

T.C.
İNÖNÜ ÜNİVERSİTESİ
SOSYAL BİLİMLERİ ENSTİTÜSÜ



LASSO VAR VE VARX MODELLERİ ÜZERİNE
BİR UYGULAMA
YÜKSEK LİSANS TEZİ

DANIŞMAN

HAZIRLAYAN

Doç.Dr. Bahadır YÜZBAŞI

Emsal Çağla AVCU

MALATYA-2019

T.C.
İNÖNÜ ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ

LASSO VAR VE VARX MODELLERİ ÜZERİNE BİR UYGULAMA

YÜKSEK LİSANS TEZİ

Hazırlayan:

Emsal Çağla AVCU

Tez Danışmanı:

Doç. Dr. Bahadır YÜZBAŞI

MALATYA-2019

T.C
İNÖNÜ ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ

LASSO VAR VE VARX MODELLERİ ÜZERİNE BİR UYGULAMA

YÜKSEK LİSANS TEZİ

DANIŞMAN

Doç. Dr. Bahadır YÜZBAŞI

HAZIRLAYAN

Emsal Çağla AVCU

Jürimiz..16.01.2019...tarihinde yapılan savunma sonucunda bu yüksek lisans tezini (oybirliği/oy çokluğu) ile başarılı bularak Ekonometri Anabilim dalında yüksek lisans tezi olarak kabul etmiştir.

Jüri Üyelerinin Unvan Ad Soyadı

1. Doç. Dr. Bahadır YÜZBAŞI (Danışman)
2. Doç. Dr. Tayfur BAYAT
3. Doç. Dr. Gökhan GÖKDERE

İmzası

İnönü Üniversitesi Sosyal Bilimler Enstitüsü Yönetim
Kurulunun.....tarih ve sayılı kararıyla onaylanmıştır.

Prof Dr. Mehmet KUBAT

Sosyal Bilimler Enstitüsü Müdürü

ONUR SÖZÜ

Doç. Dr. Bahadır YÜZBAŞI' nın danışmanlığında yüksek lisans tezi olarak hazırladığım “LASSO VAR VE VARX MODELLERİ ÜZERİNE BİR UYGULAMA” başlıklı bu çalışmanın, bilimsel ahlak ve geleneklere aykırı düşecek bir yardıma başvurmaksızın tarafımdan yazıldığını ve yararlandığım bütün yapıtların hem metin içinde hem de kaynakçada yöntemine uygun biçimde gösterilenlerden oluştuğunu belirtir, bunu onurumla doğrularım.

Tarih:

Ad-Soyad: Emsal Çağla AVCU

İmza:

BİLDİRİM

Doç. Dr. Bahadır YÜZBAŞI'nın danışmanlığında hazırladığım “ LASSO VAR VE VARX MODELLERİ ÜZERİNE BİR UYGULAMA” başlıklı yüksek lisans tezimin tamamen kendi çalışmam olduğunu ve her alıntıya kaynak gösterdiğimi taahhüt eder, yüksek lisans tezimin kâğıt ve elektronik kopyalarının İnönü Üniversitesi Sosyal Bilimler Enstitüsü arşivlerinde aşağıda belirttiğim koşullarda saklanmasına izin verdiğimi onaylarım.

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

TARİH

Emsal Çağla AVCU

ÖNSÖZ

Tez konumu belirleyen, değerli bilgileri ve önerileri ile çalışmamı yöneten tez danışmanım Doç. Dr. Bahadır YÜZBAŞI'na,

Çalışmamım her aşamasında büyük özveri ile bilgi ve desteğini esirgemeyen, yönlendiren kıymetli arkadaşım Çetin GÖRÜR'e

Attığım her adımda benimle birlikte olan, hayatımı kolaylaştıran, maddi ve manevi her türlü desteği sağlayan ablam Gökçe AVCU'ya

Sonsuz teşekkür ederim.



ÖZET

Vektör otoregresyonunun(VAR), makroekonomik zaman serilerinin ortak dinamiklerinin modellenmesi ve tahmin edilmesi için etkili bir yöntem olduğu bilinmektedir. VAR'ın uygulanabilirliğini engelleyen en temel sorun ağır parametrelere sahip olmasıdır. Yani parametre alanı, mevcut seriyi hızla tüketerek seriye dahil olan seri sayısı ile ikinci dereceden büyür. Ayrıca yüksek boyutlu makroekonomik parametrelerin VAR ile tahmini zorlu bir süreçtir.

Büyük VAR'ların tahmin edilmesine izin veren geleneksel yöntemler, ya özel sübjektif spesifikasyonlar gerektirme eğilimindedir ya da hesaplama açısından mümkün değildir. Aynı zamanda küresel ekonomiler güç geçtikçe karmaşık bir hal almaktadır. Böyle karmaşık bir süreçte stokastik, modifiye olmayan dışsal değişkenleri hesaba katmak büyük bir önem taşımaktadır. Bu dışsal değişkenlerin modellere dahil edilmesi VARX yöntemi ile yapılmaktadır.

VARX, VAR'ı modifiye edilmemiş dışsal değişkenleri modele dahil ederek tahminlerde bulunur. VARX modelinin yapılandırılmış bir ailesi olan VARX-L, yüksek boyutlu tahminlerde daha verimli ve sağlıklı sonuçlar elde etmemizi sağlar. VARX-L, VAR ve VARX modellerinin parametre alanını büyük ölçüde azaltmak için birkaç önemli skaler regresyon tekniğini bir vektör zaman serisi bağlamına uyarlar. VARX-L, hem düşük hem de yüksek boyutlu makroekonomik tahmin uygulamalarında ve simüle edilmiş veri örneklerinde etkinliğini göstermektedir.

Bu tezde, VARX-L'nin cezalı tahmincilerinden biri olan “Temel Lasso” kullanılarak yüksek boyutlu modeller, R programında yer alan BigVAR paketi ile tahmin edilmektedir. VAR ve VARX modelleri için aynı veriler kullanılarak tahmin sonuçları karşılaştırılmaktadır.

Anahtar Kelimeler: VAR, VARX, VARX-L, BigVAR

ABSTRACT

It is known that vector autoregression (VAR) is an effective method for modeling and estimating the common dynamics of macroeconomic time series. The main problem that prevents the applicability of VAR is that it has heavy parameters. That is, the parameter field grows from the second order with the number of series included in the series by rapidly consuming the current series. Furthermore, the estimation of high-dimensional macroeconomic parameters by VAR is a challenging process.

Traditional methods that allow the estimation of large VARs either tend to require specific subjective specifications or are not feasible for calculation. At the same time, global economies are becoming increasingly complex. It is of great importance to take into account the stochastic, unmodified external variables in such a complex process. These external variables are included in the models by VARX method.

VARX estimates the VAR by including the unmodified external variables in the model. VARX-L, a structured family of the VARX model, enables us to achieve more efficient and healthy results in higher dimensional estimates. The VARX-L adapts several important scalar regression techniques to a vector time series context to greatly reduce the parameter field of the VAR and VARX models. VARX-L demonstrates its effectiveness in both low and high dimensional macroeconomic estimation applications and simulated data samples.

In this thesis, one of the punished estimators of VARX-L, "Basic Lasso L, is used to estimate the high-dimensional models using the BigVAR package in the R program. Estimation results are compared using the same data for VAR and VARX models.

Keywords: VAR, VARX, VARX-L, BigVAR

İÇİNDEKİLER

Sayfa No

KABUL VE ONAY.....	ii
ONUR SÖZÜ.....	iii
BİLDİRİM.....	iv
ÖNSÖZ.....	v
ÖZET.....	vi
ABSTRACT.....	vii
İÇİNDEKİLER.....	viii
Kısaltmalar.....	x
Tablolar.....	xi
Şekil ve Grafik Listesi.....	xii
GİRİŞ.....	1
1. ZAMAN SERİLERİ.....	3
1.1. Durağanlık.....	3
1.2. Sahte Regresyon.....	4
1.3. Birim Kök Analizi.....	5
2. VAR MODELİ (VEKTÖR OTOREGRESİF MODEL).....	6
2.1. VAR Modellerinin Avantajları.....	7
2.2. VAR Modellerinin Eşanlı Modellere Göre Avantajları.....	8
2.3. VAR Modellerinin Dezavantajları.....	8
2.4. VAR Modeli Kullanım Alanları.....	9
2.5. Vektör Otoresif Serilerde Tahmin.....	9
3. VARX MODELİ.....	11

3.1. Metodoloji.....	13
3.2. VARX Tahmini.....	14
3.2.1. VARX-L:VARX Modelleri için Cezalı Tahminciler.....	15
3.2.1.1. Temel Lasso (Basic VARX-L).....	16
3.2.1.2. Cezalı Regresyon Kullanılma Nedenleri.....	16
3.2.1.2.1. Mevcut Boyut Azaltma Teknikleri.....	17
3.3. Cezalı Parametre Seçimi.....	17
3.4. BigVAR.....	19
4. UYGULAMA.....	21
4.1. 50 Yıllık GSYH, ÜHİ, NTH, TF: Türkiye Örneği.....	21
5. SONUÇ.....	27
KAYNAKÇA.....	29
EK-1: VARX KOMUTLARI.....	31
EK-2: VAR KOMUTLARI.....	32
EK-3: VERİLER.....	33
ÖZGEÇMİŞ.....	35

Kısaltmalar

AIC: Akaike Bilgi Kriteri (Akaike Information Criterion)

BIC: Bayesian Bilgi Kriteri (Bayesian Information Criterion)

EKK: En Küçük Kareler Yöntemi

GSYH: Gayri Safi Yurtiçi Hasıla

MSFE: Ortalama Hatalar Tahmini Karesi (Mean Squared Forecast Error)

