

TÜRKİYE'DEKİ ENFLASYONUN BAYESÇİ VEKTÖR OTOREGRESYON MODELLER İLE İNCELENMESİ

Elif ÇOKER¹, Funda SEZGİN²

¹Mimar Sinan Güzel Sanatlar Üniversitesi, Fen-Edebiyat Fak., İstatistik Bölümü, Araştırma Görevlisi

²Mimar Sinan Güzel Sanatlar Üniversitesi, Fen-Edebiyat Fak., İstatistik Bölümü, Yardımcı Doçent Dr.

ANALYSING THE INFLATION IN TURKEY WITH BAYESIAN VECTOR AUTOREGRESSION MODELS

Abstract: In this study, Bayesian Vector Auto-regression (BVAR) models, which are widely used in time series analysis, are explained in details. In this perspective, Vector Auto-regression (VAR) models are also examined. As is well-known, Turkey suffers from high inflation rates for a long time. In other words, high inflation rates have become one of the most important problems of Turkey. The significance of this factor has led us to model of itself. To model, two different periods, January 1986 – December 2001 and January 1986 – December 2000 are selected. For these periods different seven BVAR models are constructed, and then the forecast performances of these, for years 2002 and 2001 are compared with VAR model. When the results are examined, it is found that the forecast performances of BVAR models aren't better than VAR models for January 2002 – December 2002 period. The reason for this can be explained by the economic crisis happened at 2001. With this respect, another model is constructed for January 1986 - December 2000 period and the January 2001 - December 2001 forecasts are examined. Finally the results showed that, BVAR models are much better than VAR models for estimating the real values of 2001.

Keywords: Vector Auto-regression Models (VAR), Bayesian Vector Auto-regression Models (BVAR), Minnesota Prior, Inflation, Theil U Statistic.

TÜRKİYE'DEKİ ENFLASYONUN BAYESÇİ VEKTÖR OTOREGRESYON MODELLER İLE İNCELENMESİ

Özet: Bu çalışmada, zaman serileri analizinde yaygın biçimde kullanılan Bayesci Vektör Oto-regresyon (BVAR) modeller ayrıntılı bir şekilde açıklanmıştır. Bu çerçevede içinde Vektör Oto-regresyon (VAR) modeller de incelenmiştir. Bilindiği gibi Türkiye, çok uzun zamandan beri yüksek enflasyon oranlarının yol açtığı sıkıntılarla uğraşmaktadır. Öyle ki yüksek enflasyon oranları Türkiye'nin en önemli sorunlarından biri haline gelmiştir. Bu faktörün önemi, bizi onu modellemeye yönlendirmiştir. Modelleme için iki ayrı dönem, Ocak 1986 – Aralık 2001 ve Ocak 1986 – Aralık 2000 seçilmiştir. Bu dönemler için yedi farklı BVAR modeli oluşturulmuş ve daha sonra 2002 ve 2001 yılları için bu modellerin öngörü performansları VAR modeller ile karşılaştırılmıştır. Sonuçlar incelendiğinde, BVAR modellerinin Ocak 2002 – Aralık 2002 döneminin öngörüsünde VAR modeline oranla iyi bir performans sergileyemediği anlaşılmıştır. Bu duruma, 2001 yılında yaşanmış olan ekonomik krizin yol açtığı düşünüldüğünden, Ocak 1986 – Aralık 2000 dönemi için ayrı bir modellemeye gidilmiş ve Ocak 2001 – Aralık 2001 öngörülerine bakılmıştır. Çıkan sonuçlar BVAR modellerinin, VAR modeline göre 2001 yılı gerçek değerlerin tahmininde çok daha başarılı olduğunu kanıtlamıştır.

Anahtar Kelimeler: Vektör Oto-regresyon Modeller (VAR), Bayesci Vektör Oto-regresyon Modeller (BVAR), Minnesota önseli, Enflasyon, Theil U İstatistiği

I. GİRİŞ

Bir araştırmacının tahmin etmek ve öngöründe bulunmak istediği modelin ekonomik değişkenleri ve ekonomik sistemi hakkında kişisel görüşlere sahip olması olağandır. Öngörü için Bayesci Yaklaşım, ekonometrik model kapsamında araştırmacının kişisel görüşleri ile verinin birleşimi olarak açıklanabilir. Bu bağlamda Bayesci yaklaşım ile geçmişten gelen verilerin sahip olduğu bilgi, araştırmacının önsel inançları ya da beklentileri ile etkilenebilir.

Bayesci yaklaşım ile oluşturulan ekonomik öngörü modellerinden biri de Litterman'ın 1980'de ortaya attığı; Todd [1], Litterman [2], [3] ve Spencer [4] tarafından geliştirilen, ekonomik teoriden çok istatistiksel

düzenlemelere dayalı kısıtları içeren Bayesci Vektör Otoresyon (BVAR) modelleridir. BVAR modellerinin en önemli özelliği, araştırmacıya verilere kendi görüşlerini katabilme esnekliği sağlamasıdır.

İstatistiksel öngörü modellerinin hemen hepsi, özünde, eldeki veriyi modeli kuran kişinin görüşleri ile destekleme özelliğine sahiptir. Çünkü araştırmacı veriyi incelemeyen önce konuyla ilgili asgari düzeyde de olsa bilgiye sahiptir ve isterse modelin öngörü performansını arttıracaklarını düşündüğü bilgileri modele yansıtabilir. Modele dahil edilmek istenilen bu bilgiler önsel inanışlar ya da kısaca önseller olarak adlandırılmaktadır. BVAR modelleri, araştırmacıların kişisel görüşlerini daha doğru bir şekilde sunup, bunları geçmişten gelen verilerle birleştirip, standart ve objektif bir yöntem haline getirmek

için geliştirilmişlerdir. Bu yöntem, Theil'in karma tahmin yöntemi olarak da adlandırılabilir [4].

Başlangıç aşamasında, bütün öngörü modelleri en az düzeyde de olsa kişisel görüşlere dayanmaktadır. Örneğin, verilen herhangi bir değişkeni tahmin etmek için araştırmacı, ilgilenilen değişkenle ilişkili olduğunu düşündüğü çeşitli değişkenleri gözden geçirir. Modele girecek olan değişkenlerin belirlenmesinde, araştırmacı iktisat ve istatistik teori ile uygulamalarından yola çıkarak fikirlerini belirtir. Benzer şekilde ekonomik verinin dönüştürülmesinde (trendden veya mevsimsellikten arındırılması ya da doğrusallaştırılmasında) de araştırmacının kişisel görüşleri önemli olmaktadır.

Bütün bunların dışında araştırmacı modele girmeye aday değişkenler arasındaki ilişkiler ve iyi öngörüler oluşturabilecek eşitlikler konusunda da bilgi sahibi olabilir. Temel bir istatistik teorisi olan "Bayesci Karar Teorisi", araştırmacının olası modeller arasından en iyi öngörüye oluşturabileceğine dair olasılıklarla ifade edilen önsel bilgilere sahip olduğu gerçeğine dayanmaktadır. Önsel bilgilerin belirlenmesinden sonra bunlar, Bayesci karar teorisi kapsamı dahilinde gözden geçirilmektedir [1].

I.1. Kısıtsız VAR Modeller ve Yapısal Modellerden BVAR Modellere Geçiş

Minimum düzeyde önsel bilgi içeren bir öngörü modelinin kurulması, tahmin edilecek olan bir grup (ya da vektör) değişkenin seçimiyle başlamaktadır. Modeldeki değişkenlerin her biri, hem kendisinin bugünkü ve geçmiş değerleri hem de modelde yer alan diğer değişkenlerin bugünkü ve geçmiş değerleri ile doğrusal biçimde ilişkilidir. Bu model, araştırmacının önsel inançları açısından minimum düzeyde kısıtlı olduğu için genellikle kısıtsız VAR olarak adlandırılmaktadır. İktisatçılar, kısıtsız VAR modellerini kurmak için genellikle yeterli kadar veriye sahip değillerdir.

Kısıtsız VAR modellere Bayesci bakış açısıyla yaklaşıldığında bunların, verileri ya olduklarından daha fazla veya daha az temsil ettikleri görülmektedir. Kısıtsız VAR modellerindeki katsayıların modele etkilerinin eşit olduğu düşünülmektedir. Çoğu araştırmacı bu görüşe karşı çıkmaktadır. Örneğin, araştırmacı modeldeki katsayıların pozitif olmasının negatif olmasından daha iyi öngörüler oluşturabileceği konusunda önceden bir bilgiye sahip olabilir. Bununla birlikte, bu katsayıların kesin sonuçlarının bulunmasında önsel inançlar bir kısıt olarak kullanılmamaktadır. Bu katsayıların değerleri basit bir istatistiksel yöntem olan en küçük kareler (OLS) yöntemi ile tahmin edilmektedir.

Yeterli sayıda değişken içeren kısıtsız VAR modelleri bazen oldukça iyi sonuçlar ortaya koymaktadır. Bununla birlikte, araştırmalar fazla değişken içermesi

durumunda modelin kötü tahminler sağladığını göstermektedir. Araştırmacıların genellikle çok sayıda değişken kullanma eğiliminde oldukları dikkate alındığında, bu kısıtsız VAR'ın ciddi bir sorunu olarak ortaya çıkmaktadır [1].

