

## ENFLASYONİST KOŞULLARDA TÜRKİYE EKONOMİSİNE İLİŞKİN PARA ARZI TAHMİNİ

### FORECASTING MONEY SUPPLY GROWTH IN TURKEY UNDER INFLATIONARY CONDITIONS

Ünal ERYILMAZ

Kamu Gözetimi Kurumu

[unaleryilmaz@yahoo.com](mailto:unaleryilmaz@yahoo.com)

ORCID: 0000-0002-9056-4963

#### ÖZ

Para arzı artışı, faiz oranları ve harcama/gelir büyüklükleri arasındaki ilişkiyi anlamak, merkez bankaları ve politika yapımcılar için önemli bir konudur. Para politikasının isabeti ve etkinliği parasal büyüklüklerdeki değişimler ile mevcut ve gelecekteki harcama/gelir ve enflasyonun hareketlerinin doğru yorumlanmasına bağlıdır. Para politikalarının temel amacı enflasyonu kontrol etmek olan merkez bankası, para ve kredi arzının büyüme oranını etkileyerek, ekonomideki mal ve hizmetlere yapılan toplam harcamalara müdahale edebilmektedir. Bu çalışmada, Merkez Bankası açısından hem bir ara hedef hem de bir bilgi değişkeni olan para arzı toplamlarından reel M2 serisinin ex-post öngörüsü ve ayrıca Reel M2 ile Sanayi Üretimi arasındaki ilişki incelenmiştir. Bu çerçevede, zaman serisi analizi ile bazı öngörü modelleri oluşturularak söz konusu modellerden elde edilen sonuçlar tartışılmıştır. MA(1) ve ARMA(0,0) kullanarak RM2'nin öngörülmesi makul sonuçlar vermiştir. Ayrıca, çeşitli VAR modelleri kullanılarak sanayi üretimi (dLY) ve reel para arzı (dlrM2) birlikte belirlenmiştir. En iyi VAR modeli, içsel değişkenler olan dLY ve dlrM2'in gecikmeli değerlerini içermektedir. Granger Nedensellik Testi, RM2'nin Y'ye neden olmadığını ancak Y'nin RM2'ye neden olduğunu göstermektedir. Bu sonuç, Merkez Bankasının ekonomik aktivite seviyesine bakarak para arzının büyüklüğünü belirlediğini göstermektedir. Örneğin yaz aylarında ekonomi daha yoğun faaliyet içermektedir (turizm, ihracat, ithalat) ve Merkez Bankası ekonomik aktiviteye göre para arzını artırmaktadır.

#### ABSTRACT

Understanding the relationship between money supply growth, interest rates and spending/income volumes is an important issue for central banks and policy makers. The accuracy and effectiveness of monetary policy depends on the correct interpretation of changes in monetary aggregates, current and future expenditure/income and inflation movements. The central bank, whose main objective of monetary policies is to control inflation, can intervene in the total expenditures on goods and services in the economy by affecting the growth rate of money and credit supply. In this study, the ex-post prediction of the real M2 series and also the relationship between Real M2 and Industrial Production are examined. In this framework, some forecast models were formed and discussed. Estimating RM2 using MA(1) and ARMA(0,0) yield reasonable results. In addition, industrial production (dLY) and real money supply (dlrM2) were determined together using various VAR models. The best VAR model includes the lagged values of the endogenous variables dLY and dlrM2. The Granger Causality Test shows that RM2 does not cause Y, but Y does cause RM2. This result shows that the Central Bank determines the size of the money supply by looking at the level of economic activity.

**Geliş Tarihi:**  
06.09.2022

**Kabul Tarihi:**  
08.11.2022

**Yayın Tarihi:**  
30.12.2022

**Anahtar Kelimeler**  
Para Arzı,  
Merkez Bankası,  
Para Politikası,  
ARMA,  
VAR

**Keywords**  
Money Supply,  
Central Bank,  
Monetary Policy,  
ARMA,  
VAR

**DOI:** <https://doi.org/10.30783/newsobilen.1171796>

**Atf/Cite as:** Eryılmaz, Ü. (2022). Enflasyonist koşullarda Türkiye ekonomisine ilişkin para arzı tahmini. *Neşehir Hacı Bektaş Veli Üniversitesi SBE Dergisi*, 12(4), 2271-2289.

## Giriş

Para arzı artışı, faiz oranları ve harcama/gelir büyüklükleri arasındaki ilişkiyi anlamak, merkez bankaları ve politika yapımcılar için önemli bir konudur. Para politikasının isabeti ve etkinliği parasal büyüklüklerdeki değişimler ile mevcut ve gelecekteki harcama/gelir ve enflasyonun hareketlerinin doğru yorumlanmasına bağlıdır. Para arzının iki potansiyel rolü olan ara hedef ve bilgi değişkeni işlevleri hem politika yapımında hem de para politikası araştırmalarında önemli bir konu olarak öne çıkmaktadır. Merkez bankaları para politikası uygulamalarında faiz oranı ve diğer bazı değişkenlerle birlikte para arzını da ara hedef olarak kullanır. Bu nedenle, para arzının güvenilir bir ara hedef olabilmesi ve politika araçlarını uygulayarak para arzı değerlerini etkin bir biçimde kontrol edebilmesi için, para ve politika hedef değişkenleri (gelir veya fiyatlar gibi) arasında istikrarlı bir uzun dönemli ilişki gereklidir. Öte yandan, para arzındaki hareketler, gelir ve fiyat seviyelerindeki değişimlere ilişkin güvenilir tahmin edici bilgiler ve sinyaller taşıyabileceğinden, merkez bankaları için faydalı bir rehber görevi görebilmektedir (Miyao, 2004). Ancak para-gelir nedenselliği olarak adlandırılan (Granger nedenselliği), parasal büyüklükler ile gelir düzeyi arasındaki nedensellik ilişkisi, birçok araştırmanın çelişkili sonuçlar göstermesi nedeniyle literatürde hala tartışılan bir konudur (Stock ve Watson, 1989).

M2 gibi para arzı göstergeleri, belirli koşullarda üretim düzeyi gibi makroekonomik değişkenlerle ilgili öngörü sağlayabilmektedir. Bununla birlikte, hangi parasal göstergenin para politikası için hedef değişken olarak daha uygun olacağı sorusu, ampirik olarak nedensellik ilişkilerinin incelenmesini gerektiren bir konudur. Geniş tanımlı para arzı toplamlarındaki genişlemeler enflasyon oranının iyi bir öncü göstergesidir. Para talebinin istikrarlı olması durumunda para arzındaki büyümenin ancak enflasyona yol açacağını ileri süren ekonomistlere göre para arzı, enflasyonu kontrol etmek için önemli bir politika aracıdır (Friedman, 1970).

Merkez bankaları, faiz oranları üzerindeki etkileri yoluyla dolaylı olarak para arzının büyüme oranını da kontrol eder. Faiz oranları yükseldiğinde, tüketiciler ve işletmeler daha az para tutar, daha az borç alır ya da kredi çeker ve mevcut kredileri geri öder. Bu ise, M1 ve diğer geniş parasal büyüklüklerin büyüme oranında bir düşüşe yol açar. Para politikalarının temel amacı enflasyonu kontrol etmek olan merkez bankaları, para ve kredi arzının büyüme oranını etkileyerek, ekonomideki mal ve hizmetlere yapılan toplam harcamalara müdahale edebilmektedir. Söz konusu para politikası araçsallığı ve aktarım mekanizmalarının işleyişi konusunda Çavuşoğlu (2003), para arzının yüksek enflasyon ve bütçe açıklarına eşlik etmesinin bir sonucu olarak, kredi ve para arzının ekonomide içsel olarak genişlediğini ortaya koymuştur.

Para arzına ilişkin konular her zaman ekonomi literatürünün yaygın tartışma alanlarından biri olmuştur. Para arzının içselliği (Chappell ve Peel, 1979; Gavin ve Kydland, 1999), optimal para arzı (Stemp, 1993), para arzı ile faiz oranı (Evans ve Honkapohja, 2003), sermaye piyasaları (Singh, 1993), enflasyon (Prasad, 1968) ve büyüme ilişkisi (Chang ve ark., 2009), para stoku hedeflemesi (Asako ve Wagner, 1992; Lane, 1985; Mercenier ve Sekkat, 1988), para arzının istikrarı ve tahmini (Bagshaw ve Gavin, 1983; Koenig, 1996; Lombra ve Kaufman, 1984) literatürde bu para arzına ilişkin tartışma konularından sadece birkaçıdır. Bu çalışma, bir bilgi değişkeni olarak para arzının rolüne odaklanmakta ve reel M2 serisinin ex-post öngörüsünü yapmayı ve ayrıca reel M2 ile sanayi üretimi (Y) arasındaki ilişkiyi incelemeyi amaçlamaktadır. Bu çerçevede, zaman serisi analizi ile bazı öngörü modellerini kullanarak söz konusu modellerin özellikleri de araştırılmıştır.

## Veri Seti ve Yöntem


Çalışmada kullanılan orijinal zaman serileri mevsimsellik etkileri taşımaktadır. Bu nedenle çalışmada ilk olarak mevsimsellikten arındırılmamış RM2 ve Y serileri kullanılmıştır. Ele alınan bazı modellerde zaman trendi ve mevsimsel değişkenler ile gecikmeli değişkenler de dâhil edilmiştir. T.C. Merkez Bankası veri servisinden alınan orijinal veriler mevsimsellikten arındırılmamış, 1987:01-2004:11 dönemine ait 215 gözleme ait aylık ortalama serilerdir. ARMA ve VAR modellerinde veri setinin son 10 gözlemi dışında hepsi kullanılacak ve SIC değerine göre seçilecek en iyi ARMA Modelini kullanarak son 10 gözlem öngörülenecektir. Parasal toplamlara ilişkin veriler Türkiye Cumhuriyet Merkez Bankası (TCMB) bilançosundan alınmıştır. Veriler TCMB'nin [www.tcmb.gov.tr](http://www.tcmb.gov.tr) adresindeki internet sitesinde yayınlanmaktadır.

Çalışmada temel olarak, çalışmanın amaç ve kapsamı bakımından ampirik olarak en uygun para tanımı olan reel M2 serisi kullanılacaktır. M2; M1 (piyasada dolaşımdaki nakit para ve bankalardaki yerli ve yabancı para cinsinden vadesiz mevduat) ve bankalardaki yerli ve yabancı para cinsinden vadeli mevduatları içeren daha geniş bir para tanımıdır. Değişkenlerin nominal değerleri, geçmiş yıllardaki yüksek enflasyon, verilerdeki

mevsimsellik ve istikrarsızlık dikkate alındığında, değişkenlerdeki büyüme oranlarına odaklandığımız için RM2 ve Y serilerinin logaritmalarının (büyüme oranları) birinci farkları kullanılmıştır. İlk adım olarak, serilerin durağanlığını kontrol etmek için değişkenlerin her biri için birim kök testleri uygulanmıştır. Optimum gecikme uzunluğu Schwarz Bilgi Kriterine göre belirlenmiştir. Ardından, serileri tahmin etmek için en iyi ARMA modeli seçilmiş ve 2004:02-2004:11 dönemi için öngörü regresyonlarında M2'nin tahmin edilen içeriği incelenmiştir. Tahmin ve öngörü özelliklerini görmek için çeşitli testler yapılmış ve ayrıca bazı VAR modelleri çalıştırılmıştır.

