılan bağımsız değişkenlerin her birinin öngörü için katkıda bulunduğu marjinal etkiyi de ölçmeyi sağlamaktadır.

Giannone vd. (2008) veri setindeki değişkenler çok fazla olduğu için tam bir modeli tahmin etmek, serbestlik derecesini sınırladığı ve parametrelerin tahminindeki büyük belirsizlikten dolayı öngörü modeli için kötü performans gösterebileceğini iddia etmektedir. Giannone vd. (2008) yaklaşımındaki temel fikir, mevcut tüm bilgileri birkaç ortak faktörde özetleyerek veri setindeki eş doğrusallığı kullanmaktır. Eş doğrusallık nedeniyle ortak faktörlerin uzayı üzerine bir izdüşüm, seriler arasındaki dinamik etkileşimin büyük kısmını yakalayabilir ve öngörülerde iyi çalışan cimri bir model sağlayabilir. Sınırlı sayıda ortak faktörle belirlenen bilginin cimrilik yaklaşımı, tahminin yapılabilir olmasını sağlar. Çünkü bu durum sınırlı sayıda parametrenin kestirilmesini gerektirir.

Modeli tanımlamak için:  $x_{it|v_j}$ ,  $v_j$  dönemi için mevcut sabit aylık göstergesi temsil etsin ve çeyrek sonunda gözlemlendiğinde çeyreklik bir miktara tekabül edecek şekilde dönüştürülür  $t=3k$  zamanında, burada  $k=1,2,\dots,\lfloor T_{i,v_j}/3 \rfloor$ . Dönüşümlü aylık göstergeler için aşağıdaki faktör yapısı varsayılmaktadır:

$$x_{i,t|v_j} = \mu_i + \lambda_{i1}f_{1,t} + \dots + \lambda_{ir}f_{r,t} + \xi_{i,t|v_j}, \quad i = 1, \dots, n$$

$\mu_i$  sabit terim ve  $\chi_{it} \equiv \lambda_{i1}f_{1,t} + \dots + \lambda_{ir}f_{r,t}$  ile  $\xi_{i,t|v_j}$  iki ortogonal gözlemlenmemiş durağan stokastik süreçlerdir. Doğrusal süreçler  $\xi_{i,t|v_j}$  (tekil bileşenler) değişkenlere özgü şoklar tarafından yönlendirilirken,  $\chi_{it}$  süreçlerinin (ortak bileşenler), ekonomideki "hemen hemen tüm" ortak hareketleri yakalayan birkaç  $r \ll n$  gözlemlenmemiş ortak faktörün doğrusal fonksiyonları olduğu varsayılmaktadır.

Modelin matris notasyonu ile gösterimi aşağıdaki gibidir:

$$\mathbf{x}_{t|v_j} = \boldsymbol{\mu} + \boldsymbol{\Lambda}\mathbf{F}_t + \boldsymbol{\xi}_{t|v_j} = \boldsymbol{\mu} + \boldsymbol{\chi}_t + \boldsymbol{\xi}_{t|v_j} \quad (3.7)$$

$\mathbf{x}_t = (x_{1t|v_j}, \dots, x_{nt|v_j})'$ ,  $\boldsymbol{\xi}_{t|v_j} = (\xi_{1t|v_j}, \dots, \xi_{nt|v_j})'$ ,  $\mathbf{F}_t = (f_{1t}, \dots, f_{rt})'$  ve  $\boldsymbol{\Lambda} n \times r$   $\lambda_{ij}$  genel girdi ile yüklenen faktörün matrisini temsil etmektedir. Bağımlı değişkenin değişkenlere özgü dinamiklere bağlı olmadığı varsayıldığında, bağımlı değişkenin projeksiyonunu tüm değişkenler üzerinden yapmak yerine ortak faktörler üzerine kurmak sadece cimri ve uygulanabilir değil aynı zamanda tüm değişkenler üzerinde tam, ancak gerçekleştirilemez ve aşırı parametrelendirilmiş projeksiyon için iyi bir yaklaşım sağlamaktadır. Bağımlı değişkenin ve aylık göstergelerin ortak bir şekilde normal olduğuna dair ek varsayım altında, bağımlı değişkenin şimdi tahmininin beklenen ortak faktörlerin doğrusal bir fonksiyonu olduğu görülmektedir:

$$\hat{y}_{3k|v_j} = \alpha + \beta' \hat{F}_{3k|v_j}, \quad (3.8)$$

$v = 3k, 3k - 1, 3k - 2$  için  $\hat{F}_{3k|v_j} = E[F_{3k} | \Omega_{v_j}; \mathbb{C}]$ dir. Burada  $\mathbb{C}$  beklentinin alındığı temel modeli belirtir.

Yakın zamanda yapılan çalışmalar, gözlenmemiş ortak faktörler olan  $F_t$ 'nin gözlemlenebilir değişkenler üzerindeki temel bileşenler tarafından tutarlı olarak tahmin edilebileceğini göstermiştir. Ancak Giannone vd. (2008) modelinde sorun daha karmaşıktır; çünkü ortak faktörleri gerçek zamanlı olarak çıkarırken, örneklem sonunda eksik verilerle uğraşmayı gerektiren aylık göstergelerin yayımlanmasının güncelliğini dikkate almak ve faydalanmak istenmektedir.

Giannone vd. (2008) tarafından önerilen yöntem, Doz vd. (2006) tarafından çalışılan ve Giannone vd. (2004) tarafından gerçek zamanlı olarak makroiktisadi şokları tanımlamak için uygulanan iki adımlı kestiricidir. Bu yöntem temel bileşenleri Kalman filtreleme teknikleriyle birleştirmektedir. Burada Kalman düzgünleştiricisi, ortak

faktörlerin beklenen değerini yinelemeli hesaplamak için kullanılmaktadır. Faktör modelinin bu parametrik versiyonu, ortak faktör tahminlerinin doğruluğunun net ölçümlerini türetmek için de kullanılabilir.

Giannone vd. (2008) ortak faktörlerin çıkarılmasında kalman filtreleme tekniklerini uygulamak için modelin yapısını daha detaylı olarak ifade etmektedir. Öncelikle, ortak faktörlerin dinamiklerini bir vektör otoregresyon olarak parametreleştirilmektedir:

$$\mathbf{F}_t = \mathbf{A}\mathbf{F}_{t-1} + \mathbf{B}\mathbf{u}_t; \mathbf{u}_t \sim \text{WN}(\mathbf{0}, \mathbf{I}_q) \quad (3.9)$$

$\mathbf{B}, q$  tam ranklı  $r \times q$  boyutlu matris,  $\mathbf{A}$ ,  $\det(\mathbf{I}_r - \mathbf{A}z)$ 'nin tüm kökleri birim çemberin dışında  $r \times r$  boyutlu bir matris,  $\mathbf{u}_t$ , ortak faktörlere yönelik şokların  $q$  boyutlu beyaz gürültü sürecidir. Böyle bir modelde, ortak şok sayısına ( $q$ ) göre büyük olan bir dizi ortak faktör ( $r$ ), iş döngüsü boyunca değişkenler arasındaki öncü ve gecikme ilişkilerini yakalamayı amaçlamaktadır.

Mevcut veri açıklama zamanı için tekil bileşenlerin yatay kesitsel olarak ortogonal beyaz gürültülü olduğunu tanımlayarak, tekil bileşenler parametreleştirilir:

$$E \left( \xi_{t|v_j} \xi'_{t|v_j} \right) = \Phi_{t|v_j} = \text{diag}(\tilde{\Phi}_{1,t|v_j}, \dots, \tilde{\Phi}_{n,t|v_j}) \quad (3.10)$$

$$\text{Tüm } v \text{ ve } j \text{'ler için, } E \left( \xi_{t|v_j} \xi'_{t-s|v_j} \right) = 0, s > 0. \quad (3.11)$$

Aynı zamanda  $\xi_{it|v_j}$ 'nin ortak şoklar olan  $u_t$  ile ortogonal olduğu varsayılmaktadır:

$$\text{Tüm } v, s \text{ ve } j \text{'ler için, } E \left( \xi_{t|v_j} u'_{t-s|v_j} \right) = 0 \quad (3.12)$$

Giannone vd. (2008) eşzamansız gerçek zamanlı veri akışı tarafından üretilen örneklem sonunda eksik gözlem sorununun üstesinden gelmek için aşağıdaki varsayımda bulunmuştur:

$$\tilde{\Phi}_{1,t|v_j} = \begin{cases} \tilde{\Phi}_i & \text{eğer } x_{it|v_j} \text{ varsa} \\ \infty & \text{eğer } x_{it|v_j} \text{ yoksa} \end{cases} \quad (3.13)$$

Hataların Gauss dağılımına sahip olduğu ek varsayımı ile denklemler (3.7)-(3.13) modeli tam olarak karakterize eder.

Veri setini dengeli panel yapacak en güncel veri tarihinde veri kesiti alınır ve bu dengeli panelden faktörler elde edilir. Parametreler, bu faktörler üzerine kurulan doğrusal regresyondan EKK ile hesaplanır. Her  $v_j$  zamanında dengeli veri kümesi örneklemini  $\min\{T_{1v_j}, \dots, T_{nv_j}\}$  üzerinden kullanır.

Giannone vd. (2008) modeli tüm parametrelerin  $\delta$  de toplandığı  $\mathbb{C}_\delta$  ile göstermektedir. Parametreleri, tutarlı tahminleri ile değiştirip bunlar  $\hat{\delta}$ 'de toplanmakta, ortak faktörlerin ve bunların doğruluğu şu şekilde tahmin edilebilmektedir:

$$\hat{F}_{t|v_j} = E[F_t | \Omega_{v_j}; \mathbb{C}_\delta] \quad (3.14)$$

$$\hat{V}_{v_j} = E[(F_t - \hat{F}_t)(F_t - \hat{F}_t)'; \mathbb{C}_\delta] \quad (3.15)$$

Model durum uzayı formunda olduğundan bu ölçümlerin ikisi de Kalman düzleştiricisi kullanılarak yinelemeli olarak hesaplanabilmektedir.

Eksik gözlemlerin işleme biçimi, faktörlerin hesaplanmasında filtrenin örtük sinyal çıkarma işlemi sayesinde eksik gözlemlere ağırlık vermeyeceği anlamına gelmektedir.

Giannone vd. (2008) ortak faktörlerin iki aşamalı tahmincisinin, eksik gözlem sorununa çözüm ürettiğini, ortak faktörlerin dinamiğinden ve yatay kesitsel değişen varyanstan faydalandığını ifade etmiştir. Böylece basit temel bileşenlere kıyasla etkinlik iyileştirmeleri sağlamıştır. Doz vd. (2006) kesit boyutu,  $n$  ve örnek büyüklüğü  $T$ 'nin her ikisi de büyük olduğunda, ortak faktörler için iki adımlı kestiricinin tutarlı olduğunu göstermiştir. Önerilen model kendine özgü bileşenlerin yatay kesit ve ardışık bağımlılığına izin vermemesine rağmen tutarlılık daha genel varsayımlar altında elde edilmektedir. Tahmincinin bu dirençli özelliğini anlamak için ana unsur, basit temel bileşenlerle aynıdır: büyük sayılar yasasından dolayı kesitsel boyut arttıkça tekil bileşim ihmal edilebilir hale gelmektedir. Sonuç olarak tekil bir alana sınırlı olduğu sürece, modelin yanlış belirlenmesi tutarlılığı tehlikeye atmaz. Aynı sebepten dolayı ortak faktörlerin kestirimlerinin, revizyon hatalarının zayıf çapraz korelasyonlu olması koşuluyla veri revizyonlarının varlığına karşı güçlü olması olasıdır.