Çok fazla sayıda değişken içeren kısıtsız VAR modellerinde yaşanan sorun, modele alınan değişkenlerin arasındaki bağıllık ilişkisinin modele yansımaları ve çoklu doğrusal bağlantının kaçınılmaz olmasıdır. Örneklem küçüğü halinde bu durum çözümlenememekte, dolayısıyla mevcut veriyi en iyi şekilde açıklayan katsayıların tahmini değerleri yine en küçük kareler yöntemi tarafından belirlenmektedir. Ayrıca kısıtsız VAR modellerdeki bütün denklemlerde her bir değişkenin bugünkü ve geçmiş değerleri yer aldığından, tahmin edilecek katsayıların sayısı gözlem sayısına oranla çok fazla olmaktadır. Bunun doğal sonucu olarak çok fazla sayıda katsayı ile az sayıda gözlem çok iyi bir şekilde açıklanmaktadır. Burada katsayılar, aşırı parametreleşme (overfitting) sorununa neden olmaktadır. Bilindiği gibi katsayıların öngörüye en iyi yapacak, değişkenler arasındaki durağanlık ve süreklilik gösteren önemli ilişkileri ortaya çıkartacak şekilde belirlenmeleri istatistiksel yöntemlerle sağlanmaktadır. Aşırı parametreleşme yaşanması durumunda çok fazla sayıda katsayı olduğundan istatistiksel yöntemler, verinin az derecede öneme sahip olan özelliklerini ya da rasgele olan ilişkileri barındıran katsayıları seçebilmektedir. Böylelikle, aşırı parametreleşme modeldeki katsayılar ile yanlış ya da anlamsız olan ilişkileri doğurur. Dolayısıyla, çok sayıda değişken içeren kısıtsız VAR modellerinde doğru olmayan ve ekonomik değişkenlerdeki değişimlere fazla duyarlı olan bir yapı ortaya çıkar.

Çok sayıda değişken içeren kısıtsız VAR modellerinde yaşanan aşırı parametreleşme sorununun çözümüne getirilen geleneksel yaklaşım, önsel inançları kullanarak tahmin edilecek olan katsayı sayısını azaltmaktan yana olmuştur. Bu soruna ekonometrik öngörü için geniş çapta kullanılan yapısal ekonometrik modellerin getirdiği yaklaşım ise, iktisat teorisinin öngördüğü şekilde, modeldeki her denkleme tahmin edilecek olan değişken ile birebir ilişkili olan değişkenlerin ya da tahmin edilecek olan değişkenlerin gecikmelerinin dahil edilmesi şeklindedir. Bu açıdan yapısal modellerde önseller için temel kaynak iktisat teorisidir. Önsellerin modele yansıtılması ise, denklemlerden çoğu değişkenin çıkarılmasıyla olmaktadır. Burada dikkat edilmesi gereken nokta, değişkenlerin denklemlerden çıkarılması, o değişkenlerin katsayısının sıfır olduğundan kesinlikle emin olduğu zaman gerçekleştirilmesi gerektirir. Araştırmacı aşırı parametreleşme sorununu bu şekilde ortadan kaldırmaya çalışsa da, bir başka sorun ile karşılaşmaktadır. O da çıkarılan değişkenlerin belki de geçmişten gelen önemli verileri göz ardı edip yanlış sonuçlara yol açabilecek olmasıdır.

Yapılan bu kısıtlamaların sonucunda yapısal modellerdeki katsayıların sayısı, kısıtsız VAR modellere göre çok daha az olmaktadır. Dolayısıyla, yapısal modellerde değişkenler arasındaki anlamsız rasgele ilişkiler nadiren ortaya çıkmaktadır. Bu da yapısal modellerin yıllardır neden en çok kullanılan öngörü modellerinden biri olduğunu göstermektedir.

Yapısal modellerin aşırı parametreleşme sorununu azaltmasına ve yıllardır öngörü için geniş çapta kullanılmasına karşın, çoğu araştırmacı bu kısıtlama işleminin çok kesin olduğunu ve modeli kuran kişinin önsel inançlarını olduğundan daha fazla ya da daha az gösterdiğini düşünmektedir. Aşırı parametreleşme durumunun yapısal modellerde de gözlemlendiği bilinmektedir. Bu problemin ortaya çıkmasını engellemek için araştırmacılar genellikle, verilere çeşitli dönüşümler uygulayarak ya da farklı çıkarma kısıtlarını deneyerek çok sayıda model oluşturmaktadırlar. Bu modeller arasından da geçmişten gelen verilere en uygunluk sağlayan katsayı çiftleri belirlenip en uygun model seçilmektedir.

Birçok yapısal model, çok fazla sayıda değişken içeren kısıtsız VAR modellerinden daha iyi öngörüler üretmektedir; ama bu yine de çoğu ekonomisti çok fazla memnun etmemiştir. Buradan hareketle araştırmacılar, hatalı ekonomik teorisin iyi öngörülerin oluşmamasına yol açabileceğinden, istatistiksel ve ekonomik görüşlerden oluşan önsellerin kullanımına dayalı Bayesci modellerin sağladığı esneklik ile daha iyi öngörülerin elde edilebileceğini düşünmüşlerdir. Bayesci Vektör Otoregresyon (BVAR) modelleri de bu olasılığı test etmek üzere geliştirilmiştir [1].

BVAR modellere ilk bakıldığında kısıtsız VAR modellerden çok farklı olmadığı düşünülebilir. BVAR modelleri ile kısıtsız VAR modeller ile benzerlik gösterdiği durum denklemlerin biçimsel özellikleri ile ilgilidir. Burada bahsedilen biçimsellik, modele değişkenlerin bugünkü ve geçmiş değerlerinin katılması olmaktadır. BVAR modellerin, kısıtsız VAR modellerden farklılık gösterdiği durum ise (ki bu aynı zamanda yapısal denklemlerle benzerlik gösterdiği taraf olmaktadır) aşırı parametreleşme sorununu ortadan kaldırmak için önsel bilgilerin yoğun bir şekilde kullanılması olmaktadır. Bu açıdan BVAR modelleri, bir bakıma yapısal denklemler ile kısıtsız VAR modelleri arasında bir köprü olarak düşünülebilir [5].

BVAR modelleri yapısal modellerden, önsel bilgilerin kaynakları ve bu bilgilerin kullanıma biçimleriyle farklılık göstermektedir. Yapısal modellerde önsel bilgiler için ana kaynak iktisat teorisi olurken, BVAR modelleri için iktisat teorisi, istatistik teorisi ve gözlemler hakkındaki bilgilerden sonra gelmektedir.

Yapısal modellerde, ya verinin özelliklerine bakılmaksızın katsayılar sıfır olarak belirlenmekte ya da

araştırmacının görüşlerine bakılmaksızın doğrudan veri üzerinden belirleme yapılmaktadır. BVAR modellerde bu şekilde keskin ayırmalar yapılmamaktadır. Aksine BVAR modellerde araştırmacı, istatistiksel ve ekonomik tabanlı önsel bilgilerini kullanarak, katsayıların hangi değerleri için en iyi öngörünün elde edileceğini tahmin etmeye çalışmaktadır. Daha sonra da bu önsel bilgiler, veriler ışığında tekrardan gözden geçirilmektedir.

Yapısal modellerin aksine BVAR modelleri, aşırı parametreleşme sorununu ortadan kaldırmak için modeldeki katsayıların sayısını düşürmek yerine, modelde çok sayıda katsayının yer alıp, verilerin bu katsayılar üzerindeki etkisini düşürmek gibi bir yol izlemektedirler [1].

I. 2. BVAR Modelinin Oluşturulması

BVAR modelinin oluşturulması için öncelikle kısıtsız VAR modelinin kurulması gerekmektedir. Sonraki adım ise önsellerin VAR modeli ile birleştirilmesidir.

I. 2.1. Kısıtsız VAR Modelinin Spesifikasyonu

y vektörünün içinde yer alan n değişken için kısıtsız VAR modeli aşağıdaki gibi gösterilebilir:

$$y(t) = A(L).y(t) + X(t).\beta + u(t) \quad (1)$$

$$E[u(t).u(t)'] = \Sigma \quad t = 1, \dots, T \quad (2)$$

(1) ve (2) nolu eşitliklerde yer alan:

$y(t) \rightarrow t$ zamanında gözlenen değişkenlerden oluşan $n \times 1$ vektördür.

$A(L) \rightarrow L$ gecikme işlemindeki $n \times n$ 'lik matris

$X(t) \rightarrow k$ deterministik değişkenlerine ait gözlemlerin $n \times k$ blok diagonal matrisi

$\beta \rightarrow$ Deterministik değişkenlerin katsayılarının $n \times 1$ boyutlu vektörü

$u(t) \rightarrow$ Stokastik hata terimlerinin $n \times 1$ 'lik vektörü

$\Sigma \rightarrow n \times n$ 'lik kovaryans matrisi

L^0 'ın katsayısı, $A(L)$ 'nin tüm elemanları için 0'dır. Yani, sadece y 'nin elemanlarının gecikmeli değerleri sağ tarafa bulunacaktır.

$$X(t) \text{ matrisi} = x' \otimes I_n \quad (3)$$

Burada:

$x(t) \rightarrow$ Her eşitlikteki ortak olan k deterministik değişkenlere ait gözlemlerin $k \times 1$ 'lik vektörü

$\otimes \rightarrow$ Kronecker ürün matrisi

Eğer sabit terim varsa deterministik değişkenler, bir birim eleman içermelidir. Bu da deterministik trend, mevsimsel değişken ya da herhangi bir 'driver değişken' olabilir (Driver değişkenleri, bir sabit terim ya da zaman trendi gibi deterministik değişimlerdir. Bu değişkenler, modelin denklemlerinde yer alırlar; fakat VAR değişkenlerinin öngörülerini elde etmek için modelin sonunda tahmin edilmek zorunda değildirler. Driver değişkenlerinin, modelin dışında elde edildikleri için, deterministik oldukları düşünülür [4]). Burada amaç, y vektörünün bir ya da daha çok elemanın öngörülerini elde etmektir.

Modelin i . denklemi aşağıdaki gibi açıklanabilir.

$$y(i,t) = \sum_{j=1}^n \sum_{\tau=1}^m a(i,j,\tau) y(j,t-\tau) + x'(t) \beta(i) + u(i,t)$$

$$i = 1, \dots, n; t = 1, \dots, T \quad (4)$$

$y(i,t)$ ve $u(i,t) \rightarrow$ Sırasıyla $y(t)$ ve $u(t)$ 'nin i . elemanları

$\beta(i) \rightarrow$ i . denkleme ilişkin β vektörünün $k \times 1$ boyutlu alt vektörü

$a(i,j,\tau) \rightarrow$ i . denklemin j . değişkeninin τ . gecikmesinin katsayısıdır.