### RM2 Serisinin Modellenmesi

Şekil 1'de görüldüğü gibi, reel M2 serisi hem trend hem de mevsimsellik sergilemektedir. Seri, maksimum değerine Aralık ayında, minimum değerine Ocak ayında ulaşmakta, Temmuz ayında ise hafif bir artış göstermektedir. 1994 ve 2001 yılları arasındaki yükseliş eğilimi, esas olarak devalüasyon ve yüksek enflasyonlu ekonomik krizden kaynaklanmaktadır. Bilindiği gibi, Türkiye ekonomisinde 2001-2003 döneminde bir durgunluk yaşandı ve ardından 2004 yılında %10 GSYİH büyümesi ile ekonomik patlama dönemi başladı.




Şekil 1. Düzey Serisi Olarak RM2

### RM2 Düzey (Level) Serisi

#### RM2 Normallik Testi İçin Tanımlayıcı İstatistikler

Şekil 2'deki histogramdan RM2 serisinin normal dağılmadığı görülmektedir. Serinin iki zirvesi var. Nitekim serinin normal dağıldığına dair sıfır hipotezi altında, Jarque-Bera test istatistiği için  $p$  değeri %5 olan anlamlılık seviyesinden küçük olduğu için sıfır hipotezi reddedilir. Bu nedenle seriler normal dağılım göstermediği sabittir.



Şekil 2. RM2 Normallik Testi

### Reel M2'de Birim Kök Testi

Durağan bir zaman serisi, kesme noktasında veya trendde yapısal kırılmalar olduğunda durağan değilmiş gibi görünebilir (Nelson ve Plosser, 1982; Peron, 1989). Böyle bir durumda birim kök testleri, düşük güce yol açan yapısal kırılmaları dikkate almadığımızda, sıfır hipotezinin yanlış şekilde reddedilmemesine yol açar. Nitekim yapısal değişim durumunda Dickey-Fuller (DF)'in gücü düşük olduğundan, DF istatistiklerinin birim


kök gösterdiği durumlarda KPSS (Kwiatkowski–Phillips–Schmidt–Shin) testi kullanılır (Kwiatkowski, 1992). Test sonuçları Tablo 1'de verilmiştir.

**Tablo 1.** RM2'de Birim Kök İçin DF-GLS Testi ve KPSS Testi

(a) DF-GLS Testi					(b) KPSS Testi				
Sıfır Hipotezi: RM2'de birim kök var					Sıfır Hipotezi: RM2 durağan				
Dışsal: Sabit					Dışsal: Sabit				
Gecikme Uzunluğu: 3 (AIC, MAXLAG=8'e dayalı otomatik)					Bant genişliği: 3 (Bartlett kernel kullanan Newey-West)				
t- İstat.					LM-İstat.				
Elliott-Rothenberg-Stock DF-GLS test istatistiği					Kwiatkowski-Phillips-Schmidt-Shin test istatistiği				
-0.84659					0.650619				
Test kritik değerleri:					Asimptotik kritik değerler:				
1% düzey					1% düzey				
5% düzey					5% düzey				
10% düzey					10% düzey				
-2.66936					0.739000				
-1.95641					0.463000				
-1.6085					0.347000				
GLS Detrend Artıklar Üzerine DF-GLS Test Denklemi					Artık varyansı (düzeltmesiz)				
Bağımlı değişken: D(GLSRESID)					803.7616				
Yöntem: En az kareler					HAC düzeltilmiş varyans (Bartlett kernel)				
Örneklem: 2003:01 2004:11					2829.731				
Gözlem sayısı: 23					KPSS Test İstatistiği				
Değişken					Bağımlı Değişken: RM2				
Katsayı					Yöntem: En az kareler				
Std. Hata					Örneklem: 2003:01 2004:11				
t-İstat.					Gözlem sayısı: 23				
Olasılık					KPSS Test İstatistiği				
GLSRESID(-1)					Değişken				
-0.041236					Katsayı				
0.048708					Std. Hata				
0.928862					t-İstat.				
0.3646					Olasılık				
D(GLSRESID(-1))					C				
0.190590					215.6763				
0.211536					6.044387				
0.696938					35.68207				
0.4943					0.0000				
D(GLSRESID(-2))					R-kare				
0.425963					0.000000				
0.214115					Ort. bağımlı var.				
1.989415					215.6763				
0.0612					28.98786				
R-kare					Adj. R-kare				
0.075807					0.070118				
Ort. bağımlı var.					S.S. bağımlı var.				
2.722615					5.515566				
Adj. R-kare					Regresyon S.H.				
-0.070118					5.705661				
S.S. bağımlı var.					Akaike bilgi kriteri				
5.515566					6.477566				
Regresyon S.H.					Kareler topl. artışı				
5.705661					618.5368				
Akaike bilgi kriteri					Schwarz kriteri				
6.477566					1.773963				
Kareler topl. artışı					Log olasılık				
618.5368					-70.49201				
Schwarz kriteri					Durbin-Watson İstat.				
6.675043					1.773963				
Log olasılık					R-kare				
-70.49201					0.000000				
Durbin-Watson İstat.					Adj. R-kare				
1.773963					0.000000				
R-kare					Regresyon S.H.				
0.000000					28.98786				
Ort. bağımlı var.					Akaike bilgi kriteri				
215.6763					9.614136				
28.98786					Kareler topl. artışı				
Adj. R-kare					Log olasılık				
0.000000					-109.5626				
S.S. bağımlı var.					Durbin-Watson İstat.				
28.98786					0.043059				
Regresyon S.H.					R-kare				
28.98786					0.000000				
Akaike bilgi kriteri					Adj. R-kare				
9.614136					0.000000				
Kareler topl. artışı					S.S. bağımlı var.				
18486.52					28.98786				
Schwarz kriteri					Regresyon S.H.				
9.663506					28.98786				
Log olasılık					Akaike bilgi kriteri				
-109.5626					9.614136				
Durbin-Watson İstat.					Kareler topl. artışı				
0.043059					18486.52				
R-kare					Schwarz kriteri				
0.000000					9.663506				
Ort. bağımlı var.					Log olasılık				
215.6763					-109.5626				
28.98786					Durbin-Watson İstat.				
Adj. R-kare					0.043059				
0.000000					R-kare				
S.S. bağımlı var.					0.000000				
28.98786					Ort. bağımlı var.				
Regresyon S.H.					215.6763				
28.98786					28.98786				
Akaike bilgi kriteri					Adj. R-kare				
9.614136					0.000000				
Kareler topl. artışı					S.S. bağımlı var.				
18486.52					28.98786				
Schwarz kriteri					Regresyon S.H.				
9.663506					28.98786				
Log olasılık					Akaike bilgi kriteri				
-109.5626					9.614136				
Durbin-Watson İstat.					Kareler topl. artışı				
0.043059					18486.52				

Durağanlık sıfır hipotezi altında KPSS testi için LM istatistiği 0.651'dir ve %1, %5 ve %10'daki kritik değerler sırasıyla 0.739, 0.463, 0.347'dir. %5 ve %10 seviyelerinde, LM test istatistiği kritik değerlerden büyüktür, bu nedenle RM2 serisi durağan olmadığı için sıfır hipotezi reddedilir (Ancak dikkat edilirse, %1 seviyesinde test istatistiği anlamlıdır ve sıfır hipotezi reddedilemez).

Dickey-Fuller GLS testi için, t-testi istatistiği -0.847'dir ve "durağan değil" sıfır hipotezi altında %1, %5 ve %10'daki kritik değerler sırasıyla -2.67, -1.95, -1.61'dir. DF-GLS testi istatistik değeri kritik değerlerden büyüktür, bu nedenle birim kök sıfır hipotezi reddedilemez. RM2 durağan değildir ve birim kökü vardır. Birim kökün varlığı, daha karmaşık istatistiksel modellerin benimsenmesi gerektiğini göstermektedir. Bu nedenle, log serisinin birinci dereceden farkı alınarak durağan büyüme oranı serisine dönüştürülür. Serinin log farkı Şekil 3'te gösterilmiştir. Çizgi grafiği, seriyi tarih/gözlem numarasına karşı gösterir. Burada trend olmasa da mevsimsellik örüntüsü görüldüğünden mevsimsellik için test yapılması gerekir.



Şekil 3. Log-Farklı Alınmış RM2 Serisi

### Mevsimsellik ve Trend Testi

Mevsimsellik testi için, 12 ay boyunca sadece mevsimsel kukla değişkenleri içeren özel bir model oluşturulmuştur. Mevsimsel kuklalar üzerinde dLRM2 bağımlı değişkeni regrese edildikten sonra, modeldeki her bir mevsimsel değişkenin anlamlılığı için t-testi kullanılır. Tablo 2'de regresyon ve test sonuçları gösterilmektedir. Bazı mevsimsel değişkenlerin (S1, S6, S7, S10 ve S12) katsayıları anlamlıdır. t-istatistiklerinden anlaşılacağı üzere seride bir miktar mevsimsellik bulunmaktadır. Söz konusu değişkenlerin katsayılarının t-istatistikleri 2'den büyük ve bu t-istatistikleri için p-değerleri %5'lik anlamlılık düzeyinden küçüktür. Ancak Tablo 2'deki test sonuçlarından da görüleceği gibi seride trend yoktur. Trend değişkeni, düşük t istatistiği ve yüksek p değeri ile istatistiksel olarak anlamlı değildir. F istatistiği de trend değişkeninin istatistiksel olarak önemsiz olduğunu göstermektedir.