NTH: Net Tüketim Harcamaları

TÜHİ: Ürün Hizmet İhracatı

TF: Tüketici Fiyatları

VAR: Vektör Otoregresif Model

VARX: Dışsal Değişkenli Vektör Otoregresif Model

Tablolar

Tablo 4.1.1: VAR ve VARX Modelinde Cezalı Tahminci Kullanılarak Yapılan Tahmin Sonuçlarını Karşılaştırma Tablosu.....	24
---	----



Şekil ve Grafik Listesi

Şekil 3.1.1: VARX Modeli.....	13
Şekil 3.3.1: Verilerin Tahmin İşlem Aşaması.....	18
Grafik 4.1.1: Türkiye 1968-2017, Gayri Safi Yurt İçi Hasıla, Ürün Hizmet İhracatı, Nihai Tüketim Harcamaları, Tüketici Fiyatları Zaman Serisi Grafiği.....	22
Grafik 4.1.2: VAR ve VARX Modelinde Cezalı Tahminci Optimal λ Değeri Konumunun Karşılaştırma Tablosu.....	25
Grafik 4.1.3: VAR ve VARX Modeline Ait Seyreklik Grafiği.....	26



GİRİŞ

Zaman serisi tesadüfi seçilen değişkenlerin derlemesi olup serinin periyodik zaman aralıklarındaki hareketlerini inceler. Değişkenler günlük, haftalık, aylık, yıllık gibi değerler alabilmektedir. Zaman serisi analizi, istatistiksel yöntemler kullanılarak belirli dönemlerle toplanan verilerin istatistiksel olarak incelenip gelecekteki isabetli tahmininin yapılabilmesini sağlar. Yani serinin geçmiş zaman evresindeki değerleri ile gelecekte alabileceği değerlerin doğru tahmini temel amacıdır. Aylık yağış miktarı, yıllık işsizlik oranları, yıllık doğum oranları zaman serilerine örnek olarak verilebilir.

Eşanlı denklem modellerinde bazı değişkenler içsel bazı değişkenler de dışsal kabul edilmiştir. Değişkenlerin bu şekilde keyfi belirlenmesi Christopher Sims tarafından eleştirilmiş ve değişkenler arasında ayrım yapmadan hepsinin içsel kabul edildiği Vektör Otoregresif Model(VAR Modeli) geliştirilmiştir.

On yıllar boyunca, vektör otoregresyon (VAR) ve modifiye edilmemiş dışsal değişkenlere sahip vektör otoregresyon (VARX), çok değişkenli zaman serilerini tahmin etmede temel araçlar olarak hizmet etmiştir. Ancak regülasyonun yokluğunda VAR ve VARX aşırı derecede paramparça edilmekte, çoğu kez uygulayıcıları seri olarak modele indirgenmiş bir alt kümeyi belirlemeye zorlamaktadır. VARX modelinde cezalı tahminciler olarak Grup VARX-L, Seyrek Grup VARX-L, Yuvalanmış VARX-L ve Temel VARX-L kullanılır. Temel VARX-L en genel gruptur. Temel VARX-L, her değişkeni kendi grubuna ayırma seçeneği veya tüm VARX katsayı matrisine yapısal olmayan bir Lasso cezası uygulama seçeneği olarak görülebilir. VARX'in herhangi bir yapısını içermez ancak yapılandırılmış cezalardan çok daha büyük problemlere ölçeklenmesini sağlayan, daha basit bir optimizasyon problemiyle sonuçlanır.

R programında yer alan BigVAR paketi, geleneksel vektör otoregresyonuna(VAR) ve dışsal değişkenlere sahip vektör otoregresyona (VARX) yapısal cezalar uygulayarak yüksek boyutlu zaman serilerinin eş zamanlı tahmin edilmesini sağlar. Bu yöntem makroekonomi ve finans gibi zamana bağlı verileri kullanan birçok uygulamada kullanılabilir. BigVAR paketi ayrıca zamana bağlı bir ayar için çözüm algoritmalarını

geniřletir: sıralı apraz doęrulama ile reglasyon parametresinin seilmesinde ve geleneksel yntemlere gre performans tahmininde nemli geliřmeler saęlar.

BigVAR, zm algoritmalarını, dzenli hale getirme literatrnden ok deęiřkenli zaman serileri ayarına uyarlayarak, modifiye edilmemiř dıřsal serileri ilave etme seeneęi ile yksek boyutlu VAR'ların hesaplanması aısından verimli tahmini mmkn kılmaktadır. Dięer ifade ile BigVAR, cezalandırılmıř regresyon zm algoritmalarını, dzenleyici literatrnden ok deęiřkenli bir zaman dizisi ayarına uyarlayarak, potansiyel olarak birbiriyle iliřkili birok zaman dizisinin eřzamanlı tahminini mmkn kılar.

Bu tezde ama, VAR ve VARX erevesinde yapısal cezalar uygulayarak, tahmin performansını hesaplamalı bir řekilde byk lde iyileřtirebilmektir. Bu tez toplamda beř blmden oluřmaktadır. Birinci blmde Zaman Serilerine ait temel kavramlar aıklanıp bu bařlık altında duraęanlık, birim kk ve sahte regresyon ara bařlıkları yer almaktadır. İkinci blmde VAR modeli, VAR modelinin zellikleri ve VAR modelinin en kk kareler (EKK) yntemi ile tahmini yer almaktadır. nc blmde VARX modeli, VARX modelinin cezalı parametre seimi ve BigVAR hakkında bilgiler yer almaktadır. Drdnc blmde ise R programında yer alan BigVAR paketi kullanılarak uygulama yapılmıřtır. Uygulamada, 1968-2017 yılları arasında yer alan Trkiye'ye ait Gayri Safi Yurtii Hasıla(GSYH), rn Hizmet İhracatı(Hİ), Net Tketim Harcamaları(NTH) ve Tketici Fiyatları(TF) gerek verileri kullanılmıřtır. Son blm olan beřinci blmde ise sonu kısmı yer almaktadır.

BİRİNCİ BÖLÜM

1.ZAMAN SERİLERİ

Gözlem sonuçlarının zaman vasfının (değişkeninin) şıklarına göre sıralanmasıyla elde edilen seriye “zaman serisi” denir(Serper. 1996; 289). Bir zaman serisi bir veya daha fazla zaman değişkenini kapsayan bir veri kümesidir. Zaman serisinde ilgilenilen özellik bir değişkendir. Bu değişken zaman içerisinde çeşitli nedenlere bağlı olarak farklı değerler alır. Dolayısıyla zaman serisi, zaman sırasına konmuş veri kümesi olarak ifade edilebilir. Gelecekteki değişkenleri tahmin eden modeller geliştirdiği için zaman serisi analizi önemlidir(Chatfield, 1995; 4-5). Zaman serisi verileri günlük, haftalık, aylık, çeyrek yıllık (üç aylık), yıllık ve daha uzun dönemli aralıklarla derlenir. Zaman serileri ekonomi, mühendislik, eğitim, sağlık gibi birçok farklı alanlarda derlenmekte ve toplanmaktadır. Aylık işsizlik, haftalık para arzı, günlük sipariş sayıları vb. seriler zaman serilerine örnek gösterilebilir(Maddala, 1992; 525). Gözlem değerlerinin elde edilme biçimine göre zaman serileri kesikli ve sürekli zaman serileri olarak gruplandırılır. T bir indis kümesi olmak üzere, bir zaman serisi $\{X_t : t \in T\}$ şeklinde ifade edilir. Buradaki T indis kümesi genel olarak $T = \{1,2,3 \dots\} = N, T = \{0, \pm 1, \pm 2, \pm 3 \dots\} = Z$ olarak alınabildiği gibi $T = R, T = [0,1]$ gibi sürekli aralıklar da olabilir. Eğer T indis kümesi $T = R$ veya $T = [0,1]$ gibi sürekli aralıklar olarak seçildiğinde $\{X_t : t \in T\}$ zaman serisine sürekli zaman serisi adı verilir. Eğer T indis kümesi $T = \{0,1,2,3 \dots\}; T = N$ veya $T = Z$ şeklinde seçilmiş ise $\{X_t : t \in T\}$ ye zaman serisi denir(Akdi, 2003; 11).

1.1. Durağanlık

Zaman serisi verileri kullanılan çalışmalarda serilerin durağan (stationary) olmaları önemlidir. Zaman serileri analizinde, durağan olmayan serilerle çalışıldığında, oluşturulacak regresyonun sonuçları gerçekçi olmamaktadır ve durağan olmayan (non-stationary) serilerin kullanılması regresyona tabi tutulan değişkenler arasında sahte (spurious) ilişkiye neden olur. Bu durumda standart t istatistikleri ve R2 değerleri olduğundan daha yüksek çıkar(Enders,..171). Değişkenler arasında anlamlı bir ilişki yoksa bile anlamlı bir ilişki varmış gibi görünür. Bu nedenle, zaman serileri ile çalışırken, öncelikle serilerin durağanlığının test edilmesi gerekmektedir(Terzi, 2004; 59-75). Bir

durağan zaman serisinde ard arda gelen iki değer arasındaki fark zamanın kendisinden kaynaklanmamakta, sadece zaman aralığından kaynaklanmaktadır. Bundan dolayı serinin ortalaması zamanla değişmemektedir. Ancak gerçek dünyadaki zaman serilerinin çoğu durağan değil ve dolayısıyla serilerin ortalaması zamanla değişmektedir. Zaman serilerinin uygun bir modele oturtulabilmesi için bu serilerin önce durağan hale getirilmesi gerekir(Kutlar, 2005:252). Bir serinin durağan olup olmadığını anlamanın iki yolu vardır(Johnston ve Dinardo, 1997;215).