Burada da açıkça görüldüğü üzere i denklem sayısını, j değişken sayısını ve τ da gecikme uzunluğunu göstermektedir.

Başlangıç aşamasında, ilgilenilen değişkenin öngörüsünün başarısını arttırabilmek için, bu değişkenle ilişkili olan ve bu değişkene ait en ufak bir bilgi taşıyan tüm değişkenler modele dahil edilmelidir. Modelleme işleminin sonraki aşamalarında her bir değişken için, ayrı ayrı öngörülerin başarısını arttırıp arttırmadıklarına bakılarak bazı değişkenler model dışına çıkartılır.

Daha sonra, uygun gecikme uzunluğunun belirlenmesinde kullanılan kriterlere göre gecikme uzunluğu belirlenir. Uzun seçilen gecikme sayıları, aşırı parametreleşme sorununa, dolayısıyla başarısız öngörülere yol açar. Ama ileride bahsedilecek olan Bayesci önselin spesifikasyonu, kısıtsız VAR öngörü modeline göre daha büyük gecikme sayılarının

kullanımına olanak sağlar.

Modelleme sürecinde dikkat edilmesi gereken diğer bir nokta da serilere başlangıçta dönüşüm uygulanıp uygulanmayacağına kararlaştırılması ile ilgilidir. Bu noktada verinin olduğu gibi bırakılmasına veya logaritma, karekök ya da birinci farkının alınıp alınmayacağına karar verilir. Bu durumda, her seri ayrı ayrı incelenmelidir. Eğer seriler üstel ya da parabolik trende sahipse, logaritma ya da karekök dönüşümü kullanmak uygun olabilir. Birinci farkların alınıp alınmayacağı sorunu da, değişkenlerin dönüşümlerine ve trendin modellenen arındırılmasına ilişkin önemli diğer bir sorundur. Nelson ve Plosser [6], çoğu ekonomik zaman serisinin stokastik trende sahip olduğunu ve ancak birinci farkları alındıktan sonra durağan hale geldiğini iddia etmişlerdir. Box-Jenkins zaman serileri yöntemleri de serilerin durağan olmasını gerektirir. Bu nedenle sözkonusu yöntemler uygulanmadan önce birinci farkların alınması gerekir. Bu problem VAR modeller için sözkonusu değildir. Bunun yanında, Litterman [3] da, Tiao ve Box [7] ve Tiao ve Tsay [8] gibi fark alma işleminde bilgi kaybı olduğundan dolayı kesinlikle birinci farkların alınması yanlısı değildir. Bu görüş, özellikle bir BVAR öngörü modeli kurulumu için çok önemlidir. Çünkü bu inancıya göre seriler, otoregresif kısımlarında stokastik kısıtlarda da yer alacak birim kök yapısı barındırırlar. Eğer modelin değişkenleri Engle ve Granger'ın [9] tanımladığı gibi eşbütünleşik (cointegre) iseler, birinci farkların alınması uygun olmayacaktır (Eşbütünleşik yapılar, sistemlerde öngörü ile ilgili tartışmalar için Engle ve You [10]'ya bakılabilir). Seri birim köke sahipse serinin denklemine dahil edilen bir sabit terim, trendi arttıracaktır. Ayrıca zaman trendinin tahmin edicilerin arasına katılması sonucunda herhangi bir karesel trendin artacağı açıktır.

Serilerde mevsimsellik söz konusu ise, var olan mevsimsellik iki yolla giderilebilir. İlk yol, mevsimsel farkların alınması, ikinci yol da modele yapay değişkenlerin eklenmesidir. Birinci farkların alınması durumunda olduğu gibi, mevsimsellik sorunu da Bayesci önsel ortalamasının spesifikasyonu ile çözümlenebilir.

Model kurma sürecinde karşılaşılan diğer bir sorun da, "driver değişkenlerinin" seçimi ile ilgilidir. Bu değişkenlerin farklı öngörü kaynakları olabilir. Bu yüzden, VAR model tarafından öngörülmesi gereksizdir. Bazı durumlarda, bu değişkenlerin gecikmeli değerleri (ya da bugünkü değerleri) VAR modelindeki her denklemde yer alır; fakat kendi denklemleri yoktur. Bu değişkenlerin seçimi, genel bir kurala bağlanamaz. Burada bakılacak seçim kriteri öngörünün doğruluğu olmalıdır [4].

1.2.2. Önsel Dağılımların VAR Modeli İle Birleştirilmesi

Genel olarak VAR modeli için Bayesci yaklaşım, modeli açıklayan parametrelere (θ 'lara) önsel dağılımların atanıp, θ için sonsal dağılımın elde edilmesi olarak açıklanabilir. θ 'ların değişkenlerin katsayıları olarak belirlenmesi ve dolayısıyla katsayılara bağlı bir model oluşturulmasıyla, bir grup parametreye bağlı (π 'lara) olan önsel dağılımlar tanımlanabilir. Yani katsayılardan oluşan θ parametresi için, π ile gösterilen önsel beklenti parametresine bağlı bir önsel dağılım edilmiş olunur. Bu önsel dağılım, π parametresi üzerinde koşullu (bağlı) birleşik olasılık yoğunluk fonksiyonu şeklinde de ifade edilebilir [11].

$$p(y/\theta)q(\theta/\pi) \quad (5)$$

(5) ile açıklanan $p(y/\theta)q(\theta/\pi)$ çarpımının θ parametresine göre alınan türevi verilen π parametresi için y 'nin marjinal dağılımını yani $m(y/\pi)$ 'yi verir. Elde edilen $m(y/\pi)$ dağılımı, asıl ilgilendiğimiz dağılımdır ve bu dağılım ile modelin uyumuna bakılabilir [12].

Belirlenen önsel dağılım θ için sonsal dağılım oluşturulmasında kullanılabilir. Sonsal dağılım, π 'ya bağlı önsel dağılım fonksiyonunun ağırlıklandırılmış ortalamasıyla biçimlendirilen olabilirlik fonksiyonu olacaktır.

Sonsal dağılım, parametre hakkındaki subjektif olan önsel bilgi ile örneklemeden gelen objektif bilginin birleşimidir. Sonsal dağılım bilinmeyen parametrenin tahminini oluşturmak için kullanılır [13].

1.2.2.1. Minnesota Önseli İle BVAR Modeli

Öngörü modelinde Bayesci yaklaşım sözkonusu olduğunda, araştırmacı önsel bilgiler için dilediği kaynaklardan yararlanabilmekte ve onları istediği biçimlere sokabilmektedir. Bu nedenle, öngörü için tek bir BVAR yaklaşımından söz etmek mümkün olmamaktadır. Dolayısıyla kullanılan önsel dağılıma göre farklı BVAR modelleri oluşmaktadır. Konu ile ilgili literatürdeki çalışmaların çok büyük bir kısmında Minnesota önseli kullanılmadan ve uygulamada kullanılan RATS (Regression Analysis Using Time Series, 4.2 versiyonu) paket programda Minnesota önseli yürürlükte olduğundan dolayı burada Minnesota önseli ile BVAR modeli açıklanacaktır.

Minnesota Önseli

Son yıllarda, ekonomik öngörü uygulamalarında yapısal modellere alternatif olarak özellikle bir tane BVAR yaklaşımı geliştirilmiştir. Bu yaklaşım, öngörü

için veriler ile önsel bilgileri birleştirmede diğer yöntemlere göre daha objektif olmakta ve güncellenebilmektedir. BVAR yönteminde kullanılacak olan önsel, Minnesota Üniversitesi ve Minneapolis Merkez Bankası'nda geliştirildiğinden 'Minnesota önseli' olarak adlandırılmaktadır [1].

Minnesota önselinin kullanıldığı BVAR modeli, LBVAR modeli olarak da isimlendirilmektedir [14].

Öncelikle (1), (2) ve (4) eşitliklerinde verilen kısıtsız VAR gösteriminde, tahmin edilecek n^2m+nk tane katsayı olduğu görülmektedir. n 'nin (VAR' daki değişken sayısı) ve m 'nin (her bir denklemdaki gecikme sayılarının uzunluğu) minimum olduğu durumlarda bile toplam katsayı sayısı çok fazla olacaktır. Bu da, kısıtsız VAR'ın tahmininin aşırı parametreleşme ile sonuçlanmasına ve dolayısıyla kötü öngörüler sergilemesine neden olacaktır. Bu aşırı parametreleşme sorununun etkisi, modele kısıtlar konarak azaltılabilir. BVAR yaklaşımının amacı da, VAR modelindeki katsayılara ilişkin önsel inanışların spesifikasyonlarında esneklik sağlamaktır.

BVAR modelinin kuruluşu, her bir n^2m VAR katsayısının bağımsız normal önsel dağılımlarının spesifikasyonu ile devam eder. Buradaki her bir $a(i, j, \tau)$ 'nin $\delta(i, j, \tau)$ ortalama ve $S^2(i, j, \tau)$ varyansıyla dağıldığı varsayılır. $\delta(i, j, \tau)$ ve $S^2(i, j, \tau)$ 'nin değerleri, araştırmacının herhangi bir uygun önsel bilgiyi kullanarak; i, j ve τ indeksleri üzerinden çaprazlama olarak ortaya konulur. Herhangi belirli bir $\delta(i, j, \tau)$ için seçilen değer, $a(i, j, \tau)$ değeri için en iyi tahmini gösterecek ve benzer şekilde $S^2(i, j, \tau)$ için seçilen değer de, o tahmindeki güven derecesini verecektir. Doğal olarak burada $S^2(i, j, \tau)$ 'nin küçük değerleri daha çok güveni ifade edecektir. Önceleri, δ ve S^2 'nin değerlerinin seçimi için iktisat teorisi kullanılırdı. Fakat deneyimler, iktisat teorisinin çoğu durumda güvenilir olmadığını göstermektedir. Litterman [3] yaygın olarak kullanılan istatistiksel düzenin, δ ve S^2 'nin değerlerinin seçiminde çok büyük olasılıkla çok daha iyi bir kılavuz olduğunu önermektedir. Bu yaklaşım için, Litterman'ın [3] önsel dağılımların seçiminde istatistiksel çerçevenin kullanılması gerektiğini örnekleyen standart Minnesota önselidir [4].