Tablo 2. Mevsimselliği ve Trendi Test Etme Modelleri

(a) Mevsimselliği Test Etme Modeli					(b) Trendi Test Etme Modeli				
Bağımsız Değişken: DLRM2					Bağımsız Değişken: DLRM2				
Yöntem: En az kareler					Yöntem: En az kareler				
Örneklem (Uyarlı): 1987:02 2004:01					Örneklem (Uyarlı): 1987:02 2004:01				
Gözlem sayısı: 204, bitiş noktalarını ayarladıktan sonra					Gözlem sayısı: 204, bitiş noktalarını ayarladıktan sonra				
Değişken	Katsayı	Std. Hata	t-İstatistik	Olasılık	Değişken	Katsayı	Std. Hata	t-İstatistik	Olasılık
@SEAS(1)	-0.063900	0.009150	-6.983267	0.0000	C	-0.003585	0.006931	-0.517192	0.6056
@SEAS(2)	0.009618	0.009150	1.051132	0.2945	@TREND	6.28E-05	5.86E-05	1.071681	0.2851
@SEAS(3)	-0.003861	0.009150	-0.421916	0.6736	R-kare	0.005653	Ort. değişken var.		0.002856
@SEAS(4)	-0.009142	0.009150	-0.999079	0.3190	Adj. R-kare	0.000731	S.S. değişken var.		0.049335
@SEAS(5)	0.007917	0.009150	0.865207	0.3880	Regresyon	0.049317	Akaike bilgi kriteri		-3.171360
@SEAS(6)	0.042455	0.009150	4.639731	0.0000	S.H.				
@SEAS(7)	0.031112	0.009150	3.400095	0.0008	Kareler topl.	0.491288	Schwarz kriteri		-3.138829
@SEAS(8)	0.004013	0.009150	0.438518	0.6615	artığı				
@SEAS(9)	-0.012914	0.009150	-1.411291	0.1598	Log olasılık	325.4787	F-İstatistik		1.148499
@SEAS(10)	-0.023807	0.009150	-2.601719	0.0100	Durbin-				
@SEAS(11)	-0.017404	0.009150	-1.901974	0.0587	Watson İstat.	2.140325	Olas.(F-İstat.)		0.285142
@SEAS(12)	0.070183	0.009150	7.669907	0.0000					
R-kare	0.446865	Ort. değişken var.		0.002856					
Adj. R-kare	0.415175	S.S. değişken var.		0.049335					
Regresyon S.H.	0.037728	Akaike bilgi kriteri		-3.659804					
Kareler topl.	0.273294	Schwarz kriteri		-3.464621					
artığı									
Log olasılık	385.3000	Durbin-Watson İstat.		1.673706					

### Log-Farklı Alınmış RM2

#### dLRM2 İçin Tanımlayıcı İstatistikler - Normallik Testi

Şekil 4'teki histogramdan log-farklı serisi normal dağılım gösteriyor gibi görünse de Jarque-Bera testi bu görünümü desteklememektedir. Jarque-Bera testi, örneklemin çarpıklık ve basıklık değerlerine göre normal dağılımdan (çarpıklığı=0, basıklığı=3) ne ölçüde uzaklaştığını gösteren bir "goodness-of-fit" testidir (Jarque ve Bera, 1980; 1987).



Şekil 4. dLRM2 Normallik Testi

Normal dağılım sıfır hipotezi altında, Jarque-Bera test istatistiği için küçük olasılık değeri sıfır hipotezinin reddedilmesine yol açar. Bu nedenle, dLRM2 serisi için %5 düzeyinde normal dağılım hipotezi reddedilir. Buna ilave olarak, serinin çarpıklığı -0.34'tür, bu da sağ kuyruğun soldan daha uzun olduğunu gösterir. Ayrıca, basıklık değeri 5.755 olan tepeli bir dağılım söz konusudur.

### **dLRM2 Birim Kök Testi**

KPSS testi için LM istatistiği 0,235 ve durağanlık sıfır hipotezi altında %1, %5 ve %10'daki kritik değerler sırasıyla 0,739, 0,463 ve 0,347'dir. Tüm seviyelerde, LM test istatistiği kritik değerlerden daha küçüktür, bu nedenle sıfır hipotezi reddedilemez. dLRM2 durağan serisinin durağan olduğu sonucuna varırız.

Dickey-Fuller GLS testi için, t-istatistiği -4.158'dir ve "durağan değil" sıfır hipotezi altında %1, %5 ve %10'daki kritik değerler sırasıyla -2.67, -1.96 ve 1.61'dir. DF-GLS test istatistik değeri, tüm seviyelerde kritik değerlerden büyüktür; bu nedenle, birim kök sıfır hipotezi reddedilir. dLRM2 durağandır ve birim kökü yoktur. Birinci farkın alınması seriyi durağan hale getirmiştir. Test sonuçları Tablo 3'de verilmiştir.

Tablo 3. dLRM2 Üzerinde DF-GLS ve KPSS Birim Kök Testi

(a) DF-GLS Birim Kök Testi					(b) KPSS Birim Kök Testi				
Sıfır Hipotezi: DLRM2'de birim kök var					Sıfır Hipotezi: DLRM2 durağan				
Dışsal: Sabit					Dışsal: Sabit				
Gecikme uzunluğu: 0 (AIC, MAXLAG=8'e dayalı otomatik)					Bant Genişliği: 0 (Bartlett kernel kullanan Newey-West)				
t-İstat.					LM-İstat.				
Elliott-Rothenberg-Stock DF-GLS test istatistiği -4.158097					Kwiatkowski-Phillips-Schmidt-Shin test istatistiği 0.235017				
Test kritik değerleri:					Asimptotik kritik değerler:				
1% düzey -2.669359					1% düzey 0.739000				
5% düzey -1.956406					5% düzey 0.463000				
10% düzey -1.608495					10% düzey 0.347000				
GLS Detrend Artıklar üzerine DF-GLS Test Denklemi					Artık varyansı (düzeltmesiz) 0.000684				
Bağımlı değişken: D(GLSRESID)					HAC düzeltilmiş varyans (Bartlett kernel) 0.000684				
Yöntem: En az kareler					KPSS Test Denklemi				
Örneklem: 2003:01 2004:11					Bağımlı Değişken: DLRM2				
Dahil edilen gözlem sayısı: 23					Yöntem: En az kareler				
					Örneklem: 2003:01 2004:11				
					Dahil edilen gözlem sayısı: 23				
Değişken	Katsayı	Std. Hata	t-İstat.	Olas.	Değişken	Katsayı	Std. Hata	t-İstat.	Olasılık
GLSRESID(-1)	-0.887557	0.213453	-4.158097	0.0004	C	0.012477	0.005575	2.238011	0.0357
R-kare	0.438706	Ort. değişken var.	-0.001729		R-kare	0.000000	Ort. değişken var.	0.012477	
Adj. R-kare	0.438706	S.S. değişken var.	0.035970		Adj. R-kare	0.000000	S.S. değişken var.	0.026738	
Regresyon S.H.	0.026948	Akaike bilgi kriteri	-4.347277		Regresyon S.H.	0.026738	Akaike bilgi kriteri	-4.362964	
Kareler topl. artığı	0.015977	Schwarz kriteri	-4.297908		Kareler topl. artığı	0.015728	Schwarz kriteri	-4.313595	
Log olasılık	50.99369	Durbin-Watson istat.	1.657027		Log olasılık	51.17409	Durbin-Watson istat.	1.506871	

### **Arma Modellerini Kullanarak Tahmin ve Öngörü**

#### **Log-Farkı dLRM2 Serisi ile En İyi ARMA Modelini Tahmin Etme**

ARMA(0,0)'dan ARMA(2,2)'ye kadar, trendli ve trendsiz, farklı ARMA(p,q) modelleri tahmin edilmiştir. Hem trendli hem de trendsiz, ARMA(0,0) en küçük SIC değerine ve MA(1) ikinci en küçük SIC değerine sahiptir. Ancak modellerin geneline bakıldığında, trendsiz modellerin, trendli modellere göre daha küçük SIC

değerlerine sahip olduğu görülmektedir. Öte yandan, ARMA(0,0) modelini seçmek, sadece sabit (*constant*) üzerindeki regresyon olduğu için mantıklı değildir. Daha karmaşık bir modele ihtiyaç olduğundan, MA(1) modeli ikinci en iyi model olarak kullanılabilir. Bu nedenle, öngörü ve yorumlar için trendsiz durağan MA(1) modeli ve trendsiz ARMA(0,0) modeli seçilmiştir. (Ayrıca, serideki durumun farklı açılardan gözlemlenebilmesi için farkı alınmamış logRM2 serisi de kullanılmıştır. logRM2 serisi kullanıldığında, en iyi model SIC değeri en küçük olan AR(1) modelidir. ARMA(1,1) ikinci en küçük SIC değerine sahiptir. Ancak düzey lRM2 serisi birim köke sahip olduğu için durağan değildir. Bunun yanında, aynı ARMA modelleri mevsimsellikten arındırılmış serilerle de oluşturulmuştur. RM2 serisi Census X12 mevsimsel ayarlama yöntemini kullanılarak mevsimsel etkilerden arındırılmıştır. Ancak, mevsimsel kuklalar eklemeyen, bu yöntemin de ARMA(0,0)'ı en iyi model olarak verdiği görülmektedir.)

ARMA(0,0) modeli mevsimsel değişkenlerle birlikte aşağıdaki biçimde yazılabilir:

$$d\log(\text{RM2}) = \beta_0 + \sum_{i=2}^{12} \theta_{i-1} S_i + \varepsilon \quad (1)$$

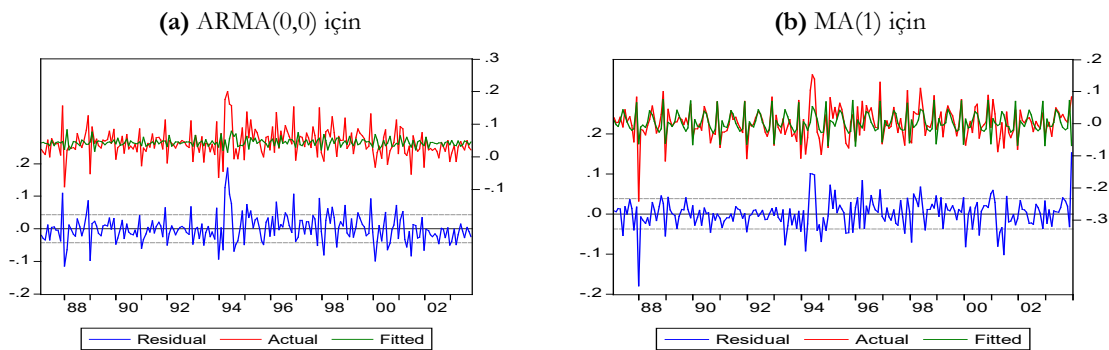
Mevsimsel değişkenli MA(1) modeli ise aşağıdaki biçimde yazılabilir:

$$d\log(\text{RM2}) = \beta_0 + \varepsilon_t + \beta_1 \varepsilon_{t-1} + \sum_{i=2}^{12} \theta_{i-1} S_i \quad (2)$$

Burada  $S_i$  mevsimsel kukla değişkenleri ve  $\varepsilon$  gözlemlenemeyen şokları temsil eder. Modellerde  $\beta_0$  sabiti bulunduğundan çoklu bağlantıdan kaçınmak için ilk mevsimsel kukla modellerden çıkarılmıştır.