- 1- Serinin korelogramının incelenmesi,
- 2- Birim kök testleri uygulanması.

Herhangi bir Y_t serisinin durağan olabilmesi için;

$$E(Y_t) = \mu \quad (1.1)$$

$$Var(Y_t) = E(Y_t - \mu)^2 = \sigma^2 \quad (1.2)$$

olmalıdır. Gecikme mesafesine bağlı kovaryans;

$$\gamma_k = E[(Y_t - \mu)(Y_{t-k} - \mu)] \quad (1.3)$$

(bütün t değerleri için) k :gecikme mesafesi. Bu koşullardan birisi sağlanmadığında serinin durağan olmadığı söylenir. Bir serinin durağanlaşması için verilerin farkı alınır ve birim kök sayısı alınan fark sayısına eşittir. Y_t serisi 1 farkı alınınca durağan oluyorsa seri 1. dereceden durağandır denir ve $I(1)$ olarak gösterilir. Genel olarak seri d kez farkı alınınca durağan oluyorsa seri d . dereceden durağandır denir ve $I(d)$ ile gösterilir(Gujarati,2004;386-425).

1.2. Sahte Regresyon

Zaman serisi kullanarak oluşturulan regresyonda durağan olmayan serilerin kullanılması, yapılan tahminde sahte (spurious) regresyonu ortaya çıkarır(Baltagi; 2003; 557). Regresyon çıktılarına bakıldığında R^2 yeterince yüksek ve t istatistikleri anlamlıdır, fakat DW (Durbin Watson) istatistik değeri küçüktür. Fakat sonuçların bir ekonomik anlamı bulunmamaktadır. Granger ile Newbold' un önerdikleri gibi $R^2 >$

DW ise tahmin edilen regresyonun sahte olduğundan şüphelenmek için gevşek bir kuraldır(Granger ve Newbold, 1974; 111-120). Durağan olmayan bir zaman serisinin, durağan olmayan bir zaman serisine göre regresyonu oluşturulduğunda standart *t* ve *F* sınamaları sınama süreçleri geçerli değildir(Enders, 2004;171).

1.3. Birim Kök Analizi

Durağanlığın analizinde kullanılan birim kök testi $Y_t = Y_{t-1} + u_t$ modeli yardımıyla denklemin sınanmasını sağlamaktadır. Modelin sağlıklı olabilmesi için Y_{t-1} katsayısı' nın 1 den küçük değer içermesi gerekir bu sayede değişken birim kök içermez ve durağan olur. Eğer ki bu katsayı 1 ve 1 den büyük ifadeler ise burada rassal yürüyüş olan durağan olmayan zaman serisi söz konusu olur (Erdoğan, 2006: 83). Bu durumda değişkenler birim kök içerdiği için birincil farkları alınarak durağanlaştırılma yoluna gidilir. Birincil farkta durağanlık yakalanabiliyorsa bu bütünleşik seri yani birinci derecen durağan olduğunun göstergesidir.

$$Y_t = \alpha Y_{t-1} + u_t \quad (1.4)$$

$$\Delta Y_t = (\alpha - 1)Y_{t-1} + u_t \quad (1.5)$$

$$(\alpha - 1) = \gamma = \gamma Y_{t-1} + u_t \quad (1.6)$$

Model değişkenlerin birincil dereceden durağanlığını ifade etmektedir. Göktaş (35) Yeni testin amacı, bir değişkene ait zaman serisinin gecikmeli değerleri kullanılarak otokorelasyonun ortadan kaldırılmasıdır. Eğer ki durağanlık birincil farkta sağlanamazsa tekrardan fark işlemi uygulanır bu durağanlık m. defa da sağlanırsa o seri m. dereceden durağan olur (Erdoğan, 2006: 83).Durağanlığın tespit edilmesinin bir diğer yolu esas hipotez testlerinin analiz edilmesiyle anlaşılır analiz t istatistik değerinden hareketle yapılmaktadır. t istatistik değeri $> 0,05$ ise H_0 red edilir. Çünkü seri durağandır. Tam tersi durumda yani t istatistik değeri $< 0,05$ olduğunda H_0 kabul H_1 red edilir bu durumda seri durağan olmadığı anlaşılır.

H_0 : γY_t birim kök içermektedir(durağan değildir).

H_0 : γY_t birim kök içermemektedir(durağandır).

İKİNCİ BÖLÜM

2. VAR MODELİ (VEKTÖR OTOREGRESİF MODEL)

Ekonomik ilişkilerin karmaşıklığı ve çok yönlü olması, birçok ekonomik olayın tek denklemlilerle modellenmesi yerine, eşanlı denklem sistemleri ile analiz edilmesine neden olmaktadır. Ekonomik olaylarda makroekonomik değişkenler birbirinden karşılıklı olarak etkilenmektedir. Bundan dolayı değişkenlerin içsel ya da dışsal olarak sınıflandırılması güçleşmektedir. Bu problemin önüne geçebilmek amacıyla modelde bir takım kısıtlamalar kullanmak gerekmektedir (Tarı ve Bozkurt, 2006: 4). Sims (1980) eşanlı denklem sistemlerinde ki değişkenlerin içsel ve dışsal olarak belirlenirken keyfi davranılmasını eleştirmiş ve tüm değişkenler arasında ayrım yapılmadan hepsinin içsel olarak kabul edildiği Vektör Otoresif Modelini (VAR) geliştirmiştir.

Y ve X gibi iki değişken için basit bir VAR modeli,

$$Y_t = \alpha_{10} + \sum_{i=1}^p \alpha_{11i} Y_{t-i} + \sum_{i=1}^p \alpha_{12i} X_{t-i} + u_{1t} \quad (2.1)$$

$$X_t = \alpha_{20} + \sum_{i=1}^p \alpha_{21i} Y_{t-i} + \sum_{i=1}^p \alpha_{22i} X_{t-i} + u_{2t} \quad (2.2)$$

biçiminde ifade edilebilir. Burada , α_{i0} sabit terim, α_{ijk} i'inci denklemdaki j'inci değişkenin k gecikmesine ait parametre, u_{it} hata terimi ve p gecikme sayısıdır. Modelde görüldüğü üzere, sağ bölümde yer alan değişkenler aynıdır. Eğer parametrelerin ortalamaları sıfırdan farklı ise modele sabit terim eklenir (Tarı, 2008:434-435).

Model matrislerle;

$$\begin{bmatrix} Y_t \\ X_t \end{bmatrix} = \begin{bmatrix} \alpha_{10} \\ \alpha_{20} \end{bmatrix} + \sum_{i=1}^p \begin{bmatrix} \alpha_{11i} & \alpha_{12i} \\ \alpha_{21i} & \alpha_{22i} \end{bmatrix} \cdot \begin{bmatrix} Y_{t-i} \\ X_{t-i} \end{bmatrix} + \begin{bmatrix} u_{1t} \\ u_{2t} \end{bmatrix} \quad (2.3)$$

biçiminde veya kısaca,

$$y_t = c + \sum_{i=1}^p A_i y_{t-i} + u_t \quad (2.4)$$

olarak ifade edilir. Bu model, sadece iki değişken içerdiğinden dolayı iki boyutlu bir VAR modelidir. Daha genel bir VAR modeli k sayıda değişken için,

$$y_t = c + A_1 y_{t-1} + A_2 y_{t-2} + \dots + A_p y_{t-p} + u_t \quad (2.5)$$

biçiminde ifade edilir. Burada, $y_t(K \times 1)$ değişken vektörü, $c(K \times 1)$ sabit terimler vektörü, $A_i(K \times K)$ parametre matrisi ve $u_t(K \times 1)$ hata terimleri vektörüdür(Tarı, 2008:434-435).

VAR modeli gecikme sayısı p dikkate alınarak P 'inci dereceden VAR modeli olarak adlandırılır ve VAR(p) olarak gösterilir. Modelde değişkenler arasında içsel-dışsal ayrımı yapmaksızın bütün değişkenler içsel olarak kabul edilir(Tarı, 2008:434-435).

VAR modeline ait parametreleri doğrudan yorumlamanın pek anlamlı olmadığı varsayılır. Bu nedenle etki-tepki (impulse-response) ve varyans ayrıştırması (variance decomposition) analizleri yapılarak bir takım sonuçlar çıkarılmaya çalışılır(Tarı, 2008:434-435).

2.1. VAR Modellerinin Avantajları

- VAR modellerinde yapısal model kullanılma zorunluluğu olmayıp ekonomik teoremin araştırılmadığı modeller için önerilmektedir. Parametre tahmini yapılmadığı için parametrelerin anlamlılığı, t'lerin istatistiksel yönden anlamlılığı önem taşımamaktadır.
- VAR modelinde eşbütünleşme testi yerine ilişki yönü Granger nedensellik testi ile incelenmektedir. Bunun sebebi ise VAR modelinde uzun dönemli ilişki değil şok tipi ilişkiler incelenmesidir.
- VAR modeli otoregresif modeller olduğundan öngöründe başarılıdır ve kolay tahmin edilir. VAR modelinde değişkenler arasındaki ilişki incelenmesi için etki tepki analizi yapılır.