Giannone vd. (2008) ortak faktörlerin tahminleri göz önünde alındığında, (3.8) numaralı denklemde bağımlı değişken,  $y_{3k}$ , ortak faktörler,  $\hat{F}_{3k|v_j}$ , üzerine regrese

edilmekte ve elde edilen modelden EKK ile  $\alpha$  ve  $\beta$  katsayıları kestirilmektedir. Bunun sonucu da bağımlı değişkenin şimdi tahmini hesaplanabilmektedir.

Dolayısıyla bağımlı değişkene ilişkin tahmini:

$$\hat{y}_{3k|v_j} = \gamma + \hat{\gamma}'\hat{F}_{3k|v_j}$$

h adım sonrası öngörü,  $v = 3(k - h) - 2, 3(k - h) - 1, 3(k - h)$  ayları boyunca yapılan kestirimlere karşılık gelir.  $h=0$  için mevcut çeyrek boyunca yapılan GSYH'nın kestirimi olan şimdi tahmini elde edilir.

Tahminin doğruluk derecesi aşağıdaki denklemden hesaplanır:

$$V_{y_{3k|v_j}} = \hat{\gamma}' \hat{V}_{0|v_j} \hat{\gamma} + \text{Var}(\hat{\epsilon}_{3k|v_j}),$$

$\hat{\epsilon}_{3k|v_j} = y_{3k} - \hat{y}_{3k|v_j}$  dan elde edilen kestirilen kalıntılardır.

Giannone vd. (2008) modele bağımlı değişkenin gecikmeli değerlerini dâhil etmemektedir. Bunun nedeni ortak faktörlerin aylık göstergeler arasında dinamik etkileşimin büyük kısmı ile birlikte bağımlı değişkendeki dinamiklerin çoğunu da yakalayabilmesidir.

## 2.6 Karma Frekanslı Veri Örnekleme- (MIDAS) Yöntemi

Tipik zaman serisi regresyon modelleri, veri setinin aynı frekansa sahip olmasını gerektirir. Fakat gerçek hayatta çok farklı frekansta veri setleri mevcuttur. Örneğin, enflasyon, işsizlik ve para arzı gibi bazı makroekonomik veriler aylık olarak örneklenirken, GSYH ve bileşenleri gibi seriler çeyreklik veya yıllık olarak örneklenir. Yapılan analizlerde farklı frekanstan dolayı modele katılamayan göstergeler bilgi kaybına neden olabilmektedir. Ghysels vd. (2004) bu durumun çözümü için MIDAS model önerisinde bulunmuşlardır.

MIDAS modeli gecikmesi dağıtılmış modellere benzemekte fakat farklı yönleri de bulunmaktadır. Zaman serisi verilerini içeren regresyon analizinde, regresyon modeli açıklayıcı değişkenlerin ( $X$ 'lerin) sadece güncel değil aynı zamanda geçmiş değerlerini de içeriyorsa, buna gecikmesi dağıtılmış model denir.

$$Y_t = \alpha + \beta_1 X_t + \beta_2 X_{t-1} + \dots + \beta_k X_{t-k-1} + \epsilon_t$$

şeklinde ifade edilir.

Gecikmesi dağıtılmış model farklı bir şekilde ifade edilecek olursa aşağıdaki gibi de ifade edilir.

$$Y_t = \alpha + \sum_{i=1}^k \beta_i X_{t-i-1} + \varepsilon_t$$

Sonlu veya sonsuz değer alabilen B(L) gecikme polinom işlemcisi ile gösterimi ise aşağıdaki gibidir.

$$Y_t = \alpha + B(L)X_t + \varepsilon_t$$

Bu tür modeller, tüm yüksek frekans değerleri ilgili düşük frekans değerlerine toplandığında köprü denklemlerinin temelini oluşturan modellerdir.

Gecikmeli modeller, bağımlı ve bağımsız değişkenlerin veri setinin aynı frekansa sahip olmasını gerektirir. Fakat MIDAS, çeyreklik GSYH verisi gibi daha düşük frekanslı bağımlı değişkenle aylık imalat sanayi verileri gibi daha yüksek frekansa sahip bağımsız değişkenler arasında bağlanım kurar.

### 2.6.1 Temel MIDAS Yöntemi

MIDAS regresyonlarını açıklamak için,  $Y_t$ 'nin sabit, örneğin yıllık, üç aylık, aylık veya günlük gibi örnekleme frekansında gözlemlendiği varsayalım ve bu süreler referans aralığı olarak ifade edildiği kabul edilsin. Ayrıca,  $X_t^{(m)}$  'nin X açıklayıcı değişkeninin t ile t-1 zaman aralığında  $Y_t$ 'den m kez daha hızlı gözlemlenebilsin, böylece örneğin  $Y_t$  yıllık veri ve  $m = 4$  olduğunda  $X^{(4)}$  çeyreklik veri,  $Y_t$  çeyreklik veri ise ve  $m = 3$  olduğunda  $X^{(3)}$  aylık veriyi ifade etmiş olacaktır. MIDAS regresyonları, sıkı parametelendirilmiş ve farklı frekanslarda örneklenen süreçleri içeren regresyonların indirgenmiş biçimidir. Bu açıklamadan sonra bir adım sonrasını öngören tek açıklayıcı değişkenli temel doğrusal MIDAS modeli:

$$y_t = \beta_0 + \beta_1 B(L^{1/m}; \theta) x_{t-1}^{(m)} + \varepsilon_t^{(m)}$$

$B(L^{1/m}; \theta) = \sum_{k=0}^K B(k; \theta) L^{k/m}$  ,  $L^{1/m}$  gecikme işlemcisinde K uzunluğunda bir polinomdur ve  $L^{j/m} x_t^{(m)} = x_{t-j/m}^{(m)}$  'dir. Diğer bir ifadeyle  $L^{j/m}$  işlemcisi  $x_t^{(m)}$  açıklayıcı değişkeninin j/m dönem gecikmesini oluşturmaktadır.

h adım sonrası için öngörü modeli yazılacak olursa küçük bir değişiklikle aşağıdaki gibi ifade edilir (Ghysels vd., 2004, 1-5):

$$y_t = \beta_0 + \beta_1 B(L^{1/m}; \theta) x_{t-h}^{(m)} + \varepsilon_t^{(m)} \quad (3.16)$$

$B(k; \theta)$  'nın gecikmeli katsayılarının cimri bir biçimde parametreleştirilmesi, MIDAS'ın en önemli sorunlarından biridir. Çünkü bağımsız değişkenler bağımlı değişkenden daha yüksek frekanslıdır ve kısıtsız doğrusal iyi bir model pek çok gecikmeyi içerecektir. Bu sorunu çözmek adına  $B(k; \theta)$  için farklı doğrusal olmayan ağırlıklandırma yöntemleri kullanılmaktadır.  $B(k; \theta)$  'nın parametreleştirilmesinde kullanılan yöntemlerden biri “Üssel Almon Gecikme” modelidir.

$$B(k; \theta) = \frac{e^{\theta_1 k + \dots + \theta_Q k^Q}}{\sum_{k=1}^K e^{\theta_1 k + \dots + \theta_Q k^Q}} \quad (3.17)$$

$B(k; \theta)$  fonksiyonunun oldukça esnek olduğu bilinir ve yalnızca birkaç parametreyle artan, azalan veya tümsek gibi çeşitli biçimler alabilir. Ghysels vd. (2005) denklem (3.17) deki fonksiyonel formu iki parametreyle,  $\theta = [\theta_1; \theta_2]$ , kullanmışlardır. Bu durum Üssel Almon Gecikme modeline esneklik sağlar ve regresyonda gerekli olan gecikme sayısının belirlenmesini sağlar.

Diğer bir parametreleştirme yöntemi olan Beta fonksiyonu da sadece iki parametre içerir;

$$\theta = [\theta_1; \theta_2]:$$

$$B(k; \theta_1, \theta_2) = \frac{f\left(\frac{k}{K}, \theta_1; \theta_2\right)}{\sum_{k=1}^K f\left(\frac{k}{K}, \theta_1; \theta_2\right)} \quad (3.18)$$

burada

$$f(x, a, b) = \frac{x^{a-1} (1-x)^{b-1} \Gamma(a+b)}{\Gamma(a)\Gamma(b)} \quad (3.19)$$

$$\Gamma(a) = \int_0^\infty e^{-x} x^{a-1} dx$$

şeklindedir (Ghysels ve Valkanov, 2006:4-6).

MIDAS modelleri genel koşullar altında doğrusal olmayan en küçük kareler (NLS) ile tahmin edilebilir. Değişen varyansı sorununu aşmak için Newey-West düzeltmeli standart hatalar kullanılabilir (Ghysels ve Valkanov, 2006:21).

Ghysels vd. (2004), MIDAS regresyonunun yüksek frekanslı serileri düşük frekanslı seri ile aynı frekansa getirmek için toplulaştırma yapıp sonra regresyon modeline dâhil eden yaklaşımlara göre daha etkili olduğunu göstermişlerdir. Bazı durumlarda, MIDAS modelleri, tüm serilerin en yüksek frekansta mevcut olduğu dağınık gecikme regresyonları kadar etkilidir. Ayırıştırma sapmaları, MIDAS ve dağıtılmış gecikme modelleri için aynıdır ve bağımsız değişkenlerin gözlenme frekansı arttığında ayırıştırma sapmaları kaybolur. Bu sonuç makroekonomik değişkenleri içeren regresyonlar ve finansal seriler genellikle makro serilerin varlığına bağlı olarak aylık, çeyreklik veya yıllık regresyonlarla sınırlandırıldığından önemlidir. Bağımlı değişken, Y için yüksek frekanslı verilerin bulunamamasına rağmen ayırıştırma sapmalarını hafifletmek için finansal serilerin daha hassas örneklemesinin kullanılabileceğini göstermektedir.

### 2.6.2 Çok değişkenli MIDAS Yöntemi

Yukarıdaki temel MIDAS denklemi tek değişken için açıklanmıştır. Model birden fazla değişken içermesi halinde Ghysels ve Valkanov (2006) aşağıdaki gibi bir model tanımlamışlardır:

$$Y_{t+1} = \beta_0 + \sum_{i=1}^K \sum_{j=1}^L B_{ij} (L^{i/m_i}) X_t^{m_i} + \varepsilon_{t+1} \quad (3.20)$$

Y, X ve  $\varepsilon$  n boyutlu vektör işlemcilerini  $\beta_0$ , n boyutlu vektörü ve  $B_{ij}$  n×n polinom matrisini temsil etmektedir. Burada asıl mesele, çok değişkenli veri seti olduğunda parametre çoğalmasının nasıl ele alınacağıdır. Bunun için önerilebilecek bir yaklaşım, köşegen olmayan elemanları bir polinom tarafından kontrol edildiği halde köşegen elemanların ortak bir ikinci polinomuna sahip olmaktır. Önerilen bu kısıtlar her zaman uygun olmayabilir. Sonuç olarak, parametrelerin sayısını azaltmak için gerekli kısıtlamalar yapılan uygulama tarafından belirlenecektir (Ghysels vd., 2007:16).

### 2.6.3 Doğrusal Olmayan MIDAS Yöntemi

Ghysels vd. (2007) (3.20) nolu denklemi genelleştirerek aşağıdaki doğrusal olmayan modeli elde etmişlerdir.

$$y_{t+k} = \beta_0 + f(\sum_{i=1}^K \sum_{j=1}^L B_{ij} (L^{1/m_i}) g(x_t^{m_i})) + \varepsilon_{t+1} \quad (3.21)$$

Burada f ve g fonksiyonları bilinen veya parametreye bağlı fonksiyonlar olabilir. Örneğin, pek çok oynaklık uygulamasında logaritmik dönüşüm alınır, yani gelecekteki logaritmik oynaklığını tahmin etmeye çalışılır ve bu nedenle  $g(x) = x$  ve  $f = \log$  olarak alınabilir.