Minnesota önselinin kullanımındaki ilk adım, araştırmacının kişisel görüşleri doğrultusunda modele girecek ve birbirleriyle doğrusal ilişki içerisinde olacak olan değişkenlerin seçimine karar vermesidir. Değişkenlerin seçiminden sonraki adım, model kapsamındaki her bir doğrusal denklemdaki değişkenlerin her birinin katsayılarıyla ilişkili olan önsel bilgilerin en iyi öngörüye verecek şekilde olasılıklar biçiminde ifade

edilmesidir. Minnesota önseli'ndeki bu olasılıklar, modelde yer alan katsayılara belirli sayıların atanması olarak tanımlanabilir. Nelson ve Plosser'in [6] de belirttiği gibi ekonomik değişkenlerin değerlerindeki değişimin belirsiz olması ve rasgele yürüyüş sürecine uymalarından dolayı, en iyi öngörüü oluşturacak olan bu katsayıların tahminleri rasgele yürüyüş sürecine göre tam ya da yaklaşık olarak belirlenmektedir. Minnesota önseli de, bu istatistiksel düzeni açıkça yansıtmaktadır. Minnesota önselinin ortalaması:

$$\delta(i, j, \tau) = 1 \text{ eğer } i = j \text{ ve } \tau = 1 \text{ ise} \quad (6)$$

$$= 0 \text{ diğer durumlarda}$$

Yukarıdaki ifade, her bir serinin rasgele yürüyüş olduğunu açıkça göstermektedir. Yani tahmin edilmesi istenen değişken dışındaki tüm değişkenlerin katsayıları sıfır olarak kabul edilmektedir. İlgilenilen değişkenin katsayısının 1'e eşit olduğu kabul edilir. Değişkenin tahmin değeri, bugünkü değerinden farklı olacak ve bu fark da bütünüyle tahmin edilemeyen rasgele olayları verecektir.

Araştırmacının her tahminini belirli bir güven aralığı içerisinde belirtebilmesi için nicel bir ölçüm tanımlaması gerekmektedir. Minnesota önseli'nde bu ölçüm, katsayının önsel varyansı olarak tanımlanmaktadır. Önsel varyans ne kadar küçük ise, araştırmacı en iyi öngörüü verecek katsayının tahminine o ölçüde yaklaşmış olacaktır. Güven aralığının genişlemesi ise, tahminin güvenilirliğinin azaldığını göstermektedir. Güven aralığının daraltılması ya da önsel varyansının düşürülmesi, önselin en iyi tahmin etrafında sıkılaştığını (tightening) ifade etmektedir. Benzer şekilde, güven aralığının genişlemesi ya da önsel varyansının artması da önselin en iyi tahmin etrafında yayıldığını (loosening) göstermektedir. Araştırmacının yüksek güven düzeyindeki tahminleri, her bir denklemdeki her bir değişkene ait katsayıların önsel varyanslarını belirleyecektir. BVAR modellerde, yüzlerce katsayı olduğundan her bir değişkene ait katsayıların önsel varyanslarının belirlenmesinde zorluklar yaşanmaktadır [1].

Minnesota önseli, aşağıdaki standart sapma fonksiyonuyla $S(i, j, \tau)$ 'nin yani i. denklemdeki j. değişkenin τ . gecikmelerinin önsel dağılımının standart sapma fonksiyonunun değerlerinin seçimini kolaylaştırmıştır.

$$S(i, j, \tau) = [Y g(\tau) f(i, j)] (s_i / s_j) \quad (7)$$

$Y \rightarrow$ Genel sıklık parametresi (overall tightness parameter)

$g(\tau) \rightarrow \tau$. gecikmenin sıklığını (tightness), birinci gecikmeye göre ifade eden bir fonksiyon

$f(i, j) \rightarrow i$. denklemdeki j. değişken üzerindeki sıklık (cross lag)

$s_i \rightarrow y(i, t)$ için tek değişkenli otoregresyonun standart hatası

olarak tanımlanmıştır.

Modeldeki değişkenler farklı büyüklüklerde olduklarından, standart hataların oranı s_i / s_j , birimlerin karşılaştırılabilmesi için bir düzeltme faktörü (rescaling factor) olarak modelde yer almaktadır.

(7) nolu eşitlikte açıklanan fonksiyon, önsel varyansların sayısını $n^2 m$ parametreden $n^2 + 2$ parametreye düşürmektedir: $f(i, j)$ için n^2 tane, Y için 1 tane ve $g(\tau)$ için de 1 tane. Bu boyut, $f(i, j)$ için daha kısıtlı önseller kullanılarak daha da düşürülebilmektedir [4].

(7) eşitliğinde ilk olarak genel sıklık parametresi yani ilgilenilen değişkenin ilk gecikmesinin standart hatası belirlenmektedir. Genel sıklık parametresi Y , önseldeki güvenin genel ölçümünü verir. Yani, daha küçük değerler daha büyük güven düzeyi ile ilişkili olmaktadır. Uygulama'da Y için çeşitli değerler üzerinden denemeler yapılarak uygun öngörüler elde edilmektedir.

Daha sonra bozulma parametresi (decay parameter)'nin, yani τ . gecikmenin sıklığını (tightness) birinci gecikmeye göre ifade eden fonksiyon $g(\tau)$ belirlenmektedir. $g(\tau)$, gecikme uzunluğu arttıkça katsayıların da 0'a yaklaştığını yüksek güven düzeyinde yansıtmalıdır. Bu fonksiyon için olası iki alternatif vardır.

1. $g(\tau) = \tau^{-d}$: Harmonik fonksiyondur.

$d = 0$ durumunda büyük gecikme uzunlukları için bozulma parametresinden bahsedilemez. d 'nin büyük değerlerinin seçimi, çok hızla artan sıklığı ve dolayısıyla gecikme uzunluğu arttıkça çok hızla azalan $S(i, j, \tau)$ 'yi ifade etmektedir.

2. $g(\tau) = d^{\tau-1}$: Geometrik fonksiyondur.

$d = 1$ durumunda bozulma parametresinden bahsedilemez. d 'nin küçük değerleri hızla artan sıklığı göstermektedir [4].

$g(\tau)$ için iki değerin kullanımı önerilmektedir. Bunlardan yayılmış ya da dağılmış değeri belirten 0 değeri ve sıkı değeri ifade eden 1'dir. Harmonik fonksiyon kullanıldığında d , 1.0 olarak alınmaktadır [15].

Doan [16] geometrik fonksiyonda sonraki değerlerin çok sıkı ve çok hızlı gitmesinden dolayı geometrik fonksiyona oranla harmonik fonksiyonun kullanılmasını tavsiye etmektedir. Bu arada her iki fonksiyonda da d 'nin herhangi bir değeri için $g(1) = 1.0$ olduğuna dikkat edilmelidir [4].

Son olarak da çapraz gecikmeler belirlenmektedir. Çapraz gecikmelerin belirlenmesinde de olası üç alternatif söz konusudur.

1. Simetrik önsel (Symmetric prior) : Eğer çapraz gecikmeler için simetrik önsel kullanılacak olunursa, bu ilgili değişkenin kendi gecikmeleri hariç olmak üzere, diğer değişkenlere eşit ağırlıklar atamayı ifade etmektedir.

2. Genel önsel (General prior) : Genel önselin kullanılması, her bir denklemdaki ilgili değişkenin kendi gecikmeleri hariç olmak üzere, diğer değişkenlere farklı ağırlıkların atanmasını mümkün kılmaktadır.

3. Dairesel önsel (Circular prior) : Çapraz gecikmeler için dairesel önselin kullanılması, değişkenleri yıldız değişkenler (star variables) yani modeli açıklamakta diğerlerine göre daha etkin olan değişkenler ve sisteme dışsal olarak etki eden dairesel değişkenler (circle variables) olarak ayırmaktadır.

Ayrıca simetrik önselin kullanılması durumunda,

$$f(i,j) = 1.0 \quad i = j \text{ ise} \quad (8)$$

= w öteki durumlar için (w sabit)

olarak açıklanmaktadır. Yani simetrik önsel, n^2 parametre değerlerinin seçimi sorununu tek bir hiperparametre w 'nin seçimine indirgemektedir. w 'nin değeri, i . denklemdaki diğer değişkenlerin katsayıları üzerindeki göreceli sıklığı vermektedir [16].

w parametresi 0 ile 1 arasında değer almaktadır. $w = 1$ durumu, her bir denklemdaki tüm değişkenlerin kendi değişkenini öngörmeye eşit ağırlığa sahip olduğunu göstermektedir. w , 0'a yaklaştıkça model, denklem sayısı kadar tek değişkenli otoregresyon modellerine yaklaşmaktadır.

Eğer Minnesota önseli ile BVAR modelinin uygulanması aşağıdaki gibi özetlenebilir.

1. Adım : İlk adım, başlangıç niteliğindeki kısıtsız VAR model gruplarını belirlemeyi amaçlayan çok geniş

bir adımdır. Bu kısıtsız VAR modelleri, sonraki adımlarda çeşitli Bayesci önsel spesifikasyonlarına tabi tutulur. İdeal olarak, bu adım tarafından seçilen modellerin oluşturduğu grubun en son durumu, sadece tek bir model içermelidir. Fakat uygulamada, bu grup birden çok model içerebilmektedir.

VAR modelleri gruplarının seçilmesi süreci başlamadan önce, araştırmacı değişkenlerin dönüşümleri ve gecikme uzunlukları konusunda seçimler yapmalıdır. Modele girecek olan her aday değişkene, gerekli dönüşümler uygulanmalıdır. Gerekli görülen dönüşüm olmaması halinde değişkenler düzeyler şeklinde tutulmaktadır. Uygun gecikme uzunluğu seçilmelidir.