- VAR modeli eşanlı modellere benzer şekilde dışsal ve yapay parametreler kullanmaktadır.
- Var modellerinde EKK tahmini her eşitlik için ayrı ayrı uygulanarak tahminler yapılır. Bu yöntemle VAR modelleri eşanlı modellerden daha üstün olduğu görülmektedir.
- VAR modellerinde parametrelere ait gecikme uzunlu farklılık gösterebilir. Eğer gecikme uzunlukları benzer ise modelleri tahmin etmek daha kolay olmaktadır.
- VAR modellerinde mevsimsel değişimlerin analiz edilmesi, yapay parametrelerin veya vektörlerin ayrılmasından kaynaklı olarak kolaylık göstermektedir.
- VAR modelleri kendinden daha üstün sınıf modeller olarak gösterilen VARMA modelleri ile karşılaştırılabilme şansına sahiptir. VAR modelleri aynı zamanda VARMA modelleri ile kıyaslanma özelliğine sahiptir.
- VAR modelinde yer alan her parametre içsel olarak kabul edilir ve her bir değişkenin diğer değişkenler üzerinde ki etkisi eşanlı olarak tahmin edilir.

2.2. VAR Modellerinin Eşanlı Modellere Göre Avantajları

- VAR modelleri eşanlı modellere alternatif olarak meydana gelmiştir. Eşanlı modellerden farklı olarak herhangi bir kısıtlama yoktur. Eşanlı modellerde kullanılan sıfır kısıtı bilgi kaybına neden olmaktadır. VAR modellerinde ise kısıtlamanın olmaması nedeniyle bilgi kaybı olmamaktadır.
- VAR modellerinde eşanlı modellerin aksine bütün değişkenler içsel olarak kabul görür. Eşanlı modellerinde içsel ve dışsal değişken sayısı fazladır. VAR'da tüm değişkenlerin içsel kabul edilmesinden kaynaklı değişken sayısı azdır ve var olan değişken sayısı kadar denklem kullanılır.
- VAR modelleri fonksiyonel olarak doğrusal kabul edilmektedir.

2.3. VAR Modellerinin Dezavantajları

- VAR modellerinde veriler durağan halde olmadığı zaman veriler durağan hale getirilmelidir. Veriler durağan hale getirildiğinde bazen bilgi kaybına neden olabilmektedir.
- VAR modelleri oluşturulurken önemli unsurlardan biri de parametre seçimidir.

- Eşanlı denklem modellerinde kullanılan öngörü VAR modellerine göre daha fazladır.
- VAR modellerinin EKK yöntemi ile kolayca tahmin edilmesinden kaynaklı olarak gecikme uzunluğuna bağlı olarak değişken sayısı fazla olur. Bundan dolayı serbestlik derecesi sorunu meydana gelebilir.
- VAR modelleri ile geleceğe dair tahminler yapılırken modelde bazı değişiklikler oluşur. Bu değişikliklerden dolayı sonuçlarda değişime uğrar.
- Gecikme uzunluğu belirlenirken farklı yöntemler kullanılmasına rağmen bazen uygulama da sorun yaratabilir.

2.4. VAR Modeli Kullanım Alanları

- 1) Zamanla değişen sistemin yapısı ve analizinde kullanılır.
- 2) Sistem bileşenleri arasında zengin dinamikleri yakalamak için kullanılır.
- 3) Ayrıca farklı kullanım alanları olan kontrol teorisi(sistem tanımlama problemleri), ekonomi (Sims tarafından 1980 yılında makroekonomik ilişkilerin tahmini), genomik (zaman çizelgesi verisinden gen düzenleyici ağı yeniden yapılandırmak) ve nörobilim (Friston tarafından 2009 yılında fMRI'den beyin bölgeleri arasındaki fonksiyonel bağlantıyı araştıran çalışmalar) de popülerdir.

2.5. Vektör Otoregresif Serilerde Tahmin

Tek değişkenli zaman serileri gibi, vektör zaman serilerinde de verilerin durağanlığı basit bir şekilde elde edilebilir. Çok değişkenli zaman serilerinde önemli amaçlardan biri seriye ait bileşenler arasında tahmin edilebilir yani durağan doğrusal birleşimin analiz edilmesidir. Başka bir deyişle, serinin bileşenleri arasındaki eş bütünleşme ilişkisinin elde edilmesidir. Böyle bir ilişki elde edildiğinde, serinin durağan doğrusal birleşimleri üzerinden istatistiki sonuçlar tahmini yapılır. $X_t = AX_{t-1} + e_t$ olarak verilen VAR(1) modeli için A matrisi biliniyorsa, bu ilişkinin belirlenmesi mümkündür. A matrisinin bilinmemesi durumunda da ilişkinin tahmini mümkündür. Değişik tahmin yöntemleri bulunmakla birlikte, tek değişkenli serilerde olduğu gibi VAR(1) modeli de, çok değişkenli regresyon modelleri ile benzerlik taşımaktadır. Buradan, A nın EKK tahmin

edicişi çok deęişkenli regresyon teknikleri ile elde edilir. VAR(1) modeli, $e_t \sim WN(0, \Sigma)$ olmak üzere,

$$X_t = AX_{t-1} + e_t, \quad t = 1, 2, 3, \dots, n$$

şeklinde verilmiş olsun. Bu gözlemlere göre, A nın EKK tahmin edicişi,

$$\hat{A}_n = \left[\sum_{t=1}^n X_t X_{t-1}' \right] \left[\sum_{t=1}^n X_{t-1} X_{t-1}' \right]^{-1} \quad (2.6)$$

dir. Bu tahmin edici X_t yerine $AX_{t-1} + e_t$ yazıldığında,

$$\begin{aligned} \hat{A}_n &= \left[\sum_{t=1}^n (AX_{t-1} + e_t) X_{t-1}' \right] \left[\sum_{t=1}^n X_{t-1} X_{t-1}' \right]^{-1} \\ \hat{A}_n &= A \left[\sum_{t=1}^n X_{t-1} X_{t-1}' \right] \left[\sum_{t=1}^n X_{t-1} X_{t-1}' \right]^{-1} + \left[\sum_{t=1}^n e_t X_{t-1}' \right] \left[\sum_{t=1}^n X_{t-1} X_{t-1}' \right]^{-1} \\ \hat{A}_n &= A + \left[\sum_{t=1}^n e_t X_{t-1}' \right] \left[\sum_{t=1}^n X_{t-1} X_{t-1}' \right]^{-1} \end{aligned}$$

olarak yazılabilir acikarsiv.ankara.edu.tr/ (11.11.2018).

ÜÇÜNCÜ BÖLÜM

3. VARX MODELİ

Birçok uygulamada VAR modelinin tahmin edilebilmesi için VAR modeli dışında modellenmemiş dışsal değişkenler modele dahil edilerek modelin tahmini geliştirilebilir. Sağlık ile ilgili bir çalışmada modele dahil edilmeyen dışsal değişkenlere hava, coğrafi konum, kullanılan ilaçlar, genetik faktörler şeklinde örnekler verilebilir. Bu şekilde kurulan modeller ekonometri literatüründe ‘VARX’ olarak adlandırılır. Aynı zamanda ‘transfer fonksiyonu’ veya ‘dağıtılmış gecikme’ olarak da bilinir.

VARX, küçük açık ekonomilerin modellemesinde özellikle içsel göstergelerinden bağımsız olarak gelişen çok çeşitli küresel makroekonomik değişkenlere karşı duyarlı olmaları nedeniyle özellikle popüler bir yaklaşım haline gelmiştir. VARX, aynı zamanda VARX'in bir parametreye indirgenmesi nedeniyle, tahminlerin sadece bir VAR modelinde bulunan seriye ait bir alt kümeden istenildiği durumlarda da kullanılabilir.

VARX literatürü incelendiğinde birçok alanda kullanıldığı görülmektedir. Örneğin Cushman ve Zha (1997) Kanada'daki para politikası şoklarının etkisini analiz etmek için yapısal bir VARX modeli kullanmıştır. VARX modelleri sadece iktisatta değil, pazarlamada da Nijs vd. (2007), siyaset bilimlerinde Wood (2009) ve gayrimenkullerde Brooks ve Tsolacos (2000) tarafından ilgi görmüştür.

Ne yazık ki, boyutsal konular VARX'in faydasını sınırlandırmıştır. Bernanke vd. (2005) yaptıkları çalışmada yüksek dereceli parametre endişelerinden kaynaklanan sorunlardan dolayı geleneksel kısıtlanmamış VAR bağlamında, çoğu uygulamayı 6 seriden fazla olmamak kaydıyla sınırlandırmıştır. Bu sınırlama uygulayıcıyı, eklenecek serilerin indirgenmiş bir alt kümesini belirtmeye zorlamaktadır. VARX de benzer kısıtlamalarla karşı karşıyadır. VAR'ın aksine VARX de bu kısıtlamaların önüne geçmek amacıyla modellenmiş değişkenlere ait önceden belirlenmiş gecikme sayısı ile modellenmemiş dışsal değişkenlere ait önceden belirlenmiş gecikme sayısı eşit olmalıdır.

İstatistiksel bir problemten ziyade genellikle ekonomik olarak görüldüğü için, VARX modelinin parametre alanını azaltmak çok daha az dikkat çekmiştir. George vd.

(2008) stokastik arama deęiřkenini VARX çerçevesine uygular; sıfır kısıtlamalarını belirlemek için veriye dayalı bir yöntem sağlar ancak yaklaşımları yüksek boyutlara ölçeklenemez. Chiuso ve Pilonetto (2010), Lasso ve Grup Lasso cezalarıyla birlikte bir VARX modelinin tahmin edilmesini önermektedir. Ancak potansiyel grup yapıları üzerinde durulmamaktadır.