## 2.7 AR-MIDAS Yöntemi

Ghysels vd. (2004), bağımlı değişkenlerin gecikmelerinin bağımsız değişken olarak kullanılmasının etkinlik kaybı yarattığını göstermiştir. Bu durum ayrıca açıklayıcı değişkenlerde mevsimlik kalıplarının oluşmasına neden olur (Forni ve Marcellino, 2016:243).

Daha yüksek frekanslı açıklayıcı değişkenli modellerde otoregresif dinamiğin de hesaba katılması gerekir. Bir aşama sonrasında öngörmek için daha düşük frekanslı olan bağımlı değişken  $y$ 'nin gecikmesi  $y_{t-1}$ ' in temel MIDAS modeline eklendiği kabul edilsin:

$$y_t = \beta_0 + \gamma y_{t-1} + \beta_1 B(L^{1/3}; \theta) x_{t-1}^{(3)} + \varepsilon_t \quad (3.22)$$

$y$  çeyreklik,  $x$  aylık bir değişkendir. Bu stratejinin genellikle uygun olmadığı, modeli aşağıdaki gibi yeniden düzenlendiğinde görülebilir:

$$y_t = \beta_0(1 - \gamma)^{-1} + \beta_1(1 - \gamma L)^{-1} B(L^{1/3}; \theta) x_{t-1}^{(3)} + \tilde{\varepsilon}_t \quad (3.23)$$

$\tilde{\varepsilon}_t = (1 - \gamma L)^{-1} \varepsilon_t$   $x$  üzerindeki polinomun,  $B(L^{1/3}; \theta)$ 'deki  $L^{1/3}$  içindeki ve  $\sum \gamma^j L^j$ 'deki  $L$  içindeki birer polinomun çarpımıdır. Bu karışım,  $x^{(3)}$ 'ün mevsimsel bir yapı sergileyip sergilemediğine bakılmaksızın  $y$ 'den  $x^{(3)}$ 'e "mevsimsel" bir etki üretir. Bu sorunu aşmak için şu AR dinamiğini modele ortak faktor olarak eklenmesi önerilmektedir:

$$y_t = \beta_0 + \gamma y_{t-1} + \beta_1 B(L^{1/3}; \theta)(1 - \gamma L) x_{t-1}^{(3)} + \varepsilon_t \quad (3.24)$$

Böylece  $y$ 'nin  $x^{(3)}$ 'e etkisi mevsimsel olmayacaktır. Çok adımlı örnek bir öngörü modeli aşağıdaki gibi yazılabilir:

$$y_t = \gamma y_{t-d} + \beta_1 + \beta_2 B(L^{1/3}; \theta)(1 - \gamma L^d) x_{t-h}^{(3)} + \varepsilon_t \quad (3.25)$$

$h$  bir tam sayı olduğu zaman denklem (3.24) deki gibi  $d=h=1$  olur. Cari çeyrekte değişkenler bilindiğinde (örneğin, ilk iki ay biliniyorsa),  $d = 1$  iken  $h = 1/3$ 'tür. Bu

denklem AR-MIDAS olarak adlandırılmıştır. AR-MIDAS'ın kestirim sürecinde, ilk önce temel MIDAS denklemi tahmin edilir. Buradan hata terimlerinin tahmini,  $\hat{\varepsilon}_t$ , alınır ve  $\hat{\gamma}_0 = (\sum \hat{\varepsilon}_{t-h}^2)^{-1} \sum \hat{\varepsilon}_t \hat{\varepsilon}_{t-h} \gamma$ 'ın ilk değeri  $\hat{\gamma}_0$ , kestirilir. Sonra  $y_t^* = y_t - \hat{\gamma}_0 y_{t-d}$  ve  $x_{t-h}^{*(3)} = x_{t-h}^{(3)} - \hat{\gamma}_0 x_{t-h-d}^{(3)}$  eşitlikleri kurulur ve aşağıdaki denkleme doğrusal olmayan en küçük kareleri uygulayarak  $\hat{\theta}_1$  tahmincisini elde edilir:

$$y_t^* = \beta_1 + \beta_2 B(L^{1/3}; \theta) x_{t-h}^{*(3)} + \varepsilon_t \quad (3.26)$$

Bu regresyon kalıntılarında yeni bir  $\gamma$  ve  $\hat{\gamma}_1$  değeri elde edilir. Sonra  $\hat{\gamma}_1$  ve  $\hat{\theta}_1$  ilk değerler olarak kullanılarak kareli artıkların toplamını en aza indirgeyen  $\hat{\gamma}$  ve  $\hat{\theta}$  tahminlerini elde etmek için Broyden–Fletcher–Goldfarg–Shanno yöntemi kullanılır (Clements ve Galvão, 2008:547).

## 2.8 Kısıtsız MIDAS (U-MIDAS) Yöntemi

Foroni vd. (2011) bağımlı ve bağımsız değişkenler arasındaki örnekleme frekanslarındaki fark büyük olduğunda, parametre çoğalmasını önleyen dinamikleri modellemek için sıklıkla gecikmesi dağıtılmış fonksiyonları kullanmıştır. Fakat makroekonomik uygulamalarda örnekleme frekanslarındaki farklılıklar genellikle küçüktür. Böyle bir durumda sıklıkla gecikmesi dağıtılmış fonksiyonların kullanılması gerekli olmayabilir. Bu düşünceden yola çıkarak Foroni vd. (2011) yeni bir yöntem önermişlerdir. Önerilen yeni yöntem standart MIDAS modelinden farklı olarak fonksiyonel gecikme polinomlarına başvurmayan, daha ziyade basit doğrusal gecikme polinomlarını kullanmaktadır. Literatürdeki standart MIDAS yaklaşımı ile karşılaştırıldığında, bu polinomlar belirli bir fonksiyonel form ile kısıtlı değildir ve bu nedenle yaklaşımı kısıtsız MIDAS (U-MIDAS) olarak adlandırılmıştır. U-MIDAS regresyon yaklaşımı aşağıdaki gibi genel bir dinamik doğrusal modelden türetilmiştir.

$$c(L^k) \omega(L) y_t = \delta_1(L) x_{1t-1} + \dots + \delta_N(L) x_{Nt-1} + u_t \quad (3.27)$$

(3.27) denkleminde  $t = k, 2k, 3k, \dots, Tk$ ,  $c(L^k) = (1 - c_1 L^k - \dots - c_c L^{kc})$ ,  $w(L)$  işlemcisi toplulaştırma şemasını temsil etmektedir ve  $w(L) = w_0 + w_1 L + \dots + w_{k-1} L^{k-1}$ , örneğin, akım değişkenler için  $w(L) = 1 + L + \dots + L^{k-1}$  ve stok değişkenleri için  $w(L) = 1$ 'dir.  $\delta_j(L) = (\delta_{j,0} + \delta_{j,1} L + \dots + \delta_{j,v} L^v)$ ,  $j=1,2,\dots,N$ .  $x_t$ ,  $t$  zamanında gözlemlenirken

y k dönemlerinde gözlemlenmektedir. Diğer bir ifade ile  $x, y$ 'den k kez sık frekanslıdır<sup>5</sup>. Hata teriminin ( $u_t$ ) otokorelasyonsuz olması için  $c$  ve  $v$  gecikme dereceleri yeterince uzun olduğu kabul edilmektedir. Denklem (3.27) deki U-MIDAS modelinde tüm parametreler sıradan en küçük kareler yöntemi ile tahmin edilebilir<sup>6</sup>. Pratik bir bakış açısı ile gecikme derecesi  $v$  değişkenler arasında farklılık gösterebilir ve  $v_i$  ve  $c$ , SIC gibi bir bilgi kriteri ile belirlenebilir.

Öngörünün  $T_k$  döneminde yapıldığını ve öngörü vadesi  $h = k$  olduğu durumda öngörü denklemi aşağıdaki gibi formulize edilebilir:

$$\hat{y}_{T_k+k|T_k} = (c_1 L^k + \dots + c_c L^{kc}) y_{T_k+k} + \delta_1(L) \hat{x}_{1T_k+k-1|T_k} + \delta_1(L) \hat{x}_{NT_k+k-1|T_k} \quad (3.28)$$

Burada  $j \leq T$  için  $\hat{x}_{iT_k+j|T_k} = x_{iT_k+j|T_k}$  'dir.

Öngörü denklemindeki (3.28) ifadeyle ilgili bir sorun, yüksek frekanslı olan  $x$  değişkenlerinin gelecekteki öngörü değerlerine ihtiyaç duymasıdır. Bu yüzden öngöründe bulunmanın basit bir yaklaşımı aşağıda verilen doğrudan kestirim formunu kullanmaktır:

$$\bar{y}_{T_k+k|T_k} = \bar{c}(L^k) y_{T_k} + \bar{\delta}_1(L) x_{1T_k} + \dots + \bar{\delta}_N(L) x_{NT_k} \quad (3.29)$$

$\bar{c}(Z) = \bar{c}_1(L^k) + \dots + \bar{c}_c(L^{kc})$  ve  $\bar{\delta}_i(L)$  polinomları  $y_t$ 'nin t-k veya daha erken tarihli bilgilerin üzerine yansıtılmasıyla elde edilir,  $t = k, 2k, 3k, \dots, T_k$ .

Genel olarak, (3.29) daki doğrudan yaklaşım modeli,  $T_k$ 'deki bilgiler mevcutken  $hk$ -adımlı öngörüler oluşturmak üzere genişletilebilir:

$$\bar{y}_{T_k+hk|T_k} = \bar{c}(L^k) y_{T_k} + \bar{\delta}_1(L) x_{1T_k} + \dots + \bar{\delta}_N(L) x_{NT_k}$$

$\bar{c}(Z)$  ve  $\bar{\delta}_i(L)$  polinomları  $y_t$ 'nin t-hk veya daha erken tarihli bilgilerin üzerine yansıtılmasıyla elde edilir,  $t = k, 2k, 3k, \dots, T_k$ .

Foroni vd. (2011) göre U-MIDAS modelinde bağımlı değişken çeyreklik, bağımsız değişkenler aylık olduğunda MIDAS'dan genellikle daha iyi performans göstermektedir. Öte yandan, örnekleme frekanslarında daha büyük farklılıklar olması durumunda, örneğin bağımlı değişken çeyreklik bağımsız değişkenler günlük

<sup>5</sup> Örnek  $x$  aylık bir veri ve  $k=3$  ise  $y$  çeyreklik bir veri demektir. Başka bir örnek  $x$  haftalık veri ve  $k=4$  ise  $y$  aylık bir veri demektir.

<sup>6</sup> Topluşturma şeması  $w(L)$  bilindiği varsayılmaktadır.

olduğunda, MIDAS daha iyi sonuç vermektedir. Bununla birlikte örneklem dışı bulgular U-MIDAS'ın yüksek frekanslı göstergelerin bazıları için kısıtlı polinomlar kullanan MIDAS'dan daha iyi performans sergileyebileceğini göstermektedir. Genel olarak, bir kısıt polinomunun tanımlanması her durumda baskın olması beklenmemektedir.

## 2.9 Üç Aşamalı Regresyon Filtreleme (3PRF) Yöntemi

Değişken sayısı gözlem sayısından büyük veya gözlem sayısına yakın olduğunda katsayıları hesaplamak ya imkânsızdır ya da elde edilen sonuçlar tatminkâr olmaktan uzaktır. Bu sorunu aşmak için literatürde kullanılan yöntemler genellikle bağımsız değişkenlerdeki, X, değişimi açıklayacak şekilde daha az sayıda faktörler elde etmek ve bunlar üzerine bağımlı değişkeni, Y, modelleyerek öngöründe bulunmak şeklindedir. Kelly ve Pruitt (2015) Y ile ilgili faktörlerin, X'i açıklayan tüm faktörlerin katı bir alt kümesi olabileceği fikrinden yola çıkarak çok sayıda değişken kullanarak tek bir zaman serisini öngörmek için üç aşamalı regresyon filtresi (3PRF) olarak adlandırılan yeni bir yöntem önermişlerdir.

