

**T.C.  
SAKARYA ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ**

**LINEER MODELLERDE BAZI YANLI TAHMİN  
EDİCİLERİN ORTALAMA HATA KARELER  
ÖLÇÜTÜNE GÖRE KARŞILAŞTIRILMASI**

**YÜKSEK LİSANS TEZİ**

**Esra HOŞ SÖZ**

**Enstitü Anabilim Dalı : MATEMATİK**  
**Enstitü Bilim Dalı : UYGULAMALI MATEMATİK**  
**Tez Danışmanı : Yrd. Doç. Dr. Nesrin GÜLER**

**Mayıs 2015**

T.C.  
SAKARYA ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ

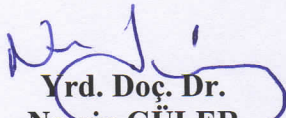
LİNEER MODELLERDE BAZI YANLI TAHMİN  
EDİCİLERİN ORTALAMA HATA KARELER  
ÖLÇÜTÜNE GÖRE KARŞILAŞTIRILMASI

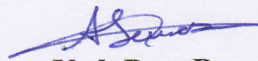
YÜKSEK LİSANS TEZİ


Esra HOŞSÖZ

Enstitü Anabilim Dalı : MATEMATİK  
Enstitü Bilim Dalı : UYGULAMALI MATEMATİK

Bu tez 16/06/ 2015 tarihinde aşağıdaki jüri tarafından oybirliği ile kabul edilmiştir.

  
Yrd. Doç. Dr.  
Nesrin GÜLER  
Jüri Başkanı

  
Yrd. Doç. Dr.  
Ayşe SÖNMEZ  
Üye

  
Yrd. Doç. Dr.  
Hakan YAKUT  
Üye

## **BEYAN**

Tez içindeki tüm verilerin akademik kurallar çerçevesinde tarafımdan elde edildiğini, görsel ve yazılı tüm bilgi ve sonuçların akademik ve etik kurallara uygun şekilde sunulduğunu, kullanılan verilerde herhangi bir tahrifat yapılmadığını, başkalarının eserlerinden yararlanılması durumunda bilimsel normlara uygun olarak atıfta bulunulduğunu, tezde yer alan verilerin bu üniversite veya başka bir üniversitede herhangi bir tez çalışmasında kullanılmadığını beyan ederim.

Esra HO SÖZ

15.05.2015

## **TE EKKÜR**

Çalı mamın tüm a amalarında bilgi ve tecrübelerinden yararlandı ım, yardımlarını benden esirgemeyen danı man hocam Sayın Yrd. Doç. Dr. Nesrin GÜLER'e, maddi ve manevi destekleriyle daima yanımda olan sevgili aileme en içten te ekkürlerimi sunarım.

Ayrıca bu çalı mamın maddi açıdan desteklenmesine olanak sa layan Sakarya Üniversitesi Bilimsel Ara tırma Projeleri (BAP) Komisyon Ba kanlı ına (Proje No: 2015-50-01-004) te ekkür ederim.

## Ç NDEK LER

TE EKKÜR.....	i
Ç NDEK LER .....	ii
S MGELER VE KISALTMALAR L STES .....	v
ÖZET .....	vi
SUMMARY .....	vii
BÖLÜM 1.	
G R .....	1
BÖLÜM 2.	
ÖN B LG LER.....	5
2.1. Bir Matrisin Sütun Uzayı, Satır Uzayı ve Rankı .....	5
2.2. Bir Matrisin Tersisi .....	6
2.3. Bir Matrisin Özde erleri ve Özvektörleri.....	6
2.4. Kuadratik Formlar, Pozitif Kararlı ve Negatif Kararlı Matrisler.....	7
2.5. Parçalanmı Matrisler .....	8
2.6. Lineer Denklem Sistemleri.....	9
2.7. Karesel ve Lineer Formların Türevleri .....	10
2.8. Rasgele Vektörler ve Bazı istatistiksel Kavramlar .....	10
BÖLÜM 3.	
BAZI YANLI TAHM N ED C LER.....	12
3.1. Giri .....	12
3.2. Alı ılmı En Küçük Kareler Tahmin Edicisi (OLSE).....	12
3.3. Alı ılmı Karma Tahmin Edici (OME).....	14
3.4. Rasgele Kısıtlı Liu Tahmin Edicisi (SRLE) .....	15
3.5. Temel Bile enler Regresyon (PCR) Tahmin Edicisi.....	16

3.6. Rasgele Kısıtlı Temel Bile enler Regresyon (SRPCR) Tahmin Edicisi.....	17
3.7. A ırlıklı Rasgele Kısıtlı Temel Bile enler Regresyon (WSRPCR) Tahmin Edicisi.....	19
3.8. Hata Kareler Ortalaması (MSE) .....	19
3.9. Bazı Yanlı Tahmin Edicilerin MSE Ölçütüne Göre Kar ıla tırılmaları.....	20
3.9.1. SRPCR ve PCR tahmin edicilerinin kar ıla tırılması.....	20
3.9.2. WSRPCR ve PCR tahmin edicilerinin kar ıla tırılması.....	23
3.9.3. WSRPCR ve SRPCR tahmin edicilerinin kar ıla tırılması...	26
3.9.4. SRLE ve SRPCR tahmin edicilerinin kar ıla tırılması .....	27
3.9.5. SRLE ve WSRPCR tahmin edicilerinin kar ıla tırılması.....	29

#### BÖLÜM 4.

BAZI GENELLE T R LM YANLI TAHM N ED C LER .....	31
4.1. Giri .....	31
4.2. Genelle tirilmi En Küçük Kareler Tahmin Edicisi (GLSE).....	31
4.3. Genelle tirilmi Alı ılmı Karma Tahmin Edici (GOME) .....	32
4.4. Genelle tirilmi Rasgele Kısıtlı Liu Tahmin Edicisi (GSRLE).....	33
4.5. Genelle tirilmi Temel Bile enler Regresyon (GPCR) Tahmin Edicisi.....	33
4.6. Genelle tirilmi Rasgele Kısıtlı Temel Bile enler Regresyon (GSRPCR) Tahmin Edicisi.....	35
4.7. Genelle tirilmi A ırlıklı Rasgele Kısıtlı Temel Bile enler Regresyon (GWSRPCR) Tahmin Edicisi.....	36
4.8. Bazı Genelle tirilmi Yanlı Tahmin Edicilerin MSE Ölçütüne Göre Kar ıla tırılması .....	36
4.8.1. GSRPCR ve GPCR tahmin edicilerinin kar ıla tırılması.....	36
4.8.2. GWSRPCR ve GPCR tahmin edicilerinin kar ıla tırılması ..	39
4.8.3. GWSRPCR ve GSRPCR tahmin edicilerinin kar ıla tırılması	42
4.8.4. GSRLE ve GSRPCR tahmin edicilerinin kar ıla tırılması....	42
4.8.5. GSRLE ve GWSRPCR tahmin edicilerinin kar ıla tırılması.	45

BÖLÜM 5.	
SONUÇ VE ÖNERİLER .....	47
KAYNAKLAR.....	49
ÖZGEÇM .....	51

## SİMGELER VE KISALTMALAR LİSTESİ

$\mathbb{R}^{n \times 1}$	: $n$ boyutlu reel vektörler kümesi
$\mathbb{R}^{m \times n}$	: $m \times n$ boyutlu reel matrisler kümesi
$A, B, C, \dots$	: Matrisler
$(a_{ij})$	: Elemanları $a_{ij}$ olan matris
$x, y, z, \dots$	: Vektörler
$I$	: Birim matris
$A'$	: $A$ matrisinin transpozu
$A^{-1}$	: $A$ matrisinin tersi
$A^-$	: $A$ matrisinin genelleştirilmiş tersi
$\mathcal{C}(A)$	: $A$ matrisinin sütun uzayı
$\mathcal{C}(A')$	: $A$ matrisinin satır uzayı
$\mathcal{N}(A)$	: $A$ matrisinin sıfır uzayı
$r(A)$	: $A$ matrisinin rankı
$\det(A)$	: $A$ matrisinin determinanı
$E(\cdot)$	: Beklenen değer operatörü
$Cov(\cdot)$	: Kovaryans operatörü
$Var(A)$	: $A$ matrisinin varyansı
$\in$	: Elemanıdır
$=$	: Eşittir
$\Leftrightarrow$	: Ancak ve ancak
$\min$	: minimum



## ÖZET

Anahtar kelimeler: Çoklu iç ili ki, Alı ılmı En Küçük Kareler Tahmin Edicisi, Alı ılmı Karma Tahmin Edici, Temel Bile enler Regresyon Tahmin Edicisi, Ortalama Hata Kareler.

Lineer modellerde çoklu iç ili ki problemi oldu unda alı ılmı en küçük kareler tahmin edicisi (OLSE) parametreler için iyi bir tahmin edici olmayabilir. Çoklu iç ili ki probleminden kaynaklanan sorunların üstesinden gelebilmek için imdiye kadar literatürde çok sayıda alternatif yanlı tahmin edici önerilmi tir. Bu yanlı tahmin edicilerin performansları farklı ölçütlere göre de erlendirilir. Bu ölçütlerden biri ortalama hata kareler (MSE) ölçütüdür.

Bu çalı mada, alı ılmı karma tahmin edici (OME) ve temel bile enler regresyon (PCR) tahmin edicisi için kullanılan yakla ım kullanılarak genel lineer modeller altında rasgele kısıtlı bazı yanlı tahmin edicilerin performansları MSE ölçütüne göre kar ıla tırılmı tir.

Ik bölümde, lineer modeller tanıtılmı ve bu modeller altında bazı yanlı tahmin ediciler ile ilgili kısa bir literatür bilgisi verilmi tir. kinci bölümde, çalı mada kullanılan bazı temel kavramlar ve ispatsız teoremler ele alınmı tir. Üçüncü bölümde, bir lineer modelde bazı yanlı tahmin ediciler ele alınmı ve bunların MSE ölçütüne göre kar ıla tırılmaları verilmi tir. Dördüncü bölümde ise, üçüncü bölümde ele alınan kavramlar genel bir lineer model için ele alınarak genelle tirilmı tir. Son bölüm ise sonuç ve önerilerden olu maktadır.

# **COMPARISON OF SOME BIASED ESTIMATORS IN LINEAR MODELS IN TERMS OF MEAN SQUARED ERROR CRITERION**

## **SUMMARY**

Keywords: Multicollinearity, Ordinary Least Squares Estimator, Ordinary Mixed Estimator, Principal Components Regression Estimator, Mean Squared Error.

The ordinary least squares estimator (OLSE) may not be a good estimator for parameters when multicollinearity problem exists in linear models. To overcome the troubles that originated from multicollinearity problem, it has been proposed so many alternative biased estimators in literature until now. The performance of this biased estimators have been evaluated by different criteria. One of these criteria is mean squared error (MSE) criterion.

In this study, the performance of some stochastic restricted biased estimators have been compared with MSE criterion by using the approach which is used for the ordinary mixed estimator (OME) and the principal components regression (PCR) estimator.

In the first chapter, linear models have been introduced and short literature information related to some biased estimators has been given under these models. In the second chapter, some fundamental concepts and theorems which will be used in the whole of the work have been considered without proofs. In the chapter three, some biased estimators have been considered and compared with MSE criterion in a linear model. In the fourth chapter, the concepts discussed in the third chapter is generalized by taking for a general linear model. The last chapter consists of conclusion and proposals.

## BÖLÜM 1. GİRİŞ

Akıl ile gerçek dünyadaki olguları anlama-anlatma işine modelleme ve anlatımın kendisine model denir. Model, gerçek dünyada karşılaşılan bir problemin ilgili olduğu alanın kavram ve kanunlarına bağlı olarak ifade edilmesidir. Modellemede en çok kullanılan araçlar matematik ve istatistiktir. Özellikle rasgelelik içeren olgularla ilgili problemlerin modellenmesinde istatistik kullanılır [1]. İstatistik araştırmalarının ortak amaçlarından biri nedenselliği araştırmak, tahmin edicilerdeki veya bağımsız değişkenlerdeki bir değişimin bağımlı değişken üzerindeki etkisini incelemektir. Değişkenler arasındaki ilişkileri ortaya koyma ve ele alınan konu ile ilgili sonuç çıkarma ve tahminlerde bulunma problemlerinde sıklıkla kullanılan lineer modeller genel olarak

$$y = X\beta + v \quad (1.1)$$

şeklinde ifade edilir.

Gauss-Markov Teoremine [2] göre en küçük kareler tahmin edicisi

$$\hat{\beta}_{OLSE} = (X'X)^{-1} X'y$$

olarak tanımlanır. Bu tahmin edici yansız ve diğer lineer yansız tahmin ediciler arasında en küçük varyansa sahiptir. Bu nedenle ve uygun istatistiksel özelliklere sahip olmasından dolayı uzun zaman boyunca en iyi tahmin edici olarak kullanılmıştır. Lineer modellerde  $X$  model matrisinin sütunlarının lineer bağımsız olduğu varsayımı altında teorik olarak bazı sonuçlar elde edilmesine rağmen uygulamalarda genellikle  $X$  matrisinin sütunlarının lineer bağımlı olduğu durumlarla karşılaşılır. Bu durum çoklu ilişki problemine neden olur. Lineer

modellerde çoklu iç ili ki problemi oldu u durumlarda  $\hat{S}_{OLSE}$  iyi bir tahmin edici olmaz. Çünkü çoklu iç ili ki  $\hat{S}_{OLSE}$  'nin gerçek de erinden uzak olmasına ve varyansının büyük çıkmasına sebep olur. Çoklu iç ili ki probleminin üstesinden gelmek için bazı yöntemler kullanılır. Bu yöntemlerden biri yanlı tahmin edicileri kullanmaktır. Literatürde önerilen yanlı tahmin edicilerden Stein tahmin edicisi [3], temel bile enler regresyon (principal components regression, PCR) tahmin edicisi [4], alı ılmı ridge regresyon (ordinary ridge regression, ORR) tahmin edicisi [5] ve Liu tahmin edicisi [6] en çok bilinenleridir. Çoklu iç ili ki probleminin üstesinden gelmenin di er bir yöntemi ise, kesin veya rasgele kısıtlarla ek örneklem bilgisi kullanmaktır. Bu yöntem (1.1) modeli bir rasgele kısıt ile birleştirilerek Durbin [7], Theil ve Goldberger [8] ve Theil [9] tarafından kullanılmı ve s için tahmin edici olarak alı ılmı karma tahmin edici (ordinary mixed estimator, OME) önerilmi tir. (1.1) modeli

$$h = HS + e$$

rasgele kısıtı ile birlikte ele alındı ında

$$\hat{S}_{OME} = (X'X + H'W^{-1}H)^{-1}(X'y + HW^{-1}h)$$

olarak elde edilir. OME ve özellikleri için ayrıca [10-12] kaynaklarına bakılabilir. OME ve Liu tahmin edicisi birleştirilerek rasgele kısıtlı Liu tahmin edicisi (stochastic restricted Liu estimator, SRLE)

$$\hat{S}_{SRLE}(d) = F_d(X'X + H'W^{-1}H)^{-1}(X'y + H'W^{-1}h)$$

olarak Hubert ve Wijekoon [10] tarafından elde edilmi tir. Burada,  $F_d = (X'X + I)^{-1}(X'X + dI)$  ve  $0 < d < 1$  eklindedir.