Geçtiğimiz yıllar, çok boyutlu çok deęiřkenli zaman serilerinin tahmin edilmesinde Tibshirani (1996) tarafından Lasso, onun yapılandırılmış varyansları olan Grup Lasso Yuan ve Lin (2006) tarafından ve Seyrek Grup Lasso Simon (2013) tarafından regülasyon metotlarının kullanılarak muazzam gelişmeler göstermiştir.

Davis vd. (2012) ile Song ve Bickel (2011) gibi birçok yazar cezalandırılmış VAR modellerini mevcut glmnet paketinde modülleri ile uygular. Zamana baęlı problemler için tasarlanmayan paket, sınırlı çok deęiřkenli ve yapılandırılmış destek sunar.

Nicholson vd. (2015) uygulamada BigVAR paketi ile, regresyon çözüm algoritmalarını, düzenleyici literatürden çok deęiřkenli bir zaman dizisi ayarına uyarlayarak, potansiyel olarak birbiriyle iliřkili birçok zaman dizisinin eşzamanlı tahminini mümkün kılmaktadırlar.

Nicholson vd. (2016) yılında yaptıkları çalışmada ise VAR bağlamında iç içe bir Grup Lasso cezası uygulayarak gecikme kavramını ele alır. Bu amaç doğrultusunda, tahminler sadece serilerin bir alt kümesinden isteniyorsa BigVAR, modellenmiş içsel serilerin tahminlerini iyileřtirmek için modifiye edilmemiş dışsal serilerin bilgisini etkili bir şekilde kullanmak için VARX-L çerçevesini kullanır.

Çok deęiřkenli bir zaman serileri ayarlaması için dışbükey optimizasyon algoritmalarına adapte olmamız nedeniyle, VARX modelleri yüksek boyutlu düşük frekanslı makroekonomik zaman serilerinin eşzamanlı olarak öngörülmesi için çok uygundur. Özellikle modeller, bileřen serilerinin sayısının ve dışsal deęiřkenlerin içerdęi serilerin uzunluęuna yakın veya bu deęerleri aşan senaryolar altında öngörmeye izin vermektedir.

3.1. Metodoloji

Vektör otoregresyon (VAR), çok değişkenli zaman serilerini modellemede temel araçlardan biri olarak uzun yıllar hizmet etmiştir. Ne yazık ki, aynı zamanda aşırı yüksek parametrelidir. Bazı senaryolarda yalnızca dahil edilen serilerin (VARX) bir alt kümesinden tahminler istenebilir. Hem VAR hem de VARX çerçevesinde yapısal cezalar uygulayarak, tahmin performansını hesaplama açısından önemli ölçüde model geliştirebilir.

$$y_t = v + \phi^1 y_{t-1} + \dots + \phi^p y_{t-p} + \beta^1 x_{t-1} + \dots + \beta^s x_{t-s} + u_t \quad (3.1.1)$$

Burada,

$y_t \in R^k$: modellenmiş içsel seri

$x_t \in R^m$: modellenmemiş dışsal seri


p, s : maksimum gecikme emri

$\phi^\ell \in R^{k \times k}$: gecikmeli ℓ 'de içsel katsayı matrisi

$\beta^j \in R^{k \times m}$: gecikmeli j 'de dışsal katsayı matrisi

Burada $m = s = 0$ olduğunda VARX, VAR olarak görünür.

Şekil 3.1.1: VARX Modeli



Bir k boyutlu çok değişkenli zaman serileri $\{y_t\}_{t=1}^T$ ve m boyutlu dışsal çok değişkenli zaman serileri $\{x_t\}_{t=1}^T$ aşağıdaki doğrusal ilişkinin (başlangıçta koşullu

tutulması halinde), $VARX_{k,m}(p,s)$, olarak gösterilen düzen (p,s) , dışsal değişkenleri ile bir vektör otoregresyonunu izler.

$$y_t = v + \sum_{\ell=1}^p \phi^\ell y_{t-\ell} + \sum_{j=1}^s \beta^j x_{t-j} + u_t, \quad t = 1, \dots, T \quad (3.1.2)$$

Burada v , bir k -boyutlu sabit kesişme vektörünü ifade eder, ϕ^ℓ , lag $\ell = 1, \dots, p$ 'de bir $k \times k$ içsel katsayı matrisini temsil eder, β^j , lag $j = 1, \dots, s$ 'de bir $k \times m$ dışsal katsayı matrisini temsil eder, ve u_t ortalama ve sıfır olmayan kovaryans matrisi Σ_u ile bağımsız ve özdeş olarak dağıtılmış bir k boyutlu beyaz gürültü vektörünü gösterir. Denklem (3.1.1) de $\beta^j = 0, j = 1, \dots, s$ olması durumunda VARX'in özel bir durumu olan VAR'ı temsil eder.

İçinde yer alan tahmincilerin sayısının, T dizisinin uzunluğundan daha küçük olduğu düşük boyutlu bir ortamda, VARX modeli, $v, \phi = [\phi^{(1)}, \dots, \phi^{(p)}]$ ve $\beta = [\beta^{(1)}, \dots, \beta^{(s)}]$ ile çok değişkenli en küçük kareler tarafından tahmin edilebilir.

$$\operatorname{argmin}_{v, \phi, \beta} \sum_{t=1}^T \left\| y_t - v - \sum_{\ell=1}^p \phi^\ell y_{t-\ell} - \sum_{j=1}^s \beta^j x_{t-j} \right\|_F^2 \quad (3.1.3)$$

Burada, $\|A\|_F = \sqrt{\sum_{i,j} A_{i,j}^2}$, bir matris olan A 'nın Frobenius formunu gösterir, A , bir vektör olduğunda L_2 normuna düşer. Düzenlemenin eksikliğinde $VARX_{k,m}(p,s)$, $k(1 + kp + ms)$ regresyon parametrelerinin tahminini gerektirir.

3.2. VARX Tahmini

Yukarda elde edilen k, s, m, p, T 'ye göre küçüktür. Aşağıda yer alan model çözümlenerek en küçük kareler yöntemi ile $\hat{y}_{t+1}$ tahmin edebiliriz.

$$\min_{v, \beta, \phi} \left\| y_t - v - \sum_{\ell=1}^p \phi^\ell y_{t-\ell} - \sum_{j=1}^s \beta^j x_{t-j} \right\|_2^2 \quad (3.2.1)$$

Burada , $B = [B^1, \dots, B^2]$, $\theta = [\theta^1, \dots, \theta^S]$ 'dır. Denklem (3.2.1) $k(kp + ms + 1)$ en küçük kareler katsayılarının tahminini gerektirir.

3.2.1. VARX-L:VARX Modelleri için Cezalı Tahminciler

VARX modelinin yapılandırılmış bir ailesi olan VARX-L, yüksek boyutlu tahminlerde daha verimli ve sağlıklı sonuçlar elde etmemizi sağlar. VARX-L, VAR ve VARX modellerinin parametre alanını büyük ölçüde azaltmak için birkaç önemli skaler regresyon tekniğini bir vektör zaman serisi bağlamına uyarlar. VARX-L, hem düşük hem de yüksek boyutlu makroekonomik tahmin uygulamalarında ve simüle edilmiş veri örneklerinde etkinliğini göstermektedir.

VARX modelinde yapılandırılmış Lasso cezalı tahmincileri aşağıdaki gibidir;

- Temel Lasso (Basic Lasso)
- Grup Lasso (Group Lasso)
- Seyrek Grup Lasso (Sparse Group Lasso)
- Yuvalanmış Grup Lasso (Nested Group Lasso)

Denklem (3.2.1) formuna aşağıda yer alan dışbükey cezalar eklenir.

$$\lambda(P_y(\phi) + P_x(\beta)),$$

Burada;

- $\lambda \geq 0$ Penaltı parametresi
- $P_y(\phi)$ İçsel katsayılar üzerinde bir ceza fonksiyonu
- $P_x(\beta)$ Dışsal katsayılar üzerinde bir ceza fonksiyonu

$$\underset{v, \phi, \beta}{\operatorname{argmin}} \sum_{t=1}^T \left\| y_t - v - \sum_{\ell=1}^p \phi^\ell y_{t-\ell} - \sum_{j=1}^s \beta^j x_{t-j} \right\|_F^2 + \lambda(P_y(\phi) + P_x(\beta)) \quad (3.2.1.1)$$

3.2.1.1. Temel Lasso (Basic VARX-L)

Chiuso ve Pillonetto (2010) tarafından önerilen Temel VARX-L (Basic VARX-L), Seyrek Grup Lasso(Sparse Lag Group VARX-L)'nin özel bir durumu olarak görülebilir.

Aşağıda yer alan Seyrek Grup Lasso modelinde $\alpha = 1$ alındığında Temel Lasso (Basic Lasso) modeli elde edilir.

Seyrek Gruop Lasso(Sparsa Lag Gruop) modeli aşağıdaki gibidir;

$$P_y(\phi) = (1 - \alpha) \left(\sqrt{k^2} \sum_{\ell=1}^p \|\phi^\ell\|_F \right) + \alpha \|\phi\|_1, P_x(\beta) = (1 - \alpha) (\sqrt{k} \sum_{j=1}^s \sum_{i=1}^m \|\beta_{:,i}^j\|_F$$

$\alpha = 1$ alındığında Temel Lasso(Basic VARX-L) modeli ise aşağıdaki gibidir;

$$P_y(\phi) = \|\phi\|_1, \quad P_x(\beta) = \|\beta\|_1 \quad (3.2.1.1.1)$$

Temel VARX-L'nin yapısal muadilleri üzerindeki en büyük avantajı, hesaplanabilirliği ve izlenebilirliğidir. Friedman vd. (2010) tarafından yapılan çalışma, Lasso problemleri için popüler hale gelen koordinat iniş kullanımını içerir. Koordinat inişi, Temel VARX-L'nin her bir skaler eleman $[\phi, \beta]_{i,j}$ için alt problemlere ayrılması, bileşenlerin çözülmesi ve daha sonra yakınsamaya kadar güncellenmesidir. Bu yaklaşım, Temel VARX-L bağlamında, her bir alt problemin kapalı bir çözüme sahip olmasından dolayı, hesaplama açısından önemlidir. Tseng (2001), küresel yakınsamanın, koordinat iniş çerçevesindeki bireysel alt problemleri çözmekten kaynaklandığını ortaya koymaktadır.