Hem MA(1) hem de ARMA(0,0) modelleri, ters kökleri birim çemberin içinde olduğundan durağandır. Ancak, her iki modelin de tahmin sonuçları biraz zayıftır. ARMA(0,0) için  $R^2=0.45$  ve MA(1) için  $R^2=0.46$  olup bu değerler oldukça düşüktür. Modeller, RM2'deki değişimin sadece %45'ini açıklayabildikleri için parasal büyüme dinamiklerine iyi bir yaklaşım sağlamıyor gibi görünüyor. Ancak ARMA(0,0), yüksek  $t$  istatistikleri ve 0,05'ten düşük  $p$  değerleri ile anlamlı görünmektedir. Öte yandan, MA(1) modelinde ilk gecikmeli yenilik istatistiksel olarak önemsizdir. Bilindiği gibi,  $t$ -istatistiği büyüklük olarak 2'yi aşarsa, değişken katsayısının sıfır olmama olasılığı en az %95'tir. Analizdeki  $t$ -istatistikleri, mevsimsel değişkenlerin önemli olduğuna işaret etmektedir. Bu ise orijinal serideki mevsimselliği kanıtlayan bir başka göstergedir. MA(1) modeli, -0.11'lik (yani 1'den küçük) bir ters köke sahiptir, bu da modelin durağan olduğu anlamına gelir.  $F$  istatistiklerinin ARMA(0,0) için 14.1, MA(1) için 13.27 ve istatistiklerin  $p=0.000$  değerlerinin de 0.05'ten küçük olması, her iki modelin de bir bütün olarak dIRM2 tahmini için anlamlı olduğunu göstermektedir.

Her iki model de regresyon katsayılarının istatistiksel güvenilirliğini gösteren küçük standart sapmalara sahiptir. Standart hata ne kadar küçükse, katsayıya o kadar az istatistiksel gürültü etki eder. Sonuç olarak, dIRM2'yi öngörmek için hem ARMA(0,0) hem de MA(1) modellerinin kullanılması uygun olacaktır. Gerçek, kestirilen ve artık değerler Şekil 4'de gösterilmiştir. Şekiller, bağımlı değişken  $d\text{RM2}_{t-1}$ 'in ve bir adım ilerideki standartlaştırılmış artıklar  $\varepsilon_{t-1}$ 'in gerçek ve bir adım ilerideki uyumlu değerlerini resmetmektedir. Artık Şekillerinden, artıklar sıfır ortalamasının altında veya üzerinde ısrarla kalmaya devam etmediği için seri korelasyon olmadığını görebiliriz.



Şekil 4. ARMA(0,0) ve MA(1) İçin Gerçek, Kestirilen ve Artık Şekilleri

### Artıkların Korelogramı

Çoğu durumda, bir zaman serisinin grafiğinin görsel olarak incelenerek herhangi bir trend, mevsimsellik ya da kısa vadeli de olsa korelasyon örüntüsü olup olmadığına bakılarak söz konusu serinin rastgele olmadığını anlamak mümkündür (Chatfield ve Xing, 2019). Ancak, bilhassa görsel analiz yeterli olmadığı durumlarda korelogram, bir zaman serisindeki rastgeleliği kontrol etmek için yaygın olarak kullanılan bir araçtır. Bir zaman serisinin rastgelelik koşulunu sağlaması için bütün zaman gecikmeleri için otokorelasyonlar sıfıra yakın olmalıdır. Rastgelelik koşulunun ihlali temel bazı varsayımlarla ilişkili istatistiksel çıkarımları şüpheli kılar (Box ve Ljung, 2015).

Tablo 4'deki artık korelogramları, MA(1) ve ARMA(0,0) süreçlerinden artıkların otokorelasyon ve kısmi otokorelasyon fonksiyonlarını göstermektedir. Bu fonksiyonlar, serideki zamansal bağımlılık örüntüsünü karakterize eder. Eğer  $\tau_1$  sıfırdan farklı ise bu serinin birinci dereceden seri bağıntılı olduğu anlamına gelir. Burada hem ACF'ler hem de PACF'ler sıfıra oldukça yakındır. Hem ACF hem de PACF, bir miktar sönümlü salınım göstermektedir. Ancak sıfır hattı ile kesişmemekte ve düzenli biçimde bozulmamaktadır.  $\theta > 0$  olduğundan son dâhil edilen gecikmelerdeki katsayılar olan PACF'ler, sönümlü salınım şeklinde bir bozulma örüntüsüne sahiptir.

**Tablo 4.** ARMA(0,0) ve MA(1) İçin Artık Korelogram

(a) ARMA(0,0)							(b) MA(1)						
Örneklem: 1987:02 2004:01 Dahil edilen gözlem sayısı: 204							Örneklem: 1987:02 2004:01 Dahil edilen gözlem sayısı: 204						
OKF	KOKF	OK	KOK	Q-İst.	Olas.	OKF	KOKF	OK	KOK	Q-İst.	Olas.		
. *	. *	1	0.122	0.122	3.1044	0.078	. .	. .	1	0.009	0.009	0.0184	
. *	. *	2	0.092	0.079	4.8801	0.087	. *	. *	2	0.087	0.087	1.5910	0.207
. .	. .	3	0.012	-0.008	4.9095	0.179	. .	. .	3	0.021	0.020	1.6849	0.431
* .	* .	4	-0.162	-0.174	10.445	0.034	* .	* .	4	-0.156	-0.165	6.7853	0.079
* .	. .	5	-0.085	-0.050	11.968	0.035	. .	. .	5	-0.058	-0.061	7.4977	0.112
* .	. .	6	-0.063	-0.019	12.811	0.046	* .	* .	6	-0.057	-0.028	8.1839	0.146
. .	. .	7	0.007	0.034	12.822	0.077	. .	. .	7	0.013	0.033	8.2174	0.223
. .	. .	8	0.020	-0.002	12.904	0.115	. .	. .	8	0.011	-0.004	8.2419	0.312
. *	. .	9	0.069	0.045	13.939	0.125	. .	. .	9	0.071	0.052	9.3151	0.316
. .	. .	10	-0.018	-0.053	14.010	0.173	. .	. .	10	-0.019	-0.040	9.3947	0.402
* .	* .	11	-0.073	-0.080	15.184	0.174	* .	* .	11	-0.078	-0.093	10.736	0.378
. .	* .	12	0.050	0.079	15.729	0.204	. .	. .	12	0.068	0.076	11.758	0.382
* .	* .	13	-0.079	-0.058	17.101	0.195	* .	* .	13	-0.094	-0.057	13.709	0.320
. *	* .	14	0.070	0.079	18.188	0.198	. .	. .	14	0.087	0.082	15.400	0.283
* .	* .	15	-0.069	-0.109	19.242	0.203	* .	* .	15	-0.080	-0.103	16.831	0.265
. .	. .	16	0.010	0.027	19.264	0.255	. .	. .	16	0.015	0.015	16.884	0.326
. .	. .	17	0.040	0.028	19.624	0.294	. .	. .	17	0.041	0.031	17.271	0.368
. .	. .	18	-0.004	0.013	19.627	0.354	. .	. .	18	-0.014	0.012	17.314	0.433
. .	. .	19	0.030	0.005	19.836	0.404	. .	. .	19	0.032	0.005	17.544	0.486
. .	. .	20	-0.007	-0.006	19.847	0.468	. .	. .	20	-0.012	-0.005	17.579	0.551
. .	. .	21	-0.003	-0.014	19.849	0.531	. .	. .	21	0.004	-0.009	17.583	0.615
. .	. .	22	-0.047	-0.038	20.363	0.560	. .	. .	22	-0.050	-0.044	18.165	0.639
. .	. .	23	0.021	0.047	20.466	0.614	. .	. .	23	0.028	0.044	18.351	0.685
. .	. .	24	-0.008	-0.010	20.480	0.669	. .	. .	24	-0.011	-0.008	18.378	0.737
. .	. .	25	0.020	0.036	20.577	0.716	. .	. .	25	0.017	0.036	18.446	0.781
. .	. .	26	0.041	-0.018	20.968	0.744	. .	. .	26	0.036	-0.020	18.758	0.809
. .	. .	27	0.004	0.029	20.972	0.788	. .	. .	27	0.003	0.035	18.760	0.846
. .	* .	28	-0.030	-0.063	21.193	0.817	. .	. .	28	-0.026	-0.056	18.926	0.873
* .	. .	29	-0.058	-0.026	21.989	0.821	. .	. .	29	-0.051	-0.031	19.563	0.880
. .	. .	30	-0.042	-0.020	22.418	0.838	. .	. .	30	-0.033	-0.023	19.833	0.898
. .	. .	31	0.001	0.028	22.418	0.869	. .	. .	31	-0.006	0.012	19.843	0.921
. .	. .	32	0.043	0.043	22.877	0.882	. .	. .	32	0.038	0.045	20.204	0.931
. .	. .	33	0.039	-0.002	23.253	0.896	. .	. .	33	0.027	-0.004	20.378	0.944
. .	. .	34	0.057	0.040	24.047	0.897	. .	. .	34	0.040	0.032	20.779	0.952
. *	. .	35	0.070	0.038	25.274	0.887	. *	. .	35	0.073	0.047	22.094	0.942
. .	. .	36	-0.044	-0.039	25.754	0.897	. .	. .	36	-0.048	-0.030	22.660	0.947




Kalıntılar arasında seri korelasyon yoksa, tüm gecikmelerde ACF ve PACF sıfır olmalı ve tüm Q istatistikleri, yüksek p değerleri ile istatistiksel olarak önemsiz olmalıdır.

Otokorelasyonlar,  $\pm 2 \div (\sqrt{T})$  olarak hesaplanan iki standart hata sınırı içinde olduğundan, yaklaşık %5 anlamlılık düzeyinde sıfırdan önemli ölçüde farklı değildir. Korelograma bakıldığında, ARMA(0,0)'dan gelen artıkların, 4., 5. ve 6. gözlemler dışında beyaz gürültü olduğu görülmektedir. Çünkü artıklar kendi otokorelasyonlarında (ACF) ve kısmi otokorelasyonlarında (PACF) standart hata bantlarını aşmamaktadır. Ancak 4., 5. ve 6. artıklar, artık bantlarını bir miktar aşmaktadır. MA(1) sürecinden gelen tüm artıklar beyaz gürültüdür ve Bartlett bantlarının içinde kalmaktadır. Aynı sonucu, beyaz gürültü sıfır hipotezi ile Ljung-Box Q İstatistiği kullanılarak da görülebilir. Sıfır hipotez,  $Y_t$  beyaz gürültüdür, otokorelasyonların sıfıra eşit olduğu anlamına gelir. Çalışmada kullanılan modellerde, p değerleri sıfırdan uzak ve 0,05'ten büyük olduğundan (ARMA(0,0)'daki 4., 5. ve 6. gözlemler hariç) Q istatistikleri anlamsızdır ve dolayısıyla MA(1) ve ARMA(0,0) modellerinde seri korelasyon bulunmamaktadır. Bu ise artıkların beyaz gürültü olduğunu gösterir.