Temel bile enler regresyonu ise, tahmin problemlerinin boyutunu indirgemedede kullanılan bir yaklaşımdır. (1.1) modeli üzerinde

$$y = XT'Ts + v = Zr + v$$

dönümü ele alındığında PCR tahmin edicisi

$$\hat{S}_{PCR} = T_r(T_r'X'XT_r)^{-1}T_r'X'y$$

olarak elde edilir [13]. Burada  $T \in \mathbb{R}^{p \times p}$  ortogonal matristir. PCR tahmin edicisi de çoklu iç ili kiyi gidermek için kullanılan yanlı tahmin edicilerden biridir ve ilk olarak Hotelling [14] tarafından önerilmiştir.

Bu ekiideki yanlı tahmin edicilerin performansları bazı farklı ölçütlere göre değerlendirilir. Bunlardan biri ortalama hata kareler (mean squared error, MSE) matrisinin kullanıldığı MSE ölçütüdür.  $\hat{S}$  tahmin edicisi için MSE matrisi,

$$M(\hat{S}) = E(\hat{S} - S)(\hat{S} - S)' = Var(\hat{S}) + Bias(\hat{S})Bias(\hat{S})'$$

olarak tanımlanır [13].  $S$  için herhangi iki tahmin edici  $\hat{S}_1$  ve  $\hat{S}_2$  olmak üzere, bu tahmin ediciler için MSE ölçütü

$$M(\hat{S}_1) - M(\hat{S}_2) \geq 0 \tag{1.2}$$

olarak ifade edilir [15]. Bu ifade  $\hat{S}_2$  tahmin edicisinin  $\hat{S}_1$  tahmin edicisinden üstün olduğunu anlamındadır.

Bu çalışmada (1.1) modelinde  $E(v) = 0$  ve  $Cov(v) = \sigma^2 I$  kabulü altında OME, SRLE, PCR tahmin edicisi, rasgele kısıtlı temel bileşenler regresyon (stochastic restricted principal components regression, SRPCR) tahmin edicisi ve ağırlıklı rasgele kısıtlı temel bileşenler regresyon (weighted restricted principal components regression, WSRPCR) tahmin edicisi ele alınmıştır ve bu yanlı tahmin edicilerden

hangisinin üstün olduğunu (1.2)'de verilen MSE ölçütü kullanılarak detaylı olarak incelenmiştir. Daha sonra (1.1) modelinde daha genel olan  $E(v)=0$  ve  $Cov(v)=\sigma^2V$  durumu kabul edilerek daha önce ele alınmış tahmin edicilerin tümünün genelleştirilmiş durumları ele alınmış ve MSE ölçütüne göre bu genel yanlı tahmin edicilerin karşılaştırılmaları yapılmıştır.

## BÖLÜM 2. ÖN B LG LER

Bu bölümde çalı manın di er bölümlerinde kullanılacak bazı tanımlar ve ispatsız olarak bazı teoremler verilecektir.

### 2.1. Bir Matrisin Sütun Uzayı, Satır Uzayı ve Rankı

**Tanım 2.1.1.**  $c_1x_1 + c_2x_2 + \dots + c_nx_n = 0$  olacak eilde tümü birden sıfır olmayan  $c_1, c_2, \dots, c_n$  skalerleri varsa,  $x_1, x_2, \dots, x_n \in \mathbb{R}^{n \times 1}$  vektörlerinin kümesine lineer ba ımlıdır, aksi takdirde lineer ba ımsızdır denir [16].

**Tanım 2.1.2.**  $A \in \mathbb{R}^{m \times n}$ ,  $a_1, a_2, \dots, a_n$  sütunlarına sahip olan bir matris olsun.  $x' = (x_1, x_2, \dots, x_n)$  vektörü için  $Ax = x_1a_1 + x_2a_2 + \dots + x_na_n$  ifadesi  $A$  matrisinin sütunlarının bir lineer kombinasyonunu gösterir.  $A$  matrisinin sütunlarının lineer kombinasyonu olarak ifade edilebilen tüm vektörlerin kümesine  $A$  matrisinin sütun uzayı denir ve  $\mathcal{C}(A) = \{y \in \mathbb{R}^{m \times 1} \mid y = Ax, x \in \mathbb{R}^{n \times 1}\}$  ekinde gösterilir.  $\mathcal{C}(A)$ ,  $A$  matrisinin sütunları tarafından üretilir [17].

**Tanım 2.1.3.**  $A$  matrisinin  $a_1, a_2, \dots, a_n$  satırları tarafından üretilen  $\mathbb{R}^{n \times 1}$  vektör uzayının alt uzayına  $A$  matrisinin satır uzayı denir ve  $\mathcal{C}(A')$  ile gösterilir [17].

**Tanım 2.1.4.**  $A$  matrisinin sıfır uzayı  $\mathcal{N}(A) = \{x \in \mathbb{R}^{n \times 1} \mid Ax = 0\}$  olarak tanımlanır [17].

**Teorem 2.1.5.**  $C$  matrisi  $A \in \mathbb{R}^{m \times n}$  matrisinin satır indirgenmi e olon biçimi olsun.  $A$  matrisinin satır uzayı ile  $C$  matrisinin satır uzayı aynıdır [18].

**Tanım 2.1.6.**  $A$  matrisinin sütun uzayının boyutuna  $A$  matrisinin sütun rankı, satır uzayının boyutuna ise  $A$  matrisinin satır rankı denir. Bir  $A$  matrisinin satır indirgenmi  $e$  olon biçimindeki sıfırdan farklı satırlarının sayısına  $A$  matrisinin rankı denir ve  $r(A)$  ile gösterilir [18].

**Teorem 2.1.7.** Bir  $A$  matrisinin satır rankı, sütun rankı ve rankı  $e$  ittir [18].

## 2.2. Bir Matrisin Tersi

**Tanım 2.2.1.**  $A \in \mathbb{R}^{m \times m}$  olmak üzere, e er  $\det(A) \neq 0$  ise  $A$  matrisine tersinir matris denir [19].

**Tanım 2.2.2.**  $A \in \mathbb{R}^{m \times n}$  matrisinin genelle tirilmi tersi  $AGA = A$  denklemini sa layan  $G$  matrisi olarak tanımlanır ve  $G = A^-$  olarak gösterilir [19].

**Teorem 2.2.3.** Her matris en az bir genelle tirilmi tere sahiptir. Genel olarak  $A^-$  tek de ildir.  $A^-$  matrisinin tek olması için gerek ve yeter ko ul  $A$  matrisinin tersinir matris olmasıdır. Bu durumda  $A^- = A^{-1}$  dir [19].

**Teorem 2.2.4.**  $A \in \mathbb{R}^{m \times m}$  ve  $B \in \mathbb{R}^{n \times n}$  tersinir matrisler,  $C \in \mathbb{R}^{m \times n}$  ve  $D \in \mathbb{R}^{n \times m}$  herhangi matrisler olmak üzere, e er  $A + CBD$  tersinir ise

$$(A + CBD)^{-1} = A^{-1} - A^{-1}C(B^{-1} + DA^{-1}C)^{-1}DA^{-1}$$

dir [19].

## 2.3. Bir Matrisin Özde erleri ve Özvektörleri

**Tanım 2.3.1.**  $A \in \mathbb{R}^{n \times n}$  olmak üzere  $c(\lambda) = \det(A - \lambda I)$  polinomu karakteristik polinom ve  $c(\lambda) = 0$  denklemi karakteristik denklem olarak adlandırılır. Karakteristik denklemin köklerine  $A$  matrisinin özde erleri denir. Özde erler reel veya kompleks olabilir.



$Ax = \lambda x$  olacak şekilde her  $\lambda_i$ 'nin sıfırdan farklı bir  $x$  çözümü vardır. Bu  $x$  çözümüne  $\lambda_i$ 'ye ilişkin bir özvektör denir [19].

## 2.4. Kuadratik Formlar, Pozitif Kararlı ve Nonnegatif Kararlı Matrisler

**Tanım 2.4.1.**  $y = (y_i) \in \mathbb{R}^{n \times 1}$  vektörü ve simetrik bir  $A = (a_{ij}) \in \mathbb{R}^{n \times n}$  matrisi için,

$$Q(y) = y'Ay = \sum_{i=1}^n \sum_{j=1}^n y_i y_j a_{ij}$$

ifadesi  $y_1, y_2, \dots, y_n$  elemanlarının bir kuadratik formudur. Burada  $A$  matrisine bu kuadratik formun matrisi denir. Böyle bir  $A$  matrisi için aşağıdakiler söylenebilir.

- (i) Eğer  $\forall y \neq 0$  için  $y'Ay > 0$  ise  $A$  pozitif kararlı matristir ve  $A > 0$  ile gösterilir.
- (ii) Eğer  $\forall y \neq 0$  için  $y'Ay < 0$  ise  $A$  negatif kararlı matristir ve  $A < 0$  ile gösterilir.
- (iii) Eğer  $\forall y \neq 0$  için  $y'Ay \geq 0$  ise  $A$  nonnegatif kararlı matristir ve  $A \geq 0$  ile gösterilir [17].

**Teorem 2.4.2.**  $A \in \mathbb{R}^{n \times n}$  matrisi  $r$  ranklı nonnegatif kararlı bir matristir ancak ve ancak  $A = R'R$  olacak şekilde  $r$  ranklı  $R \in \mathbb{R}^{n \times n}$  matrisi vardır [20].

**Teorem 2.4.3.** Eğer  $A \in \mathbb{R}^{n \times n}$  matrisi pozitif kararlı ve  $C \in \mathbb{R}^{p \times n}$  matrisi  $p$  ranklı ise  $CAC'$  matrisi pozitif kararlıdır [20].

**Teorem 2.4.4.** Eğer  $A$  ve  $B$  nonnegatif kararlı matrisleri için  $B - A$  nonnegatif kararlı ise Löwner sıralamasına göre  $A$ ,  $B$ 'den daha küçüktür denir ve  $A \leq B$  ( $A \leq_L B$ ) veya  $B \geq A$  ( $B \geq_L A$ ) ile gösterilir. Eğer  $B - A$  pozitif kararlı ise bu durumda  $A$  matrisine kesinlikle  $B$  matrisinden küçüktür denir ve  $A < B$  ( $A <_L B$ ) veya  $B > A$  ( $B >_L A$ ) ile gösterilir [17].

**Teorem 2.4.5.**  $A, B \in \mathbb{R}^{n \times n}$  matrisleri için  $A > 0$  ve  $B \geq 0$  olmak üzere

$$A > B \Leftrightarrow \lambda_1(BA^{-1}) < 1$$

dir. Burada  $\lambda_1(BA^{-1})$ ,  $BA^{-1}$  matrisinin en büyük özde eridir [21].

**Teorem 2.4.6.**  $A > 0$  ve  $r$  herhangi bir vektör olmak üzere  $A - rr' \geq 0 \Leftrightarrow r'A^{-1}r \leq 1$  dir [22].

## 2.5. Parçalanmış Matrisler

**Tanım 2.5.1.** Bir kümenin parçalanmasına benzer olarak bir matrisin parçalanması, orijinal matrisin her bir elemanının parçalanmışının yalnız ve yalnız bir alt matrisine düşecek şekilde karışık ayrı matrislere ayrılması halidir. Örneğin  $A \in \mathbb{R}^{m \times n}$  için

$$A = \begin{pmatrix} A_{11} & A_{12} \\ A_{21} & A_{22} \end{pmatrix}$$

ifadesi  $A$  matrisinin bir parçalanmasıdır. Burada  $m_1 + m_2 = m$  ve  $n_1 + n_2 = n$  olmak üzere  $A_{11} \in \mathbb{R}^{m_1 \times n_1}$ ,  $A_{12} \in \mathbb{R}^{m_1 \times n_2}$ ,  $A_{21} \in \mathbb{R}^{m_2 \times n_1}$ ,  $A_{22} \in \mathbb{R}^{m_2 \times n_2}$  dir. Yukarıda verilen matrisin transpozunu

$$A' = \begin{pmatrix} A'_{11} & A'_{21} \\ A'_{12} & A'_{22} \end{pmatrix}$$

eklinindedir.

**Teorem 2.5.2.**  $A_{12}$  ve  $A_{21}$  matrisleri sıfır matris,  $A_{11}$  ve  $A_{22}$  matrisleri tersinir kare matrisler ise  $A$  matrisinin tersi

$$A^{-1} = \begin{pmatrix} A_{11}^{-1} & 0 \\ 0 & A_{22}^{-1} \end{pmatrix}$$

eklindedir [23].

## 2.6. Lineer Denklem Sistemleri

$A \in \mathbb{R}^{m \times n}$ ,  $B \in \mathbb{R}^{k \times t}$  ve  $C \in \mathbb{R}^{m \times t}$  bilinen matrisler olmak üzere,

$$AXB = C \quad (2.1)$$

matris denklem sistemi ele alınsın. Bu durumda aşağıdakiler verilebilir.

**Tanım 2.6.1.** (2.1) matris denklem sistemini sağlayan en az bir  $X \in \mathbb{R}^{n \times k}$  matrisi varsa, sistem tutarlıdır denir. Aksi takdirde sistem tutarsızdır [24].

**Teorem 2.6.2.** (2.1) matris denklem sisteminin tutarlı olmasının gerek ve yeter şartı  $\mathcal{C}(C) \subset \mathcal{C}(A)$  ve  $\mathcal{C}(C') \subset \mathcal{C}(B')$  olmasıdır [24].

**Teorem 2.6.3.** (2.1) matris denklem sistemi tutarlı ise uygun boyutlu herhangi  $U$  ve  $V$  matrisleri için

$$X = A^{-1}CB^{-1} + (I - A^{-1}A)U + V(I - B^{-1}B)$$

ile verilen  $X$  matrisi, (2.1) matris denkleminin genel çözümüdür. (2.1) matris denklem sisteminde  $A$  ve  $B$  matrisleri tersinir ise

$$X = A^{-1}CB^{-1}$$

(2.1) denklem sisteminin tek çözümüdür.

(2.1) matris denkleminde  $X$  matrisi yerine  $x \in \mathbb{R}^{n \times 1}$  vektörü,  $B = I$  ve  $C$  matrisi yerine  $g \in \mathbb{R}^{m \times 1}$  vektörü alınırsa,  $Ax = g$  lineer denklem sistemi elde edilir. Böylece Teorem 2.6.2 ve Teorem 2.6.3'ün daha özel durumu olarak aşağıdaki teorem verilebilir [24].