3.2.1.2. Neden Cezalı Regresyon Kullanılır?

1. Hızlı ve ölçeklenebilir çözüm algoritmaları sunar.
2. Seyrekliğin uygulanmasını sağlar.
3. Tek adımda değişken seçimi ve tahmini yapılır.
4. Tekrar üretilebilir.
5. Karmaşık ya da öznel hiper-parametrelerden bağımsız değildir.

3.2.1.2.1. Mevcut Boyut Azaltma Teknikleri

VARX'in parametre alanını azaltmak için kullanılan yöntemler şunlardır;

1. Gonzalo ve Pitarakis (2002) yaptıkları çalışmalarında Akaike ve Bayes bilgi kriterlerini (AIC/BIC) yöntemini kullanmışlardır.
2. Klasik Bayes Yöntemleri (Bayesian VAR) seyrek çözümler sunmamaktadır.
3. Seyrekliği (Stokastik arama değişkeni seçimi) empoze eden modern Bayes yaklaşımları çok zayıftır.
4. Lasso yönelimli düzenleme prosedürleri genellikle zamana bağlı problemlere uyarlanmamıştır.


3.3. Cezalı Parametre Seçimi

Düzenleme (ayar) parametresi, λ , pratikte bilinmemektedir ve tipik olarak çapraz doğrulama ile seçilmektedir. $[\phi, \beta]$ 'in tüm bileşenlerinin sıfır olacağı ve log-lineer artışlarda azaldığı en küçük değerle başlayan ve potansiyel ceza parametrelerinden oluşan bir ızgara seçilir. Bu değer her prosedür için kendi algoritmaları ile çıkarılabilir. Izgara nokta sayısı N ve ızgara derinliği kullanıcı girişine bırakılmıştır. Derin bir ızgara ve çok sayıda ızgara noktası, artan hesaplama maliyetleriyle sonuçlanır ve genellikle öngörme performansını geliştirmez.

Zaman bağımlılığı nedeniyle, problemlerin geleneksel K katlama çapraz doğrulaması için çok uygun değildir. Bunun yerine, Banbura vd. (2009) yaptıkları çalışmalarında $h = 1, 2, 3 \dots$ olan h -adımı tahmin eden ortalama kare tahmin hatasını (MSFE) en aza indirerek optimal ceza parametresini seçmeyi önermişlerdir. Bu kısımda veriler, başlangıç, eğitim ve değerlendirme olmak üzere üç kısımda işleme alınır. Burada zaman indekslerini; $T_1 = \left\lfloor \frac{T}{3} \right\rfloor$, $T_2 = \left\lfloor \frac{2T}{3} \right\rfloor$, şeklinde tanımlarız.

T_1 'e kadar olan tüm verileri kullanıp bir model kurarak $\hat{y}_{T_1+1}^{\lambda_i}$, $i = 1 \dots N$ tahminini yapıldıktan sonra validasyon sürecine başlanır. Ardından, tek seferde sırayla bir gözlem eklenerek ve bu işlem $T_2 - h$ zamanına kadar tekrarlanır. Bu süreç aşağıdaki şekilde gösterildiği gibidir:

Şekil 3.3.1: Verilerin Tahmin İşlem Aşaması



$\hat{\lambda}$ 'i küçültücü olarak seçilip aşağıdaki denklemde yer aldığı şekilde kullanılır;

$$MSFE_{(\lambda_i)} = \frac{1}{T_2 - T_1 - h + 1} \sum_{t=T_1}^{T_2-h} \left\| \hat{y}_{t+h}^{\lambda_1} - y_{t+h} \right\|_F^2 \quad (3.3.1)$$

Son olarak, $t = T_2 - h$ 'nın orijinal zaman kaynaklarından $t = T - h$ zamanına kadar, $\hat{\lambda}$ 'in h -adım ileriye yönelik tahmin doğruluğu değerlendirilir. İstenirse, ilave kriterler yerine konulabilir. MSFE, en küçük kareler objektif fonksiyonunu kullanmanın en doğal kriteridir. Çapraz doğrulama prosedürünü paralelleştirmekten ziyade, MSFE yaklaşımı, önceki döneme ait bir başlangıç veya “warm start,” sonucunu kullanır bu da hesaplama süresini önemli ölçüde azaltır.

VAR bağlamında, çok adımlı ön tahminler elde etmek için iki olası yöntem vardır. Bu yöntemler, yinelenen tek adımlı önceden tahminler veya doğrudan daha uzun ufuk tahmini şeklindedir. VAR bağlamında, Clark ve McCracken (2013) tarafından h adımlı ön tahminler aşağıdaki gibi modellenmiştir:

$$\hat{y}_{t+h|t} = \hat{v} + \sum_{\ell=1}^p \hat{\phi}^{\ell} \hat{y}_{t+h-\ell|t} , \quad (3.3.2)$$

alternatif ise, h adımlı ön tahminleri doğrudan öngörmeyi içeren model

$$\hat{y}_{t+h} = \hat{v} + \sum_{\ell=1}^p \hat{\phi}^{\ell} y_{t+1-\ell} , \quad (3.3.3)$$

şeklindedir.

Her iki yaklaşımın da avantajları vardır; Marcellino vd. (2006)'ne göre doğrudan yaklaşım, VAR'ın belirtilmemesi durumunda daha doğru tahminler sağlayabilir ancak eğer model doğru bir şekilde belirtilmişse, yinelenen yaklaşım teorik olarak daha verimlidir. VAR ayarında, BigVAR, tahminlerin ufkunu birden fazla olduğunda optimizasyon yaparken ya yinelenen ya da doğrudan tahminlerin yapılmasına izin verir. Dışsal değişkenlerin tahminine geri dönülmediği için VARX ayarında sadece doğrudan tahminler mevcuttur.

3.4. BigVAR

BigVAR, geleneksel vektör otoregresyonuna (VAR) yapısal olarak uygulanan cezalar ve dışsal değişkenler (VARX) çerçevesine sahip vektör otoregresyonu uygulayarak yüksek boyutlu zaman serilerinin eş zamanlı tahmin edilmesini sağlar. Bu alanda yer alan yöntemler, makroekonomi, finans ve internet trafiği gibi zamana bağlı verileri kullanan pek çok uygulamada kullanılabilir.

R programında yer alan BigVAR paketi ile geleneksel vektör otoregresyonuna (VAR) yapısal cezalar ve dışsal değişkenlere sahip vektör otoregresyonu (VARX) uygulayarak yüksek boyutlu zaman serilerinin eş zamanlı tahmin edilmesini sağlar. Ayrıca makine öğrenimi ve sinyal işleme literatüründen zamana bağlı bir ayar için çözüm algoritmalarını genişletir: sıralı çapraz doğrulama ile regülasyon parametresinin seçilmesi ve geleneksel yöntemlere göre performans tahmininde önemli gelişmeler sağlar.

Yıllar boyunca, vektör otoregresyon (VAR) ve modifiye edilmemiş dışsal değişkenlere sahip vektör otoregresyonu (VARX), çok değişkenli zaman serilerini tahmin etmede temel araçlar olarak hizmet etmiştir. Ancak, regülasyonun yokluğunda, VAR ve VARX aşırı derecede paramparça edilmekte, çoğu kez uygulayıcıları seriden modele indirgenmiş bir alt kümeyi belirlemeye zorlamaktadır seri olarak modele indirgenmiş bir dizi alt dizisini keyfi olarak belirtmeye zorlamaktadır. BigVAR, veri güdümlü bir şekilde sıfır kısıtlamaları koyarak birçok potansiyel kullanışlı serinin dahil edilmesine izin verir. Ayrıca, tahminler sadece VARXL çerçevesinin kullanılmasıyla birlikte sunulan serilerin bir alt kümesinden isteniyorsa Nicholson ve arkadaşlarına(2015) göre BigVAR,

modellenmiş içsel serilerin tahminlerini iyileştirmek için modifiye edilmemiş dışsal seriden gelen bilgileri etkin bir şekilde kullanabilir.



DÖRDÜNCÜ BÖLÜM

4. UYGULAMA

R programında yer alan BigVAR paketi kullanılarak VAR ve VARX modelinin öngörü analizi yapılmıştır. Uygulamada kullanılan veriler Dünya Bankası web sayfasından alınan gerçek verilerdir. Veriler Türkiye'ye ait 1968-2017 yılları arasında yer alan Gayri Safi Yurtiçi Hasıla(GSYH), Ürün Hizmet İhracatı(ÜHİ), Net Tüketim Harcamaları(NTH) ve Tüketici Fiyatları(TF) değerlerini içerir.


Veriler kullanılarak sağlıklı parametre tahminleri elde edip, geleceğe yönelik etkili kararlar almak için uygulama yapılmaktadır. Uygulama sonucunda tahmin edilen modelin sonuçlarına bakarak model seçiminin doğruluğu anlaşılır. Çalışmanın bu bölümünde aynı veriler kullanılarak VAR ve VARX modelleri kurulum modellerin tahmin sonuçları karşılaştırılacaktır. Sonuçlara göre hangi modelin tahmin açısından daha başarılı olduğu analiz edilecektir.