Bu başlangıç seçimleri yapıldıktan sonra, araştırmacı öncelikle ilgilenilen değişkenin öngörüsüne katkısı olmayan değişkenleri uygun öngörü kriterlerini (örneğin Theil' in U istatistiği) kullanarak eleyebilir. Bu temelden hareketle, araştırmacı bir ya da iki grup VAR değişkenleri, $y(t)$ 'nin elemanlarını ve aynı zamanda bir ya da iki grup driver değişkenlerini seçebilir. Buna ek olarak, alışlagelmiş olan önemlilik testleri, modele mevsimsel yapay değişkenlerinin konulup konulmayacağını belirlemek ve herhangi bir deterministik trend için spesifikasyon seçimine yardımcı olmak bakımından kullanılmalıdır. Bu spesifikasyon konularının sonraki modelleme aşamalarında herhangi bir zamanda tekrardan kullanılabilmesi unutulmamalıdır [4].

2. Adım : Bu adımda standart Minnesota önselinin kullanımı ile Y ve w hiperparametreleri için çeşitli değerler denenmektedir. Uygulama'da Y için genellikle küçük değerler denenmektedir; çünkü genel sıklık parametresi Y 'nin küçük olması, ilgili değişkenin kendi gecikmelerinin önselin ortalamasına yaklaşmasını sağlayacaktır [16].

Y ve w parametrelerinin değerlerinin seçimi, alternatif zaman serisi modellerinin karşılaştırmalı, göreceli öngörü başarısı hakkında güvenilir miktarda bilgi sağlar. Y 'nin çok büyük değeri (örneğin 3.0) az sıklığı gösterir ve bu da aslında BVAR'ın Bayesci kısmını yok etmektedir. Diğer taraftan, w 'nin çok küçük değeri (örneğin 0,001) de her denklemdaki, ilgili değişken dışındaki diğer değişkenlerin katsayıları üzerinde yüksek derecede sıklık olduğunu göstermektedir. Bu katsayıların önsel ortalamaları 0 olduğu için, w 'nin çok küçük bir değeri gerçekte BVAR'ın vektör kısmını gidermiş olmaktadır. Böylece Y 'nin büyük bir değeri ile w 'nin küçük bir değerinin birleşimi, kombinasyonu OLS ile tek değişkenli otoregresyon modelini tahmin etmektedir [4].

Y ve w parametrelerinin değerlerinin seçimi ile çeşitli $g(\tau)$ kombinasyonları denenerak çeşitli modeller ve bunlara karşılık gelen öngörüler oluşturacaktır. Bu modellerin değerlendirilmesi için uygun öngörü kriterleri

kullanılır (örneğin Theil U istatistiği) ve en iyi birkaç model belirlenip 3. adım için elde tutulur.

3.Adım : İkinci adımda, kullanılan $g(\tau)$ gecikme sıklık fonksiyonu seçilmişti. Üçüncü adımda, ikinci adımdan sonra elde edilen ilk geçiş BVAR modelleri, bozulma parametresi d'nin alternatif pozitif değerleri (örneğin 1.0, 2.0 ve 3.0) için yeniden tahmin edilir. Tahminlerin öngörü performansı, bozulma parametresi d'nin yüksek değerlerinin öngörü başarısını artırıp artırmadığını anlamak için değerlendirilir. Çünkü bozulma parametresinin daha büyük değerleri aşırı parametreleşmeyi düşürebilmektedir. Bu nedenle d'nin büyük değerleri ile daha uzun gecikmeler modele dahil edilip gözden geçirilmelidir. Eğer d'nin büyük değerleri için modelden daha iyi öngörüler elde ediliyorsa, daha kısa gecikmelerin de yeterli olabileceği de göz önünde bulundurulmalıdır.

4.Adım : Önceki adımlarda uygulananların tekrardan gözden geçirilip, yapılanların uygunluğuna bakılmaktadır.

Öngörü modelleriyle esas olarak iyi öngörülere ulaşmanın hedeflendiği unutulmamalıdır. Sonuç olarak, spesifikasyon seçimlerine karar verirken araştırmacıya yol gösterecek olan kriter, kullanılan spesifikasyon testleri ya da diğer örneklem içi (insample) kriterlerinden çok öngörünün doğruluğu olmalıdır. Bu amaçla örneklem dönemi iki alt döneme ayrılır. Bunlar, öngörü modelinin tahminlendiği dönem ile öngörülerin elde edilip gerçek değerlerle karşılaştırıldığı dönemdir. Bundan sonra, verilen herhangi bir BVAR modelinin öngörülerinin performansı, diğer alternatif modellerle karşılaştırılabilmektedir. Alternatif öngörülerin göreceli doğruluğunu hesaplamada kullanılan çeşitli objektif kriterler vardır. Buna göre RMSE ve Theil U istatistiği aşağıdaki gibi hesaplanmaktadır [15]:

$$RMSE = \sqrt{\frac{\sum_{t \in T} (Y_t - \hat{Y}_t)^2}{T}} \quad (9)$$

$$Theil U = \frac{RMSE(model)}{RMSE(rasgele yürüyüş)} = \left[\frac{\sum_{t \in T} (Y_t - \hat{Y}_t)^2}{\sum_{t \in T} (Y_t - \hat{Y}_{t-1})^2} \right]^{\frac{1}{2}} \quad (10)$$

Burada T, tahmin yapılan dönemdeki toplam gözlem sayısını, Y, tahmin yapılan dönemdeki gerçek değerleri ve \hat{Y} da, tahmin yapılan dönemde elde edilen tahmini değerler olmaktadır.

Eğer $U < 1$ ise, model rasgele yürüyüş sürecine göre daha iyi çalışır. $U > 1$ olması durumunda ise rasgele yürüyüş süreci, modele uygunluk sağlamamaktadır [3].

Dolayısıyla U istatistiği birimden bağımsız bir ölçü olmaktadır.

I.3. BVAR Modellerin Değerlendirilmesi

Bir öngörü modelinin doğruluğu, genellikle gelecek hakkında yapılan tahmin ile gelecekte oluşan gerçek değerler arasındaki farka bakılarak değerlendirilmektedir.[1]. BVAR modelleri, diğer alternatif modellerine göre (VAR ve ARIMA modelleri) daha etkin sonuçlar vermektedir. Çünkü BVAR modellerinde, öznel düzeltmeler yapılmadan çok sayıda değişken ve dolayısıyla az sayıda serbestlik derecesi ile çalışılarak objektif öngörüler elde edilebilmektedir [15].

Ayrıca diğer modellere kıyasla, gelecekteki ekonomi hakkında gözlenemeyen özellikleri ortaya çıkartıp, karmaşık sorulara çok daha iyi ve doğru yanıtlar verebilmektedirler.

BVAR modeller, değişkenler arasındaki hipotetik ilişkileri de açıklayabilmektedirler.

Dolayısıyla BVAR modeller, alternatif olan yapısal modeller veya kısıtlı ya da kısıtsız VAR modeller ile karşılaştırıldığında, bu modellerin bahsedilen modellere göre çeşitli açılardan üstün olduğu ortaya çıkmaktadır [1].

Bunun yanında çeşitli çalışmalarda BVAR modellerin VAR modellerinden çok farklı sonuçlar vermedikleri de gözlemlenmiştir [17]. Buna neden olarak da her dönem için en iyi ortak bir modelin olmaması belirtilmiştir [18].

II. UYGULAMA

Çalışmada, VAR ve BVAR modeli sistemi ile Türkiye'deki enflasyonun tahminlenmesi (TEFE) amaçlanmış olup; çeşitli önsel bilgi ile BVAR modellerinin VAR modeline göre öngörü performansı değerlendirilmiştir. Uygulama için, enflasyon üzerinde etkili olduğu düşünülen değişkenler; Tüketici Fiyat İndeksi (1978-1979 = 100 bazlı indeks, TÜFE), Toptan Eşya Fiyat İndeksi (1981=100 bazlı indeks, TEFE), Dolar alış fiyatı (DOLAR), Sanayi Üretim İndeksi (1997 = 100 bazlı indeks, SUI), Mevduat faiz oranı (üç ay vadeli ağırlıklandırılmış mevduat, MFO), M2 para arzı (M2), İhracat (99 ülke için tüm fasıllar üzerinden, İHRACAT), İthalat (99 ülke için tüm fasıllar üzerinden, İTHALAT) olarak belirlenmiştir.

Veriler, T.C. Merkez Bankası'nın internet sayfasından elde edilmiş [19] ve 1986 yılının ilk ayından 2002 yılının sonuna kadar olan (1986:01-2002:12) dönem ele alınmıştır.

Analizlerde esas olarak RATS paket programı kullanılmış olmakla birlikte, Eviews programından da yararlanılmıştır.

Değişken değerlerinin üssel olarak artması sonucu ortaya çıkan aşırı değişimi dengelemek ve bu değerleri doğrusallaştırıp varyansta durağanlığı sağlamak amacıyla değişkenlere doğal logaritmik dönüşüm uygulanmıştır [20]. Bu sebeple, analiz süresince değişkenlerin logaritmik formlarıyla çalışılmıştır.

Bilgi kaybına neden olması ve hatalı sonuçlar oluşturması bakımından değişkenlerin logaritmik farkları üzerinden çalışılması önerilmediği için logaritmik farklar çalışma kapsamına alınmamıştır [3], [10].

II.1. VAR Modelinin Oluşturulması

VAR ve BVAR modellerini oluşturmak için öncelikle gecikme uzunluğunun belirlenmesi gerekmektedir. VAR modeli için uygun gecikme uzunluğunun saptanması amacıyla hesaplanan değerlerle oluşturulan Tablo.1 aşağıda gösterilmiştir. BVAR modelinin gecikme uzunluğu, VAR modeli için belirlenen uygun gecikme uzunluğunu aşmaması gerektiği bilinmektedir [14]. Bu bilgi çerçevesinde BVAR modeli için de VAR modeli için bulunan gecikme uzunluğu esas alınmıştır.