**Teorem 2.6.4.**  $Ax = g$  lineer denklem sisteminin tutarlı olmasının gerek ve yeter şartı  $AA^{-1}g = g$  olmasıdır. Eğer sistem tutarlı ise bu durumda herhangi bir  $h \in \mathbb{R}^{n \times 1}$  vektörü için  $x = A^{-1}g + (I - A^{-1}A)h$  ile verilen  $x$  vektörü  $Ax = g$  lineer denklem sisteminin genel çözümüdür [24].

## 2.7. Karesel ve Lineer Formların Türevleri

**Tanım 2.7.1.** Eğer  $f$ ,  $x$  vektörünün bir fonksiyonu ise  $\left(\frac{\partial f}{\partial x_i}\right)$  kısmi türevler vektörü,  $\frac{\partial f}{\partial x}$  sütun vektörü aracılığıyla gösterilir. Yani  $\frac{\partial f}{\partial x} = \left(\frac{\partial f}{\partial x_i}\right)$  eklindedir.

Benzer şekilde satır vektörü için kısmi türevler vektörü  $\frac{\partial f}{\partial x'} = \left(\frac{\partial f}{\partial x}\right)'$  eklindedir [23].

**Teorem 2.7.2.**  $x, a \in \mathbb{R}^{n \times 1}$  vektörleri ve  $A \in \mathbb{R}^{n \times n}$  matrisi için

$$(i) \quad \frac{\partial x'a}{\partial x} = \frac{\partial a'x}{\partial x} = a,$$

$$(ii) \quad \frac{\partial x'Ax}{\partial x} = (A + A')x \text{ ve eğer } A \text{ matrisi simetrik ise } \frac{\partial x'Ax}{\partial x} = 2Ax$$

dir [23].

## 2.8. Rasgele Vektörler ve Bazı Statistiksel Kavramlar

Rasgele vektör, elemanları rasgele de i kenler olan bir vektör ve benzer şekilde rasgele matris ise, elemanları rasgele de i kenler olan matristir. Rasgele vektör ve matrislerle ilgili bazı temel kavram ve teoremler aşağıda verilmektedir.

**Tanım 2.8.1.**  $Z = (z_{ij}) \in \mathbb{R}^{n \times n}$  olan rasgele bir matris olmak üzere Z matrisinin beklenen değeri

$$E(Z) = \left( E(z_{ij}) \right) = \begin{pmatrix} E(z_{11}) & \dots & E(z_{1n}) \\ \vdots & \ddots & \vdots \\ E(z_{n1}) & \dots & E(z_{nn}) \end{pmatrix}$$

eklindedir [20].

**Teorem 2.8.2.**  $X$  rasgele bir matris ve  $A, B, C$  bilinen uygun boyutlu matrisler olmak üzere  $E(AXB + C) = AE(X)B + C$  dir [20].

**Sonuç 2.8.3.**  $A$  ve  $B$  uygun boyutlu matrisler,  $x$  ve  $y$  uygun boyutlu rasgele vektörler olmak üzere  $E(Ax + By) = AE(x) + BE(y)$  dir [20].

**Tanım 2.8.4.**  $x$  rasgele vektörünün varyansı  $Var(x) = \dagger_x^2 = E(x - \sim)^2$  eklindedir. Burada  $\sim = E(x)$  dir [20].

**Tanım 2.8.5.**  $X$  ve  $Y$  rasgele matrisleri arasındaki kovaryans

$$Cov(X, Y) = \dagger_{XY} = E[(X - E(X))(Y - E(Y))']$$

eklindedir [25].

**Teorem 2.8.6.**  $A \in \mathbb{R}^{k \times m}$ ,  $B \in \mathbb{R}^{p \times n}$  bilinen matrisler ve  $x \in \mathbb{R}^{m \times 1}$ ,  $y \in \mathbb{R}^{n \times 1}$  rasgele vektörler olsun. Bu durumda aşağıdakiler sağlanır [25].

- (i)  $Cov(Ax, By) = ACov(x, y)B'$ .
- (ii)  $Cov(Ax, Ax) = AVar(x)A'$ .

## BÖLÜM 3. BAZI YANLI TAHMİN EDİCİLER

### 3.1. Giriş

Genel olarak bir lineer model

$$y = X\beta + v \quad (3.1)$$

olarak ifade edilir. Burada  $y \in \mathbb{R}^{n \times 1}$  gözlenebilir rasgele vektörü,  $X \in \mathbb{R}^{n \times p}$  model matrisini,  $v \in \mathbb{R}^{n \times 1}$  rasgele hata vektörünü temsil etmektedir. Bu modelde

$$E(v) = 0 \text{ ve } Cov(v) = \sigma^2 I_n$$

olmasının yanı sıra  $r(X) = p$  kabul edilmektedir.

Bu bölümde Wu ve Yang tarafından [13]'de elde edilen sonuçlar detaylı bir biçimde incelenecektir. Aşağıda önce (3.1) modelindeki  $\beta$  parametresinin tahmini için kullanılacak olan bazı tahmin ediciler tanıtılacaktır. Daha sonra bu tahmin edicilerin MSE ölçütüne göre karşılaştırılmaları ile ilgili bazı sonuçlar verilecektir.

### 3.2. Alınımı En Küçük Kareler Tahmin Edicisi (OLSE)

En küçük kareler tahmini yöntemindeki düşünce  $X\beta$  vektörü için gözlemlenmiş  $y$  değerlerine mümkün olduğunca yakın olacak şekilde  $\beta$  vektörünü bulmaktır. Bu yöntem  $(y - X\beta)'(y - X\beta)$  ifadesinin  $\beta$  vektörüne göre minimumlaştırılması ile yapılır. Gauss-Markov [2] teoremine göre klasik alınımı en küçük kareler tahmin edicisi (OLSE) aşağıdaki gibi elde edilmektedir.

$$\hat{S}_{LS} = \min_S (y - XS)'(y - XS) \quad (3.2)$$

dir. (3.2)'deki ifade düzenlenirse,

$$(y' - S'X')(y - XS) = y'y - y'XS - S'X'y + S'X'XS$$

elde edilir.  $S'X'y = (S'X'y)' = y'XS$  oldu undan

$$(y - XS)'(y - XS) = y'y - 2S'X'y + S'X'XS$$

olur. Bu ifadede  $S$ 'ya göre türev alınır ve sıfıra e itlenirse

$$X'XS = X'y \quad (3.3)$$

elde edilir. (3.3) denklemleri normal denklemler olarak bilinir.  $S$ 'nın OLSE'si bu denklemlerin çözümüyle elde edilir ve  $\hat{S}_{OLSE}$  ile gösterilir.  $X$  matrisi  $p$  ranklı oldu undan  $X'X$  matrisinin tersi ve dolayısıyla (3.3) denkleminin tek çözümü vardır. Böylece

$$\hat{S}_{OLSE} = (X'X)^{-1}X'y \quad (3.4)$$

olarak elde edilir.

Alın ılımı en küçük kareler tahmin edicisi yansız tahmin edicidir. Çünkü

$$\begin{aligned} E(\hat{S}_{OLSE}) &= E[(X'X)^{-1}X'y] \\ &= (X'X)^{-1}X'E(XS + v) \\ &= (X'X)^{-1}X'[E(XS) + E(v)] \\ &= (X'X)^{-1}X'XS + 0 \\ &= S \end{aligned}$$

dir. Ayrıca  $\hat{S}_{OLSE}$ 'nin varyansı,

$$\begin{aligned}
 \text{Var}(\hat{S}_{OLSE}) &= \text{Var}[(X'X)^{-1}X'y] \\
 &= (X'X)^{-1}X'\text{Var}(y)((X'X)^{-1}X')' \\
 &= (X'X)^{-1}X'\text{Var}(y - XS)X(X'X)^{-1} \\
 &= (X'X)^{-1}X'\text{Var}(v)X(X'X)^{-1} \\
 &= \dagger^2(X'X)^{-1}X'X(X'X)^{-1} \\
 &= \dagger^2(X'X)^{-1}
 \end{aligned}$$

dir.

### 3.3. Alı ılımlı Karma Tahmin Edici (OME)

(3.1) modelinde verilen  $S$  parametresi üzerinde  $E(e) = 0$  ve  $\text{Cov}(e) = \dagger^2 W$  olmak üzere

$$h = HS + e \quad (3.5)$$

formundaki lineer kısıtlar ele alınsın. Burada  $H \in \mathbb{R}^{m \times p}$  rankı  $r$  ( $\leq p$ ) olan bir matris,  $h \in \mathbb{R}^{m \times 1}$ ,  $e \in \mathbb{R}^{m \times 1}$  hata vektörü ve  $W \in \mathbb{R}^{m \times m}$  bilinen pozitif kararlı bir matristir.

(3.1) modeli (3.5) kısıtı ile birlikte ele alınırsa, bu iki model

$$\begin{pmatrix} y \\ h \end{pmatrix} = \begin{pmatrix} X \\ H \end{pmatrix} S + \begin{pmatrix} v \\ e \end{pmatrix}$$

modeliyle ifade edilebilir. OME

$$\mathbb{E} = v'v + e'W^{-1}e \quad (3.6)$$



ifadesinin minimumla tırılmasıyla elde edilir. (3.6) ifadesi düzenlenirse

$$\begin{aligned} \mathbb{E} &= (y - XS)'(y - XS) + (h - HS)'W^{-1}(h - HS) \\ &= y'y - 2S'X'y + S'X'XS + h'W^{-1}h - h'W^{-1}HS - S'H'W^{-1}h + S'H'W^{-1}HS \end{aligned}$$

bulunur. Burada  $h'W^{-1}HS = S'H'W^{-1}h$  oldu undan

$$\mathbb{E} = y'y - 2S'X'y + S'X'XS + h'W^{-1}h - 2S'H'W^{-1}h + S'H'W^{-1}HS$$

yazılır.  $S$  'ya göre türev alınır ve sıfıra e itlenirse

$$(X'X + H'W^{-1}H)S = X'y + H'W^{-1}h$$

elde edilir. Böylece

$$\hat{S}_{OME} = (X'X + H'W^{-1}H)^{-1}(X'y + H'W^{-1}h) \quad (3.7)$$

olarak bulunur. (3.7)'de verilen  $\hat{S}_{OME}$  Durbin [7], Theil ve Goldberger [8] ve Theil [9] tarafından tanımlanmıştır.  $\hat{S}_{OME}$  'nin özellikleri ve uygulamaları için ayrıca Hubert ve Wijekoon [10], Li ve Yang [11] ve Yang ve Xu [12] kaynaklarına bakılabilir.

### 3.4. Rasgele Kısıtlı Liu Tahmin Edicisi (SRLE)

Hubert ve Wijekoon [10] makalesinde OME ve Liu tahmin edicileri birleştirilerek rasgele kısıtlı Liu tahmin ediciyi tanımlamışlardır. Bu tahmin edici

$$\hat{S}_{SRLE}(d) = F_d (X'X + H'W^{-1}H)^{-1}(X'y + H'W^{-1}h) \quad (3.8)$$

olarak ifade edilir. Burada  $0 < d < 1$  ve  $F_d = (X'X + I)^{-1}(X'X + dI)$  şeklindedir.

### 3.5. Temel Bile enler Regresyon (PCR) Tahmin Edicisi

Temel bile enler regresyonu, tahmin problemlerinin boyutunu indirgemedeki kullanılan bir yaklaşımdır.

$$y = XTT'S + v = Zr + v \quad (3.9)$$

dönümü ele alınsın. Burada  $T = (t_1, t_2, \dots, t_p) \in \mathbb{R}^{p \times p}$  ortogonal matristir. Ayrıca

$$T'X'XT = Z'Z = \Lambda$$

olarak yazılabilir. Burada  $\Lambda$  köegen elemanları  $X'X$  matrisinin özdeğerleri olan köegen matristir. Yani  $\Lambda = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_p)$  dir.

$$Z = XT = (z_1, z_2, \dots, z_p)$$

temel bile enler matrisi olarak bilinir. Bu matrisin  $i$ . elemanı  $z_i = Xt_i$ ,  $i$ . temel bileendir.

$S$ 'nin temel bile enler tahmini bazı  $z_i$  değerlerinin ihmal edilmesi ile elde edilir. Bunun için  $Z = (Z_r, Z_{p-r})$  parçalanmış matrisi ele alınsın. Bu durumda  $Z_r = XT_r$  ve  $T_r'S = r_r$  olur.  $T_r'S = r_r$  ifadesi soldan  $T_r$  ile çarpılırsa  $T_rT_r'S = T_r r_r$  elde edilir.  $T_rT_r' = I$  olduğundan  $S = T_r r_r$  olur. Yani (3.9) modelinde  $Z$  yerine  $Z = (Z_r, Z_{p-r})$  parçalanmış matrisi yazılırsa

$$\begin{aligned} y &= (Z_r, Z_{p-r}) \begin{pmatrix} r_r \\ r_{p-r} \end{pmatrix} + v \\ &= X(T_r, T_{p-r}) \begin{pmatrix} T_r' \\ T_{p-r}' \end{pmatrix} S + v \\ &= X(T_rT_r' + T_{p-r}T_{p-r}')S + v \\ &= XT_rT_r'S + XT_{p-r}T_{p-r}'S + v \end{aligned}$$

$$= Z_r \Gamma_r + Z_{p-r} \Gamma_{p-r} + v$$

elde edilir. Burada  $Z_{p-r} \Gamma_{p-r}$  ihmal edilirse model

$$y = Z_r \Gamma_r + v \quad (3.10)$$

modeline indirgenmi olur. (3.10) modeli üzerinde en küçük kareler tahmini yöntemi uygulanırsa

$$\hat{\Gamma}_r = (Z_r' Z_r)^{-1} Z_r' y \quad (3.11)$$

elde edilir. (3.11)'de  $Z_r$  ile  $\Gamma_r$  yerine yazılır ve bulunan ifade  $T_r$  ile soldan çarpılırsa

$$\hat{S}_{PCR} = T_r (T_r' X' X T_r)^{-1} T_r' X' y \quad (3.12)$$

elde edilir.

### 3.6. Rasgele Kısıtlı Temel Bile enler Regresyon (SRPCR) Tahmin Edicisi

(3.5)'te verilen  $h = HS + e$  kısıtlaması

$$h = HTT'S + e \quad (3.13)$$

olarakta yazılabilir. Burada  $T = (t_1, t_2, \dots, t_p) \in \mathbb{R}^{p \times p}$  ortogonal matristir.  $T = (T_r, T_{p-r})$  ifadesi (3.13)'te yazılırsa

$$h = (HT_r T_r' + HT_{p-r} T_{p-r}') S + e$$

elde edilir.  $T_{p-r}' S = 0$  kısıtlaması varyans üzerinde bir indirgemeyi gösterir ve bu kısıtlamayla

$$h = H_r r_r + e \quad (3.14)$$

elde edilir. Burada  $r_r = T_r' S$  ve  $H_r = H T_r \in \mathbb{R}^{m \times r}$  eklindedir. Ayrıca  $H_r T_r T_r' S = h$ ,  $S$  üzerindeki daha fazla kısıtlamayı gösterir.