4.1. 50 Yıllık GSYH, ÜHİ, NTH, TF: Türkiye Örneği

Bir ülkenin ekonomik gücünü gösteren en önemli parametre GSYH'dir. Gelişmemiş olan ülkeler düşük bir GSYH'ya sahiptir. İhracat, ülkenin üretim sektörünü gösteren bir etmendir. Ülke hangi sektörde başarılı ise o sektöre dayalı ihracat yapar. Net tüketim harcamaları, toplumun alım gücünün gösteren etmenlerden biridir. Alım gücü yüksek olan toplumlar refah düzeyi yüksek olan toplumdur. Tüketim harcamaları, bir ülkenin, belirli bir zamanda toplumun mal ve hizmet ihtiyaçlarını karşılamak için yaptığı toplam harcama tutarıdır.

Uygulamada, VAR ve VARX modelinde Temel Lasso (Basic Lasso) cezalı tahmincisi kullanılarak öngörü yapılmıştır. Tahmin sonuçları tablo ve grafiklerle sunulmuştur.

Grafik 4.1.1: Türkiye 1968-2017, Gayri Safi Yurt İçi Hasıla, Ürün Hizmet İhracatı, Nihai Tüketim Harcamaları, Tüketici Fiyatları Zaman Serisi Grafiği



Grafik 4.1.1 üç bölümden oluşmaktadır. İlk bölümde tüm veriler kullanılarak model kurularak tahmin sürecine başlanır. İkinci bölümde ideal cezalı parametre modele dahil edilir. $\hat{\lambda}$ 'i küçültücü olarak seçilir. Üçüncü bölümde $\hat{\lambda}$ 'in h -adım ileriye yönelik tahmin doğruluğu değerlendirilir.

Tablo 4.1.1: Çapraz Doğrulama ile VAR ve VARX Modeli Tahmin Sonuçları

*** BIGVAR MODEL Results *** Structure [1] "Basic" Forecast Horizon [1] 1 Minnesota VAR [1] FALSE Maximum Lag Order [1] 4 Optimal Lambda [1] 398.6802 Grid Depth [1] 500 Index of Optimal Lambda [1] 59 In-Sample MSFE [1] 357.757 BigVAR Out of Sample MSFE [1] 224.981 *** Benchmark Results *** Conditional Mean Out of Sample MSFE [1] 1272.105 AIC Out of Sample MSFE [1] 180.75 BIC Out of Sample MSFE [1] 178.082 RW Out of Sample MSFE [1] 88.584	*** BIGVAR MODEL Results *** Structure [1] "Basic" Forecast Horizon [1] 1 Minnesota VAR [1] FALSE VARX Specs \$`k` [1] 3 \$s [1] 2 \$contemp [1] FALSE Maximum Lag Order [1] 4 Optimal Lambda [1] 67.4563 Grid Depth [1] 500 Index of Optimal Lambda [1] 65 In-Sample MSFE [1] 68.1 BigVAR Out of Sample MSFE [1] 27.855 *** Benchmark Results *** Conditional Mean Out of Sample MSFE [1] 94.298 AIC Out of Sample MSFE [1] 28.298 BIC Out of Sample MSFE [1] 28.298 RW Out of Sample MSFE [1] 45.279
---	--

Çapraz doğrulama yöntemi kullanılarak VAR ve VARX modelinin tahmini yapılmıştır. Tablo, iki modelin ceza yapısı, maksimum gecikme sayısı, seçilen cezalı parametre (λ) ile hem örnek içi MSFE hem de örnek dışı MSFE gibi özelliklerini görüntüler. Ayrıca VARX tablosunda içsel değişken sayısı olan k ve dışsal değişken gecikme sayısı olan s değerleri belirtilmiştir. AIC ve BIC tahmin değerleri kıyaslandığında VARX modelinde daha küçük değer verdiği görülmektedir. VAR ve VARX modelleri tahmin sonuçları karşılaştırıldığında yüksek boyutlu tahmin uygulamalarında VARX modelinin daha iyi öngöründe bulunduğu görülmektedir.

Tablo 4.1.2: VAR ve VARX Modelinde Cezalı Tahminci Kullanılarak Yapılan Tahmin Sonuçlarını Karşılaştırma Tablosu


VAR Modeli k=4 s=0 m=0	AIC	BIC	Mean MSFE	Mean SD	Optimal Lambda
p=1	172,478	172,478	1120,935	97,24753	155,1133
p=2	172,436	172,436	1169,419	103,1562	217,1531
p=3	171,897	171,897	1225,07	109,4884	235,9036
p=4	180,75	178,082	1272,105	114,8117	398,6802
p=5	1299,868	566,153	1331,641	121,1293	860,5315
p=6	2086,447	1756,345	1390,325	127,0724	455,3668
p=7	1296,126	1296,126	1453,952	133,4142	444,0419
p=8	1193,651	1131,406	1516,104	139,6922	956,2832

VARX Modeli k=3 s=2 m=1	AIC	BIC	Mean MSFE	Mean SD	Optimal Lambda
p=1	28,397	28,397	104,9196	16,4608	29,26864
p=2	28,397	28,397	104,9196	16,4608	33,18388
p=3	28,381	28,381	99,07335	16,09277	60,47933
p=4	28,298	28,298	94,29774	15,72135	64,45625
p=5	28,971	28,32	89,79724	15,2579	90,26243
p=6	106,521	88,905	85,69966	15,03024	108,3787
p=7	175,118	160,661	81,2919	14,66077	80,64263
p=8	164,776	153,256	76,16132	14,09833	70,16074

Yukarıdaki tabloda da görüldüğü gibi gecikme sayısı olan p değeri değiştiğinde AIC ve BIC değerleri de değişmektedir. Gecikme değeri değiştiğinde bile VARX modelinde AIC ve BIC değeri VAR modelindeki değerlerine göre minimum çıkmaktadır. Çalışmamızda tahmin hatasını (MSFE) en aza indirecek optimal ceza parametresini

seçerek tahmin uygulaması yapılmıştır. Sonuçlara bakıldığında MSFE değerini minimum yapan modelin VARX modeli olduğu anlaşılmaktadır.


Grafik 4.1.2: VAR ve VARX Modelinde Cezalı Tahminci Optimal λ Değeri Konumunun Karşılaştırma Tablosu



VAR ve VARX modelinde her λ değeri için örnek MSFE değerini minimum yapan değer elde edilmiştir. $\hat{\lambda}$ 'nın şebekenin ortasına yakın olması idealdir. Alt sınırdaki olması,

şebekenin derinliğini artırarak, gelişmiş tahmin performansını sağlar. Eğer alt sınırdaki değilse "gran" argümanının ilk parametresini artırarak daha derin bir ceza ızgarası oluşturabiliriz. İzgaranız yeterince derine inmiyorsa, tahmin sonuçlarınız en uygun olmayabilir, ancak eğer çok derinse, programın çalışması için önemli miktarda zaman alabilir ve tahmin performansını geliştirmez. VAR ve VARX modelinde λ' 'nin konumu incelendiğinde VARX modelinde daha derinde yani daha küçük olduğu görülmektedir. Bundan dolayı VARX modelin tahmin performansı açısından daha etkili olduğu anlaşılmaktadır.

Grafik 4.1.3: VAR ve VARX Modeline Ait Seyreklik Grafiği



Seyreklik grafiği tahmin edilen son katsayı matrisi $[\phi, \beta]$ 'nin her katsayısının büyüklüğünü çizmek için seyreklik grafiğini sunar. Koyu gölgeleme daha büyük katsayıları gösterir. VARX modelinde içsel değişken $k = 3$, dışsal değişken $m = 1$, içsel

değişkenlerin gecikme sayısı $p = 4$, dışsal değişken gecikme sayısı $s = 2$ olarak grafik çizilmiştir. VAR modelinde dışsal değişken olmadığı için kullanılan verideki parametre sayısı 4 değerini değişken sayısı olarak almış ve $p = 4$ gecikme değerinde grafik çizilmiştir.



BEŞİNCİ BÖLÜM

5. SONUÇ

Bu çalışmada Bu çalışmada zaman serileri, VAR modeli ve VARX modeli hakkında teorik olarak genel bilgiler verilmiştir. Son yıllarda oldukça popüler olan R paket programı kullanılmış ve R programında yer alan BigVAR paketi kullanılarak uygulama yapılmıştır.

Uygulama kullanılan veriler Dünya Bankası web sayfasından alınan gerçek verilerdir. Türkiye'ye ait 1968-2017 yılları arasında yer alan Gayri Safi Yurtiçi Hasıla(GSYH), Ürün Hizmet İhracatı(ÜHİ), Net Tüketim Harcamaları(NTH) ve Tüketici Fiyatları(TF) verileri kullanılmıştır.

Uygulama bölümünde VAR ve VARX metodolojisine uygun model kurularak verilere ait tahmini değerlerin ileriye dönük nasıl bir seyir izlediği analiz edilmiştir. VAR ve VARX modeline yapısal ceza uygulayarak tahmin performansı hesaplanmıştır.

VARX modelinde, değişkenler hem içsel hem dışsal olarak kabul edilmektedir. VARX modeli, $VARX_{k,m}(p,s)$ olarak gösterilir. Uygulamamız da bu model $VARX_{3,1}(4,2)$ şeklindedir. Kullanılan verideki parametre sayısı 4 olduğundan k değeri 3 ve m değeri 1 alınmıştır. k değeri içsel değişken sayısı, m değeri dışsal değişken sayısı olarak alınır. p , içsel değişkene ait gecikme değerini s , dışsal değişkene ait gecikme değerini belirtir. Değişkenlerin sağlıklı tahminlerini elde etmek için en uygun gecikme sayısı(p ve s değerleri) belirlenmiştir. AIC ve BIC değerleri $p = 4$ alındığında en düşük değeri vermektedir. Amaç, AIC ve BIC değerini en küçük değer yapan p gecikme değerini almaktır. Bu durumda gecikme sayısının AIC ve BIC değerleri üzerinde etkili olduğu sonucuna varılmaktadır.