Üç aşamalı regresyon filtresi, bağımlı değişken olan Y ile alakasız ancak bağımsız değişkenler arasında yaygın olabilecek faktörleri atarken sadece öngörülecek hedefi etkileyen faktörlerin alt kümesini dikkatlice tespit eder. 3PRF, kapalı formda ve hemen hemen anlık olarak hesaplanma avantajına sahiptir.

Kelly ve Pruitt (2015) ampirik uygulamalarda 3PRF yönteminin makroekonomik toplamların ve hisse senedi piyasası getirilerinin başarılı bir tahmincisi olduğunu ve genellikle alternatif yöntemlerden daha iyi performans gösterdiğini savunmaktadır.

Öngöründe bulunmak için 3PRF yöntemi özellikle bağımlı değişken ile alakalı faktörleri vekil değişkenler olarak kullanır. Faktörler bağımlı ve bağımsız değişkenlerden elde edilebileceği gibi ekonomik teoriye dayanarak ekonometrisyenler tarafından da elde edilebilir. Y, gizli faktörlerin alt kümesinin ve bazı öngörülemeyen gürültünün toplamının doğrusal bir fonksiyonudur. Bu yüzden en uygun öngörü, temel ilgili faktörlerin regresyonundan elde edilir. Bununla birlikte, bu faktörler gözlemlenemediğinden, bu mümkün olmayan en iyi tahmin olarak adlandırılır (Kelly ve Pruitt, 2015:295).

$\mathbf{y} = (\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_T)'$  bağımlı değişken zaman serisinin  $T \times 1$  vektörü olsun,  $T$  örneklem dönemindeki zaman serisi gözlemlerinin sayısını göstermektedir.  $N$  bağımsız değişken sayısına temsil etmek üzere  $T \times N$  bağımsız değişken matrisi  $\mathbf{X}$ ,  $\mathbf{X} = (\mathbf{x}'_1, \mathbf{x}'_2, \dots, \mathbf{x}'_T)' = (\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N)$  birim zaman serileri varyansına sahip olacak şekilde standartlaştırılmıştır.  $\mathbf{x}_t$   $t$  zamanında gözlemlenen bağımsız değişkenin  $N$  boyutlu yatay kesitini,  $\mathbf{x}_i$ ,  $T$  boyutlu zaman serisinin  $i$ .değişkenini temsil eder,  $i=1,2,\dots,N$ ;  $t=1,2,\dots,T$ .  $\mathbf{Z}$ ,  $L$  sayıdaki vekil değişken için  $(T \times L)$  boyutlu vekil matrisidir.  $N$  ve  $T$  'nin sayısal büyüklüğü hakkında bir varsayımda bulunulmamıştır fakat indirgeme işleminin doğası gereği  $L \ll \min\{T, N\}$  olmalıdır.

3PRF yöntemi aşağıdaki gibi üç aşamayı izleyerek gerçekleştirilebilir:

1)  $\mathbf{x}_i$ ' nin  $\mathbf{Z}$  üzerine zaman serisi regresyonu aşağıdaki gibi tahmin edilir

$$x_{i,t} = \varphi_{0,i} + \mathbf{z}'_t \boldsymbol{\varphi}_i + \varepsilon_{it}, \quad i=1,2,\dots,N; \text{ buradan } \hat{\boldsymbol{\varphi}}_i \text{ 'nin kestirimi yapılır.}$$

2)  $\mathbf{x}_t$  'nin  $\hat{\boldsymbol{\varphi}}_i$  üzerine yatay kesit serisi regresyonu aşağıdaki gibi tahmin edilir

$$x_{i,t} = \varphi_{0,i} + \hat{\boldsymbol{\varphi}}_i' \mathbf{F}_t + \varepsilon_{it}, \quad t=1,2,\dots,T \text{ buradan da } \hat{\mathbf{F}}_t \text{ kestirimi yapılır.}$$

3)  $y_{t+1} = \beta_0 + \hat{\mathbf{F}}_t' \boldsymbol{\beta} + \eta_{t+1}$  denkleminde  $\hat{y}_{t+1}$  öngörüsü elde edilir.

Üç model de sıradan EKK ile tahmin edilir. Kelly ve Pruitt (2015) vekil değişken seçimi için otomatik vekil seçim yöntemini tercih etmişlerdir. Bu yöntemde ilk aşamada  $L=1$  seçilir. Bu durumda tek vekil değişken vardır o da bağımlı değişkendir. Bu tek vekil değişken kullanılarak yukarıdaki 3PRF yönteminin aşamaları sırasıyla tahmin edilir. 3PRF'nin üçüncü aşamasında elde edilen kalıntılar  $L=2$  durumunda ikinci vekil olarak kullanılır. Sonra bu iki vekille yukarıdaki 3 aşamalı 3PRF model süreci tekrar tahmin edilir ve bu modelin de kalıntıları elde edilir. Süreç uygun faktör sayısına ( $L$ ) ulaşana kadar yinelemeli şekilde devam ettirilir (Kelly ve Pruitt, 2015:299).

3PRF modelinde, uygun faktör sayısını ( $L$ ) seçmek için bir bilgi kriteri kullanılabilir. Faktör seçimi için bilgi kriteri yaklaşımı özellikle 3PRF'nin otomatik vekil seçim süreci ile ilişkilidir. 3PRF'nin otomatik vekil seçim süreci istatistiksel olarak belirlenen bir tahmin sürecidir ve uygun bir şekilde bir bilgi kriterine tabidir. Buna karşın temel ekonomik teori tarafından önceden belirlenen vekil sayısı daha doğru olabilir (Kelly ve Pruitt, 2015:302).

### 2.9.1 Karma Frekanslı 3PRF Yöntemi

Hepenstrick ve Marcellino (2016), Kelly ve Pruitt (2015) tarafından önerilen 3PRF yaklaşımını karma frekanslı veri setlerine uygulanacak şekilde geliştirmişlerdir. Hepenstrick ve Marcellino (2016) hedef değişken,  $y$  veya vekil değişkenler  $\mathbf{z}$ 'nin bağımsız değişkenlerden,  $\mathbf{x}$ , daha düşük frekanslı olduğu durumu ele almışlardır.  $\mathbf{x}$ 'in bazı bileşenlerinin sadece düşük frekansta olmasına imkân sağlanmıştır. Son olarak da  $\mathbf{x}$  açıklanma tarihlerindeki farklılıklardan dolayı örneklem sonunda bazı değişkenlerin eksik gözlemlili olması nedeniyle “düzensiz kesit” şeklinde adlandırılan durumu ele almıştır.

*1. Durum: Düşük Frekanslı Bağımlı veya Vekil Değişkenler ve Yüksek Frekanslı Bağımsız Değişkenler*

Bu durum uygulamada yaygın olarak karşılaşılan durumdur. Örnek olarak; GSYH büyümesi çeyreklik olarak mevcutken, sanayi üretimi, beklenti anketleri ve birçok mali değişken aylık olarak bulunmaktadır.

Hepenstrick ve Marcellino (2016) bu frekans uyumsuzluğunun üstesinden gelmek için 3PRF'in aşamalarında aşağıdaki gibi değişiklik yapmıştır.

Aşama 1: 3PRF yönteminde de olduğu gibi, modeli düşük frekanslı değişken ve zamansal olarak toplulaştırılmış yüksek frekanslı değişkenle tahmin edilir.

Aşama 2: 3PRF de olduğu gibi, yüksek frekanslı tahmini faktörleri elde etmek için yüksek frekanslı değişkenleri kullanılır.

Aşama 3: Düşük frekanslı bağımlı değişkeni yüksek frekanslı bağımsız değişkenlerle ilişkilendiren öngörü modelini kurmak için U-MIDAS yaklaşımı kullanılır.

Aşama 3'te önerilen U-MIDAS'dan dolayı aşama 2'den kestirilmiş aylık faktör matrisi,  $\hat{\mathbf{F}}_t$ ,  $\hat{\mathbf{F}}_t^1$ ,  $\hat{\mathbf{F}}_t^2$  ve  $\hat{\mathbf{F}}_t^3$  diye üç tane çeyreklik faktöre paylaşmayı gerekli kılmaktadır. Sonra  $\hat{\mathbf{F}}_t^1$ ,  $\hat{\mathbf{F}}_t^2$  ve  $\hat{\mathbf{F}}_t^3$  aşama 3'te  $y_t$  için açıklayıcı değişken olarak kullanılırlar böylece eşitliğin her iki tarafında dengeli frekans elde edilmiş olur. Üstelik denklemdeki doğrusallık devam etmektedir ve tüm olası bilgiler hala kullanılmaktadır.

## 2. Durum: Düşük Frekanslı Bağımsız Değişkenler

Bazen sadece bağımlı değişken veya vekil değişken düşük frekanslı olmayabilir. Bunların yanı sıra bağımsız değişkenlerden bazıları da sadece düşük frekanslı olarak bulunabilir. Bu durum, gözlenemeyen faktörler için model kurulmasını gerektiren Kalman filtresinin kullanılması ile çözülebilir. Alternatif olarak, faktörler için model kurmaya gerek kalmadan temel bileşenler analizi ile birlikte Stock ve Watson (2002) de önerilen beklenti maksimizasyonu uygulanabilir. Her iki durumda da düşük frekanslı gözlemlerdeki eksik gözlemler sistematik biçimde en iyi tahmini ile değiştirilir ve analiz devam ettirilir. EM algoritması yüksek frekanslı (aylık) faktör kestirimleri ve her  $i$  için  $\hat{x}_i$  zaman serisinin eksik değerinin kestirimini sağlar. Böylece  $\hat{x}$  dengeli panele dönüşür ve karma frekanslı-3PRF uygulanır.

## 3. Durum: Düzensiz kesit

Ampirik çalışmalarda göstergelerin başından veya sonunda eksik veri sorunu ile karşılaşmaktadır. Açıklanma tarihlerindeki farklılıklardan dolayı örneklem sonunda bazı değişkenlerin eksik gözlemlili olması “düzensiz kesit” olarak adlandırılır. Öngörü için daha uygun olduğundan bu duruma odaklanılmaktadır, ancak örnek başlangıcındaki gözlem eksikliği de benzer bir şekilde ele alınabilir.

“Düzensiz kesit” sorununun üstesinden gelmek için beklenti maksimizasyona ek olarak üç yaklaşım önerilmiştir. İlki, Kalman filtresinin kullanılmasıdır. İkincisi, düzensiz kesit’li değişkenle zaman serisi modeli kurmaktır ve her zaman serisinin sonuna eksik gözlem yerine öngörülen değeri koymaktır. Daha basit olan üçüncü yaklaşımsa verinin dikey yeniden hizalamasının kullanılmasıdır.

Durum uzayının doğru belirlenmesi şartıyla eksik gözlemlerin en iyi doğrusal kestirimlerinin üretilmesi bakımından düzensiz kesit sorunun ele almada Kalman filtresi kullanmak uygundur. Ancak gözlenemeyen faktörler için model belirlenmesi ve kestirilmesini gerekli kılmaktadır. İkinci ve üçüncü yaklaşımların uygulanması daha kolaydır fakat daha az uygun olabilir (Hepenstrick ve Marcellino, 2016:6-9).

## BÖLÜM 3

### 3 VERİ VE UYGULAMA

Çalışmanın uygulama aşamasına geçmeden önce literatürde gerek Türkiye gerekse diğer ülkeler için yapılmış çalışmalara kısaca değinilecektir.