**Uyarı:**  $H_r$  matrisi ne tam sütun ranklı ne de tam satır ranklıdır [26].

(3.10) modeli ve (3.14) kısıtı birlikte ele alınırsa

$$Y = \begin{pmatrix} y \\ h \end{pmatrix}, G = \begin{pmatrix} Z_r \\ H_r \end{pmatrix} \text{ ve } u = \begin{pmatrix} v \\ e \end{pmatrix} \text{ olmak üzere}$$

$$Y = G r_r + u \quad (3.15)$$

modeli elde edilir. Burada

$$E(u) = 0, \text{ Cov}(u) = \Sigma = \dagger^2 \begin{pmatrix} I_n & 0 \\ 0 & W \end{pmatrix}$$

ve  $W$  pozitif kararlı matristir. (3.15) modelinde OME'nin elde edilme yöntemi kullanılarak yeni tahmin edici

$$\mathbb{E} = (y - Z_r r_r)'(y - Z_r r_r) + (h - H_r r_r)' W^{-1} (h - H_r r_r)$$

ifadesinin  $r_r$ 'ye göre minimumla tırılmasıyla elde edilir. Yani  $\mathbb{E}$ 'nin  $r_r$ 'ye göre türevi alınır ve sıfıra e itlenirse

$$Z_r' y - Z_r' Z_r' r_r + H_r' W^{-1} h - H_r' W^{-1} H_r r_r = 0$$

yazılır ve buradan

$$(Z_r'Z_r + H_r'W^{-1}H_r)r_r = Z_r'y + H_r'W^{-1}h$$

bulunur. Böylece

$$r_r^* = (Z_r'Z_r + H_r'W^{-1}H_r)^{-1}(Z_r'y + H_r'W^{-1}h)$$

elde edilir. Burada  $H_r$  ile  $r_r$  yerine yazılır ve bulunan ifade  $T_r$  ile soldan çarpılırsa

$$\hat{S}_{SRPCR} = T_r(T_r'X'XT_r + T_r'H'W^{-1}HT_r)^{-1}(T_r'X'y + T_r'H'W^{-1}h) \quad (3.16)$$

olarak bulunur.

### 3.7. A ırlıklı Rasgele Kısıtlı Temel Bile enler Resgesyon (WSRPCR) Tahmin Edicisi

(3.1) modeli ve (3.5) kısıtlamasında regresyon parametrelerinin tahmininde e it a ırlıkların gereklili i söz konusu olmadı ında

$$\hat{S}_{WSRPCR}(w) = T_r(T_r'X'XT_r + wT_r'H'W^{-1}HT_r)^{-1}(T_r'X'y + wT_r'H'W^{-1}h) \quad (3.17)$$

ile verilen a ırlıklı rasgele temel bile enler resgesyon tahmin edicisi (WSRPCR) tanımlanmı tır. Burada  $w$  rasgele de ildir ve  $0 \leq w \leq 1$  aralı ındadır [13].

### 3.8. Hata Kareler Ortalaması (MSE)

Lineer regresyon modellerinde ortaya çıkan bazı problemlerin üstesinden gelebilmek için  $\hat{S}_{OLSE}$  yerine birçok alternatif tahmin edici ve bu tahmin edicilerin bazı kombinasyonları ele alınmı tır. Bu tahmin edicilerin performansları bazı ölçütlere göre de erlendirilir. Bu ölçütlerden biri hata kareler ortalaması (Mean Squared Error, MSE) ölçütüdür.  $S$  'nın herhangi bir  $\hat{S}$  tahmin edicisi için MSE matrisi,

$$M(\hat{S}) = E(\hat{S} - S)(\hat{S} - S)'$$

olarak tanımlanır [13].  $s$  ile  $E(\hat{S})$  arasındaki fark  $Bias(\hat{S})$  ile gösterilirse

$$M(\hat{S}) = Var(\hat{S}) + Bias(\hat{S})Bias(\hat{S})' \quad (3.18)$$

olarak yazılır. Bu matrisin izi

$$SMSE(\hat{S}) = E(\hat{S} - s)(\hat{S} - s)' + iz(Var(\hat{S})) + Bias(\hat{S})Bias(\hat{S})' \quad (3.19)$$

olarak tanımlanır [15].

$\hat{S}_1$  ve  $\hat{S}_2$ ,  $s$  için herhangi iki tahmin edici olarak kabul edilirse,

$$M(\hat{S}_1) - M(\hat{S}_2) \geq 0 \quad (3.20)$$

oldu unda  $\hat{S}_2$  tahmin edicisinin  $\hat{S}_1$  tahmin edicisinden daha üstün olduğu kabul edilir [15].

### 3.9. Bazı Yanlı Tahmin Edicilerin MSE Ölçütüne Göre Karşılaştırılmaları

İmdi yukarıda verilen bazı yanlı tahmin edicilerin MSE ölçütüne göre karşılaştırılması ayrı bölümler halinde aşağıda incelenecektir.

#### 3.9.1. SRPCR ve PCR tahmin edicilerinin karşılaştırılması

$$\begin{aligned} E(\hat{S}_{PCR}) &= T_r(T_r'X'XT_r)^{-1}T_r'X'E(y) \\ &= T_r(T_r'X'XT_r)^{-1}T_r'X'E(Z_r\Gamma_r + v) \\ &= T_r(T_r'X'XT_r)^{-1}T_r'X'Z_r\Gamma_r \\ &= T_r(T_r'X'XT_r)^{-1}(T_r'X'XT_r)T_r's \\ &= T_rT_r's \end{aligned} \quad (3.21)$$

oldu undan  $\hat{S}_{PCR}$  tahmin edicisinin yanlılı 1

$$\begin{aligned} Bias(\hat{S}_{PCR}) &= E(\hat{S}_{PCR}) - S \\ &= T_r T_r' S - S \\ &= (T_r T_r' - I) S \\ &= -T_{p-r} T_{p-r}' S \end{aligned}$$

dir.

$$\begin{aligned} Cov(\hat{S}_{PCR}) &= (T_r \Lambda_r^{-1} T_r' X') Cov(y) (T_r \Lambda_r^{-1} T_r' X')' \\ &= (T_r \Lambda_r^{-1} T_r' X') Cov(y - X S) (T_r \Lambda_r^{-1} T_r' X')' \\ &= (T_r \Lambda_r^{-1} T_r' X') Cov(v) (T_r \Lambda_r^{-1} T_r' X')' \\ &= (T_r \Lambda_r^{-1} T_r' X') \dagger^2 I (T_r \Lambda_r^{-1} T_r' X')' \\ &= \dagger^2 T_r \Lambda_r^{-1} T_r' X' X T_r \Lambda_r^{-1} T_r' \\ &= \dagger^2 T_r \Lambda_r^{-1} T_r' \end{aligned} \tag{3.22}$$

olarak bulunur. Böylece (3.18)'e göre  $\hat{S}_{PCR}$  tahmin edicisinin MSE matrisi

$$M(\hat{S}_{PCR}) = \dagger^2 T_r \Lambda_r^{-1} T_r' + T_{p-r} T_{p-r}' S S' T_{p-r} T_{p-r}'$$

olarak elde edilir.

$$E(\hat{S}_{SRPCR}) = T_r (T_r' X' X T_r + T_r' H' W^{-1} H T_r)^{-1} (T_r' X' E(y) + T_r' H' W^{-1} E(h))$$

dir.

$$E(y) = E(Z_r r_r + v) = E(Z_r r_r) = Z_r r_r = X T_r T_r' s ,$$

$$E(h) = E(H_r r_r + e) = E(H_r r_r) = H_r r_r = H T_r T_r' s$$

oldu undan

$$E(\hat{S}_{SRPCR}) = T_r (T_r' X' X T_r + T_r' H' W^{-1} H T_r)^{-1} (T_r' X' X T_r T_r' S + T_r' H' W^{-1} H T_r T_r' S)$$

bulunur. Bu ifade sa dan  $T_r' S$  parantezine alınırsa

$$\begin{aligned} E(\hat{S}_{SRPCR}) &= T_r (T_r' X' X T_r + T_r' H' W^{-1} H T_r)^{-1} (T_r' X' X T_r + T_r' H' W^{-1} H T_r) T_r' S \\ &= T_r T_r' S \end{aligned} \quad (3.23)$$

elde edilir. Bu ifade (3.21) ile aynı oldu undan, benzer ekilde  $\hat{S}_{SRPCR}$  tahmin edicisinin yanlılı  $\hat{S}_{PCR}$  ile aynı bulunur.

$$\begin{aligned} Cov(\hat{S}_{SRPCR}) &= T_r (\Lambda_r + T_r' H' W^{-1} H T_r)^{-1} (T_r' X' \underbrace{Cov(y)}_{\dagger^2 I} X T_r + T_r' H' W^{-1} \underbrace{Cov(H)}_{\dagger^2 W} W^{-1} H T_r) \\ &\quad \times (T_r (\Lambda_r + T_r' H' W^{-1} H T_r)^{-1})' \\ &= T_r (\Lambda_r + T_r' H' W^{-1} H T_r)^{-1} \dagger^2 (\Lambda_r + T_r' H' W^{-1} H T_r) \\ &\quad \times (\Lambda_r + T_r' H' W^{-1} H T_r)^{-1} T_r' \\ &= T_r (\Lambda_r + T_r' H' W^{-1} H T_r)^{-1} \dagger^2 T_r (\Lambda_r + T_r' H' W^{-1} H T_r) \\ &\quad \times (T_r (\Lambda_r + T_r' H' W^{-1} H T_r)^{-1})' \\ &= \dagger^2 T_r (\Lambda_r + T_r' H' W^{-1} H T_r)^{-1} T_r' \end{aligned} \quad (3.24)$$

olarak elde edilir. Böylece (3.18)'e göre  $\hat{S}_{SRPCR}$  tahmin edicisinin MSE matrisi

$$M(\hat{S}_{SRPCR}) = \dagger^2 T_r (\Lambda_r + T_r' H' W^{-1} H T_r)^{-1} T_r' + T_{p-r} T_{p-r}' S S' T_{p-r} T_{p-r}' \quad (3.25)$$

yazılabilir.



$\hat{S}_{PCR}$  ve  $\hat{S}_{SRPCR}$  tahmin edicilerinin MSE ölçütüne göre karşılaştırılmaları ile ilgili aşağıdaki teorem verilebilir.

**Teorem 3.9.1.** MSE ölçütüne göre  $\hat{S}_{SRPCR}$  tahmin edicisi her zaman  $\hat{S}_{PCR}$  tahmin edicisinden üstündür.

**spat:**  $\hat{S}_{SRPCR}$  ve  $\hat{S}_{PCR}$  tahmin edicilerinin yanlılıkları aynı olduğundan MSE ölçütüne göre karşılaştırılmaları yapılırken sadece kovaryans matrislerinin farklarına bakmak yeterli olacaktır. Böylece (3.22) ve (3.24) eşitliklerinden

$$Cov(\hat{S}_{PCR}) - Cov(\hat{S}_{SRPCR}) = T_r' [\Lambda_r^{-1} - (\Lambda_r + T_r' H' W^{-1} H T_r)^{-1}] T_r' \quad (3.26)$$

elde edilir. Teorem 2.2.4'e göre

$$(\Lambda_r + T_r' H' W^{-1} H T_r)^{-1} = \Lambda_r^{-1} - \Lambda_r^{-1} T_r' H' (W + H T_r \Lambda_r^{-1} T_r' H')^{-1} H T_r \Lambda_r^{-1}$$

olduğundan bu ifade (3.26)'da yerine yazılır ve Teorem 2.4.3 kullanılırsa

$$Cov(\hat{S}_{PCR}) - Cov(\hat{S}_{SRPCR}) = \Lambda_r^{-1} T_r' H' (W + H T_r \Lambda_r^{-1} T_r' H')^{-1} H T_r \Lambda_r^{-1} \geq 0$$

olur ve ispat biter.

### 3.9.2. WSRPCR ve PCR tahmin edicilerinin karşılaştırılması

$$\begin{aligned} E[\hat{S}_{WSRPCR}(w)] &= T_r (T_r' X' X T_r + w T_r' H' W^{-1} H T_r)^{-1} (T_r' X' \underbrace{E(y)}_{X T_r' T_r' S} + w T_r' H' W^{-1} \underbrace{E(h)}_{H T_r' T_r' S}) \\ &= T_r (T_r' X' X T_r + w T_r' H' W^{-1} H T_r)^{-1} (T_r' X' X T_r T_r' S + w T_r' H' W^{-1} T_r T_r' S) \end{aligned}$$

bulunur. Bu ifade sağdan  $T_r' S$  parantezine alınırsa

$$\begin{aligned} E[\hat{S}_{WSRPCR}(w)] &= T_r (T_r' X' X T_r + w T_r' H' W^{-1} H T_r)^{-1} (T_r' X' X T_r + w T_r' H' W^{-1} T_r) T_r' S \\ &= T_r T_r' S \end{aligned}$$

olarak elde edilir. Benzer şekilde yanlılık

$$Bias[\hat{S}_{WSRPCR}(w)] = -T_{p-r} T_{p-r}' S \quad (3.27)$$

olur.

$$\begin{aligned} Cov[\hat{S}_{WSRPCR}(w)] &= T_r (\Lambda_r + w T_r' H' W^{-1} H T_r)^{-1} \\ &\quad \times (T_r' X' \underbrace{Cov(y)}_{\dagger^2 I} X T_r + w T_r' H' W^{-1} \underbrace{Cov(h)}_{\dagger^2 W} W^{-1} H T_r, w) \\ &\quad \times (T_r (\Lambda_r + w T_r' H' W^{-1} H T_r)^{-1})' \\ &= \dagger^2 T_r (\Lambda_r + w T_r' H' W^{-1} H T_r)^{-1} (\Lambda_r + w^2 T_r' H' W^{-1} H T_r)^{-1} \\ &\quad \times (\Lambda_r + w T_r' H' W^{-1} H T_r)^{-1} T_r' \end{aligned} \quad (3.28)$$

elde edilir. Böylece (3.18)'e göre  $\hat{S}_{WSRPCR}(w)$  tahmin edicisinin MSE matrisi

$$\begin{aligned} M[\hat{S}_{WSRPCR}(w)] &= \dagger^2 T_r (\Lambda_r + w T_r' H' W^{-1} H T_r)^{-1} (\Lambda_r + w^2 T_r' H' W^{-1} H T_r)^{-1} \\ &\quad \times (\Lambda_r + w T_r' H' W^{-1} H T_r)^{-1} T_r' + T_{p-r} T_{p-r}' S S' T_{p-r} T_{p-r}' \end{aligned} \quad (3.29)$$

olarak bulunur.