### **Normallik Testi**

Normallik testi için Jarque-Bera istatistikleri de dâhil olmak üzere artıkların bir histogramını ve tanımlayıcı istatistikleri Şekil 5'te verilmektedir. Kalıntılar normal dağılıyorsa, histogramlar çan şeklinde olmalı ve Jarque-Bera istatistikleri anlamlı olmamalıdır.



Şekil 5. ARMA(0,0) ve MA(1) Üzerinde Normallik Testi

Ancak, Şekil 5'deki histogramlar simetrik görünmüyor. Ayrıca J-B test istatistiğine bakıldığında her iki model için de p değeri 0.000 olduğu için her iki model de normal dağılıma sahip değildir. Hem ARMA(0,0) hem de MA(1) modellerinde artık basıklığının 3'ten çok daha yüksek ve çarpıklığın sıfırdan uzak olması Jarque-Bera testinin normallik hipotezinin reddedilmesine neden oluyor. Genel olarak, normal dağılıma sahip olmayan artıklar, aykırı değerlerin varlığına veya modelin genel uyum eksikliğine işaret eder. Aslında dIRM2 serisinin grafiğinden de görüldüğü gibi seride bazı aykırı değerler vardır. Ancak, her ne kadar artıkların sağ kuyrukları biraz uzun olsa ve görece olarak toplu görünseler de, normal dağılımla iyi bir şekilde yaklaşılabilmeleri mümkün görünmektedir.

### **Mevsimsellik Testi**

ARMA(0,0) ve MA(1) modellerinin mevsimsellik testi için Wald Testi kullanılmıştır. LM (Lagrange multiplier) ve LR (likelihood-ratio) testleri ile birlikte, mevsimsellik testi için kullanılan yöntemlerden biri olan Wald testi, sıfır hipotezi altında asimptotik bir  $\chi^2$  dağılımına sahiptir ve istatistiksel olarak anlamlılığı belirlemek için söz konusu dağılım kullanılır (Martin vd. 2013; Engle, 1984). Tablo 5'de yer verilen test çıktılarından görüleceği üzere mevsimselliğin olmadığı sıfır hipotezi altında, hem Ki-kare istatistikleri hem de F istatistikleri için p olasılık değeri 0.000'dır ve bu 0.05 kritik değerinden düşüktür. Düşük olasılık değerleri, mevsimselliğin olmadığı (yani  $C(i)=0$ ) sıfır hipotezinin reddedildiğini gösterir. Bu nedenle, mevsimsel kukla değişkenler her iki modelde de istatistiksel olarak anlamlıdır.

**Tablo 5.** ARMA(0,0) ve MA(1) Üzerinde Mevsimsellik İçin Wald Testi

<b>(a) ARMA(0,0)</b>				<b>(b) MA(1)</b>			
Wald Testi:				Wald Testi:			
Ho: C(2)=C(3)=C(4)=C(5)=C(6)=C(7)=C(8)=C(9)=C(10)=C(11)=C(12)=0				Ho: C(2)=C(3)=C(4)=C(5)=C(6)=C(7)=C(8)=C(9)=C(10)=C(11)=C(12)=0			
Denklemler: ARMA00				Denklemler: ARMA01			
Test İstatistiği	Değer	df	Olasılık	Test İstatistiği	Değer	df	Olasılık
F-İstatistiği	14.10113	(11, 192)	0.0000	F- İstatistiği	15.46046	(11, 191)	0.0000
Ki-kare	155.1124	11	0.0000	Ki-kare	170.0650	11	0.0000
Sıfır Hipotez Özeti:				Sıfır Hipotez Özeti:			
Normalize Kısıtlar (= 0)	Değer	Std.Hata		Normalize Kısıtlar (= 0)	Değer	Std. Hata.	
C(2)	0.073518	0.012941		C(2)	0.074493	0.012274	
C(3)	0.060039	0.012941		C(3)	0.059989	0.012966	
C(4)	0.054758	0.012941		C(4)	0.054708	0.012966	
C(5)	0.071817	0.012941		C(5)	0.071767	0.012966	
C(6)	0.106355	0.012941		C(6)	0.106305	0.012966	
C(7)	0.095012	0.012941		C(7)	0.094962	0.012966	
C(8)	0.067912	0.012941		C(8)	0.067862	0.012966	
C(9)	0.050986	0.012941		C(9)	0.050936	0.012966	
C(10)	0.040093	0.012941		C(10)	0.040043	0.012966	
C(11)	0.046496	0.012941		C(11)	0.046446	0.012966	
C(12)	0.134082	0.012941		C(12)	0.134032	0.012208	
Katsayılar üzerindeki kısıtlar doğrusaldır				Katsayılar üzerindeki kısıtlar doğrusaldır.			

### Seri Korelasyon Testi

Doğrusal bir modelin hata serisinde otokorelasyon varsa, değişken katsayılarının en küçük kareler (OLS) yöntemiyle tahminleri verimsizdir ancak yansızdır. Ancak, bağımlı değişkenin gecikmeli değerlerinin regresör olarak yer aldığı bir denklemde, OLS tahminleri hem tutarsız hem de taraflıdır. Bu nedenle tahmin çalışması yapılan modellerde otokorelasyon testi yapılması önemlidir (Breusch, 1978). Bilhassa bağımlı değişkenin gecikmelerinin bağımsız değişkenler arasında bulunduğu durumlarda Lagrange Multiplier yaklaşımını benimseyen Breusch-Godfrey LM testi, Durbin-Watson ve Ljung-Box testlerinden daha güçlü ve geçerli sonuç verir. Sıfır hipotezi,  $k$  gecikme sayısına kadar seri korelasyonunun olmadığıdır (Godfrey, 1978). Ele aldığımız ARMA(0,0) ve MA(1) modelleri için Breusch-Godfrey LM testinin sıfır hipotezi, gecikme sayısı 2'ye kadar seri korelasyon olmadığıdır. Obs\*R-kare etiketli istatistik, sıfır hipotez için LM test istatistiğidir. Düşük olasılık değerleri, artıklarda seri korelasyonun varlığını gösterir. Bizim durumumuzda p değerleri 0.05'ten büyüktür. Bildiğimiz gibi, test artıklarda seri korelasyon gösteriyorsa, OLS standart hataları geçersizdir ve çıkarım için kullanılmamalıdır. Modellerimizde RM2 serisinin log farkını aldığımız için seri korelasyonu yoktur. Test çıktıları her iki model için Tablo 6'da gösterilmiştir.


**Tablo 6.** ARMA(0,0) ve MA(1) Üzerinde LM Seri Korelasyon Testi

<b>(a) ARMA(0,0)</b>					<b>(b) MA(1)</b>				
Breusch-Godfrey Serial Correlation LM Testi:					Breusch-Godfrey Serial Correlation LM Testi:				
F-istatistik	2.187098	Olasılık	0.115060		F- istatistik	0.956193	Olasılık	0.386205	
Obs*R-kare	4.590814	Olasılık	0.100720		Obs*R-kare	2.043484	Olasılık	0.359967	
Test Denklemleri:					Test Denklemleri:				
Bağımlı Değişken: RESID					Bağımlı Değişken: RESID				
Yöntem: En az kareler					Yöntem: En az kareler				
Değişken	Katsayı	Std. Hata	t-İstatistik	Olas.	Değişken	Katsayı	Std. Hata	t- İstatis.	Olas.
C	-7.46E-17	0.009094	-8.20E-15	1.0000	C	-3.17E-05	0.009169	-0.003458	0.9972
@SEAS(2)	0.000915	0.012880	0.071015	0.9435	@SEAS(2)	-0.000381	0.012286	-0.031006	0.9753
@SEAS(3)	0.000725	0.012879	0.056310	0.9552	@SEAS(3)	0.000795	0.012987	0.061180	0.9513
@SEAS(4)	6.90E-17	0.012861	5.37E-15	1.0000	@SEAS(4)	0.000499	0.012989	0.038409	0.9694
@SEAS(5)	7.50E-17	0.012861	5.83E-15	1.0000	@SEAS(5)	3.15E-05	0.012969	0.002427	0.9981
					@SEAS(6)	3.17E-05	0.012969	0.002447	0.9981


@SEAS(6)	9.03E-17	0.012861	7.02E-15	1.0000	@SEAS(7)	3.17E-05	0.012969	0.002445	0.9981
@SEAS(8)	8.20E-17	0.012861	6.38E-15	1.0000	@SEAS(8)	3.17E-05	0.012969	0.002445	0.9981
@SEAS(7)	7.07E-17	0.012861	5.50E-15	1.0000	@SEAS(9)	3.17E-05	0.012969	0.002445	0.9981
@SEAS(9)	7.65E-17	0.012861	5.95E-15	1.0000	@SEAS(10)	3.17E-05	0.012969	0.002445	0.9981
@SEAS(10)	7.53E-17	0.012861	5.85E-15	1.0000	@SEAS(11)	3.17E-05	0.012969	0.002445	0.9981
@SEAS(11)	6.94E-17	0.012861	5.40E-15	1.0000	@SEAS(12)	3.17E-05	0.012211	0.002596	0.9979
@SEAS(12)	7.51E-17	0.012861	5.84E-15	1.0000	MA(1)	3.100664	5.592910	0.554392	0.5800
RESID(-1)	0.121284	0.075916	1.597600	0.1118	RESID(-1)	-3.096761	5.599627	-0.553030	0.5809
RESID(-2)	0.082823	0.076064	1.088857	0.2776	RESID(-2)	0.451280	0.645534	0.699080	0.4854
R-kare	0.022504	Ort. bağımlı var	-5.71E-18		R-kare	0.010017	Ort. bağımlı var	-3.74E-06	
Adj. R-kare	-0.044377	S.S. bağımlı var	0.036692		Adj. R-kare	-0.063315	S.S. bağımlı var	0.036434	
Regresyon S.H.	0.037497	Akaike bilgi kriteri	-3.662957		Regresyon S.H.	0.037570	Akaike bilgi kriteri	-3.654528	
Kareler topl. artışı	0.267143	Schwarz kriteri	-3.435243		Kareler topl. artışı	0.266776	Schwarz kriteri	-3.410549	
Log olasılık	387.6217	F-istatistik	0.336477		Log olasılık	387.7619	F-istatistik	0.136599	
Durbin-Watson istat.	1.913154	Olasılık(F-istat.)	0.985415		Durbin-Watson istat.	1.899667	Olasılık(F-istat.)	0.999926	

### MA(1) ve ARMA (0,0) Modellerini Kullanarak Öngörü

Çalışmanın bu bölümünde, 2004:02 ve 2004:11 arası döneme ait dLRM2'yi öngörmek için MA(1) ve ARMA(0,0) modelleri kullanılmıştır (Şekil 6). MA(1) ve ARMA(0,0) modelleri kullanılarak yapılan öngörülerde küçük bir fark vardır. Şekil 7 ise dLRM2'nin geçmişini ve 2004 için 10 aylık bir öngörüyle gerçek değerlerle birlikte göstermektedir. Görsel yorumlamaya yardımcı olmak için sadece iki yıllık geçmiş veriler gösterilmiştir. Yapılan öngörülerin makul olduğu ve kullanılan modellerin, serinin davranışına hâkim olan örüntüyü yakaladığı görsel olarak görülebilmektedir.