#### 3.1 Şimdi Tahmin Yöntemleri İle İlgili Literatür Taraması

Şimdi tahmin, şimdiki durumun, çok yakın geleceğin ve çok yakın geçmişin tahmini olarak tanımlanmakta ve iktisat literatürüne yakın zamanda Giannone vd. (2008) tarafından kazandırılmıştır. Tahmin yapmada kullanılan modellerde eğer az sayıda değişken kullanılıyorsa bu model küçük ölçekli model aksi takdirde büyük ölçekli model denmektedir. Giannone vd. (2008) yaklaşık 200 değişken kullanarak geliştirdikleri dinamik faktör modeli (DFM) ABD GSYH büyümesini tahmin etmişlerdir. Benzer yöntemi kullanarak pek çok ülke için şimdi tahmin çalışmaları yapılmıştır. Örneğin; İrlanda için D'Agostino vd. (2008), Çin için Yiu ve Chow (2010), Çek Cumhuriyeti için Arnostova vd. (2011), Yeni Zellanda için Matheson (2010), Norveç için Aastveit ve Trovik (2012) ve İsviçre için Siliverstovs ve Kholodilin (2012) şimdi tahmin yöntemini kullanmışlardır.

Makro iktisadi serilerin mevcut durumunu tahmin etmek için farklı şimdi tahmin yöntemlerinin kullanılmaya başlanması bunların farklı ülkeler için farklı veri setlerinde hangisinin daha iyi sonuç verdiğini belirleme ihtiyacını da ortaya çıkarmıştır. Bunun sonucu olarak karşılaştırmalı çalışmaların sayısı artmaktadır.

10 farklı Avrupa ülkesi için Barhoumi vd. (2008) AR, VAR, köprü modeli ve temel bileşenler gibi dinamik faktör modellerini kullanarak GSYH'yı tahmin etmiştir ve farklı ülkelerde farklı modellerin iyi sonuçlar verdiğini göstermiştir. Euro bölgesi için Kuzin vd. (2011) GSYH büyümesi tahminini yaptıkları çalışmada MIDAS ve MF-VAR yöntemlerini karşılaştırmalarını yapmışlardır. Çek Cumhuriyeti için Rusnak (2012) GSYH dinamik faktör, MIDAS ve karma frekanslı Bayesyen VAR modellerini karşılaştırmıştır. ABD için Libermann (2014) dinamik faktör model ile AR modelinin performansını karşılaştırmıştır. ABD için Aastveit vd. (2014) yaptıkları çalışmada köprü model, faktör model ve karma frekanslı VAR ve bunların bileşim modellerinin performansını karşılaştırmışlardır. Rusya için Porshakov (2015) dinamik faktör model,

rassal yürüyüş ve köprü modeli ile karşılaştırmalı olarak tahmin yapmışlardır. Slovekyaya için Peter (2017) dinamik faktör model, AR ve rassal yürüyüş modeli ile karşılaştırmalı olarak tahmin yapmıştır. ABD için Foroni vd. (2012) de yaptıkları çalışmada U-MIDAS ve MIDAS yöntemlerini performansını karşılaştırmışlardır. Almanya için Antipa vd. (2012) GSYH'nın şimdi tahmini için köprü modeli ve faktor modeli karşılaştırmıştır. ABD için Alvarez vd. (2012) yaptıkları çalışmada küçük ölçekli dinamik faktör modeller ile büyük ölçekli dinamik faktör modelleri karşılaştırmış ve küçük ölçeklilerin daha iyi sonuç verdiklerini bulmuşlardır. İngiltere için Bell vd. (2014) endüstri modeli ve ağırlıklandırılmış araştırma modelini kullanarak GSYH büyümesini karşılaştırmalı tahmin etmişlerdir. Euro bölgesi için Foroni ve Marcellino (2014) GSYH büyümesini köprü, AR-MIDAS ve MF-VAR modelleri ile karşılaştırmalı tahmin etmiştir. Almanya, Fransa, İtalya, İspanya ve Hollanda için Jansen vd. (2016) 12 farklı yöntemin performansını karşılaştırmışlardır. Euro bölgesi için Schumacher (2016) MIDAS ve Köprü modellerininin karşılaştırmasını yapmıştır. 10 Avrupa ülkesi için Rünstler vd. (2009) dinamik faktör, genelleştirilmiş dinamik faktör, köprü ve çeyreklik VAR modellerini uygulanarak tahminde bulunmuşlardır. Altı sanayileşmiş ülke için yaptıkları çalışmada Kuzin vd. (2013) MIDAS modeller ile Dinamik faktör modellerin performansını karşılaştırmak için GSYH büyümesini tahmin etmişlerdir. Liebermann (2012) rassal yürüyüş, AR, bayesyen VAR ve dinamik faktör modelleri performansını karşılaştırmak için ABD'nin bazı makro iktisadi verilerini şimdi tahminini yapmıştır.

Türkiye için yapılan çalışmalardan bazıları ise şunlardır:

Akkoyun ve Günay (2012) 2008Ç1-2012Ç2 dönemlerinde Türkiye'nin GSYH büyümesini küçük ölçekli dinamik faktör modeli kullanmışlardır ve elde edilen sonuçlarıda kıstas model olarak seçtikleri AR modelini ile karşılaştırmışlardır. Öngörü performans ölçütü olarak RMSE kullanmışlar ve kendi tahmin modellerinin kıstas modelden daha iyi sonuç verdiğini göstermişlerdir.

Ermişoğlu vd. (2013) 2007Ç1-2012Ç2 dönemlerinde Türkiye'nin GSYH'sını banka kredileri verisini dâhil ettikleri köprü modelini kullanarak tahmin etmişlerdir. Kıstas model olarak yine başka bir köprü modeli seçmiştir. Öngörü performans ölçütü olarak RMSE ve MAE kullanmışlar ve banka kredileri verisininin dâhil edildiği modelin daha iyi sonuç verdiğini göstermişlerdir.

Mudugno vd. (2016) 2008Ç1-2013Ç4 dönemlerinde Türkiye'nin GSYH'sını orta ölçekli dinamik faktör modelini kullanarak tahmin etmişlerdir. Öngörü performans ölçütü olarak RMSE kullanmışlar ve orta ölçekli dinamik faktör modelin kıstas model olarak kullanılan AR(1) ile köprü modellerine göre daha iyi sonuç verdiğini belirlemişlerdir.

Doğan ve Midiliç (2016) günlük finansal seriler ile MIDAS yöntemi kullanarak 2010Ç2-2015Ç1 dönemleri arasında Türkiye'nin GSYH büyüme oranını tahmin etmişlerdir. Öngörü performans ölçütü olarak RMSE kullanmışlar ve MIDAS yönteminin kıstas yöntem olarak kullanılan AR(1) yöntemine göre daha iyi sonuç verdiğini tespit etmişlerdir.

Türkiye için yapılan çalışmaların hem kısıtlı sayıda olması hem de literatüre yeni kazandırılmış tahmin gücünü artırdığı iddia edilen farklı şimdi tahmin yöntemlerinin karşılaştırmalı çalışmanın eksikliği bu çalışmanın motive kaynağı olmuştur.

### 3.2 Türkiye İçin Uygulama

Veri seti 2005Ç3-2017Ç3 aralığında çeyrek yıllık olarak elde edilmiştir. GSYH büyüme verisi bir önceki çeyreğe göre değişimi gösterecek şekilde çeyreklik olarak düzenlenmiş, diğer tüm veriler aylık olacak şekilde düzenlenmiştir. Veriler Türkiye Cumhuriyet Merkez Bankası, Türkiye İstatistik Kurumu ve Ekonomik Kalkınma ve İşbirliği Örgütü'nden alınmıştır. Tablo 3.1 çalışmada kullanılan değişkenleri ve hangi modelde kullanıldıklarını göstermektedir.


Tablo 3-1: Uygulamada Kullanılan Değişkenler

	Seri Adı	Model Adı						
		AR(1)	KM1	KM2	MIDAS	U-MIDAS	3PRF	DFM
1	GSYH(Bir Önceki Çeyreğe Göre Yüzde Değişim)	✓	✓	✓	✓	✓	✓	✓
2	İhracat			✓	✓	✓	✓	✓
3	İthalat			✓	✓	✓	✓	✓
4	Sanayi Üretim Endeksi		✓	✓	✓	✓	✓	✓
5	BİST 100 Endeks				✓	✓	✓	✓
6	BİST Hizmet Endeksi						✓	✓
7	BİST Mali Endeks						✓	✓
8	BİST Sınai Endeks						✓	✓
9	BİST Teknoloji Endeksi						✓	✓
10	ABD Doları (Döviz Alış)						✓	✓

11	Euro (Döviz Alış)					✓	✓
12	Reel Efektif Döviz Kuru			✓	✓	✓	✓
13	Ticari Krediler					✓	✓
14	Bankalar Arası Faiz Oranı					✓	✓
15	1 Aya Kadar Vadeli (TL Üzerinden Açılan Mevduatlar)					✓	✓
16	M1 Para Arzı						✓
17	M2 Para Arzı						✓
18	M3 Para Arzı						✓
19	Toplam Tüketici Kredileri (TL+YP)					✓	✓
20	Genel Tüketici Fiyat Endeksi			✓	✓	✓	✓
21	Gıda Ve Alkolsüz İçecekler için Tüketici Fiyat Endeksi					✓	✓
22	Konut, Su, Elektrik, Gaz Ve Diğer Yakıtlar için Tüketici Fiyat Endeksi					✓	✓
23	Yurt İçi Üretici Fiyat Endeksi					✓	✓
24	Madencilik ve taşocakçılığı Üretici Fiyat Endeksi					✓	✓
25	İmalat Üretici Fiyat Endeksi					✓	✓
26	Reel Kesim Güven Endeksi-						✓
27	Toplam Sipariş						✓
28	Mamul Mal Stoku						✓
29	Üretim Hacmi (Gelecek 3 Ay)						✓
30	Toplam İstihdam (Gelecek 3 Ay)					✓	✓
31	Tüketici Güven Endeksi			✓	✓		
32	(Toplam) İki ve Daha Fazla Daireli İkamet Amaçlı Binalar (Yapı Sayısı)					✓	✓
33	(Toplam) Binalar (Yapı Sayısı)					✓	✓
34	(Toplam) Binalar (Daire Sayısı)					✓	✓
35	Sanayi Ciro Endeksi			✓	✓	✓	✓
36	Ara Malı İmalatı Endeksi					✓	✓
37	Dayanıklı Tüketim Malı İmalatı Endeksi					✓	✓
38	Dayanıksız Tüketim Malı İmalatı Endeksi					✓	✓
39	Enerji Üretim Endeksi					✓	✓
40	Sermaye Malı İmalatı Endeksi					✓	✓
41	Madencilik Ve Taşocakçılığı Endeksi					✓	✓
42	İmalat Sanayi Endeksi					✓	✓
43	İşgücü Endeksi					✓	✓
44	İstihdam edilenler					✓	✓
45	İşsiz					✓	✓
46	İşsizlik oranı (%)					✓	✓
47	Tarım dışı işsizlik oranı (%)			✓	✓	✓	✓
48	İstihdam oranı (%)					✓	✓
49	İşgücüne katılma oranı (%)					✓	✓

Şekil 3-1 de 2005Ç3 ile 2017Ç3 yılları arasında Türkiye'nin GSYH'nin bir önceki çeyreğe göre büyüme oranı görülmektedir.


Şekil 3-1: Bir Önceki Çeyreğe Göre GSYH'deki Büyüme Oranı



Şekil 3-1 de kolayca görüldüğü gibi Türkiye'nin GSYH çeyreklik büyüme oranı hayli oynaklık göstermektedir. Oynaklık, serilerin öngörüsünün yapılmasını zorlaştırmaktadır. Elde edilen sonuçları bütün halinde değerlendirmeden önce her bir öngörü modelinin sonucunun GSYH ile olan ilişkisi aşağıda sırasıyla ele alınmıştır.