$\hat{S}_{PCR}$  ve  $\hat{S}_{WRPCR}(w)$  tahmin edicilerinin MSE ölçütüne göre karşılaştırılmaları ile ilgili aşağıdaki teorem verilebilir.

**Theorem 3.9.2** MSE ölçütüne göre  $\hat{S}_{WSRPCR}(w)$  tahmin edicisi her zaman  $\hat{S}_{PCR}$  tahmin edicisinden üstündür.

**spat:**  $\hat{S}_{WSRPCR}(w)$  ve  $\hat{S}_{PCR}$  tahmin edicilerinin yanlılıkları aynı oldu undan MSE ölçütüne göre kar ıla tırılmaları yapılırken sadece kovaryans matrislerinin farklarına bakmak yeterli olacaktır. Böylece (3.22) ve (3.28) e itliklerinden

$$\begin{aligned}
& Cov(\hat{S}_{PCR}) - Cov(\hat{S}_{WSRPCR}(w)) \\
&= \dagger^2 T_r \Lambda_r^{-1} T_r' - \dagger^2 T_r (\Lambda_r + w T_r' H' W^{-1} H T_r)^{-1} \\
&\quad \times (\Lambda_r + w^2 T_r' H' W^{-1} H T_r)^{-1} (\Lambda_r + w T_r' H' W^{-1} H T_r)^{-1} T_r' \\
&= \dagger^2 T_r \left\{ \Lambda_r^{-1} T_r' - (\Lambda_r + w T_r' H' W^{-1} H T_r)^{-1} \right. \\
&\quad \left. \times (\Lambda_r + w^2 T_r' H' W^{-1} H T_r)^{-1} (\Lambda_r + w T_r' H' W^{-1} H T_r)^{-1} \right\} T_r' \\
&= \dagger^2 T_r \left\{ (\Lambda_r + w T_r' H' W^{-1} H T_r)^{-1} (\Lambda_r + w T_r' H' W^{-1} H T_r) (\Lambda_r + w T_r' H' W^{-1} H T_r)^{-1} \right. \\
&\quad \left. - (\Lambda_r + w T_r' H' W^{-1} H T_r)^{-1} (\Lambda_r + w^2 T_r' H' W^{-1} H T_r) (\Lambda_r + w T_r' H' W^{-1} H T_r)^{-1} \right\} T_r' \\
&= \dagger^2 T_r (\Lambda_r + w T_r' H' W^{-1} H T_r)^{-1} [(\Lambda_r + w T_r' H' W^{-1} H T_r) \Lambda_r^{-1} (\Lambda_r + w T_r' H' W^{-1} H T_r) \\
&\quad - (\Lambda_r + w^2 T_r' H' W^{-1} H T_r)] (\Lambda_r + w T_r' H' W^{-1} H T_r)^{-1} T_r' \tag{3.30}
\end{aligned}$$

elde edilir. Burada

$$(\Lambda_r + w T_r' H' W^{-1} H T_r) \Lambda_r^{-1} (\Lambda_r + w T_r' H' W^{-1} H T_r)$$

ifadesi düzenlenirse

$$\begin{aligned}
& (\Lambda_r + w T_r' H' W^{-1} H T_r) \Lambda_r^{-1} (\Lambda_r + w T_r' H' W^{-1} H T_r) \\
&= \Lambda_r + 2w T_r' H' W^{-1} H T_r + w^2 T_r' H' W^{-1} H T_r \Lambda_r^{-1} T_r' H' W^{-1} H T_r
\end{aligned}$$

olur. Bu ifade (3.30)'da tekrar yerine yazılırsa

$$\begin{aligned}
M(\hat{S}_{PCR}) - M[\hat{S}_{WSRPCR}(w)] &= \dagger^2 (\Lambda_r + w T_r' H' W^{-1} H T_r)^{-1} [(2-w) w T_r' H' W^{-1} H T_r' \\
&\quad + w^2 T_r' H' W^{-1} H T_r \Lambda_r^{-1} T_r' H' W^{-1} H T_r] (\Lambda_r + w T_r' H' W^{-1} H T_r)^{-1} T_r'
\end{aligned}$$

bulunur.  $0 \leq w \leq 1$  oldu undan  $2 - w > 0$  olur ve Teorem 2.4.3'e göre

$$M(\hat{S}_{PCR}) - M[\hat{S}_{WSRPCR}(w)] \geq 0$$

elde edilir ve ispat biter.

### 3.9.3. WSRPCR ve SRPCR tahmin edicilerinin kar ıla tırılması

**Teorem 3.9.3.** MSE ölçütüne göre  $\hat{S}_{SRPCR}$  tahmin edicisi her zaman  $\hat{S}_{WSRPCR}(w)$  tahmin edicisinden üstündür.

**spat:**  $\hat{S}_{WSRPCR}(w)$  ve  $\hat{S}_{SRPCR}$  tahmin edicilerinin yalılıkları aynı oldu undan MSE ölçütüne göre kar ıla tırılmaları yapılırken sadece kovaryans matrislerinin farklarına bakmak yeterli olacaktır. Böylece (3.24) ve (3.28) e itliklerinden

$$\begin{aligned} & Cov(\hat{S}_{SRPCR}) - Cov[\hat{S}_{WSRPCR}(w)] \\ &= \dagger^2 T_r (\Lambda_r + T_r' H' W^{-1} H T_r)^{-1} T_r' - \dagger^2 T_r (\Lambda_r + w T_r' H' W^{-1} H T_r)^{-1} \\ & \quad \times (\Lambda_r + w^2 T_r' H' W^{-1} H T_r) (\Lambda_r + w T_r' H' W^{-1} H T_r)^{-1} T_r' \\ &= \dagger^2 T_r \left\{ (\Lambda_r + T_r' H' W^{-1} H T_r)^{-1} T_r' - (\Lambda_r + w T_r' H' W^{-1} H T_r)^{-1} \right. \\ & \quad \left. \times (\Lambda_r + w^2 T_r' H' W^{-1} H T_r) (\Lambda_r + w T_r' H' W^{-1} H T_r)^{-1} \right\} T_r' \\ &= -\dagger^2 (w-1)^2 T_r (\Lambda_r + w T_r' H' W^{-1} H T_r)^{-1} (\Lambda_r + T_r' H' W^{-1} H T_r) \Lambda_r \\ & \quad \times (T_r' H' W^{-1} H T_r) (\Lambda_r + w T_r' H' W^{-1} H T_r)^{-1} T_r' \end{aligned}$$

elde edilir.  $0 \leq w \leq 1$  oldu undan  $0 \leq (w-1)^2 \leq 1$  dır. Dolayısıyla Teorem 2.4.3'e göre

$$M(\hat{S}_{SRPCR}) - M(\hat{S}_{WSRPCR}(w)) \leq 0$$

olur ve ispat biter.

### 3.9.4. SRLE ve SRPCR tahmin edicilerinin karşılaştırılması

$$E[\hat{S}_{SRLE}(d)] = E(F_d \hat{S}_{OME}) = F_d S$$

dir. Böylece

$$\begin{aligned} Bias[\hat{S}_{SRLE}(d)] &= E[\hat{S}_{SRLE}(d)] - \hat{S}_{SRLE}(d) \\ &= F_d S - S = (F_d - I)S \end{aligned} \quad (3.31)$$

elde edilir. Ayrıca

$$\begin{aligned} Cov[\hat{S}_{SRLE}(d)] &= Cov(F_d \hat{S}_{OME}) \\ &= Cov(F_d (X'X + H'W^{-1}H)^{-1} (X'y + H'W^{-1}h)) \\ &= F_d (X'X + H'W^{-1}H)^{-1} (X' \underbrace{Cov(y)}_{\dagger^2 I} X + H'W^{-1} \underbrace{Cov(h)}_{\dagger^2 W} W^{-1}H) \\ &\quad \times (X'X + H'W^{-1}H)^{-1} F_d' \\ &= \dagger^2 F_d (X'X + H'W^{-1}H)^{-1} (X'X + H'W^{-1}H) (X'X + H'W^{-1}H)^{-1} F_d' \\ &= \dagger^2 F_d (X'X + H'W^{-1}H)^{-1} F_d' \end{aligned} \quad (3.32)$$

olur. Böylece (3.18)'e göre  $\hat{S}_{SRLE}(d)$  tahmin edicisinin MSE matrisi

$$M[\hat{S}_{SRLE}(d)] = \dagger^2 F_d (X'X + H'W^{-1}H)^{-1} F_d' + (F_d - I)SS'(F_d - I)' \quad (3.33)$$

eklinde olur.  $\hat{S}_{SRLE}(d)$  ve  $\hat{S}_{SRPCR}$  tahmin edicilerinin MSE matris farkları

$$\begin{aligned} \Delta_1 &= M[\hat{S}_{SRLE}(d)] - M[\hat{S}_{SRPCR}] \\ &= \dagger^2 F_d (X'X + H'W^{-1}H)^{-1} F_d' + (F_d - I)SS'(F_d - I)' \\ &\quad - \left[ \dagger^2 T_r (\Lambda_r + T_r' H' W^{-1} H T_r)^{-1} T_r' + T_{p-r} T_{p-r}' SS' T_{p-r} T_{p-r}' \right] \end{aligned} \quad (3.34)$$

olarak gösterilir.

$$D_1 = F_d (X'X + H'W^{-1}H)^{-1} F_d' - T_r (\Lambda_r + T_r' H'W^{-1}HT_r)^{-1} T_r',$$

$$b_1 = (F_d - I)S,$$

$$b_2 = T_{p-r} T_{p-r}' S$$

olmak üzere (3.34)

$$\Delta_1 = \dagger^2 D_1 + b_1 b_1' - b_2 b_2'$$

olarakta yazılabilir

$\hat{S}_{SRPCR}$  ve  $\hat{S}_{SRLE}(d)$  tahmin edicilerinin MSE ölçütüne göre karşılaştırılmaları ile ilgili aşağıdaki teorem verilebilir.

**Teorem 3.9.4.**  $0 < d < 1$  ve

$$\} _1 \left\{ \left[ T_r (\Lambda_r + T_r' H'W^{-1}HT_r)^{-1} T_r' \right] \left[ F_d (X'X + H'W^{-1}H)^{-1} F_d' \right] \right\} < 1$$

iken MSE ölçütüne göre  $\hat{S}_{SRPCR}$  tahmin edicisi,  $\hat{S}_{SRLE}(d)$  tahmin edicisinden üstündür. Yani

$$\Delta_1 \geq 0 \Leftrightarrow b_2' (\dagger^2 D_1 + b_1 b_1')^{-1} b_2 \leq 1$$

dir.

**spat:**  $0 < d < 1$  iken  $F_d (X'X + H'W^{-1}H)^{-1} F_d' > 0$ ,  $T_r (\Lambda_r + T_r' H'W^{-1}HT_r)^{-1} T_r' \geq 0$  oldu u açıktır.  $D_1 = A - B$  olarak düşünülürse Teorem 2.4.5'e göre  $\} _1 (BA^{-1}) < 1$  oldu undan

$$D_1 = A - B > 0$$

elde edilir. Teorem 2.4.6' dan

$$\Delta_1 \geq 0 \Leftrightarrow b_2' (\dagger^2 D_1 + b_1 b_1')^{-1} b_2 \leq 1$$

olur ve ispat biter.

### 3.9.5. SRLE ve WSRPCR tahmin edicilerin karşılaştırılması

$\hat{S}_{SRLE}(d)$  ve  $\hat{S}_{WSRPCR}(w)$  tahmin edicilerinin MSE matris farkları

$$\begin{aligned} \Delta_2 &= M(\hat{S}_{SRLE}(d)) - M(\hat{S}_{WSRPCR}(w)) \\ &= \dagger^2 F_d (X'X + H'W^{-1}H)^{-1} F_d' + (F_d - I) S S' (F_d - I)' \\ &\quad - \left\{ \dagger^2 T_r (\Lambda_r + w T_r' H' W^{-1} H T_r)^{-1} (\Lambda_r + w^2 T_r' H' W^{-1} H T_r)^{-1} \right. \\ &\quad \left. \times (\Lambda_r + w T_r' H' W^{-1} H T_r)^{-1} T_r' + T_{p-r} T_{p-r}' S S' T_{p-r} T_{p-r}' \right\} \end{aligned} \quad (3.35)$$

olarak gösterilir.

$$\begin{aligned} D_2 &= F_d (X'X + H'W^{-1}H)^{-1} F_d' - T_r (\Lambda_r + T_r' H' W^{-1} H T_r)^{-1} \\ &\quad \times (\Lambda_r + w^2 T_r' H' W^{-1} H T_r)^{-1} (\Lambda_r + w T_r' H' W^{-1} H T_r)^{-1} T_r' , \end{aligned}$$

$$b_1 = (F_d - I) S ,$$

$$b_2 = T_{p-r} T_{p-r}' S$$

olmak üzere (3.35)

$$\Delta_2 = \dagger^2 D_2 + b_1 b_1' - b_2 b_2'$$

olarak yazılabilir.

$\hat{S}_{SRL E}(d)$  ve  $\hat{S}_{WSRPCR}(w)$  tahmin edicilerinin MSE ölçütüne göre karşılaştırılmaları ile ilgili aşağıdaki teorem verilebilir.

**Teorem 3.9.5.**  $0 < d < 1$ ,  $0 \leq w \leq 1$  ve

$$\left\{ [T_r(\Lambda_r + T_r' H' W^{-1} H T_r)^{-1} (\Lambda_r + w^2 T_r' H' W^{-1} H T_r)^{-1} (\Lambda_r + w T_r' H' W^{-1} H T_r)^{-1} T_r'] \right. \\ \left. \times [F_d (X' X + H' W^{-1} H)^{-1} F_d']^{-1} \right\} < 1 \quad (3.36)$$

iken MSE ölçütüne göre  $\hat{S}_{WSRPCR}(w)$  tahmin edicisi  $\hat{S}_{SRL E}(d)$  tahmin edicisinden üstündür. Yani

$$\Delta_2 \geq 0 \Leftrightarrow b_2' (\dagger^2 D_2 + b_1 b_1')^{-1} b_2 \leq 1$$

dir.

**spat:**  $D_2 = A - B$  olarak düşünülmüşse  $0 < d < 1$ ,  $0 \leq w \leq 1$  iken  $A > 0$  ve  $B \geq 0$  dır ve  $\lambda_1(BA^{-1}) < 1$  oldu u zaman Teorem 2.4.5'e göre  $D_2 > 0$  dır. Teorem 2.4.6'ya göre

$$\Delta_2 \geq 0 \Leftrightarrow b_2' (\dagger^2 D_2 + b_1 b_1')^{-1} b_2 \leq 1$$

olur ve ispat biter.