Gecikme uzunluğunun belirlenmesi için 12 gecikme uzunluğuna kadar denemeler yapılmış ve aşağıdaki bulgular elde edilmiştir.

Tablo.1. VAR Model İçin Gecikme Uzunluğu Değerleri

Gecikme	Hataların Kovaryans Matrisinin Determinantı	Logaritmik Olabilirlik	AIC	SC
1	8,54E-27	3564,275	-36,56832	-35,34233
2	3,70E-27	3625,092	-36,72728	-34,40310
3	2,04E-27	3662,080	-36,63577	-33,20535
4	6,82E-28	3745,878	-37,04126	-32,49647
5	4,27E-28	3769,676	-36,80936	-31,14197
6	2,52E-28	3798,747	-36,63169	-29,83334
7	1,41E-28	3832,173	-36,49917	-28,56143
8	7,12E-29	3873,996	-36,45648	-27,37079
9	3,33E-29	3922,539	-36,48676	-26,24447
10	1,23E-29	3991,471	-36,74144	-25,33377
11	4,32E-30	4064,517	-36,74144	-24,46246
12	8,45E-31	4188,905	-37,92116	-24,15597

Gecikme uzunluğunun seçimi için LR, AIC, SC, HQ vb. kriterler kullanılabilir. Luthepohl [21] ve Hsu, Wang, Shyu ve Yu'nun [14] çalışmalarında olduğu gibi bu çalışmada da yorum için SC kriteri ya da hataların kovaryans matrisinin determinantı dikkate alınacaktır. Tablo 1'de hem hataların kovaryans matrisinin determinantına hem de SC kriterine bakıldığında, uygun gecikme uzunluğunun 1 olduğu görülebilir. Hataların kovaryans matrisinin determinant değerleri incelendiğinde, gecikme uzunluğu arttıkça determinant değerinin küçüldüğü görülecektir. İstenen en büyük determinanta sahip gecikme uzunluğu ilk gecikmede 8,54E-27 değeri ile yakalanmıştır. Schwarz kriterine

bakıldığında mutlak değerce en büyük değer, (|-35.34233|) değerinin, 1. gecikmede yakalandığı görülebilir. Dolayısıyla her iki kriterle bakıldığında VAR modeli için uygun gecikme uzunluğu 1 olarak belirlenmiştir. BVAR modeli için de, VAR model ile aynı gecikme uzunluğunun esas alınacağı hatırlanabilir. Bu sebeple bundan sonra yapılacak analizlerde gecikme uzunluğu için 1 kullanılmıştır.

VAR(1) modelinin sonuçları aşağıdaki gibidir:

Tablo.2. VAR(1) Modelinin Sonuçları

	LSUI	LMFO	LTUFE	LTEFE	LM2	LDOLAR	LHRACA	LITHALAT
LSUI(-1)	0.46618	0.17616	0.06685	-0.02567	-0.00234	-0.02874	0.41059	0.404975
	-0.08863	-0.13665	-0.02841	-0.03183	-0.03209	-0.05737	-0.7995	-0.17347
	-5.26003	-1.28913	-2.35309	-0.80625	-0.07296	-0.50095	-0.51357	-2.33462
LMFO(-1)	-0.03209	0.76299	0.02495	0.03795	0.0626	0.01496	0.24288	-0.143213
	-0.02938	-0.04529	-0.00942	-0.01055	-0.01063	-0.01902	-0.26499	-0.05749
	-1.09241	-16.8458	-2.65009	-3.59673	-5.86644	-0.78144	-0.91656	(-2.49092)
LTUFE(-1)	0.03326	0.68936	0.99863	0.11705	-0.01483	0.23131	3.15215	-0.397969
	-0.16088	-0.24775	-0.0515	-0.05772	-0.05817	-0.10401	-1.44951	-0.3145
	-0.20697	-2.78244	-19.3897	-2.028	-0.25486	2.22382	-2.17462	(-1.26541)
LTEFE(-1)	0.23514	-0.49761	-0.03939	0.80443	-0.03862	-0.23946	-2.20214	1.199872
	-0.1881	-0.29002	-0.06029	-0.06756	-0.06809	-0.12176	-1.69678	-0.36815
	-1.2501	-1.71578	-0.65343	-11.9066	-0.56707	-1.96665	-1.29783	-3.25922
LM2(-1)	-0.0259	-0.23057	-0.01448	-0.01112	0.97969	-0.02181	-0.62701	-0.125813
	-0.0414	-0.06383	-0.01327	-0.01487	-0.01499	-0.0268	-0.37346	-0.08103
	-0.62553	-3.61213	-1.09147	-0.74764	-65.3677	-0.81371	-1.67892	(-1.55270)
LDOLAR(-1)	-0.20371	0.0476	0.05018	0.0811	0.06964	1.0263	-0.25592	-0.555933
	-0.05834	-0.08996	-0.0187	-0.02096	-0.02112	-0.03777	-0.52632	-0.11419
	-3.49143	-0.5291	-2.68322	-3.86976	-3.29677	-27.1741	-0.48625	(-4.86832)
LHRACAT(-1)	-0.00227	0.0001	0.0032	0.00442	-0.00131	0.00361	0.29538	-0.007657
	-0.00818	-0.01262	-0.00262	-0.00294	-0.00296	-0.0053	-0.07381	-0.01601
	-0.27781	-0.00827	-1.22055	-1.50492	-0.44256	-0.68104	-4.00188	(-0.47874)
LITHALAT(-1)	-0.02345	-0.06096	0.00611	0.03181	0.03308	-0.00619	-0.06276	0.34245
	-0.04219	-0.06505	-0.01352	-0.01515	-0.01527	-0.02731	-0.38061	-0.08258
	-0.55571	-0.93698	-0.45198	-2.09915	-2.16575	-0.22657	-0.16489	-4.14669
C	1.17019	0.50819	-0.1974	-0.36059	-0.33319	-0.02665	4.17178	5.629159
	-0.33307	-0.51354	-0.10676	-0.11963	-0.12058	-0.2156	-3.00455	-0.65189
	-3.51339	-0.98958	-1.84908	-3.01414	-2.76325	-0.12361	-1.38849	-8.63515
R-kare	0.87305	0.88514	0.99993	0.9999	0.99992	0.99966	0.61137	0.930651
Düzeltilmiş R-kare	0.86747	0.88009	0.99992	0.9999	0.99991	0.99965	0.59429	0.927603
Hata_Top.Sapması	0.16922	0.4023	0.01739	0.02183	0.02218	0.07091	13.7708	0.648259
Denk. std. Hatası	0.03049	0.04702	0.00977	0.01095	0.01104	0.01974	0.27507	0.059681
Log.Olabirlik	400,234	317,532	617,553	595,801	594,299	483,303	-19,8787	2,719,707
Akaike AIC	-4,09669	-3,2307	-6,37228	-6,14451	-6,12879	-4,96653	0,3024	-2,75362
Schwarz SC	-3,94344	-3,07745	-6,21904	-5,99126	-5,97554	-4,81328	0,45564	-2,600372
Bağımlı deg. Ort.	1,90401	1,78591	4,91693	4,2957	5,67421	4,33361	8,75393	9,350664
Bağımlı deg. std. sap.	0,08376	0,13578	1,12073	1,07668	1,17546	1,04694	0,43185	0,221808
Hataların Det.		8,54E-27						
Log.Olabirlik		3564,28						
AIC		-36,5683						
SC		-35,3423						

II.2. BVAR Modelinin Oluşturulması

Uygulama'da BVAR modeli oluşturulurken Minnesota önseli kullanılmıştır. En uygun model arayışı sürecinde, Minnesota önselindeki parametreler için olası değerler ile ilgili çok çeşitli kombinasyonlar denenmiş, karşılaştırılmaların daha etkin yapılabilmesi amacıyla bu modellerden 7 tanesi ele alınmıştır. Dolayısıyla uygulamada 7 farklı BVAR modeli ile çalışılmıştır. Bu modeller,

$$BVAR1 (\gamma = 0.1, w = 0.001)$$

$$BVAR2 (\gamma = 0.1, w = 0.1)$$

$$BVAR3 (\gamma = 0.1, w = 0.5)$$

BVAR4 ($\gamma = 0.2, w = 0.1$)

BVAR5 ($\gamma = 0.2, w = 0.5$)

BVAR6 ($\gamma = 0.3, w = 0.1$)

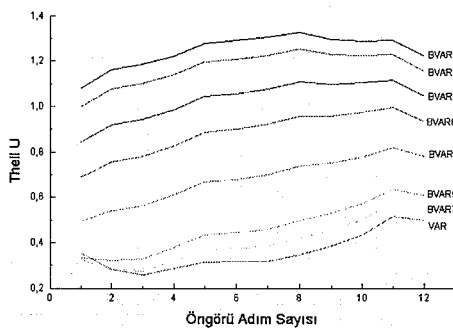
BVAR7 ($\gamma = 0.3, w = 0.5$)

şeklinde isimlendirilmiştir.

II.3.1. Ocak.2002-Aralık.2002 Dönemi için 12 Adım İleriye Yönelik Dönem Dışı Öngörü Değerlerinin Elde Edilmesi

Ocak.1986-Aralık.2001 dönemi için VAR ve BVAR modeller oluşturulduktan sonra, Ocak.2002-Aralık.2002 dönemine ait gerçek değerler ile karşılaştırma yapmak amacıyla 1'den 12 aya kadar ileriye yönelik dönem dışı öngörü değerleri (one-through-twelve months ahead out-of-sample forecasting) elde edilmiştir. İleriye yönelik öngörülerin her adımında bir önceki ayın bilgisini de içeren bu değer, "Kalman Filtresi" yardımıyla belirlenmiştir. Modellerin karşılaştırılmasında Theil U istatistiği kullanılmıştır. Theil U istatistiğinin 1 değerini alması, karşılaştırılan iki modelin birbirlerinden farklı sonuçlar vermediği anlamına gelmektedir. Dolayısıyla uygun model için istenen, düşük bir Theil U istatistiği değeri olmaktadır. Diğer bir deyişle, bu kriteri sağlayan model, alternatif modellere göre performans ve etkinlik açısından daha uygundur.