Türkiye'nin GSYH'sinin çeyreklik büyüme oranının şimdi-tahminini yapmak için kullanılan AR(1) modelinin öngörü sonucu ve GSYH'nin gerçek değerinin birlikte gösterimi şekil 3-2 de verilmiştir.

Şekil 3-2: AR(1) Modelinin Öngörü Değeri ve Gerçek GSYH Değeri




Şekil 3-2 incelendiğinde AR(1) modelinin Türkiye'nin GSYH çeyreklik büyüme oranlarını şimdi tahmini iyi performans sergilemediği görülmektedir. Özellikle değişim

oranının büyük olduğu dönemlerde AR(1) modelin tahmin başarısı oldukça kötüleşmektedir.

Türkiye'nin GSYH'sinin çeyreklik büyüme oranının şimdi-tahminini yapmak için kullanılan birinci köprü modelinin (KM1) öngörü sonucu ve GSYH'nin gerçek değerinin birlikte gösterimi Şekil 3.3 de verilmiştir.

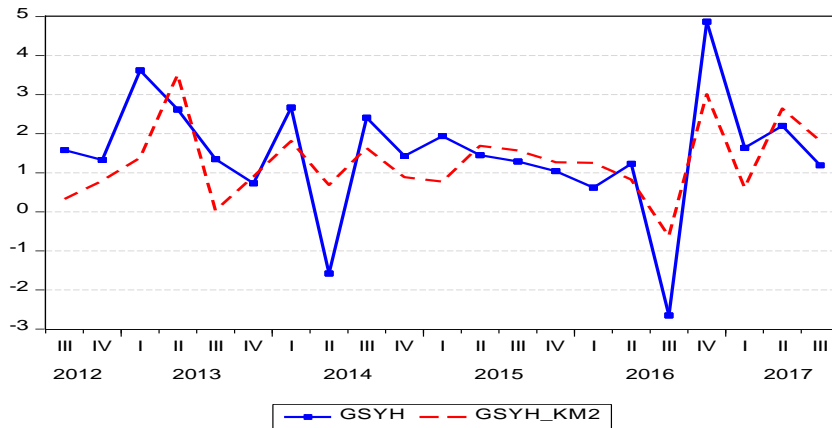
Şekil 3-3: Birinci Köprü Modeli(KM1) Öngörü Değeri ve Gerçek GSYH Değeri



Şekil 3-3 incelendiğinde (KM1) modelinin Türkiye'nin GSYH çeyreklik büyüme oranlarını şimdi tahmininin AR(1) modeline göre iyi performans sergilediği görülmektedir. Öngörü değerlerinin gerçek değerlerle benzer hareket ettiği fakat hala büyük sapmalar olduğu görülmektedir.

Türkiye'nin GSYH'sinin çeyreklik büyüme oranının şimdi-tahminini yapmak için kullanılan ikinci köprü modelinin (KM2) öngörü sonucu ve GSYH'nin gerçek değerinin birlikte gösterimi Şekil 3-4 de verilmiştir.


Şekil 3-4: İkinci Köprü Modeli(KM2) Öngörü Değeri ve Gerçek GSYH Değeri



Şekil 3-4 incelendiğinde (KM2) modelinin Türkiye'nin GSYH çeyreklik büyüme oranlarını şimdi tahmininin AR(1) modeline göre iyi performans sergilediği açıkça görülmektedir. Fakat (KM2) ve (KM1) modelleri öngörü değerlerinin benzer hareket şekilsel olarak hangi modelin daha iyi performans sergilediğinin kesin tespiti pek mümkün gözükme de (KM2) modelinin daha iyi olduğu söylenebilir.

Türkiye'nin GSYH'sinin çeyreklik büyüme oranının şimdi-tahminini yapmak için kullanılan dinamik faktör modelinin öngörü sonucu ve GSYH'nin gerçek değerinin birlikte gösterimi Şekil 3-5 de verilmiştir.

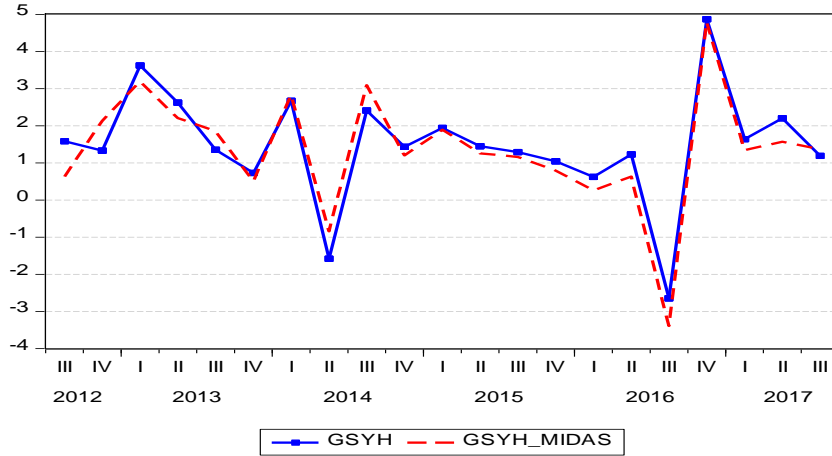
Şekil 3-5: Dinamik Faktör Modelin Öngörü Değeri ve Gerçek GSYH Değeri



Şekil 3-5 incelendiğinde dinamik faktör modelinin AR(1) modeline benzer şekilde Türkiye'nin GSYH çeyreklik büyüme oranlarını şimdi tahmininin gerçek GSYH değeri ile örtüşmediği görülmektedir. Şekil üzerinden yapılabilecek başka bir değerlendirme de dinamik faktör modelinden elde edilen öngörü değerinin (KM1) ve (KM2) modellerinden elde edilen öngörü değerine göre kötü bir performans sergilediğidir.

Türkiye'nin GSYH'sinin çeyreklik büyüme oranının şimdi-tahminini yapmak için kullanılan MIDAS modelinin öngörü sonucu ve GSYH'nin gerçek değerinin birlikte gösterimi Şekil 3-6 da verilmiştir.


Şekil 3-6: MIDAS Modelin Öngörü Değeri ve Gerçek GSYH Değeri



Şekil 3-6 incelendiğinde MIDAS modelinin Türkiye'nin GSYH çeyreklik büyüme oranlarını şimdi tahmininin AR(1), (KM1), (KM2) ve dinamik faktör modellerine göre çok daha iyi bir performans sergilediği açıkça görülmektedir. MIDAS modeli kullanılarak elde edilen GSYH öngörü değerlerinin yüksek dalgalanma dönemleri de dâhil gerçek GSYH değerlerine oldukça yakın olduğu görülmektedir.

Türkiye'nin GSYH'sinin çeyreklik büyüme oranının şimdi tahminini yapmak için kullanılan U-MIDAS modelinin öngörü sonucu ve GSYH'nin gerçek değerinin birlikte gösterimi Şekil 3-7 da verilmiştir.

Şekil 3-7: U-MIDAS Modelin Öngörü Değeri ve Gerçek GSYH Değeri




Şekil 3-7 incelendiğinde U-MIDAS modelinin Türkiye'nin GSYH çeyreklik büyüme oranlarını şimdi tahmininin AR(1), (KM1), (KM2), dinamik faktör modellerine göre çok daha iyi bir performans sergileyen MIDAS modelinden üstün performans sergilediği görülmektedir. Şekil 3-7 de U-MIDAS modeli kullanılarak elde edilen GSYH öngörü değerlerinin yüksek dalgalanma dönemleri de dâhil gerçek GSYH

değerleri ile neredeyse bire bir örtüştüğü görülmektedir. Bu yüzden şimdiye kadar kullanılan öngörü modelleri arasında tercih yapmak zorunda kalınırsa U-MIDAS yönteminin tercih edilebileceği söylenebilir.

Türkiye'nin GSYH'sinin çeyreklik büyüme oranının şimdi tahminini yapmak için kullanılan 3PRF modelinin öngörü sonucu ve GSYH'nin gerçek değerinin birlikte gösterimi Şekil 3-8 de verilmiştir.


Şekil 3-8: 3PRF Modelin Öngörü Değeri ve Gerçek GSYH Değeri



Şekil 3-8 incelendiğinde 3PRF modelinin Türkiye'nin GSYH çeyreklik büyüme oranlarını şimdi tahmininin çok da iyi bir performans sergilemediği görülmektedir. Şekilsel olarak öngörü performansını diğer modeller kıyaslamak gerekirse AR(1) ve dinamik faktör modeller aradaki farkı belirlemek güç gözükmemektedir. Fakat diğer modeller sonucu elde edilen öngörülerin gerçek değere yakınlığı göz önüne alındığında 3PRF modeline göre daha iyi performans sergiledikleri görülmektedir.

Yukarıda verilen şimdi tahmin modelleri ile elde edilmiş sonuçlar ve GSYH grafiği ikili değerlendirmeye imkân sağlamaktadır. Ele alınan model ile elde edilen sonuçların Türkiye'nin GSYH büyüme oranının gerçek değeri ile nasıl bir ilişki içinde olduğu sunmaktadır. Şekil 3-9 ise çalışmada uygulaması yapılan tüm modellerin GSYH'nin gerçek değeri ve kendi aralarında nasıl bir ilişki içinde olduğu konusunda karşılaştırma yapma fırsatı sunmaktadır.

Şekil 3-9: Tüm Modellerin Öngörü Sonuçları ve Gerçek GSYH Çeyreklik Büyüme Oranı



Şekil 3-9 incelendiğinde MIDAS ve U-MIDAS modelinin diğer modellere göre oldukça başarılı öngörülerde bulunduğu görülmektedir.

Modeller arasında değerlendirmeler şimdiye kadar şekilsel olarak yapıldı fakat bu değerlendirme türü nesnel değildir. Bundan dolayı hangi modelin öngörü sonucunun daha üstün olduğunu belirlemek için farklı biçimsel test sonuçlarına ihtiyaç duyulmaktadır. Bunlardan ilki kapsama testidir. Türkiye'nin GSYH'nin çeyreklik büyüme oranının şimdi-tahminini yapmak için kullanılan modellerin kapsama testi sonuçları Tablo 3-2 de verilmiştir.

Tablo 3-2: Kapsama Testi Karşılaştırma Sonuçları

Model	F*
AR(1)	0.000
KM1	0.000
KM2	0.002
U-MIDAS	0.446
MIDAS	0.990
3PRF	0.000
DFM	0.000

\* Tablodaki test istatistikleri F istatistiğinin olasılık değerleridir.

Kapsama testinin sıfır hipotezi i. model geriye kalan diğer modellerin içerdiği tüm bilgileri kapsamaktadır şeklinde kurulmaktadır. Tablo 3-2 de verilen sonuçlar incelendiğinde MIDAS ve U-MIDAS dışında kalan modellerde sıfır hipotezi güçlü bir şekilde reddedilmektedir. Sıfır hipotezinin reddedildiği modeller diğer modellerin içerdiği tüm bilgileri içermiyor demektir. Bu modeller için diğer modellerle birleşme

sağlandığında öngörü doğruluğunda iyileşme olacağı söylenebilir. Sıfır hipotezinin reddedilemediği MIDAS ve U-MIDAS modeli için diğer modellerin içerdiği bilgileri de kapsadığı söylenebilmektedir. Başka bir ifadeyle bu modellerin diğer modellerle birleşmesi durumunda öngöründe bir iyileşme olmasının beklenmeyeceği anlamına gelmektedir.

Türkiye'nin GSYH'nin çeyreklik büyüme oranının şimdi-tahminini yapmak için kullanılan modellerin kapsama testi ikili olarak karşılaştırması Tablo 3-3 de verilmiştir.