## BÖLÜM 4. BAZI GENELLE TIRILMI YANLI TAHMİN EDİCİLER

### 4.1. Giri

$E(v) = 0$  ve  $Cov(v) = \sigma^2 V$  olmak üzere ,

$$y = X\beta + v \quad (4.1)$$

modeli ele alınsın. Burada  $y \in \mathbb{R}^{n \times 1}$  gözlenebilir rasgele vektörü,  $X \in \mathbb{R}^{n \times p}$  model matrisini,  $v \in \mathbb{R}^{n \times 1}$  rasgele hata vektörünü temsil etmektedir. Ayrıca  $V$  pozitif kararlı matristir.

Bu bölümde (3.1)'de verilen lineer modelin genel hali olan (4.1) modeli ele alınarak bazı yanlı tahmin ediciler ve bunların MSE ölçütüne göre karşılaştırılmaları ele alınacaktır.

### 4.2. Genelle tirilmi En Küçük Kareler Tahmin Edicisi (GLSE)

Kısım (3.2)'de ifade edildi i gibi en küçük kareler tahmini yöntemindeki dü ünce  $X\beta$  vektörü için gözlemlenmi  $y$  de erlerine mümkün oldu unca yakın olacak ekilde  $\beta$  vektörünü bulmaktır. Genelle tirilmi en küçük kareler yöntemi ile GLSE ise  $(y - X\beta)'V^{-1}(y - X\beta)$  ifadesinin  $\beta$  vektörüne göre minimumla tırılması ile yani

$$\hat{\beta}_{LS} = \min_{\beta} (y - X\beta)'V^{-1}(y - X\beta)$$

ile bulunur. Buradaki  $(y - X\beta)'V^{-1}(y - X\beta)$  ifadesi düzenlenirse

$$(y' - \beta'X')V^{-1}(y - X\beta) = y'V^{-1}y - y'V^{-1}X\beta - \beta'X'V^{-1}y + \beta'X'V^{-1}X\beta$$

$$= y'V^{-1}y - 2S'XV^{-1}y + S'XV^{-1}XS$$

elde edilir. Bu ifadenin  $s$ 'ya göre türevi alınır ve sıfıra e itlenirse

$$X'V^{-1}XS = X'V^{-1}y \quad (4.2)$$

olur. (4.2) denklemi normal denklemler olarak bilinir,  $s$ 'nın GLSE'si bu denklemin çözümüyle elde edilir ve  $\hat{S}_{GLSE}$  ile gösterilir. Böylece

$$\hat{S}_{GLSE} = (X'V^{-1}X)^{-1}(X'V^{-1}y) \quad (4.3)$$

bulunur.

### 4.3. Genelleştirilmiş Alınım Karma Tahmin Edici (GOME)

(4.1) lineer modeli ve (3.5) kısıtı birlikte ele alınırsa, bu iki ifade

$$\begin{pmatrix} y \\ h \end{pmatrix} = \begin{pmatrix} X \\ H \end{pmatrix} S + \begin{pmatrix} v \\ e \end{pmatrix},$$

modeli ile gösterilebilir. Burada  $Cov \begin{pmatrix} v \\ e \end{pmatrix} = \begin{pmatrix} V & 0 \\ 0 & W \end{pmatrix}$  dir. GOME

$$\mathbb{E} = v'V^{-1}v + e'W^{-1}e \quad (4.4)$$

ifadesinin minimumla tırılmasıyla elde edilir. (4.4) ifadesi düzenlenirse

$$\begin{aligned} \mathbb{E} &= (y - XS)'V^{-1}(y - XS) + (h - HS)'W^{-1}(h - HS) \\ &= y'V^{-1}y - 2S'XV^{-1}y + S'XV^{-1}XS + h'W^{-1}h - 2S'H'W^{-1}h + S'H'W^{-1}HS \end{aligned}$$

bulunur.  $s$ 'ya göre türev alınır ve sıfıra e itlenirse

$$(X'V^{-1}X + H'W^{-1}H)S = X'V^{-1}y + H'W^{-1}h$$

olur. Böylece

$$\hat{S}_{GOME} = (X'V^{-1}X + H'W^{-1}H)^{-1}(X'V^{-1}y + H'W^{-1}h) \quad (4.5)$$

olarak elde edilir.

#### 4.4. Genelle tirilmi Rasgele Kısıtlı Liu Tahmin Edicisi (GSRLE)

GOME ve Liu tahmin edicileri birle tirilerek genelle tirilmi rasgele kısıtlı Liu tahmin edicisi

$$\hat{S}_{GSRLE}(d) = F_d(X'V^{-1}X + H'W^{-1}H)^{-1}(X'V^{-1}y + H'W^{-1}h) \quad (4.6)$$

olarak tanımlanabilir.

#### 4.5. Genelle tirilmi Temel Bile enler Regresyon (GPCR) Tahmin Edicisi

PCR'nin elde edilme yöntemine paralel olarak (4.1) modelinde

$$y = XTT's + v = Zr + v \quad (4.7)$$

dönü ümü ele alınsın. Burada  $T = (t_1, t_2, \dots, t_p) \in \mathbb{R}^{p \times p}$  ortogonal matristir. Ayrıca

$$T'X'XT = Z'Z$$

olarakta yazılabilir.  $Z = XT = (z_1, z_2, \dots, z_p)$  matrisi temel bile enler matrisi olarak bilinir. Bu matrisin  $i$ . elemanı  $z_i = Xt_i$ ,  $i$ . temel bile endir.  $S$ 'nin genelle tirilmi temel bile enler tahmin edicisi bazı  $z_i$  de  $i$  kenlerinin ihmal edilmesi ile elde edilir.

Bunun için  $Z = (Z_r, Z_{p-r})$  parçalanmış matrisi ele alınsın. Bu durumda  $Z_r = XT_r$  ve  $T_r'S = r_r$  olur. Ayrıca  $T_r'S = r_r$  ifadesi soldan  $T_r$  ile çarpılırsa

$$T_r T_r' S = T_r r_r$$

elde edilir.  $T_r T_r' = I$  oldu undan  $S = T_r r_r$  olur. Yani (4.7) modelinde  $Z$  matrisinin yerine  $Z = (Z_r, Z_{p-r})$  parçalanmış matrisi yazılırsa

$$\begin{aligned} y &= (Z_r, Z_{p-r}) \begin{pmatrix} r_r \\ r_{p-r} \end{pmatrix} + v \\ &= X(T_r, T_{p-r}) \begin{pmatrix} T_r' \\ T_{p-r}' \end{pmatrix} S + v \\ &= X(T_r T_r' + T_{p-r} T_{p-r}') S + v \\ &= XT_r T_r' S + XT_{p-r} T_{p-r}' S + v \\ &= Z_r r_r + Z_{p-r} r_{p-r} + v \end{aligned}$$

elde edilir. Burada  $Z_{p-r} r_{p-r}$  ihmal edilirse model

$$y = Z_r r_r + v \quad (4.8)$$

modeline indirgenmiş olur. (4.8) modeli üzerinde genelleştirilmiş en küçük kareler tahmini yöntemi uygulanırsa

$$\hat{r}_r = (Z_r' V^{-1} Z_r)^{-1} (Z_r' V^{-1} y) \quad (4.9)$$

elde edilir. (4.9)'da  $Z_r$  ile  $r_r$  yerine yazılır ve bulunan ifade  $T_r$  ile soldan çarpılırsa

$$\hat{S}_{GPCR} = T_r (T_r' X' V^{-1} X T_r)^{-1} (T_r' X' V^{-1} y) \quad (4.10)$$

olarak elde edilir.

#### 4.6. Genelle tirilmi Rasgele Kısıtlı Temel Bile enler Regresyon (GSRPCR)

##### Tahmin Edicisi

(4.1) lineer modeli ve (3.14) kısıtı ile birlikte ele alınsın. Bu iki model birlikte

$$Y = \begin{pmatrix} y \\ h \end{pmatrix}, G = \begin{pmatrix} Z_r \\ H_r \end{pmatrix} \text{ ve } u = \begin{pmatrix} v \\ e \end{pmatrix} \text{ olmak üzere}$$

$$Y = G\Gamma_r + u \quad (4.11)$$

modeli ile ifade edilebilir. Burada

$$E(u) = 0, \text{ Cov}(u) = \Sigma = \dagger^2 \begin{pmatrix} V & 0 \\ 0 & W \end{pmatrix}$$

ve  $W$  pozitif kararlı matristir. (4.11) modelinde GOME'nin elde edilme yöntemi kullanılarak yeni tahmin edici

$$\mathbb{E} = (y - Z_r\Gamma_r)'V^{-1}(y - Z_r\Gamma_r) + (h - H_r\Gamma_r)'W^{-1}(h - H_r\Gamma_r)$$

ifadesinin  $\Gamma_r$ 'ye göre minimumla tırılmasıyla elde edilir. Yani  $\mathbb{E}$ 'nin  $\Gamma_r$ 'ye göre türevi alınır ve sıfıra e itlenirse

$$(Z_r'V^{-1}Z_r + H_r'W^{-1}H_r)\Gamma_r = Z_r'V^{-1}y + H_r'W^{-1}h$$

bulunur. Buradan

$$\Gamma_r^* = (Z_r'V^{-1}Z_r + H_r'W^{-1}H_r)^{-1}(Z_r'V^{-1}y + H_r'W^{-1}h)$$

elde edilir.  $H_r$  ile  $\Gamma_r$  yerine yazılır ve bulunan ifade  $T_r$  ile soldan çarpılırsa

$$\hat{S}_{GSRPCR} = T_r(T_r'X'V^{-1}XT_r + T_r'H'W^{-1}HT_r)^{-1}(T_r'X'V^{-1}y + T_r'H'W^{-1}h) \quad (4.12)$$

bulunur.

#### 4.7. Genelle tirilmi A ırlıklı Rasgele Temel Bile enler Regresyon (GWSRPCR) Tahmin Edicisi

(4.1) modeli ve (3.5) kısıtlamasında regresyon parametrelerinin tahmininde e it a ırlıkların gereklili i söz konusu olmadı ında

$$\hat{S}_{GWSRPCR}(w) = T_r(T_r'X'V^{-1}XT_r + wT_r'H'W^{-1}HT_r)^{-1}(T_r'X'V^{-1}y + wT_r'H'W^{-1}h) \quad (4.13)$$

ile verilen genelle tirilmi a ırlıklı rasgele temel bile enler resgesyon tahmin edicisi (GWSRPCR) ele alınabilir. Burada WSRPCR'de oldu u gibi  $w$  rasgele de ildir ve  $0 \leq w \leq 1$  olarak alınabilir.

#### 4.8. Bazı Genelle tirilmi Yanlı Tahmin Edicilerin MSE Ölçütüne Göre Kar ıla tırılmaları

##### 4.8.1. GSRPCR ve GPCR tahmin edicilerinin kar ıla tırılması

$$\begin{aligned} E(\hat{S}_{GPCR}) &= T_r(T_r'X'V^{-1}XT_r)^{-1}(T_r'X'V^{-1}E(y)) \\ &= T_r(T_r'X'V^{-1}XT_r)^{-1}(T_r'X'V^{-1}E(Z_r\Gamma_r + v)) \\ &= T_r(T_r'X'V^{-1}XT_r)^{-1}(T_r'X'V^{-1}Z_r\Gamma_r) \\ &= T_r(T_r'X'V^{-1}XT_r)^{-1}(T_r'X'V^{-1}XT_r)T_r'S \\ &= T_rT_r'S \end{aligned} \quad (4.14)$$

oldu undan  $\hat{S}_{GPCR}$ 'nin yanlılı ı

$$\begin{aligned} Bias(\hat{S}_{GPCR}) &= E(\hat{S}_{GPCR}) - S \\ &= T_rT_r'S - S \\ &= (T_rT_r' - I)S \\ &= -T_{p-r}T_{p-r}'S \end{aligned} \quad (4.15)$$

dir.

$$\begin{aligned}
Cov(\hat{S}_{GPCR}) &= [T_r(T_r'X'V^{-1}XT_r)^{-1}T_r'X'V^{-1}]Cov(y)[T_r(T_r'X'V^{-1}XT_r)^{-1}T_r'X'V^{-1}]' \\
&= [T_r(T_r'X'V^{-1}XT_r)^{-1}T_r'X'V^{-1}]Cov(y - X\beta)[T_r(T_r'X'V^{-1}XT_r)^{-1}T_r'X'V^{-1}]' \\
&= [T_r(T_r'X'V^{-1}XT_r)^{-1}T_r'X'V^{-1}]Cov(v)[V^{-1}XT_r(T_r'X'V^{-1}XT_r)^{-1}T_r'] \\
&= [T_r(T_r'X'V^{-1}XT_r)^{-1}T_r'X'V^{-1}]\dagger^2V[V^{-1}XT_r(T_r'X'V^{-1}XT_r)^{-1}T_r'] \\
&= \dagger^2T_r(T_r'X'V^{-1}XT_r)^{-1}(T_r'X'V^{-1}VV^{-1}XT_r)(T_r'X'V^{-1}XT_r)^{-1}T_r' \\
&= \dagger^2T_r(T_r'X'V^{-1}XT_r)^{-1}T_r'
\end{aligned} \tag{4.16}$$

olarak bulunur. Böylece (3.18)'e göre  $\hat{S}_{GPCR}$  tahmin edicisinin MSE matrisi

$$M(\hat{S}_{GPCR}) = \dagger^2T_r(T_r'X'V^{-1}XT_r)^{-1}T_r' + T_{p-r}T_{p-r}'SS'T_{p-r}T_{p-r}'$$

olarak elde edilir.

$$E(\hat{S}_{GSRPCR}) = T_r(T_r'X'V^{-1}XT_r + T_r'H'W^{-1}HT_r)^{-1}[T_r'X'V^{-1}E(y) + T_r'H'W^{-1}E(h)]$$

dir.

$$E(y) = E(Z_r r_r + v) = E(Z_r r_r) = Z_r r_r = XT_r T_r' S,$$

$$E(h) = E(H_r r_r + e) = E(H_r r_r) = H_r r_r = HT_r T_r' S$$

oldu undan

$$E(\hat{S}_{GSRPCR}) = T_r(T_r'X'V^{-1}XT_r + T_r'H'W^{-1}HT_r)^{-1}(T_r'X'V^{-1}XT_r T_r' S + T_r'H'W^{-1}HT_r T_r' S)$$

olarak bulunur. Bu ifade sa dan  $T_r' S$  parantezine alınırsa

$$\begin{aligned}
E(\hat{S}_{GSRPCR}) &= T_r(T_r'X'V^{-1}XT_r + T_r'H'W^{-1}HT_r)^{-1}(T_r'X'V^{-1}XT_r + T_r'H'W^{-1}HT_r)T_r'S \\
&= T_rT_r'S
\end{aligned} \tag{4.17}$$

elde edilir. (4.14) ve (4.17) aynı oldu undan  $\hat{S}_{GSRPCR}$  tahmin edicisinin yanlışlığı ıda  $\hat{S}_{GPCR}$ 'nin yanlışlığı ı ile aynı bulunur.

$$\begin{aligned}
Cov(\hat{S}_{GSRPCR}) &= T_r(T_r'X'V^{-1}XT_r + T_r'H'W^{-1}HT_r)^{-1}(T_r'X'V^{-1}\underbrace{Cov(y)}_{\dagger^2V}V^{-1}XT_r \\
&\quad + T_r'H'W^{-1}\underbrace{Cov(h)}_{\dagger^2W}W^{-1}HT_r)[T_r(T_r'X'V^{-1}XT_r + T_r'H'W^{-1}HT_r)^{-1}]' \\
&= \dagger^2T_r(T_r'X'V^{-1}XT_r + T_r'H'W^{-1}HT_r)^{-1}(T_r'X'V^{-1}XT_r + T_r'H'W^{-1}HT_r) \\
&\quad \times (T_r'X'V^{-1}XT_r + T_r'H'W^{-1}HT_r)^{-1}T_r' \\
&= \dagger^2T_r(T_r'X'V^{-1}XT_r + T_r'H'W^{-1}HT_r)^{-1}T_r'
\end{aligned} \tag{4.18}$$

olarak bulunur. Böylece (3.18)'e göre  $\hat{S}_{GSRPCR}$  tahmin edicisinin MSE matrisi

$$M(\hat{S}_{GSRPCR}) = \dagger^2T_r(T_r'X'V^{-1}XT_r + T_r'H'W^{-1}HT_r)^{-1}T_r' + T_{p-r}T_{p-r}'SS'T_{p-r}T_{p-r}' \tag{4.19}$$

eklinindedir.