Şekil 6. ARMA(0,0) ve MA(1) Kullanılarak dLRM2 için Öngörü Çıktısı



Şekil 7. ARMA(0,0) ve MA(1) Kullanılarak Üst ve Alt Sınırlı Öngörü ve Gerçek Veriler

dlog(RM2)'nin gerçek değerleri, tüm öngörü dönemi için öngörü aralığı içindedir. Gerçek veriler, üst ve alt sınırlar arasında ve öngörüyle hemen hemen aynı şekildedir. Ancak, öngörü döneminin ortasında yetersiz tahmin varken, dönemin başında ve sonunda aşırı tahmin vardır. Gerçek seri düşerken, öngörüler gerçek

serinin altındadır, ancak gerçek seri yükseldiğinde, öngörüler gerçek serinin üzerinde kalmaktadır. Bununla birlikte, görüldüğü gibi, kullanılan modeller yeterince iyi bir öngörü sağlamaktadır.

Öngörüler yapıldıktan sonra, serinin gözlemlenen gerçek değerlerine göre değerlendirilebilir. Ex post öngörüler yapıldığı için tahmin hataları hesaplanabilir ve bu hatalar öngörülen modelin kalitesi hakkında önemli bilgiler verir. Bu çalışmada da kullanılan Eviews programı, öngörülerin ex-post olması durumunda, değerlendirme istatistiklerini raporlamaktadır.

İyi bir öngörü elde etmek için, sapma ve varyans oranları küçük olmalı ve böylece sapmaların çoğu kovaryans oranlarında yoğunlaşmalıdır. Sapma, modeldeki sistematik hatanın bir göstergesidir. Bu nedenle, öngörü modellerinde sapmanın 0'a yakın olması umulur. Büyük bir sapma, öngörünün üzerinde veya altında sistematik bir hata olduğunu gösterir. Burada, her iki modelde de küçük bir sapma söz konusudur. Varyans, öngörülerin, öngörümü yapılacak değişkendeki değişkenlik derecesini tekrarlama yeteneğinin göstergesidir. Varyans oranı büyükse, gerçek seri çok fazla dalgalanırken, öngörülen seri o derecede dalgalanmamış demektir. Bu çalışmada kullanılan her iki modelde de dalgalanma oldukça küçüktür. Diğer yandan, kovaryans oranı öngörüdeki sistematik olmayan hatayı ölçer ve ne kadar büyük olursa o kadar iyidir, çünkü bu, hatanın çoğunun rastgele olaylardan kaynaklandığına ve kullanılan modelin gerçek serinin ortalamasını veya varyansını tekrarlamadaki yetersizliğinden kaynaklanmadığına işaret eder. İdeal olarak kovaryans oranı; sapma, varyans ve kovaryans oranlarının toplamı bire eşit olacak şekilde en yüksek eşitsizlik oranına sahip olmalıdır (Brooks ve Sotiris, 2010; Pindyck ve Rubinfeld 1991). Hem MA(1) hem de ARMA(0,0) modellerinde kovaryans oranı oldukça büyükken, sapma ve varyans oranı küçüktür. Bu nedenle, öngörülerin başarılı olduğunu söylemek mümkündür.

### ARCH Modelinin İncelenmesi

Ekonometrik modeller, rastgele terimin varyansının değişmediğini (homoskedastisite) varsayımıyla çalışır. Ancak, büyük (yüksek volatilité) ve küçük hataların (düşük volatilité) bir arada kümelenme eğiliminde seyrettiği, rastgele hatanın beklenen değerlerinin zamanla değişken olduğu koşullu varyans durumları için ARCH modelleri önerilmiştir. Bir zaman serisinde ARCH olup olmadığını anlamak için hata teriminin zamana göre varyansına bakılır. Yüksek volatilité dönemlerini daha yüksek volatilitenin ve düşük volatilité dönemlerini daha düşük volatilitenin izlemesi halinde ARCH örüntüsü söz konusudur (Enders, 2015; Engle, 1982). dlrM2'nin grafiğine bakıldığında ARCH örüntüsü görmüyoruz. Ayrıca, MA(1) ve ARMA(0,0) süreçlerinin artıklarında otoregresif koşullu heteroskedastisite (ARCH) kanıtı yoktur. Nitekim ARCH etkisinin olmadığı sıfır hipotezi altında, ARCH test sonuçları Tablo 7'de görüldüğü gibi artıklarda ARCH olmadığını göstermektedir.

**Tablo 7.** ARMA(0,0) ve MA(1) Üzerinde ARCH Testleri

(a) ARMA(0,0)					(b) MA(1)				
F-statistic	1.875598	Olasılık	0.155963		F-istatistik	1.098907	Olasılık	0.335249	
Obs*R-kare	3.737297	Olasılık	0.154332		Obs*R-kare	2.206576	Olasılık	0.331778	
Test Denklemi: Bağımlı Değişken: RESID^2 Yöntem: En az kareler Örneklem(Uyarlı): 1987:04 2004:01 Dahil edilen gözlem sayısı: 202 (bitiş noktalarını ayarladıktan sonar)					Test Denklemi: Bağımlı Değişken: RESID^2 Yöntem: En az kareler Örneklem(Uyarlı): 1987:04 2004:01 Dahil edilen gözlem sayısı: 202 (bitiş noktalarını ayarladıktan sonar)				
Değişken	Katsayı	Std. Hata	t-İstatistik	Olasılık	Değişken	Katsayı	Std. Hata	t-İstatistik	Olasılık
C	0.001099	0.000263	4.174808	0.0000	C	0.001144	0.000266	4.298437	0.0000
RESID^2(-1)	0.096843	0.079160	1.223395	0.2226	RESID^2(-1)	0.053991	0.080178	0.673390	0.5015
RESID^2(-2)	0.107022	0.079131	1.352467	0.1778	RESID^2(-2)	0.102211	0.080147	1.275300	0.2037
R-kare	0.018501	Ort. bağımlı var	0.001352		R-kare	0.010924	Ort. bağımlı var	0.001334	
Adj. R-kare	0.008637	S.S. bağımlı var	0.003263		Adj. R-kare	0.000983	S.S. bağımlı var	0.003274	
Regresyon S.H.	0.003249	Akaike bilgi kriteri	-8.606246		Regresyon S.H.	0.003272	Akaike bilgi kriteri	-8.592132	
Kareler topl. artışı	0.002101	Schwarz kriteri	-8.557113		Kareler topl. artışı	0.002130	Schwarz kriteri	-8.543000	
Log olasılık	872.2308	F-istatistik	1.875598		Log olasılık	870.8054	F-istatistik	1.098907	
Durbin-Watson istat.	1.801237	Olasılık(F-istat.)	0.155963		Durbin-Watson istat.	1.779312	Olasılık(F-istat.)	0.335249	


Ayrıca, artıklardaki otoregresif koşullu heterokedastisite (ARCH)'nin olup olmadığını kontrol etmek için karesi alınmış artıkların korelogramı kullanılabilir. Artıklarda ARCH yoksa, otokorelasyonların ve kısmi otokorelasyonların tüm gecikmelerde sıfır olması ve bu çalışmada olduğu gibi Q-istatistiklerinin anlamlı olmaması gerekir.

ARCH etkilerinin göz ardı edilmesi öngöründe verimlilik kaybına neden olabilir. Ancak burada daha iyi bir yaklaşım elde etmek için ARCH modelinin kullanılmasına gerek yoktur.

### VAR Modeli

#### Modelde İkincil Zaman Serileri, Endüstriyel Üretim

Çalışmada, VAR modellerini reel M2 ile birlikte oluşturmak için kullanılan ikincil seri Toplam Sanayi Üretim Endeksi (Y)'dir. Şekil 8'de görüldüğü gibi, Y serisi hem trend hem de mevsimsellik sergilemektedir. Ancak Y üzerinde öncelikle birim kök testi yapılması daha uygundur.



Şekil 8. Y Düzey Serisinde Toplam Üretim Endeksi Grafiği

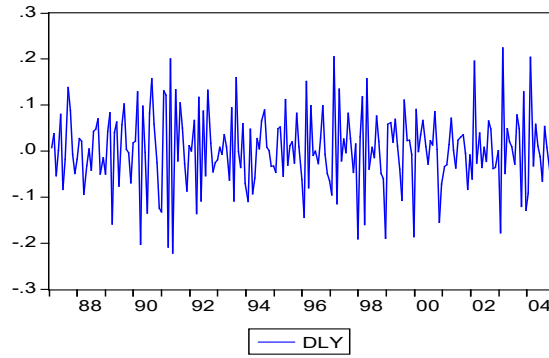
KPSS testi Y serisinin durağan olmadığını göstermektedir. KPSS testi için, LM istatistiği 1.708'dir ve durağanlığın sıfır hipotezi altında %1, %5 ve %10'daki kritik değerler sırasıyla 0.739, 0.463 ve 0.347'dir. %5 ve %10 seviyelerinde, LM test istatistiği kritik değerlerden büyüktür, bu nedenle sıfır hipotezi reddedilir. Bunun yanı sıra, Dickey-Fuller birim kök testi, Y serisinin birim köke sahip olduğunu gösterir. Dickey-Fuller GLS testi için, serinin birim köke sahip olduğu sıfır hipotezi altında  $t$  istatistiği 1.175 ve %1, 5 ve %10'daki kritik değerler sırasıyla -2.577, -1.942 ve 1.615'tir. DF-GLS test istatistik değeri, %5 ve %10 anlamlılık seviyelerinde kritik değerlerden büyüktür. Bu nedenle, bu seviyelerde sıfır hipotezi reddedilemez. Sonuç olarak, Y serisi durağan değildir ve birim kökü vardır. Birim kök testi sonuçları Tablo 8'de verilmiştir.