Tablo 3-3:Kapsama Testi İkili Karşılaştırma Sonuçları

		1.değişken(Bağımlı)						
		AR(1)	KM1	KM2	U-MIDAS	MIDAS	3PRF	DFM
2.değişken (Bağımsız)	AR(1)	...	0.4511	0.9337	0.3470	0.6277	0.1362	0.1168
	KM1	0.0009	...	0.2672	0.8022	0.7584	0.0768	0.0014
	KM2	0.0004	0.1067	...	0.5988	0.9229	0.0071	0.0007
	U-MIDAS	0.0000	0.0000	0.0001	...	0.9847	0.0000	0.0000
	MIDAS	0.0000	0.0000	0.0002	0.8019	...	0.0000	0.0000
	3PRF	0.2632	0.9473	0.3822	0.2156	0.5880	...	0.5339
	DFM	0.5664	0.6827	0.8509	0.5578	0.9498	0.0476	...

Tablodaki test istatistikleri F istatistiğinin olasılık değerleridir.

Tablo 3-3 incelendiğinde Tablo 3-2'dekine benzer sonuçlar elde edildiği görülmektedir. MIDAS ve U-MIDAS modelleri ikili karşılaştırmada da diğer modellerin içerdiği tüm bilgileri kapsadığı sıfır hipotezi reddedilememektedir. Tablo 3-3'den elde edilen sonuçlara göre AR(1) modeli için 3PRF ve DFM modelleri karşısında sıfır hipotezini reddedilememiştir. Yani 3PRF ve DFM modellerin öngörülerini ayrı ayrı AR(1) modelinin öngörüsü ile birleştirildiğinde öngörünün iyileşmesi için ek bilgi sağlamayacağı belirlenmiştir. Fakat AR(1) modeli için KM1 ve KM2 modelleri karşısında sıfır hipotezini reddedilmektedir. Bu da KM1 ve KM2 modellerinin öngörülerini ayrı ayrı AR(1) modelinin öngörüsü ile birleştirildiğinde öngörünün iyileşmesi için ek bilgi sağlayacağı anlamına gelmektedir. Yine tablodaki sonuçlara göre, KM1 ve KM2 modelleri ikili karşılaştırmada MIDAS ve U-MIDAS dışında diğer modellerin içerdiği tüm bilgileri kapsadığı söylenebilmektedir. Diğer bir ifadeyle diğer modellerin öngörülerini KM1 ve KM2 modellerin öngörüsü ile ayrı ayrı birleştirildiğinde öngörünün iyileşmesi için ek bilgi sağlamayacakları anlamına gelmektedir.

Tablo 3-4 de ise Türkiye'nin GSYH'nin şimdi tahmininin farklı modellerden elde edilen sonuçları arasında istatistikî olarak fark olup olmadığını gösteren Diebold-Mariano test sonuçları verilmiştir.

Tablo 3-4: Diebold-Mariano(DM) Test Sonuçları

	AR(1)	KM1	KM2	U-MIDAS	MIDAS	3PRF	DFM
AR(1)	...	0.2920	0.2281	0.0288	0.0432	0.8996	0.6329
KM1	...	...	0.5536	0.0080	0.0209	0.1976	0.2482
KM2	...	...	...	0.0055	0.0163	0.1398	0.1906
U-MIDAS	...	...	...	...	0.0005	0.0032	0.0191
MIDAS	...	...	...	...	...	0.0063	0.0296
3PRF	...	...	...	...	...	...	0.7683
DFM	...	...	...	...	...	...	...

Tablodaki test istatistikleri Gauss dağılımı istatistiğinin olasılık değerleridir.

Tablo 3-4 incelendiğinde MIDAS ve U-MIDAS ile elde edilen Türkiye'nin GSYH'nin çeyreklik büyüme oranının şimdi tahmininin diğer modellerle elde edilen şimdi-tahmin sonuçlarından farklı olduğu sonucuna ulaşılmaktadır. Bu iki model dışında kalan modellerle elde edilen şimdi-tahmin sonuçlarının Diebold-Mariano testine göre istatistikî olarak birbirinden farklı olmadığı sonucu elde edilmektedir.

Şimdi tahmin sonuçlarının yer aldığı şekillerde modellerden elde edilen öngörüler ile GSYH büyüme oranının gerçek değeri grafiksel olarak kıyaslanabilmektedir. Fakat daha somut kıyaslamaya ihtiyaç vardır. Tablo 3-5 uygulaması yapılan şimdi-tahmin yöntemlerinden elde edilen sonuçların doğruluğunu biçimsel olarak değerlendiren yöntemlerin sonucunu vermektedir.

Tablo 3-5: Öngörü Doğruluğu Değerlendirme Sonuçları

Model	RMSE	MAE	MAPE	Theil U1
AR1	1.580	0.987	46.04	0.458
KM1	1.223	0.969	52.88	0.351
KM2	1.168	0.892	54.35	0.322
DFM	1.610	1.109	54.38	0.475
MIDAS	0.486	0.410	26.69	0.115
U-MIDAS	<b>0.105*</b>	<b>0.081*</b>	<b>4.94*</b>	<b>0.024*</b>
3PRF	1.548	1.224	68.73	0.415
Ortalama	0.948	0.714	36.84	0.266

\* Belirlenen ölçüt için en küçük değeri göstermektedir.

Farklı performans ölçütlerine göre farklı yöntemleri iyi sonuç verebileceği gerçeğine binaen dört farklı performans ölçütü kullanılmıştır. Tablo 3-5 incelendiğinde U-MIDAS yönteminin tüm değerlendirme ölçütlerine göre en iyi performansı gösterdiği açıkça görülmektedir. Diğer yöntemler arasında kıyaslama yapılacak olunursa U-MIDAS'tan sonra MIDAS yönteminin tüm performans ölçütlerine göre diğer yöntemlerden açık bir şekilde iyi olduğu görülmektedir. Fakat diğer yöntemler arasında kıyaslama yaparken U-MIDAS ve MIDAS yönteminde olduğu gibi tüm ölçütler bir öngörü yönteminin daha iyi olduğunu göstermemektedir. Örneğin, MAE ölçütüne göre AR(1) iyi performans sergilemiştir diyebilirken Theil U1 ölçütüne göre 3PRF yöntemi iyi performans sergilemiştir diyebilmektedir. Başka bir örnek RMSE ölçütüne göre KM2 yöntemi iyi performans sergilemiştir fakat MAPE ölçütüne göre KM1 yöntemi iyi performans sergilemiştir.

## SONUÇ

Mevcut ekonomik durum ve gelecekteki ekonomik beklentiler tüm iktisadi ajanların, özellikle merkez bankaları ve hükümetlerin alacakları kararlarda önem arz etmektedir. Bu yüzden iktisadi ajanların ekonominin şimdiki ve gelecekteki işleyişi hakkında bilgi sahibi olması önemlidir. Bir ülkedeki ekonomik işleyiş hakkındaki en genel bilgiyi GSYH verisi barındırmaktadır. Eldeki bilgi ne kadar gerçek veya gerçeğe yakın olursa atılacak olan ekonomik adımlar da o kadar isabetli olacaktır. Bu yüzden açıklanmamış verilerin gerçek değerlerine yakın tahmini çok önemlidir. Literatür kısmında bahsi geçen çalışmalar Türkiye'nin GSYH'nin çeyreklik büyüme oranını şimdi-tahminin yapmak için iki veya üç yöntemi kullanırken bu çalışmada yedi farklı yöntem kullanılmıştır. Bunlar AR(1), KM1 ve KM2 şeklinde adlandırılan iki farklı köprü modeli, MIDAS ve U-MIDAS, DFM ve 3PRF modelleridir. Modellerin işleyişlerinin ve modellerde kullanılan değişkenlerin farklı olması daha doğru öngörü elde edebilmek adına farklı denemeler yapma gerekliliğine bir cevaptır. Ayrıca bu çalışmada diğer çalışmalarda kullanılan yöntemlerin bazılarında yer verildiği gibi daha güncel yöntemlere de yer verilmiştir. Çalışmada kullanılan veri seti büyüme oranı dışında aylık hale dönüştürülmüş verilerden oluşmaktadır ve 2005:Ç3 ile 2017:Ç3 arasında kapsamaktadır. Öngörü değerlendirmesi ise 2012:Ç3 ile 2017:Ç3 arası için yapılmıştır. Öngörü performans ölçütü olarak sadece RMSE değil bunun yanında MAE, MAPE ve Theil U1 olmak üzere dört farklı ölçü kullanılmıştır. Bu ölçütler her zaman aynı sonucu vermedikleri için farklı ölçütleri kullanmak daha kapsamlı performans karşılaştırması yapmaya imkân sunmuştur.

Bu çalışmada ele alınan şimdi tahmin yöntemlerini karşılaştırmak için öncelikle iki farklı kapsama testi yapılmıştır. İlk olarak, seçilen bir yöntemin geriye kalan yöntemleri kapsayıp kapsamadığı test edilmiştir. Bu test sonuçlarında MIDAS ve U-MIDAS yöntemleri sonucu elde edilen öngörülerin bu iki model dışında kalan yöntemlerden elde edilen bilgileri kapsadığı bu yüzden öngöründe bir iyileşme sağlamak için MIDAS ve U-MIDAS öngörü sonuçları ile diğer yöntemlerden elde edilen öngörü sonuçlarını birleştirmeye gerek olmadığı sonucu elde edilmiştir. İkinci aşamada, yöntemler arasında biraz daha detaylı karşılaştırma yapmak için ikili kapsama testi yapılmıştır. İkili değerlendirmede MIDAS ve U-MIDAS yöntemlerinin diğer yöntemleri kapsadığı sonucu elde edilmiştir. Fakat burada ilgi çekici olan çok sayıda değişkenin

kullanıldığı DFM ve 3PRF yöntemlerinin AR(1) yöntemini kapsamadığı sonucunun elde edilmesidir. Bu sonuç, öngörüler arasında fark olmadığını test eden DM testi ile de bir nevi doğrulanmaktadır. DM test sonuçlarına göre MIDAS ve U-MIDAS yöntemleri ile elde edilen öngörü sonuçları diğer modellerle elde edilen öngörü sonuçları ile farklı iken DM istatistiği diğer modellerin öngörülerini arasında fark olmadığını sonucunu vermektedir.

İkili kapsama testlerinde her ne kadar MIDAS ve U-MIDAS yöntemlerinin birbirini kapsadığı sonucu elde edilsede öngörü performansı değerlendirme için kullanılan ölçülerden elde edilen sonuçlar tüm performans ölçülerine göre U-MIDAS yöntemi MIDAS yöntemi de dâhil diğer modellere açık ara üstünlük sağladığını göstermiştir. Tüm performans ölçülerine göre U-MIDAS yönteminin en iyi performans verdiği tespit edildikten sonra diğer yöntemler arasında sıralama yapılacak olursa MIDAS yönteminin diğer yöntemlere kıyasla tüm performans ölçülerine göre en iyi yöntem olduğu görülmektedir. Fakat diğer yöntemler arasında sıralama yapmak zorlaşmaktadır çünkü farklı performans ölçülerine göre farklı yöntemler iyi olarak seçilebilir. Örneğin RMSE'ye göre AR(1) modeli daha iyi iken Theil U1'e göre DFM modeli daha iyidir. Bu çalışmada için tüm performans ölçütlerine göre diğer modellere göre çok daha yüksek performans gösteren ve neredeyse sıfır hata ile öngöründe bulunan U-MIDAS tartışmasız en iyi öngörü modeli olarak belirlenmiştir. bu bulgudan yola çıkarak yakın zamanda Türkiye'nin GSYH için yapılacak öngörülerde U-MIDAS yönteminin mutlaka alternatif bir yöntem olarak kullanılması gerektiği söylenebilir.

## KAYNAKÇA

Aastveit, K. A., R. Gerdrup, K. R., and Jore, A. S., Thorsrud, L. A.,(2014) Nowcasting GDP in Real Time: A Density Combination Approach, *Journal of Business & Economic Statistics*, 32:1, 48-68.