Ocak.2002-Aralık.2002 dönemi LTEFE serisi için uygulamada esas alınan bütün BVAR modelleri ile VAR modelinin 12 adım ileriye öngörü ile Theil U istatistiği değerleri Şekil 1'de topluca verilmiştir.



Şekil.1. Ocak.2002-Aralık.2002 Dönemindeki LTEFE Serisi İçin BVAR ve VAR Modellerinin Theil U Değerleri

VAR modelinin Theil U değerinin bütün BVAR modellerinden oldukça düşük olduğu görülmektedir. Yalnızca BVAR5 modeli ile BVAR7 modelinin 2 adım ileriye öngörü performansının VAR modele oranla daha iyi olduğu anlaşılmaktadır. Bu adımdan sonraki adımlarda

da VAR modelin daha uygun sonuçlar verdiği dikkat edilmelidir.

II.3.2. Ocak.2001-Aralık.2001 Dönemi İçin 12 Adım İleriye Yönelik Dönem Dışı Öngörü Değerlerinin Elde Edilmesi

Alt bölüm III.3.1.'de Ocak.1986-Aralık.2001 dönemi kullanılarak 2002 yılı için tahminleme yapılmış olup, tahmin değerleri ile 2002 yılı gerçekleşen değerlerinin karşılaştırılmasında Theil U istatistiği kullanılmıştır. Ulaşılan sonuçlarla düzenlenen Şekil 1., BVAR modellerinin öngörü performansının düşük olduğunu ortaya koymaktadır. Öngörü performansının düşük olmasına yol açan nedenin 2001 yılında yaşanan ekonomik kriz olabileceği düşünülmüş, bu düşünce sonucunda aynı modeller bu kez Ocak.1986-Aralık.2000 dönemi için oluşturularak 2001 yılı dönem dışı öngörü değerleri elde edilmiştir.

Ocak.2001-Aralık.2001 dönemindeki LTEFE değişkeni için BVAR1 ve VAR modellerinin Theil U değerleri Tablo.3'de gösterilmiştir.

Tablo.3. Ocak.2001 – Aralık.2001 Dönemindeki LTEFE Serisi İçin BVAR1 İle VAR Modellerinin Theil U Değerleri

Dönem Dışı Öngörü Adım Sayısı	Theil U istatistiği		Gözlem Sayısı
	BVAR1	VAR	
1	0,5260104	0,5335885	12
2	0,4755320	0,5551420	11
3	0,4159762	0,5371133	10
4	0,3790367	0,5144009	9
5	0,3549581	0,4904404	8
6	0,3482217	0,4767328	7
7	0,3553649	0,4775589	6
8	0,3684008	0,4807532	5
9	0,3800005	0,4808849	4
10	0,3910444	0,4782494	3
11	0,4054485	0,4714996	2
12	0,4211445	0,4630237	1

Tablo.3, 12 adım için de BVAR1 modelinin, VAR modelinden daha etkin olduğunu ortaya koymaktadır. Çünkü 12 adım için de BVAR1 modelinin Theil U değerleri, VAR modeline göre daha düşük olmaktadır. Bu beklenen bir sonuçtur; çünkü ikinci parametre w'nin 0.001 olması, ilgilenilen LTEFE değişkenine ilişkin modeldeki yer alan diğer değişkenlerin ağırlıklandırılmalarını çok küçük tutmaktadır. Bu da aslında modelin vektör kısmının çıkarılıp, bir anlamda yalnızca tek değişkenli BVAR modelinin kalması anlamına gelmektedir [16].

İncelenen dönemindeki LTEFE değişkeni için BVAR2 ve VAR modellerinin Theil U değerleri Tablo.4'te gösterilmiştir.

Tablo.4: Ocak.2001 – Aralık.2001 Dönemindeki LTEFE Serisi İçin BVAR2 İle VAR Modellerinin Theil U Değerleri

Dönem Dışı Öngörü Adım Sayısı	Theil U İstatistiği		Gözlem Sayısı
	BVAR2	VAR	
1	0,5582296	0,5335885	12
2	0,5210746	0,5551420	11
3	0,4747009	0,5371133	10
4	0,4423333	0,5144009	9
5	0,4161533	0,4904404	8
6	0,4044100	0,4767328	7
7	0,4061005	0,4775589	6
8	0,4135251	0,4807532	5
9	0,4198347	0,4808849	4
10	0,4246726	0,4782494	3
11	0,4305399	0,4714996	2
12	0,4366569	0,4630237	1

Yukarıdaki tablo incelendiğinde, BVAR2 modelinin ilk adım dışında, diğer adımlarda VAR modelinden daha etkin öngörü performansı sergilediği görülecektir. İlk parametre olan genel sıklık parametresi, BVAR2 modeli için 0.1'dir. Genel sıklık parametresi ne kadar düşük olursa, modelin Bayesci kısmına o ölçüde önem verilmiş olur. Bu gerçek, BVAR2 modelinde, modelin Bayesci kısmını öne çıkardığını göstermektedir.

Aynı dönemdeki LTEFE değişkeni için BVAR3 ve VAR modellerinin Theil U değerleri Tablo 5'te gösterilmiştir.

Tablo.5. Ocak.2001 – Aralık.2001 Dönemindeki LTEFE Serisi İçin BVAR3 ile VAR Modellerinin Theil U Değerleri

Dönem Dışı Öngörü Adım Sayısı	Theil U İstatistiği		Gözlem Sayısı
	BVAR3	VAR	
1	0,5659555	0,5335885	12
2	0,5589619	0,5551420	11
3	0,5307144	0,5371133	10
4	0,5036259	0,5144009	9
5	0,4772525	0,4904404	8
6	0,4625701	0,4767328	7
7	0,4624012	0,4775589	6
8	0,4668519	0,4807532	5
9	0,4692218	0,4808849	4
10	0,4687580	0,4782494	3
11	0,4655483	0,4714996	2
12	0,4605658	0,4630237	1

Tablo.5'e bakıldığında, ilk 2 adım dışında BVAR3 modelinin VAR modeline göre etkin sonuçlar verdiği görülmektedir.

LTEFE değişkeni için BVAR4 ve VAR modellerinin Theil U değerleri Tablo.6'da gösterilmiştir.

Tablo 6: Ocak.2001 – Aralık.2001 Dönemindeki LTEFE Serisi İçin BVAR4 İle VAR Modellerinin Theil U Değerleri

Dönem Dışı Öngörü Adım Sayısı	Theil U İstatistiği		Gözlem Sayısı
	BVAR4	VAR	
1	0,5764816	0,5335885	12
2	0,5516168	0,5551420	11
3	0,5148412	0,5371133	10
4	0,4859122	0,5144009	9
5	0,4597562	0,4904404	8
6	0,4463785	0,4767328	7
7	0,4463407	0,4775589	6
8	0,4515407	0,4807532	5
9	0,4553657	0,4808849	4
10	0,4569748	0,4782494	3
11	0,4577756	0,4714996	2
12	0,4577467	0,4630237	1

Tablo.6'da da yine ilk adım dışında BVAR4 modelinin Theil U değerleri VAR modelinin Theil U değerlerine göre küçük olduğundan dolayı, BVAR4 modelinin ilk adım dışında VAR modeline göre etkin olduğu söylenebilmektedir.

Ocak.2001-Aralık.2001 dönemindeki LTEFE değişkeni için BVAR5 ve VAR modellerinin Theil U değerleri Tablo.7'de gösterilmiştir.

Tablo.7. Ocak.2001 – Aralık.2001 Dönemindeki LTEFE Serisi İçin BVAR5 İle VAR Modellerinin Theil U Değerleri

Dönem Dışı Öngörü Adım Sayısı	Theil U İstatistiği		Gözlem Sayısı
	BVAR5	VAR	
1	0,5506074	0,5335885	12
2	0,5555213	0,5551420	11
3	0,5309678	0,5371133	10
4	0,5052322	0,5144009	9
5	0,4797756	0,4904404	8
6	0,4654207	0,4767328	7
7	0,4659391	0,4775589	6
8	0,4699992	0,4807532	5
9	0,4713892	0,4808849	4
10	0,4699335	0,4782494	3
11	0,4648253	0,4714996	2
12	0,4578378	0,4630237	1

Tablo.7'ye bakıldığında, yine ilk iki adım dışında BVAR5 modelinin öngörü performansının VAR modeline göre daha etkin olduğu görülmektedir.

İncelenen dönemdeki LTEFE değişkeni için BVAR6 ve VAR modellerinin Theil U değerleri Tablo.8'de gösterilmiştir.

Tablo 8: Ocak.2001 – Aralık.2001 Dönemindeki LTEFE Serisi İçin BVAR6 İle VAR Modellerinin Theil U Değerleri

Dönem Dışı Öngörü Adım Sayısı	Theil U İstatistiği		Gözlem Sayısı
	BVAR6	VAR	
1	0,5748169	0,5335885	12
2	0,5574961	0,5551420	11
3	0,5245978	0,5371133	10
4	0,4965900	0,5144009	9
5	0,4702452	0,4904404	8
6	0,4560679	0,4767328	7
7	0,4556276	0,4775589	6
8	0,4600856	0,4807532	5
9	0,4627953	0,4808849	4
10	0,4629124	0,4782494	3
11	0,4612168	0,4714996	2
12	0,4581238	0,4630237	1

Tablo.8’de, ilk adım dışında BVAR6’nın VAR modele göre daha iyi bir öngörü performansı sergilediğini göstermektedir.