$\hat{S}_{GPCR}$  ve  $\hat{S}_{GSRPCR}$  tahmin edicilerinin MSE ölçütüne göre karşılaştırılmaları ile ilgili aşağıdaki teorem verilebilir.

**Teorem 4.8.1.** MSE ölçütüne göre  $\hat{S}_{GSRPCR}$  tahmin edicisi her zaman  $\hat{S}_{GPCR}$  tahmin edicisinden üstündür.



**spat:**  $\hat{S}_{GSRPCR}$  ve  $\hat{S}_{GPCR}$  tahmin edicilerinin yanlılıkları aynı oldu undan MSE ölçütüne göre kar ıla tırılmaları yapılırken sadece kovaryans matrislerinin farklarına bakmak yeterli olacaktır. Böylece (4.18) ve (4.16) e itliklerinden

$$\begin{aligned} & Cov(\hat{S}_{GPCR}) - Cov(\hat{S}_{GSRPCR}) \\ &= \dagger^2 T_r [(T_r' X V^{-1} X T_r)^{-1} - (T_r' X V^{-1} X T_r + T_r' H' W^{-1} H T_r)^{-1}] T_r' \end{aligned} \quad (4.20)$$

elde edilir. Teorem 2.2.4'e göre,

$$\begin{aligned} & (T_r' X V^{-1} X T_r + T_r' H' W^{-1} H T_r)^{-1} \\ &= (T_r' X V^{-1} X T_r)^{-1} - (T_r' X V^{-1} X T_r)^{-1} T_r' H' (W + H T_r (T_r' X V^{-1} X T_r)^{-1} T_r' H')^{-1} H T_r (T_r' X V^{-1} X T_r)^{-1} \end{aligned}$$

bulunur. Bu e itlik (4.20)'de yerine yazılır ve Teorem 2.4.3 kullanılırsa

$$\begin{aligned} & Cov(\hat{S}_{GPCR}) - Cov(\hat{S}_{GSRPCR}) \\ &= \dagger^2 T_r [(T_r' X V^{-1} X T_r)^{-1} T_r' H' (W + H T_r (T_r' X V^{-1} X T_r)^{-1} T_r' H')^{-1} H T_r (T_r' X V^{-1} X T_r)^{-1}] T_r' \geq 0 \end{aligned}$$

olur ve ispat biter.

#### 4.8.2. GWSRPCR ve GPCR tahmin edicilerinin kar ıla tırılması

$$E[\hat{S}_{GWSRPCR}(w)] = T_r (T_r' X V^{-1} X T_r + w T_r' H' W^{-1} H T_r)^{-1} [T_r' X V^{-1} \underbrace{E(y)}_{XT_r' S} + w T_r' H' W^{-1} \underbrace{E(h)}_{HT_r' S}]$$

olarak yazılır. Bu ifade sa dan  $T_r' S$  parantezine alınırsa

$$\begin{aligned} E[\hat{S}_{GWSRPCR}(w)] &= T_r (T_r' X V^{-1} X T_r + w T_r' H' W^{-1} H T_r)^{-1} (T_r' X V^{-1} X T_r + w T_r' H' W^{-1} T_r) T_r' S \\ &= T_r T_r' S \end{aligned}$$

elde edilir.

$$Bias[\hat{S}_{GWSRPCR}(w)] = -T_{p-r} T'_{p-r} S \quad (4.21)$$

olarak bulunur.  $\hat{S}_{GWSRPCR}(w)$  ve  $\hat{S}_{GPCR}(w)$ 'nin sırasıyla (4.21) ve (4.14)'te verilen yanlışlıkların aynı oldu u görülür.

$$\begin{aligned} Cov[\hat{S}_{GWSRPCR}(w)] &= T_r (T_r' X V^{-1} X T_r + w T_r' H' W^{-1} H T_r)^{-1} \\ &\quad \times (T_r' X V^{-1} \underbrace{Cov(y)}_{\dagger^2 V} V^{-1} X T_r + w T_r' H' W^{-1} \underbrace{Cov(h)}_{\dagger^2 W} W^{-1} H T_r w) \\ &\quad \times (T_r (T_r' X V^{-1} X T_r + w T_r' H' W^{-1} H T_r)^{-1})' \\ &= \dagger^2 T_r (T_r' X V^{-1} X T_r + w T_r' H' W^{-1} H T_r)^{-1} (T_r' X V^{-1} X T_r \\ &\quad + w^2 T_r' H' W^{-1} H T_r)^{-1} (T_r' X V^{-1} X T_r + w T_r' H' W^{-1} H T_r)^{-1} T_r' \end{aligned} \quad (4.22)$$

elde edilir. Böylece (3.18)'e göre  $\hat{S}_{GWSRPCR}(w)$  tahmin edicisinin MSE matrisi

$$\begin{aligned} M[\hat{S}_{WSRPCR}(w)] &= \dagger^2 T_r (T_r' X V^{-1} X T_r + w T_r' H' W^{-1} H T_r)^{-1} (T_r' X V^{-1} X T_r + w^2 T_r' H' W^{-1} H T_r)^{-1} \\ &\quad \times (T_r' X V^{-1} X T_r + w T_r' H' W^{-1} H T_r)^{-1} T_r' + T_{p-r} T'_{p-r} S S' T_{p-r} T'_{p-r} \end{aligned} \quad (4.23)$$

olarak bulunur.

$\hat{S}_{GPCR}$  ve  $\hat{S}_{GWRPCR}(w)$  tahmin edicilerinin MSE ölçütüne göre karşılaştırılmaları ile ilgili aşağıdaki teorem verilebilir.

**Teorem 4.8.2.** MSE ölçütüne göre  $\hat{S}_{GWSRPCR}(w)$  tahmin edicisi her zaman  $\hat{S}_{GPCR}$  tahmin edicisinden üstündür.

**spat:**  $\hat{S}_{GWSRPCR}(w)$  ve  $\hat{S}_{GPCR}$  tahmin edicilerinin yanlışlıkları aynı olduğundan MSE ölçütüne göre karşılaştırılmaları yapılırken kovaryans matrislerinin farklarına bakılacaktır. (4.22) ve (4.16) eşitliklerinden

$$\begin{aligned}
& Cov(\hat{S}_{GPCR}) - Cov[\hat{S}_{GWSRPCR}(w)] \\
&= \dagger^2 T_r (T_r' X V^{-1} X T_r)^{-1} T_r' - \dagger^2 T_r (T_r' X V^{-1} X T_r + w T_r' H' W^{-1} H T_r)^{-1} \\
&\quad \times (T_r' X V^{-1} X T_r + w^2 T_r' H' W^{-1} H T_r)^{-1} (T_r' X V^{-1} X T_r + w T_r' H' W^{-1} H T_r)^{-1} T_r' \\
&= \dagger^2 T_r \left[ (T_r' X V^{-1} X T_r)^{-1} - (T_r' X V^{-1} X T_r + w T_r' H' W^{-1} H T_r)^{-1} \right. \\
&\quad \left. \times (T_r' X V^{-1} X T_r + w^2 T_r' H' W^{-1} H T_r)^{-1} (T_r' X V^{-1} X T_r + w T_r' H' W^{-1} H T_r)^{-1} \right] T_r' \\
&= \dagger^2 T_r (T_r' X V^{-1} X T_r + w T_r' H' W^{-1} H T_r)^{-1} \\
&\quad \times \left[ (T_r' X V^{-1} X T_r + w T_r' H' W^{-1} H T_r) (T_r' X V^{-1} X T_r)^{-1} (T_r' X V^{-1} X T_r + w T_r' H' W^{-1} H T_r) \right. \\
&\quad \left. - (T_r' X V^{-1} X T_r + w^2 T_r' H' W^{-1} H T_r)^{-1} \right] (T_r' X V^{-1} X T_r + w T_r' H' W^{-1} H T_r)^{-1} T_r' \quad (4.24)
\end{aligned}$$

elde edilir. Burada

$$(T_r' X V^{-1} X T_r + w T_r' H' W^{-1} H T_r) (T_r' X V^{-1} X T_r)^{-1} (T_r' X V^{-1} X T_r + w T_r' H' W^{-1} H T_r)$$

ifadesi düzenlenirse

$$\begin{aligned}
& (T_r' X V^{-1} X T_r + w T_r' H' W^{-1} H T_r) (T_r' X V^{-1} X T_r)^{-1} (T_r' X V^{-1} X T_r + w T_r' H' W^{-1} H T_r) \\
&= T_r' X V^{-1} X T_r + 2w T_r' H' W^{-1} H T_r + w^2 T_r' H' W^{-1} H T_r (T_r' X V^{-1} X T_r)^{-1} T_r' H' W^{-1} H T_r
\end{aligned}$$

olur. Bu ifade (4.24)'te yerine yazılırsa

$$\begin{aligned}
&= \dagger^2 T_r (T_r' X V^{-1} X T_r + w T_r' H' W^{-1} H T_r)^{-1} \left[ (2-w) w T_r' H' W^{-1} H T_r' \right. \\
&\quad \left. + w^2 T_r' H' W^{-1} H T_r (T_r' X V^{-1} X T_r)^{-1} T_r' H' W^{-1} H T_r \right] (T_r' X V^{-1} X T_r + w T_r' H' W^{-1} H T_r)^{-1} T_r'
\end{aligned}$$

bulunur.  $0 \leq w \leq 1$  oldu undan  $2-w > 0$  olur ve Teorem 2.4.3'e göre

$$M(\hat{S}_{GPCR}) - M(\hat{S}_{GWSRPCR}(w)) \geq 0$$

elde edilir ve ispat biter.

### 4.8.3. GWSRPCR ve GSRPCR tahmin edicilerinin kar ıla tırılması

**Teorem 4.8.3.** MSE ölçütüne göre  $\hat{S}_{GSRPCR}$  tahmin edicisi her zaman  $\hat{S}_{GWSRPCR}(w)$  tahmin edicisinden üstündür.

**spat:**  $\hat{S}_{GWSRPCR}(w)$  ve  $\hat{S}_{GSRPCR}$  tahmin edicilerinin yanlılıkları aynı oldu undan MSE ölçütüne göre kar ıla tırılmaları yapılırken kovaryans matrislerinin farklarına bakılacaktır. (4.18) ve (4.22) e itliklerinden

$$\begin{aligned}
& Cov(\hat{S}_{GSRPCR}) - Cov[\hat{S}_{GWSRPCR}(w)] \\
&= \dagger^2 T_r (T_r' X V^{-1} X T_r + T_r' H' W^{-1} H T_r)^{-1} T_r' - \dagger^2 T_r (T_r' X V^{-1} X T_r + w T_r' H' W^{-1} H T_r)^{-1} \\
&\quad \times (T_r' X V^{-1} X T_r + w^2 T_r' H' W^{-1} H T_r) (T_r' X V^{-1} X T_r + w T_r' H' W^{-1} H T_r)^{-1} T_r' \\
&= \dagger^2 T_r \left[ (T_r' X V^{-1} X T_r + T_r' H' W^{-1} H T_r)^{-1} - (T_r' X V^{-1} X T_r + w T_r' H' W^{-1} H T_r)^{-1} \right. \\
&\quad \left. \times (T_r' X V^{-1} X T_r + w^2 T_r' H' W^{-1} H T_r) (T_r' X V^{-1} X T_r + w T_r' H' W^{-1} H T_r)^{-1} \right] T_r' \\
&= -\dagger^2 (w-1)^2 T_r (T_r' X V^{-1} X T_r + w T_r' H' W^{-1} H T_r)^{-1} (T_r' X V^{-1} X T_r + T_r' H' W^{-1} H T_r) \\
&\quad \times (T_r' X V^{-1} X T_r) (T_r' H' W^{-1} H T_r) (T_r' X V^{-1} X T_r + w T_r' H' W^{-1} H T_r)^{-1} T_r'
\end{aligned}$$

elde edilir.  $0 \leq w \leq 1$  oldu undan  $0 \leq (w-1)^2 \leq 1$  oldu u görülür. Dolayısıyla Teorem 2.4.3'e göre

$$M(\hat{S}_{GSRPCR}) - M[\hat{S}_{GWSRPCR}(w)] \leq 0$$

olur ve ispat biter.