VAR modelinde tüm değişkenler içsel kabul edilerek kendi aralarındaki karşılıklı ilişkileri incelenmektedir. Uygulamamızda VAR modeli $VARX_4(3)$ şeklindedir. VAR modelinde içsel-dışsal değişken ayrımı yapılmadığı için veriye ait 4 parametrenin tamamını alarak tahmin gerçekleştirilmiştir. VARX modelinde $m = s = 0$ değeri alındığında VAR modeli elde edilmektedir.

Bu alıřmada ama, VAR ve VARX modelleri kullanılarak hangi modelin, tahmin bařarıřı aısından daha etkili sonu verdiđini analiz etmektir. Bundan dolayı VAR ve VARX modeline ait tahmin deđerleri ayrı ayrı verilen tablolar üzerinden karřılařtırılarak incelenmiřtir. VAR modeli ile yapılan tahminde AIC ve BIC deđerleri yksek ıkarken VARX modelinde dřk ıkmaktadır. Karřılařtırma sonularına bakarak VARX modelinin tahmin bařarıřı aısından daha etkili sonu verdiđi grlebilir.



KAYNAKÇA

- Baltagi, B.H., (2003), A Companion to Theoretical Econometrics, (1. edition), Blackwell Publishing, UK.
- Chatfield, C., (1980), The Analysis of Time Series: An Introduction, (2. edition), Chapman & Hall/CRC, Newyork.
- Cornell Universty, BigVAR: Tools for Modeling Sparse High-Dimensional Multivariate Time Series, < <https://arxiv.org/abs/1702.07094> > (04.11.2018)
- Enders, W., (2004), Applied Econometrics Time Series, (2. edition), John Wiley & Sons, Newyork.
- Gujarati, D.N., (2004), Basic Econometrics, (4. edition), The McGraw- Hill Companies, Newyork.
- Granger, C.W.J. and Newbold, P. (1977), Forecasting Economic Time Series, (2. edition), Academic Pres, London.
- Johnston, J. and Dinardo, J. (1997), Econometric Methods, (16. edition), McGraw-Hill International Edit, Newyork.
- Kutlar, A., (2005), Uygulamalı Ekonometri, (2. baskı), Nobel Akademik Yayıncılık, Ankara.
- Maddala, G.S., (1992), Introduction to Econometrics, (2. Edition), Macmillan Publishing Company, Newyork.
- Serper, Ö., (1996), Uygulamalı İstatistik 2, (1. baskı), Filiz Kitabevi, İstanbul.
- Tarı, R., (2008), Ekonometri, (5. baskı), Avcı Ofset, İstanbul.

Tarı, R. ve Bozkurt, H.,“ Türkiye’de İstikrarsız Büyümenin VAR Modelleri İle Analizi (1991:1-2004:3)”, *İstanbul Üniversitesi İktisat Fakültesi Ekonometri ve İstatistik Dergisi*, 2006, (4), ss.12-28.

TERZİ, H., “Türkiye’de Enflasyon ve Ekonomik Büyüme İlişkisi (1924-2002)”, *Gazi Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 6/2004, (3), ss.59-75.

Zaman Serileri Analizi, Ankara Üniversitesi Açık Erişim Sistemi
<acikarsiv.ankara.edu.tr/> (11.11.2018).

World Bank, (2018) <<https://databank.worldbank.org/data/source/world-development-indicators>>(02.12.2018)

Will Nicholson, BigVAR, <<http://www.wbnicholson.com/BigVAR.html>>(10.11.2018).

Will Nicholson, BigVAR User's Guide Dimension Reduction Procedures for Multivariate Time Series, <<http://www.wbnicholson.com/BigVAR.pdf>> (5.11.2018).

Will Nicholson, VARX-L,< <http://www.wbnicholson.com/Nicholsonetal2015.pdf>> (05.11.2018)

EK-1: VARX KOMUTLARI

```
library(BigVAR)
Y <- VERI
VERI <- as.matrix(VERI)
VARX=list()
VARX$k=3
VARX$s=2
T1=floor(nrow(VERI)/3)
T2=floor(2*nrow(VERI)/3)
Model1=constructModel(VERI,p=4,struct="Basic",gran=c(500,100),
                      cv="Rolling",verbose=TRUE,VARX=VARX,T1=T1,T2=T2)
BigVAR.est(Model1)
plot(Model1)
results=cv.BigVAR(Model1)
results
predict(results,n.ahead=1)
str(results)
plot(results)
SparsityPlot.BigVAR.results(cv.BigVAR(Model1))
```

EK-2: VAR KOMUTLARI

```
library(BigVAR)
Y <- VERI
VERI <- as.matrix(VERI)
T1=floor(nrow(VERI)/3)
T2=floor(2*nrow(VERI)/3)
Model2=constructModel(VERI,p=4,struct="Basic",gran=c(500,100),
  verbose=TRUE,T1=T1,T2=T2,IC=TRUE)
plot(Model2)
results=cv.BigVAR(Model2)
results
plot(results)
predict(results,n.ahead=1)
str(results)
plot(results)
SparsityPlot.BigVAR.results(cv.BigVAR(Model2))
```

EK-3: VERİLER

GDP	ÜHİ	NTH	TF
6,777996	3,682539683	61,01587302	0,401606427
4,081146	3,595890411	61,01598174	7,866666666
3,233509	4,427480916	62,54452926	6,929851669
5,566695	5,319587629	67,67010309	15,74308215
7,425788	6,018678658	67,27775856	11,66666667
3,262335	7,032967033	69,06593407	15,43965565
5,594474	5,728116176	71,56111335	15,81521476
7,174113	4,421346572	69,95035681	19,19973241
10,46118	4,859086492	67,48056365	17,36293802
3,40667	3,815204014	69,37423081	27,08090499
1,502933	4,146911941	70,06131867	45,28457197
-0,62411	3,218026709	67,22220222	58,69202752
-2,44735	5,16193171	72,70485222	110,1732087
4,856649	8,236932034	69,073535	36,57546945
3,563228	11,86405139	69,36772078	30,83768071
4,971081	12,47321262	71,66506062	31,40448868
6,712016	15,60660269	71,40895845	48,37782277
4,241336	15,86072288	65,7172572	44,96020668
7,012031	13,31243772	61,54998209	34,61941993
9,485539	15,58084042	76,10071478	38,84621339
2,320737	18,65397042	71,10694953	73,66666667
0,290244	16,20291575	74,95032419	63,27255278
9,266147	13,36510285	79,54147991	60,31270205
0,720279	13,84113011	83,02056333	65,96942143
5,035635	14,39223573	82,4584129	70,07279114
7,651265	13,67380285	81,98725333	66,09708259
-4,66815	21,36213121	81,61502818	106,2627286
7,878267	19,8916075	81,09734624	88,10770257
7,379664	21,54265814	78,84414916	80,34690278
7,577664	24,58171768	80,29648213	85,7332416
2,308213	20,56833735	75,28106079	84,6413357
-3,38931	18,57785908	78,9042167	64,8674792
6,640061	19,44877184	79,3028916	54,91538241
-5,96231	26,57792143	78,10751967	54,40018404
6,430279	24,46069454	77,29599146	44,96412355
5,608255	22,24313335	78,64169101	25,29636788
9,644323	22,75048113	77,41340925	10,58423624
9,009853	21,01778127	76,3680308	10,13840492
7,109703	21,65041805	75,28503538	9,597242123

5,030458	21,22022457	76,13540331	8,75618091
0,845251	22,82625733	75,3179035	10,44412838
-4,70447	22,57367254	77,76669193	6,250976631
8,487372	20,44880782	78,02883717	8,566444206
11,1135	22,26240792	76,86943136	6,471879671
4,78994	23,66736586	76,60642858	8,891569965
8,491309	22,27225514	76,03260356	7,493090305
5,166691	23,76433477	74,85205847	8,854572714
6,085887	23,34593035	74,24598048	7,670853648
3,183832	21,96508274	74,65884179	7,775134153
7,418644	24,83934749	73,63151619	8,85463525



ÖZGEÇMİŞ

KİŞİSEL BİLGİLER	
Adı ve Soyadı	Emsal Çağla AVCU
Uyruğu	T.C.
Doğum Tarihi ve Yeri	1989 Elazığ
Medeni Hali	Bekar
e-mail	emsalcagla.avcu@hotmail.com

EĞİTİM BİLGİLERİ		
Derece	Eğitim Birimi	YIL
Yüksek Lisans	İnönü Üniversitesi İktisadi İdari Bilimler Fakültesi Ekonometri Bölümü	2017-2019
Lisans	Fırat Üniversitesi Spor Bilimleri Fakültesi Antrenörlük Bölümü	2015-2019
Lisans	İnönü Üniversitesi İktisadi İdari Bilimler Fakültesi Ekonometri Bölümü	2008-2012
Lisans	Elazığ Mehmet Akif Ersoy Lisesi	2003-2006

İŞ DENEYİMLERİ			
TARİH	DENEYİMİN GEÇTİĞİ KURUM/KURULUŞLAR	ALANLAR	YER
2013-2018	Şekerbank T.A.Ş.	Bireysel Bankacılık Servisi	Elazığ