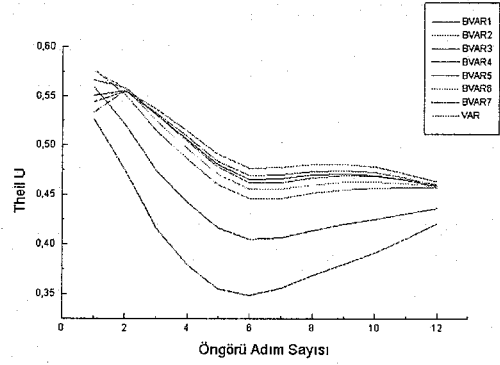
Aynı dönemdeki LTEFE değişkeni için BVAR7 ve VAR modellerinin Theil U değerleri Tablo 9’da gösterilmiştir.

Tablo 9: Ocak.2001 – Aralık.2001 Dönemindeki LTEFE Serisi İçin BVAR7 İle VAR Modellerinin Theil U Değerleri

Dönem Dışı Öngörü Adım Sayısı	Theil U İstatistiği		Gözlem Sayısı
	BVAR7	VAR	
1	0,5438652	0,5335885	12
2	0,5548807	0,5551420	11
3	0,5326583	0,5371133	10
4	0,5081340	0,5144009	9
5	0,4834101	0,4904404	8
6	0,4694079	0,4767328	7
7	0,4701598	0,4775589	6
8	0,4739057	0,4807532	5
9	0,4747750	0,4808849	4
10	0,4728325	0,4782494	3
11	0,4669897	0,4714996	2
12	0,4593166	0,4630237	1

Tablo.9’a bakıldığında ise, yine Theil U değerlerine bakılarak BVAR7 modelinin de VAR modeline göre üstünlük sağladığı görülebilmektedir.

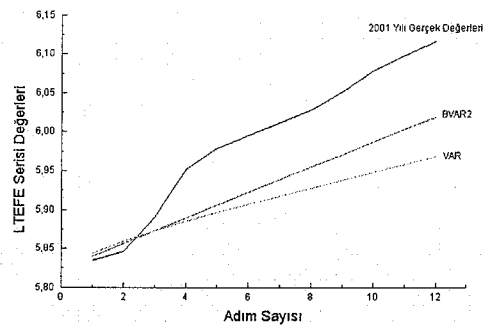
Bu açıklamaların ardından, hangi modelin tercih edilmesi konusunda karar vermede yardımcı olması için, oluşturulan bütün BVAR modellerinin VAR modeli ile karşılaştırmalı grafikleri aşağıda Şekil 2’de sunulmuştur.



Şekil.2. Ocak.2001-Aralık.2001 Dönemindeki LTEFE Serisi İçin BVAR Ve VAR Modellerinin Theil U Değerleri

Şekil.2’den açıkça görüleceği gibi, en düşük Theil U istatistik değerlerine sahip modeller sırasıyla BVAR1, BVAR2, BVAR4, BVAR6, BVAR3, BVAR5, BVAR7 ve VAR modelidir. Bu sıralama kullanılan tüm BVAR modellerinin öngörü performanslarının VAR modelinin öngörü performansına üstünlük sağladığına işaret etmektedir. BVAR modellerden, BVAR2 modelinin öne çıktığı söylenebilir. Bu noktada BVAR1 modelinin neden seçilmediği sorulabilir. BVAR1 modelinin tercih edilmeme nedeni, anılan modelde kullanılan parametre değerlerinin bu modelin tek değişkenli BVAR modeline yaklaşıyor olmasıdır. Dolayısıyla uygun model ($\gamma = 0.1, w = 0.1$) parametre değerleri ile BVAR2 modelidir.

BVAR2 modelinin öngörü değerleri ile VAR modelinin öngörü değerlerinin, 2001 yılında gerçekleşen değerler ile karşılaştırılması amacıyla, çizilen grafik Şekil.3’de gösterilmiştir.



Şekil.3. Ocak.2001-Aralık.2001 Dönemindeki LTEFE Serisi İçin Gerçekleşen Değerler İle BVAR2 Ve VAR Modellerinin Karşılaştırılması

Şekil.3'den de görüleceği gibi, BVAR2 ile öngörülen değerlerin 2001 yılı gerçek değerlerine yaklaşımı VAR modelinkinden daha iyidir. Bu çerçevede BVAR2'nin VAR'dan daha etkin sonuçlar verdiği söylenebilir.

III. Sonuçların Karşılaştırılması ve Yorumlanması

Sonuçlar incelendiğinde, BVAR modellerinin Ocak.2002-Aralık.2002 döneminin öngörüsünde VAR modeline oranla iyi bir performans sergileyemediği anlaşılmıştır. Bu duruma, 2001 yılında yaşanmış olan ekonomik krizin yol açtığı düşünüldüğünden, Ocak.1986-Aralık.2000 dönemi için ayrı bir modellemeye gidilmiş ve Ocak.2001-Aralık.2001 öngörülerine bakılmıştır. Çıkan sonuçlar BVAR modellerinin, VAR modeline göre 2001 yılı gerçek değerlerin tahmininde çok daha başarılı olduğunu kanıtlamıştır. Buradan hareketle, BVAR modelinin Ocak.2002-Aralık.2002 döneminin öngörüsündeki başarısızlığına 2001 yılında yaşanan ekonomik krizin neden olduğu söylenebilir. Sonuç olarak, çalışmada dikkate alınan zaman periyotları ve analizler sonucunda BVAR modellerinin, VAR modellere göre, dönem dışı öngörü performansının oldukça etkin olduğunu kanıtlanmıştır.

YARARLANILAN KAYNAKLAR

- [1] Todd, R., (1984). Improving Economic Forecasting with Bayesian Vector Autoregression. *Quarterly Review*, Federal Reserve Bank of Minneapolis, 8(Fall), 18-29.
- [2] Litterman, R. (1986). A Statistical Approach to Economic Forecasting. *Journal of Business and Economic Statistics*, 4(1), 1-4.
- [3] Litterman, R. (1986). Forecasting with Bayesian Vector Autoregression – Five Years of Experience. *Journal of Business and Economic Statistics*, 4(1), 25-38.
- [4] Spencer, D. (1993). Developing a Bayesian Vector Autoregression Forecasting Model. *International Journal of Forecasting*, 9(3), 407-421.
- [5] Bessler, D.A. & Kling, J.L. (1986). Forecasting Vector Autoregressions with Bayesian Priors. *American Journal of Agricultural Economics*, 68(1), 144-151.
- [6] Nelson, C.R. & Plosser, C. (1982). Trends and Random Walks in Macroeconomic Time Series. *Journal of Monetary Economics*, 10(2), 139-162.
- [7] Tiao, G.C. & Box, G.E.P. (1981). Modelling Multiple Time Series with Application. *Journal of The American Statistical Association*, 76(376), 802-816.
- [8] Tiao, G. & Tsay, R. (1983). Multiple Time Series Modeling and Extended Sample Cross-Correlations. *Journal of Business and Economic Statistics*, 1(1), 43-56.
- [9] Engle, R.F. & Granger, C.W.J. (1987). Cointegration and Error Correction: Representation, Estimation and Testing. *Econometrica*, 55(2), 251-276.
- [10] Engle, R.F. & You, B.S. (1987). Forecasting and Testing in Cointegrated Systems. *Journal of Econometrics*, 35(1), 143-159.
- [11] Fırat, B.E. (1994). Estimating and Forecasting Exchange Rate: Comparison of Structural and VAR Models. A Master's Thesis, Middle East Technical University. *Master of Science in Economics*, Ankara.
- [12] Doan, T.; Litterman, R.B. & Sims, C. (1983). Forecasting and Conditional projection Using Realistic Prior Distributions. *NBER Working Papers Series*. No:1202, Cambridge.
- [13] Larson, H.J. (1982). *Introduction to Probability Theory and Statistics Inference*. Third Edition. New York: John Wiley and Sons.
- [14] Hsu, P.; Wang, C.; Shyu, J.Z. & Yu, H. (2003). A Litterman BVAR Approach for Production Forecasting of Technology Industries. *Technological Forecasting & Social Change*, 70(1), 67-82.
- [15] Ramos, F. (2003). Forecasts of Market Shares from VAR and BVAR Models: A Comparison of Their Accuracy. *International Journal of Forecasting*, 19(1), 95-110.
- [16] Doan, T. (1992). *RATS*. Users Manual Version 4. Illinois: Estima.
- [17] Bischoff, C.W.; Belay, H. & Kang, I. (2000). Bayesian VAR Forecasts Fail To Live Up to Their Promise. *Business Economics*, 35(July), 19-29.
- [18] Wi, S. (1999). An Evaluation Of Combining Forecasts and a Strategy For Searching For An Optimum Bayesian Var Prior To Forecast Business Cycle Turning Points. *Dissertation of Doctor of Philosophy in Economics*. State University of New York, Graduate School of Binghamton University, New York.
- [19] (www.tcmb.gov.tr). [10.05.2001].
- [20] Joutz, F.L.; Maddala, G.S. & Trost, R.P. (1995). An Integrated Bayesian Vector Autoregression and Error Correction Model for Forecasting Electricity Consumption and Prices. *Journal of Forecasting*, 14(3), 287-310.
- [21] Lutkepohl, H. (1993). *Introduction to Multiple Time Series Analysis*. Second Edition. Berlin: Springer-Verlag.

Elif ÇOKER (eunal@msu.edu.tr) graduated from the Hacettepe University Department of Statistics in 2001. She received her Master's Degree of Statistics from Mimar Sinan University Institute of Science and Technology Institute in 2003. She started her Ph.D. same year in Mimar Sinan Fine Arts University Institute of Science and Technology and still continuing. She is a Research Assistant at Mimar Sinan Fine Arts University Department of Statistics since 2001. Her research areas are time series and multilevel models.

Funda SEZGİN (fsezgin@msu.edu.tr) has Ph.D. degree in Econometrics at Marmara University Social Sciences Institute. She is an Assistant Professor at Mimar Sinan Fine Arts University. Her research areas are econometrics, time series and economics.