### 4.8.4. GSRLE ve GSRPCR tahmin edicilerinin kar ıla tırılması

$$E[\hat{S}_{GSRLE}(d)] = E(F_d \hat{S}_{GOME}) = F_d S$$

dir. Böylece

$$\begin{aligned} \text{Bias}[\hat{S}_{GSRL E}(d)] &= E[\hat{S}_{GSRL E}(d)] - \hat{S}_{GSRL E}(d) \\ &= F_d S - S = (F_d - I)S \end{aligned} \quad (4.25)$$

elde edilir. Ayrıca

$$\begin{aligned} \text{Cov}[\hat{S}_{GSRL E}(d)] &= \text{Cov}(F_d \hat{S}_{GOME}) \\ &= \text{Cov}[F_d (X'V^{-1}X + H'W^{-1}H)^{-1}(X'V^{-1}y + H'W^{-1}h)] \\ &= F_d (X'V^{-1}X + H'W^{-1}H)^{-1} (X' \underbrace{\text{Cov}(y)}_{\dagger^2 V} X + H'W^{-1} \underbrace{\text{Cov}(h)}_{\dagger^2 W} W^{-1}H) \\ &\quad \times (X'V^{-1}X + H'W^{-1}H)^{-1} F_d' \\ &= \dagger^2 F_d (X'V^{-1}X + H'W^{-1}H)^{-1} (X'V^{-1}X + H'W^{-1}H) \\ &\quad \times (X'V^{-1}X + H'W^{-1}H)^{-1} F_d' \\ &= \dagger^2 F_d (X'V^{-1}X + H'W^{-1}H)^{-1} F_d' \end{aligned} \quad (4.26)$$

olur. Böylece (3.18)'ye göre  $\hat{S}_{GSRL E}(d)$  tahmin edicisinin MSE matrisi

$$M[\hat{S}_{GSRL E}(d)] = \dagger^2 F_d (X'V^{-1}X + H'W^{-1}H)^{-1} F_d' + (F_d - I)SS'(F_d - I)' \quad (4.27)$$

olarak yazılır.  $\hat{S}_{GSRL E}(d)$  ve  $\hat{S}_{GSRPCR}$  tahmin edicilerinin MSE matris farkları

$$\begin{aligned} \Delta_1 &= M[\hat{S}_{GSRL E}(d)] - M(\hat{S}_{GSRPCR}) \\ &= \dagger^2 F_d (X'V^{-1}X + H'W^{-1}H)^{-1} F_d' + (F_d - I)SS'(F_d - I)' \\ &\quad - \left[ \dagger^2 T_r (T_r'X'V^{-1}XT_r + T_r'H'W^{-1}HT_r)^{-1} T_r' + T_{p-r} T_{p-r}' SS' T_{p-r} T_{p-r}' \right] \end{aligned} \quad (4.28)$$

olarak gösterilir.

$$D_1 = F_d (X'V^{-1}X + H'W^{-1}H)^{-1} F_d' - T_r (T_r' X' V^{-1} X T_r + T_r' H' W^{-1} H T_r)^{-1} T_r',$$

$$b_1 = (F_d - I)S,$$

$$b_2 = T_{p-r} T_{p-r}' S$$

olmak üzere (4.28)

$$\Delta_1 = \dagger^2 D_1 + b_1 b_1' - b_2 b_2'$$

olarakta yazılabilir.

$\hat{S}_{GSRPCR}$  ve  $\hat{S}_{GSRL E}(d)$  tahmin edicilerinin MSE ölçütüne göre karıla tırılmaları ile ilgili a a ıdaki teorem verilebilir.

**Teorem 4.8.4.**  $0 < d < 1$  ve

$$\} _1 \left\{ \left[ T_r (T_r' X' V^{-1} X T_r + T_r' H' W^{-1} H T_r)^{-1} T_r' \right] \left[ F_d (X' V^{-1} X + H' W^{-1} H)^{-1} F_d' \right] \right\} < 1$$

iken MSE ölçütüne göre  $\hat{S}_{GSRPCR}$  tahmin edicisi  $\hat{S}_{GSRL E}(d)$  tahmin edicisinden üstündür. Yani

$$\Delta_1 \geq 0 \Leftrightarrow b_2' (\dagger^2 D_1 + b_1 b_1')^{-1} b_2 \leq 1$$

dir.

**spat:**  $0 < d < 1$  iken

$$F_d (X' V^{-1} X + H' W^{-1} H)^{-1} F_d' > 0 \text{ ve } T_r (T_r' X' V^{-1} X T_r + T_r' H' W^{-1} H T_r)^{-1} T_r' \geq 0$$

oldu u açıktır.  $D_1 = A - B$  olarak dü ünülürse Teorem 2.4.5'e göre  $\} _1(BA^{-1}) < 1$

oldu undan  $D_1 = A - B > 0$  elde edilir. Teorem 2.4.6'ya göre

$$\Delta_1 \geq 0 \Leftrightarrow b_2'(\dagger^2 D_1 + b_1 b_1')^{-1} b_2 \leq 1$$

olur ve ispat biter.

#### 4.8.5. GSRLE ve GWSRPCR tahmin edicilerinin karşılaştırılması

$\hat{S}_{GSRLE}(d)$  ve  $\hat{S}_{GWSRPCR}(w)$  tahmin edicilerinin MSE matris farkları

$$\begin{aligned} \Delta_2 &= M[\hat{S}_{GSRLE}(d)] - M[\hat{S}_{GWSRPCR}(w)] \\ &= \dagger^2 F_d (X'V^{-1}X + H'W^{-1}H)^{-1} F_d' + (F_d - I)SS'(F_d - I)' \\ &\quad - \left[ \dagger^2 T_r (T_r'X'V^{-1}XT_r + wT_r'H'W^{-1}HT_r)^{-1} (T_r'X'V^{-1}XT_r + w^2T_r'H'W^{-1}HT_r)^{-1} \right. \\ &\quad \left. \times (T_r'X'V^{-1}XT_r + wT_r'H'W^{-1}HT_r)^{-1} T_r' + T_{p-r}T_{p-r}'SS'T_{p-r}T_{p-r}' \right] \end{aligned} \quad (4.29)$$

olarak gösterilir.

$$\begin{aligned} D_2 &= F_d (X'V^{-1}X + H'W^{-1}H)^{-1} F_d' - T_r (T_r'X'V^{-1}XT_r + T_r'H'W^{-1}HT_r)^{-1} \\ &\quad \times (T_r'X'V^{-1}XT_r + w^2T_r'H'W^{-1}HT_r)^{-1} (T_r'X'V^{-1}XT_r + wT_r'H'W^{-1}HT_r)^{-1} T_r' \end{aligned}$$

$$b_1 = (F_d - I)S$$

$$b_2 = T_{p-r}T_{p-r}'S$$

olmak üzere (4.29)

$$\Delta_2 = \dagger^2 D_2 + b_1 b_1' - b_2 b_2'$$

olarakta yazılabilir.

$\hat{S}_{GSRLE}(d)$  ve  $\hat{S}_{GWSRPCR}(w)$  tahmin edicilerinin MSE ölçütüne göre karşılaştırmaları

ile ilgili aşağıdaki teorem verilebilir.

**Teorem 4.8.5.**  $0 < d < 1$ ,  $0 \leq w \leq 1$  ve

$$\} _1 \left\{ [T_r (T_r' X V^{-1} X T_r + w T_r' H' W^{-1} H T_r)^{-1} (T_r' X V^{-1} X T_r + w^2 T_r' H' W^{-1} H T_r)^{-1} \right. \\ \left. \times (T_r' X V^{-1} X T_r + w T_r' H' W^{-1} H T_r)^{-1} T_r'] [F_d (X' X + H' W^{-1} H)^{-1} F_d']^{-1} \right\} < 1 \quad (4.30)$$

iken MSE ölçütüne göre  $\hat{S}_{GWSRPCR}(w)$  tahmin edicisi  $\hat{S}_{GSRL E}(d)$  tahmin edicisinden üstündür. Yani

$$\Delta_2 \geq 0 \Leftrightarrow b_2' (\dagger^2 D_2 + b_1 b_1')^{-1} b_2 \leq 1$$

dir.

**spat:**  $D_2 = A - B$  olarak dü ünülürse  $0 < d < 1$  ve  $0 \leq w \leq 1$  iken  $A > 0$  ve  $B \geq 0$  dır.  $\} _1(BA^{-1}) < 1$  oldu undan Teorem 2.4.5'e göre  $D_2 > 0$  dır. Teorem 2.4.6'ya göre ise

$$\Delta_2 \geq 0 \Leftrightarrow b_2' (\dagger^2 D_2 + b_1 b_1')^{-1} b_2 \leq 1$$

olur ve ispat biter.



## BÖLÜM 5. SONUÇ VE ÖNERİLER

Bu çalışmada lineer modeller altında bazı yanlış tahmin ediciler ayrıntılı olarak incelendi ve bu tahmin edicilerin MSE ölçütüne göre karşılaştırılmaları ile ilgili bazı sonuçlar verildi.

Bölüm 3'te  $E(v)=0$  ve  $Cov(v)=\sigma^2 I$  varsayımları altında  $y=XS+v$  lineer modeli ve bu model için  $E(e)=0$  ve  $Cov(e)=\sigma^2 W$  olmak üzere  $h=HS+e$  kısıtı ele alınarak

$$\hat{S}_{OME} = (X'X + H'W^{-1}H)^{-1}(X'y + H'W^{-1}h)$$

tahmin edicisi elde edildi. Daha sonra  $y=XS+v$  modeli için  $y=XTT'S+v=Zr+v$  dönüşümü ele alınarak

$$\hat{S}_{PCR} = T_r(T_r'X'XT_r)^{-1}T_r'X'y$$

tahmin edicisi ve  $h=HS+e$  kısıtı için  $h=HTT'S+e$  dönüşümü ele alınarak OME'nin elde edilme yöntemi kullanılarak

$$\hat{S}_{SRPCR} = T_r(T_r'X'XT_r + T_r'H'W^{-1}HT_r)^{-1}(T_r'X'y + T_r'H'W^{-1}h)$$

tahmin edicisi elde edildi.  $\hat{S}_{SRPCR}$ 'nin

$$\hat{S}_{WSRPCR}(w) = T_r(T_r'X'XT_r + wT_r'H'W^{-1}HT_r)^{-1}(T_r'X'y + wT_r'H'W^{-1}h)$$

ayrık tahmin edicisi detaylı olarak incelendi. Daha sonra bu ele alınan tahmin edicilerinin MSE ölçütüne göre karşılaştırılmaları ile ilgili teoremler ve ispatları verildi.

Bölüm 4'te önceki bölümde ele alınan lineer model  $E(v)=0$   $Cov(v)=\sigma^2V$  varsayımları altında ele alınarak Bölüm 3'te incelenen yanlı tahmin ediciler ve özellikleri bu varsayımlar altında genelleştirildi. Daha sonra elde edilen genelleştirilmiş yanlı tahmin edicilerin MSE ölçütüne göre karşılaştırılmaları ile ilgili teoremler ve ispatları verildi.

Bu çalışmada ele alınan genelleştirilmiş yanlı tahmin edicilerin performansları farklı ölçütlere göre karşılaştırılabilir. Ayrıca ele alınan lineer modelde hata vektörünün kovaryans matrisinin nonnegatif kararlı olması durumunda daha genel sonuçlar elde edilebilir.

## KAYNAKLAR

- [1] ÖZTÜRK, F., Olasılık ve istatisti e giri II., Ankara, 2011.
- [2] ALBERT, A., The Gauss-Markov thorem for regression models with possible singular covariances, SIAM Journal on Applied Mathematics, 24, 182-187, 1973.
- [3] STEIN, C., Inadmissibility of the usual estimator for mean of multivariate normal distribution, in Proceedings of the 3<sup>rd</sup> Berkley Symposium on Mathematical and Statistics Probability, J. Neyman, 1, 197-206, 1956.
- [4] MASSY, W. F., Principal components regression in exploratory stactical research, Journal of the American Stactical Association, 60(309), 234-266, 1965.
- [5] HOERL A. E., KENNARD R. W., Ridge regression: biased estimation for nonorthogonal problems, Thecnometrics, 12(1), 55-67, 2000.
- [6] LIU K., A new class of biased estimate in linear regression, Communications in Statistics-Theory and Methods, 22(1), 393-402, 1993.
- [7] DURBIN, J., A note on regression when there is extraneous information that one of coefficients, J. Amer. Statist. Assoc., 48, 799-808, 1953.
- [8] THEIL, H., GOLDBERGER, A. S., On pure and mixed statistical estimation in economics, Inern. Econ. Rev., 2, 65-78, 1961.
- [9] THEIL. H., On the use of incompleteprior information in regression analysis, J. Amer. Statist. Assoc., 58, 401-414, 1963.
- [10] HUBERT, M. H., WIJEKON, P., Improvement of the Liu estimator in linear regression model, Statical Paper, 47, 471-479, 2006.
- [11] LI, Y. L. , YANG, H., A new stochastic mixed ridge estimator in linear regression model, Statical Paper, 51, 315-323, 2010.
- [12] YANG, H., XU, J. W., An alternative stochastic restricted Liu estimator in linear regression, Statical Paper, 50, 639-647, 2009.
- [13] WU, J. and YANG, H., Two stochastic restricted principal components regression estimator in linear regression, Communications in Statistics–Theory and Methods, 42, 3793-3804, 2013.

- [14] HOTELLING, H., Analysis of a complex of statistical variables into principal components, *Journal of Educational Psychology*, 24, 417-441 and 489-520, 1933.
- [15] PUNTANEN, S., STYAN, G.P.H., ISOTALO, J., *Matrix tricks for linear statistical models*, Our Personal Top Twenty, Springer, Heidelberg, 2011.
- [16] MAGNUS, J. R., NEUDECKER, H., *Matrix differential calculus with applications in statistics and econometrics*, John Wiley, G.Britain, 1988.
- [17] SENGUPTA, D., JAMMALAMADAKA, S. R., *Linear models an integrated approach*, World Scientific, Singapore, 2003.
- [18] VENIT, S., BISHOP, W., *Elementary linear algebra*, PWS publishers, Massachusetts, 1985.
- [19] SCHOTT, J. R., *Matrix analysis for statistic*, Wiley Series in Probability and Statistic, 2005.
- [20] SEBER, G. A. F., *Linear regression analysis*, John Wiley, New York, 1977.
- [21] WANG, S. G., WU, M. X., JIA, Z. Z., *Matrix inequalities*, 2nd ed. Beijing: Chinese Science Press, 2006.
- [22] FAREBROTHER, R. W., Further results on the mean square error of ridge regression, *J. Roy. Statist. Soc. B*, 38, 248-250, 1976.
- [23] SEBER, G. A. F., *A matrix handbook for statisticians*, John Wiley & Sons, Inc. , New Jersey, 2008.
- [24] GRAYBILL, F. A., *Introduction to matrices with applications in statistics*, Wadworth Publishing Company inc., California, 1969.
- [25] JOHNSON, R. A, WICHERN, D. W., *Applied multivariate statistical analysis*, Prentice –Hall, New Jersey, 1982.
- [26] ÖZKALE, M. R., Principal components regression estimator and a test for the restrictions, *Statistics*, 43, 541-551, 2009.

## ÖZGEÇM

Esra Ho söz, 26.08.1987 de Ankara'da do du. lk, orta ve lise e itimini Ankara'da tamamladı. 2006 yılında Hacettepe Üniversitesi Fen Fakültesi Matematik Bölümü'nde ba ladı ı lisans e itimini 2011 yılında tamamladı. 2012 yılında yüksek lisans e itimine ba ladı. Ayrıca 2012-2013 yılları arasında Sakarya'da özel bir bankada çalı tı. u anda özel bir okulda ö retmenlik yapmaktadır.