Aastveit, K., Trovik,T., (2012). Nowcasting norwegian GDP: the role of asset prices in a small open economy. *Empirical Economics* 42 (1), 95–119.

Akkoyun, H. Ç., Günay, M.,(2012) Nowcasting Turkish GDP Growth, *Türkiye Cumhuriyet Merkez Bankası*, Working paper NO: 12/33.

Alvarez, R., M. Camacho, and G. Perez-Quiros (2012). Finite Sample Performance of Small Versus Large Scale Dynamic Factor Models. CEPR Discussion Papers No. DP8867.

Anderson, M.K., Reijher Ard H.J., (2015) “Nowcasting”, *Sveriges Riksbank Economic Review* 2015:1.

Antipa P., Barhoumi K. Brunhes-Lesage V., Darne O. (2012). Nowcasting German GDP: A comparison of bridge and factor models, *Journal of Policy Modeling* 34 (2012) 864-878.

Armstrong, J. S. (Ed.). (2001). *Principles of forecasting: a handbook for researchers and practitioners* (Vol. 30). Springer Science & Business Media.

Arnostova, K., Havrlant, D., Ruzicka, L.,Toth, P., 2011. Short-term forecasting of Czech Quarterly GDP Using Monthly Indicators. *Czech Journal of Economics and Finance* 61 (6), 566–583.

Baffigi A., Golinelli R. and Parigi G. (2004). Bridge model to forecast the euro area GDP. *International Journal of Forecasting*, 20, 447-460.

Banbura, M. and M. Modugno (2010). Maximum Likelihood Estimation of Factor Modelson Datasets with Arbitrary Pattern of Missing Data. Working Paper Series No. 1189,European Central Bank.

Banbura, M.,Giannone, D.,Reichlin,L.,(2010) “Nowcasting”, ECARES working paper 2010-021.

Barhoumi, K, Benk, S, Cristadoro, R, Reijer, A, Jakaitiene, A, Jelonek, P, Rua, A, Runstler, G, Ruth, K and Van Nieuwenhuyze, C., (2008), ‘Short-term forecasting of GDP using large monthly datasets’, European Central Bank Occasional Paper No. 84.

Bell, V., Co L. W., Stone, S., Wallis., (2014), Nowcasting UK GDP growth, Quarterly Bulletin 2014:Q1.

Brockwell, J. B., Davis, R.A. (2002). *Introduction to time series and forecasting*. Springer, New York.

Castle, J. L., Hendry, D. F., & Kitov, O. I. (2013). Forecasting and nowcasting macroeconomic variables: A methodological overview. *Economics Series Working Paper. University of Oxford, Department of Economics*.

Charpin, F., MAzzi, G.L., (2016). Combined Forecasting Methods. *Handbook on Rapid Estimates*.

Chong, Y. Y., & Hendry, D. F. (1986). Econometric evaluation of linear macroeconomic models. *The Review of Economic Studies*, 53(4), 671-690.

Clements, M. P., Galvão, A. B. (2008). Macroeconomic forecasting with mixed-frequency data: Forecasting output growth in the United States. *Journal of Business & Economic Statistics*, 26(4), 546-554.

D’Agostino, A., McQuinn, K., O’Brien, D., 2008. Now-casting Irish GDP. Research Technical Papers 9/RT/08, Central Bank & Financial Services Authority of Ireland (CBFSAI).

Diebold, F.X. and R.S. Mariano (1995). Comparing predictive accuracy. *Journal of Business and Economic Statistics*, 13, 253–63.

Doğan, B. Ş., & Midiliç, M. (2016). Forecasting Turkish real GDP growth in a data-rich environment. *Empirical Economics*, 1-29.

Doz, C., Giannone, D., & Reichlin, L. (2012). A quasi–maximum likelihood approach for large, approximate dynamic factor models. *Review of economics and statistics*, 94(4), 1014-1024.

Ediger, V. Ş., Akar, S. (2007). ARIMA forecasting of primary energy demand by fuel in Turkey. *Energy Policy*, 35, 1701-1708.

Enders, W., (2010). *Applied Econometric Time Series*. 3th Edition, John Wiley&Sons,

Ermişoğlu, E., Akçelik, Y., Oduncu, A., (2013), Nowcasting GDP growth with credit data: Evidence from an emerging market economy, *Borsa \_Istanbul Review* 13, 93-98.

Foroni, C. and M. Marcellino (2013). A survey of econometric methods for mixed frequency data. *Norges Bank Working Paper* 2013/06.

Foroni, C., and M. Marcellino (2012): "A Comparison of Mixed Frequency Approaches for Modelling Euro Area Macroeconomic Variables", *EUI ECO Working Papers*, 2012/07.

Foroni, C., M. Marcellino, and C. Schumacher (2012): "U-MIDAS: MIDAS regressions with unrestricted lag polynomials", *CEPR Discussion Papers*, 8828.

Foroni, C., Marcellino M., (2013) "A Survey of Econometric Methods For Mixed Frequency Data" Working Paper Norges Bank Research.

Foroni, C., Marcellino, M., 2016 "A Survey of Econometric Methods for Mixed-Frequency Data", *Handbook on Rapid Estimates*, Draft For Global Consultation, 237-272.

Foroni, C., Marcellino, M., Schumacher, C., 2011, "U-MIDAS: MIDAS regressions with unrestricted lag polynomials", *Discussion Paper Series 1: Economic Studies* No 35/2011.

Foroni, M., Marcellino, M., (2014) A Comparison Of Mixed Frequency Approaches For Nowcasting Euro Area Macroeconomic Aggregates, *International Journal of Forecasting* 30, 554–568.

Franta, M., Havrlant, D., & Rusnák, M. (2016). Forecasting Czech GDP Using Mixed-Frequency Data Models. *Journal of Business Cycle Research*, 12(2), 165-185.

Ghysels, E. A. Sinko and R. Valkanov (2007): "MIDAS Regressions: Further Results and New Directions", *Econometric Reviews*, vol. 26, pp. 53-90.

Ghysels, E., and R. Valkanov (2006): "Linear time series processes with mixed data Sampling and MIDAS regressions models," *mimeo*, Chapel Hill, N.C.

Ghysels, E., P. Santa-Clara, and R. Valkanov (2004): “The MIDAS touch: MIXed DATA Sampling regression models,” *mimeo*, Chapel Hill, N.C.

Ghysels, E., Santa-Clara, P., Valkanov, R. (2005), There is a risk-return after all, *Journal of Financial Economics* 76, 509-548.

Giannone, D., L. Reichlin, and D. Small (2008) “Nowcasting: The real-time informational content of macroeconomic data,” *Journal of Monetary Economics*, 55(4), 665-676.

Giannone, D., Reichlin, L., & Sala, L. (2004). Monetary policy in real time. *NBER macroeconomics annual*, 19, 161-200.

Golinelli R. and Parigi G. (2007). The use of monthly indicators to forecast quarterly GDP in the short run: An application to the G7 countries. *Journal of Forecasting*, 26, 77-94.

Hepenstrick, C., and Marcellino, M., 2016,”Forecasting with Large Unbalanced Datasets: The Mixed-Frequency Three-Pass Regression Filter”, SNB Working Papers,4/2016

Jansen W.J., Jin, X., Winter, J. M., (2016) Forecasting and nowcasting real GDP: Comparing statistical models and subjective forecasts, *International Journal of Forecasting* 32, 411–436.

Kelly, B., Pruitt, S.,(2015) “The Three-Pass Regression Filter: A New Approach To Forecasting Using Many Predictors” *Journal of Econometrics* 186 (2015) 294–316.

Kennedy, P. (2008). *A guide to econometrics*. Blackwell Publishing 6th ed.

Kumar, U.,Jain, V.K. (2010). ARIMA forecasting of ambientairpollutants. *StochEnvironRes Risk Assess*, 24, 751-760.

Kuzin, V., Marcellino, M., & Schumacher, C. (2011). MIDAS vs. mixedfrequency VAR: nowcasting GDP in the Euro area. *International Journal of Forecasting*, 27, 529–542.

Kuzin, V., Marcellino, M., & Schumacher, C. (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.

Lamprou, D. (2015). Nowcasting GDP in Greece: A note on forecasting improvements from the use of bridge models. *South-Eastern Europe Journal of Economics*, 1 (2015) 85-100.

Liebermann, J. (2012). Real-time forecasting in a data-rich environment. Research Technical Papers 07/RT/12. Central Bank of Ireland.

Liebermann, L.. 2014, Real-Time Nowcasting of GDP:A Factor Model vs. Professional Forecasters, *Oxford Bulletin Of Economics And Statistics*, 76, 6 (2014) 0305–9049,doi: 10.1111/obes.12047.

Mariano, R. S. (2004) Testing Forecast Accuracy. In M. P. Clements and D. F. Hendry (eds), *A Companion to Economic Forecasting*. Oxford: Blackwell, 284-98.

Mariano, R.S. and Tse, Y-K., 2008, “Econometric Forecasting And High-Frequency Data Analysis”, *Lecture Notes Series*, Institute for Mathematical Sciences, National University of Singapore, Vol 13.

Matheson,T.D., 2010.An Analysis of the Informational Content of New Zealand data releases: the Importance of Business Opinion Surveys. *Economic Modelling* 27 (1), 304–314.

Mitchell, J. (2009). Where are we now? The UK recession and nowcasting GDP growth using statistical models. *National Institute Economic Review*, **209**, 60–69.

Montgomery, D. C., Jennings, C. L., & Kulahci, M. (2015). *Introduction to time series analysis and forecasting*. John Wiley & Sons.

Modugno, M., Soybilgen, B., & Yazgan, E. (2016). Nowcasting Turkish GDP and news decomposition. *International Journal of Forecasting*, 32(4), 1369-1384.

Peter, T. (2017). Nowcasting Slovak GDP by a Small Dynamic Factor Model. *Ekonomický časopis (Journal of Economics)*, 65(2).

Porshakov, A.,Deryugina, E.,Ponomarenko,A.,Sinyakov, A.,(2015), Nowcasting and Short-Term Forecasting of Russian GDP with a Dynamic Factor Model,Bank of Russia Working Paper Series , No. 2/March ,2015.

Runstler, G., K. Barhoumi, S. Benk, R. Cristadoro, A. Den Reijer, A. Jakaitiene, P. Jelonek, A. Rua, K. Ruth, and C. Van Nieuwenhuyze (2009). Short-term forecasting of GDP using large datasets: a pseudo real-time forecast evaluation exercise. *Journal of Forecasting* 28 (7), 595-611.

Schumacher, C., (2016), A Comparison of MIDAS and Bridge Equations, *International Journal of Forecasting* 32, 257–270.

Sevüktekin, M. & Çınar, M. (2014). *Ekonometrik Zaman Serileri Analizi*. 4. Baskı, Dora Yayıncılık, Bursa.

Shumway, R.H., Stoffer, D.S. (2006). *Time series analysis and its applications—with R examples*. Springer Science+Business Media, LLC.

Silverstovs, B., Kholodilin, K.A., 2012. Assessing The Real-Time Informational Content Of Macroeconomic Data Releases For Now-/Forecasting GDP: Evidence for Switzerland. *Journal of Economics and Statistics/Jahrbücher für Nationalökonomie und Statistik* 232 (4), 429–444.

Timmermann, A. (2006). Forecast combinations. *Handbook of economic forecasting, 1*, 135-196.

Wohlrabe, K., 2008, *Forecasting with Mixed-frequency Time Series Models*, Yayınlanmamış Doktora Tezi, Münih Üniversitesi.

Woschnagg, E. & Cıpan, J. (2004). Evaluating forecast accuracy. *University of Vienna, Department of Economics*.

Yiu, M.S., Chow, K.K., 2010. Nowcasting Chinese GDP: information content of economic and financial data. *China Economic Journal* 3 (3), 223–240.