Tablo 8. Y Üzerinde KPSS ve DF-GLS Birim Kök Testi

(a) KPSS Birim Kök Testi	(b) DF-GLS Birim Kök Testi				
Sıfır Hipotezi: Y durağan	Sıfır Hipotezi: Y'de birim kök var				
Dışsal: Sabit	Dışsal: Sabit				
Bant genişliği: 11 (Bartlett kernel kullanan Newey-West)	Gecikme Uzunluğu: 13 (AIC, MAXLAG=14'e dayalı otomatik)				
LM-İstat.	t-İstatist.				
Kwiatkowski-Phillips-Schmidt-Shin test istatistiği	1.707831				
Asimptotik kritik değerler: 1% düzey	0.739000				
5% düzey	0.463000				
10% düzey	0.347000				
Artık varyansı (düzeltmesiz)	238.7044				
HAC düzeltilmiş varyans (Bartlett kernel)	2245.035				
KPSS Test Denklemi	GLS Detrend Artıklar üzerine DF-GLS Test Denklemi				
Bağımlı Değişken: Y	Bağımlı Değişken: D(GLSRESID)				
Yöntem: En az kareler	Yöntem: En az kareler				
Örnekleme: 1987:01 2004:01	Örnekleme (Uyarlı): 1988:03 2004:01				
Dahil Edilmiş Gözlem Sayısı: 205	Dahil Edilmiş Gözlem Sayısı: 191 (bitiş noktalarını uyarladıktan sonra)				
	Değişken	Katsayı	Std. Hata	t- İstat	Olasılık



Log-fark dLY serisinin grafiđi Őekil 9'da g r lmektedir. Log-farkı dLY serisi trend deđil mevsimsellik g stermektedir. Bunun i in VAR modellerinde mevsimsel kuklalar dıŐsal deđiŐkenler olarak kullanılacaktır.



Őekil 9. Y Log-Farkı Serisinin Grafiđi

### VAR Model Seđimi

Vekt r otoregresyonu (VAR), birbiriyle iliŐkili zaman serisi sistemlerinin tahmini i in yaygın olarak kullanılır. Birden fazla deđiŐkene ait zaman serilerinden oluŐan bir sistemde hangi deđiŐkenin dıŐsal hangisinin i sel olarak dikkate alınacađından emin olunamayan durumlarda her bir deđiŐken simetrik olarak ele alınır ve birbirlerinin mevcut ve ge miŐ ger ekleŐmelerinden etkilenmelerine izin veren bir denklem sistemi ile birlikte tahmin edilirler. Bu Őekilde, VAR modeli, sistemdeki her i sel deđiŐkeni, sistemdeki t m i sel deđiŐkenlerin gecikmeli deđerlerinin bir fonksiyonu olarak ele alır (Enders, 2015). Bu nedenle VAR iŐlemini ger ekleŐtirmeden  nce gecikme uzunluđunun modele uygunluđu test edilmiŐtir.

VAR'ın gecikme uzunluđunun belirlenmesi gibi model seđimlerinde Akaike (AIC), Hannan-Quinn (HQC) veya Schwarz (SIC) bilgi kriterleri kullanılabilir. Bu  alıŐmada Schwarz bilgi kriteri kullanılmıŐ ve bilgi kriterinin daha k çük deđerleri tercih edilerek model seđimi yapılmıŐtır. Sistemdeki t m i sel deđiŐkenlerin birinci ila d rd nc  gecikmelerini, gecikme uzunluđuna g re  eŐitli VAR modellerinde kullanılmıŐ ve en k çük SIC deđerleri tek gecikmeli modelde elde edilmiŐtir. Bu sonu , alternatif VAR modelleri oluŐturmadan  nce ger ekleŐtirdiđimiz VAR gecikme sırası seđim kriterleri s reciyle (Tablo 10'da) tutarlıdır. En uygun VAR modeli, bir gecikmeli i sel deđiŐkene sahip olandır. Bu nedenle,  rneklemede VAR(1) modeli kullanılacaktır.

Tablo 10. VAR Gecikme Sayısı Seđimi Kriterleri

VAR Gecikme Sayısı Seđim Kriteri					
İ�sel deđiŐkenler: DLRM2 DLY					
DıŐsal deđiŐkenler: C @SEAS(2) @SEAS(3) @SEAS(4) @SEAS(5) @SEAS(6) @SEAS(7) @SEAS(8) @SEAS(9) @SEAS(10) @SEAS(11) @SEAS(12)					
�rnekleme: 1987:01 2004:11					
Dahil edilen g�zlem sayısı: 201					
Gecikme	LogL	LR	FPE	AIC	SC
0	660.1522	NA	6.11E-06	-6.329872	-5.935448
<b>1</b>	688.3228	52.41695	4.81E-06	-6.570376	<b>-6.110214*</b>
2	696.2133	14.52491	4.62E-06	-6.609088	-6.083189
3	698.6746	4.481759	4.70E-06	-6.593777	-6.002141
4	707.0106	15.01297	4.50E-06	-6.636921	-5.979547
5	709.7572	4.891964	4.56E-06	-6.624449	-5.901338
6	710.4108	1.151271	4.72E-06	-6.591153	-5.802304
7	712.9527	4.426104	4.79E-06	-6.576644	-5.722057
8	716.3663	5.876075	4.82E-06	-6.570808	-5.650485
9	716.8503	0.823620	4.99E-06	-6.535824	-5.549763
10	726.3549	15.98286	4.73E-06	-6.590596	-5.538798
11	739.5808	21.97736	4.32E-06	-6.682396	-5.564860
12	754.1692	23.95110*	3.90E-06*	-6.787753*	-5.604480

13	755.1076	1.521927	4.02E-06	-6.757289	-5.508278
* kriter tarafından seçilen gecikme sırasını gösterir					
LR: sıralı değiştirilmiş LR test istatistiği (her test %5 düzeyinde)					
FPE: Son tahmin hatası					
AIC: Akaike bilgi kriteri					
SC: Schwarz bilgi kriteri					

VAR modelinde, sanayi üretimi (dIY) ve reel para arzı (dlrM2) birlikte belirlenmekte ve sabit, trend değişkeni ile mevsimsel değişkenler dışsal değişkenler olarak kullanılmaktadır.

### **VAR(1) Modeli**

VAR'ın içsel değişkenlerin bir gecikmeli değerini içerdiğini varsayarsak, model aşağıdaki biçimde yazılabilir:

$$\begin{aligned} dIRM2_t &= \beta_1 + \varphi_{1,1} dIRM2_{t-1} + \varphi_{1,2} dIY_{t-1} + \delta_{1,1} \bar{T} + \sum_{i=2}^{12} \theta_{1,i-1} S_i + \varepsilon_{1t} \\ dIY_t &= \beta_2 + \varphi_{2,1} dIRM2_{t-1} + \varphi_{2,2} dIY_{t-1} + \delta_{2,1} \bar{T} + \sum_{i=2}^{12} \theta_{2,i-1} S_i + \varepsilon_{2t} \end{aligned} \quad (3)$$

Burada  $\varphi_{ij}$  tahmin edilecek parametrelerdir,  $\beta_i$  sabit katsayıdır,  $\bar{T}$  trendi temsil eden kukla değişkendir ve  $S_i$  aylık mevsimselliği temsil eden kukla değişkenlerdir.

Son 10 gözlem dışında tüm verileri kullanarak tahmin edilen VAR modelleri, sabit katsayı, mevsimsel kukla değişkenler ve doğrusal bir trend ile  $p=1,2,3,4$  gecikmelerini içermektedir. Sistem için Schwarz kriterine göre en iyi model VAR(1)'dir. Bu model, elde edilebilen en küçük SIC değerine -5.86 sahiptir. SIC'ye göre dışsal bir değişken olarak bir trend eklendiğinde, en iyi VAR modeli yine VAR(1) modeli çıkmaktadır. Ancak,  $t$  istatistiği 2'den küçük olduğu için trend değişkeni anlamlı görünmemektedir.

RM2 ile Y arasında deterministik bir ilişki olup olmadığını test etmek mümkündür. Bu amaçla VAR(1) modelini kullanarak VAR Çift Yönlü Granger Nedensellik Testi yapılmıştır. dIRM2 bağımlı değişken olduğunda, dIY'nin dIRM2'ye neden olmadığı sıfır hipotezi altında,  $p$ -değeri 0.05 anlamlılık düzeyinden küçüktür. Bu nedenle sıfır hipotezi reddedilemez. Ancak, dIY bağımlı değişken olduğunda, dIRM2'nin dIY'ye neden olmadığı sıfır hipotezi altında,  $p$  değeri 0,05 anlamlılık düzeyinden büyüktür, bu da sıfır hipotezinin reddedilmesi anlamına gelir. Bu nedenle, Granger Nedensellik Testi, RM2'nin Y'yi etkilemezken Y'nin RM2'yi etkilediğini göstermektedir. Bu sonuç, önceki yorumla tutarlıdır.

Merkez Bankası, para arzını ekonomik faaliyet düzeyine göre ayarlamaktadır. Ekonomi büyürken yani üretim seviyesi arttıkça para talebi de yükselerek daha yoğun piyasa işlemlerine karşılık gelmekte, dolayısıyla merkez bankası para talebindeki ve ekonomik aktivitedeki bu artışa cevap vermektedir. ARMA tahmin grafiği genel olarak yaz aylarında para arzının arttığını gösteriyor. Bunun nedeni, yaz aylarında ihracat, ithalat, turizm ve dışarıda çalışan ve Türkiye'ye tatil için gelen Türk işçilerinin artması nedeniyle ekonomik faaliyetlerin ve işlemlerin artıyor olmasıdır.

### **Sonuç**

SIC değerine göre dIRM2'yi tahmin etmek için en iyi ARMA modeli ARMA(0,0)'dır. Ancak bu mantıklı olmayacağı için ikinci en küçük SIC değerine sahip MA(1) modeli kullanılmıştır. Artıklar beyaz gürültüdür ve seri korelasyon yoktur, ancak seri normal dağılıma sahip değildir. Mevsimsellik etkilerini karşılamak için mevsimsel kukla değişkenler eklenmiştir. Birinci farkı alarak birim kök problemi giderilmiş ve ayrıca büyüme hızları (yani logaritmik seriler) kullanılmıştır.

MA(1) ve ARMA(0,0) kullanarak RM2'nin öngörülmesi makul sonuçlar vermiştir. Gerçek veriler, üst ve alt sınırlar arasında ve öngörüyle hemen hemen aynı şekildedir. Tahmin sapması ve varyansı nispeten daha küçüktür, kovaryans ise oranların en büyüğüdür.

Çeşitli VAR modelleri kullanılarak sanayi üretimi (dIY) ve reel para arzı (dlrM2) birlikte belirlenmiş ve sabit, trend kukla değişkeni ve mevsimsel kukla değişkenler dışsal değişkenler olarak modellere dahil edilmiştir. En iyi VAR modeli, modellerdeki içsel değişkenler olan dIY ve dlrM2'in bir gecikmeli değerlerini içermektedir. Granger Nedensellik Testi, RM2'nin Y'ye neden olmadığını ancak Y'nin RM2'ye neden olduğunu göstermektedir. Bu sonuç, Merkez Bankasının ekonomik aktivite seviyesine bakarak para arzının büyüklüğünü belirlediğini göstermektedir. Örneğin yaz aylarında ekonomi daha yoğun faaliyet içermektedir (turizm, ihracat, ithalat) ve Merkez Bankası ekonomik aktiviteye göre para arzını artırmaktadır.

Serideki reel hareketlere daha iyi bir yaklaşım elde etmek için daha karmaşık öngörü modelleri oluşturulması bu konuda ufuk açıcı olabilir. M2 ve diğer makroekonomik değişkenler arasındaki ilişkinin daha geniş bir



resmini çekmek için enflasyon, faiz oranı ve bütçe açığı gibi diğer serilerin de ARCH, GARCH veya VAR modellerine eklenmesi faydalı olabilir. Türkiye için özel mevsimsellik koşulları, resmî tatiller, bayramlar, Ramazan ayı da dikkate alınabilir. Örneğin, Atuk ve Ural (2002) tarafından yapılan bir araştırmada hareketli tatil etkisi parasal toplamlar serisinde %5 düzeyinde anlamlı bulunmuştur. Ramazan ayı, parasal büyüklükleri etkileyen bir diğer özel mevsimseliktir. Ancak aynı çalışmada M2 serisi için iş günü ve artık yıl etkileri %5 düzeyinde önemsiz bulunmuştur.

### Kaynakça

- Asako, K. ve Wagner, H. (1992). Nominal income targeting versus money supply targeting. *Scottish Journal of Political Economy*, 39(2), 167–187.
- Atuk, O. ve Ural, B.P. (2002). Seasonal adjustment methods: An application to the Turkish monetary aggregates. *Central Bank Review*, 2(1), 21–37.
- Bagshaw, M.L. ve Gavin, W.T. (1983). Forecasting the money supply in time series models. *Working Papers (Old Series)* 8304. Federal Reserve Bank of Cleveland.
- Box, Jenkins ve Reinsel, Ljung (2015). *Time series analysis: Forecasting and control*. 5<sup>th</sup> Edition. John Wiley and Sons Inc., Hoboken, New Jersey.
- Breusch, T.S. (1978). Testing for autocorrelation in dynamic linear models. *Australian Economic Papers*, 17, 334–355.
- Brooks, C. ve Tsolacos, S. (2010). *Real estate modelling and forecasting*. Cambridge: Cambridge University Press.
- Çavuşoğlu, A.T. (2003). The endogenous money growth: An outcome of high budget deficits in Turkey. *H.Ü. İktisadi ve İdari Bilimler Fakültesi Dergisi*, 21(1), 111–127.
- Chappell, D. ve Peel, D.A. (1979). On the dynamic stability of monetary models when the money supply is endogenous. *The Manchester School*, 47(4), 349–358.
- Chang, C.-H., Chan, K.C. ve Fung, H.G. (2009). Effect of money supply on real output and price in China. *China & World Economy*, 17(2), 35–44.
- Chatfield, C. ve Xing, H. (2019). *The analysis of time series: An introduction with R*. 7<sup>th</sup> Edition. New York: Chapman and Hall/CRC Press.
- Enders, W. (2015). *Applied econometric time series*. Hoboken, NJ: Wiley.
- Engle, R.F. (1982). Autoregressive conditional heteroscedasticity with estimates of the variance of United Kingdom inflation. *Econometrica*, 50(4), 987–1007.
- Engle, R.F. (1984). Wald, likelihood ratio, and lagrange multiplier tests in econometrics. *Handbook of Econometrics*, Vol. 2, Chapter 13, 775–826.
- Evans, G.W. ve Honkapohja, S. (2003). Friedman's money supply rule vs. optimal interest rate policy. *Scottish Journal of Political Economy*, 50(5), 550–566.
- Friedman, M. (1970). Counter-revolution in monetary theory, *Occasional Paper 33*, Wincott Memorial Lecture, Institute of Economic Affairs.
- Gavin, W.T. ve Kydland, F.E. (1999). Endogenous money supply and the business cycle. *Review of Economic Dynamics*, 2(2), 347–369.
- Godfrey, L.G. (1978). Testing against general autoregressive and moving average error models when the regressors include lagged dependent variables. *Econometrica*, 46, 1293–1301.
- Koenig, E.F. (1996). Forecasting M2 growth: An exploration in real time. *Economic and Financial Policy Review*, Federal Reserve Bank of Dallas, Issue Q II, 16–26.
- Kwiatkowski, D., Phillips, P.C.B, Schmidt, P. ve Shin, Y. (1992). Testing for the null hypothesis of stationarity against the alternative of unit root: How sure are we that economics time series have a unit root. *Journal of Econometrics*, 54, 159–178.
- Lane, T.D. (1985). The rationale for money-supply targets: A survey. *The Manchester School*, 53(2), 179–207.
- Miyao, Ryuzo (2004). Use of money supply in the conduct of Japan's monetary policy: Reexamining the time series evidence. *Discussion Paper Series*, Research Institute for Economics & Business Administration, Kobe University.

- Nelson, C.R. ve Plosser, C.I. (1982). Trends and random walks in macroeconomic time series: Some evidence and implications. *Journal of Monetary Economics*, 10, 139–162.
- Jarque, C.M. ve Bera, A.K. (1980). Efficient tests for normality, homoscedasticity and serial independence of regression residuals. *Economics Letters*, 6(3), 255–259.
- Jarque, Carlos M. ve Bera, Anil K. (1987). A test for normality of observations and regression residuals. *International Statistical Review*, 55(2), 163–172.
- Lombra, R.E. ve Kaufman, H.M. (1984). The money supply process: Identification, stability, and estimation. *Southern Economic Journal*, 50(4), 1147–1159.
- Martin, V., Hurn, S. ve Harris, D. (2013). *Econometric modelling with time series: Specification, estimation and testing*. Cambridge: Cambridge University Press.
- Mercenier, J. ve Sekkat, K. (1988). Money stock targeting and money supply: An intertemporal optimization approach (with an application to Canada). *Journal of Applied Econometrics*, 3(3), 215–228.
- Perron, P. (1989). The great crash, the oil price shock, and the unit root hypothesis. *Econometrica*, 57(6), 1361–1401.
- Pindyck, R.S. ve Daniel L. R. (1991). *Econometric models and economic forecasts*. 3<sup>rd</sup> Edition. New York: McGraw-Hill.
- Prasad, K. (1968). The impact of money supply on the price level and the rate of interest in India, 1950-51 to 1961-62. *Bulletin of Economic Research*, 20(1), 14–27.
- Singh, R.A. (1993). Response of stock prices to money supply announcements: Australian evidence. *Accounting & Finance*, 33(2), 43–59.
- Stemp, P.J. (1993). Optimal money supply rules under asymmetric objective criteria. *Journal of Economics*, 57(3), 215–232.

## EXTENDED SUMMARY

The main objective of the Turkish central bank's monetary policy is price stability. By changing the rate at which the supply of money and credit is growing, total spending on goods and services in the economy could be shifted upward or downward. In monetary policy making and research, two potential roles of money supply shows up as important subjects matter, which are to function as an "intermediate target" and as an "information variable". Indicators such as M2 provide useful information about changes that are taking place in the economy (e.g. the future level of production in the economy). The growth of the broader monetary aggregates is a good leading indicator of the rate of inflation.

This study focuses on the role of money supply as an information variable and aims to make an ex-post forecast of real M2 series and also examines the relationship between Real M2 and Industrial Production (Y). We investigate a variety of model specifications using some forecasting models with the time series analysis. Our study mainly will be based on real M2 series, which is empirically the most appropriate definition of money for our purpose. Our original series are seasonally unadjusted. Therefore, in our study, we first employed those seasonally unadjusted RM2 and Y series. We later used time trend and seasonal variables and lagged variables in some models, as well. For our purpose, we used the data from the high-inflation period of 1987-2004 to extract some insight for nowadays.

As an initial step, we perform unit root tests for each of the variables to check for stationarity of the series. Optimal lag length will be chosen based on the Schwarz Information Criterion. Then, we choose the best ARMA model to forecast our series. We examine the predicted content of M2 in the forecasting regressions for the period of 2004:02-2004:11. We perform various tests to see the estimation and forecast characteristics and we conduct some VAR models, as well.

The ARMA(0,0) model with seasonal variables can be written as follows:

$$d\log(\text{RM2}) = \beta_0 + \sum_{i=2}^{12} \theta_{i-1} S_i + \varepsilon \quad (1)$$

The seasonally variable MA(1) model can be written as:

$$d\log(\text{RM2}) = \beta_0 + \varepsilon_t + \beta_1 \varepsilon_{t-1} + \sum_{i=2}^{12} \theta_{i-1} S_i \quad (2)$$

where  $S_i$  represents the seasonal dummy variables and  $\varepsilon$  represents the unobservable shocks. Since the models have a constant  $\beta_0$ , the first seasonal dummy was excluded from the models to avoid multicollinearity.

We find out that the best ARMA model is ARMA(0,0) to estimate  $d\log(\text{RM2})$  with respect to SIC value. However, since it wouldn't make sense, we also used MA(1) model that has the second smallest SIC value. Residuals are white noise and there is no serial correlation, however our series is not normally distributed. To deal with the seasonality, we added seasonal dummy variables. We fixed the unit root problem by taking the first difference and also we used growth rates (logarithmic series).

Forecasting RM2 using MA(1) and ARMA(0,0) gave us reasonable results. Actual data falls between upper and lower bounds and almost in the same way with the forecast. Forecast bias and variance are smaller relatively while covariance is the greatest of the proportions.

In various VAR models we constructed, industrial production ( $d\log(Y)$ ) and real money supply ( $d\log(\text{RM2})$ ) are jointly determined and the constant, trend variable and seasonal variables are included into the models as exogenous variables. The best VAR model contains one lagged values of the endogenous variables,  $d\log(Y)$  and  $d\log(\text{RM2})$ . The Granger Causality Test shows that RM2 doesn't Granger-cause Y while Y Granger cause RM2. It is consistent with our assumption that Central Bank takes policy actions to determine the size of the money supply as a response to economic activity. For example, during the summer, economic activity is higher (due to increasing tourism, export and import) and Central Bank increases the money supply in response to economic activity.

We need to construct complex forecasting models to achieve a better approximation to the actual movements in the series. We would try an alternative model using M1 or another monetary aggregate to avoid getting ARMA(0,0) as the best forecast model. We might try ARCH and GARCH models; we could add other series such as inflation, interest rate and budget deficit into the VAR models to take a wider picture of the relation among M2 and the other macroeconomic variables. We should also consider the special seasonality conditions in Turkey's case. For example, in a research made by Atuk and Ural, the moving holiday effect is found to be significant at 5 % level in monetary aggregate series. Holy Ramadan month is another special seasonality affecting the monetary aggregates. However, working day and the leap year effects are found to be insignificant at 5 % level for M2 series in the same study.