
GAZİ ÜNİVERSİTESİ
Gazi
1926

RİDGE VE LİU REGRESYONDA TAVLAMA BENZETİMİ OPTİMİZASYONU KULLANILARAK YANLILIK PARAMETRELERİNİN ELDE EDİLMESİ VE BAZI YANLILIK PARAMETRELERİ İLE KARŞILAŞTIRILMASI

Gizem İklil KOCASOY

YÜKSEK LİSANS TEZİ
İSTATİSTİK ANA BİLİM DALI

GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

HAZİRAN 2023

ETİK BEYAN

Gazi Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmasında;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmasında yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu,

bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Gizem İklil KOCASOY

19/06/2023

RİDGE VE LİU REGRESYONDA TAVLAMA BENZETİMİ OPTİMİZASYONU KULLANILARAK YANLILIK PARAMETRELERİNİN ELDE EDİLMESİ VE BAZI YANLILIK PARAMETRELERİ İLE KARŞILAŞTIRILMASI

(Yüksek Lisans Tezi)

Gizem İklil KOCASOY

GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Haziran 2023

ÖZET

Çoklu doğrusal regresyon analizinde en temel problemlerden biri çoklu bağlantıdır. Modelde çoklu bağlantının var olması durumunda, En Küçük Kareler tahmin edicisi yansız olmasına karşın varyansı aşırı büyür. Bu nedenle En Küçük Kareler tahmin edicisiyle elde edilen parametre tahmin değeri parametrenin gerçek değerinden uzaklaşır. Çoklu bağlantı problemini ortadan kaldırmak için yanlı tahmin yöntemlerini kullanmak bir çözüm olarak önerilmiştir. Bu yanlı tahmin edicilerden sıklıkla tercih edileni Ridge regresyon tahmin edicisidir. Daha sonra bu tahmin ediciye alternatif olarak Liu tahmin edicisi önerilmiştir. Bu çalışmada Ridge ve Liu regresyon tahmin edicileri için optimal yanlılık parametresini bulmak amacıyla daha önce önerilen Parçacık Sürü Optimizasyonu yöntemine kıyasla belirli şartlarda daha iyi performans gösteren Tavlama Benzetimi Optimizasyonu algoritması önerilmiştir. Parçacık Sürü Optimizasyonu ve Tavlama Benzetimi Optimizasyonu algoritmaları ile önerilen yanlılık parametreleri literatürde daha önce farklı araştırmacılar tarafından önerilen yanlılık parametreleri ile; farklı bağımlılık yapıları, farklı varyans değerleri, farklı açıklayıcı değişken sayıları ve farklı örnek çaplarına sahip simülasyon verileri kullanılarak Hata Kare Ortalaması kriteri bakımından karşılaştırılmıştır. Bu çalışmada iki optimizasyon yönteminin de literatürde önerilen klasik yöntemlere kıyasla daha iyi performans gösterdiği sonucuna varılmıştır. Ayrıca Tavlama Benzetimi Optimizasyonu algoritması ve Parçacık Sürü Optimizasyonu algoritması kendi aralarında kıyaslandığında Tavlama Benzetimi Optimizasyonu algoritmasının Liu tahmin edicisi için; Parçacık Sürü Optimizasyonu algoritmasının ise Ridge tahmin edicisi için Hata Kare Ortalaması kriteri bakımından daha iyi sonuçlar verdiği görülmüştür. Çalışma gerçek hayat verisi üzerinden bir uygulama ile desteklenmiş ve uygulama sonucunda hem Hata Kare Ortalaması hem de Varyans Şişirme Faktörü kriterine göre, önerilen Tavlama Benzetimi Optimizasyonu algoritması ile elde edilen sonuçlar Liu tahmin edicisi için diğer yöntemlere kıyasla daha iyi performans göstermiştir.

Bilim Kodu	:	20513
Anahtar Kelimeler	:	Çoklu bağlantı, yanlı tahmin yöntemleri, ridge, liu, parçacık sürü optimizasyonu, tavlama benzetimi optimizasyonu
Sayfa Adedi	:	91
Danışman	:	Prof. Dr. Meral EBEGİL

OBTAINING THE BIASING PARAMETERS USING SIMULATED ANNEALING OPTIMIZATION IN RIDGE AND LIU REGRESSION AND COMPARING THEM WITH SOME BIASING PARAMETERS

(M. Sc. Thesis)

Gizem İklil KOCASOY

GAZİ UNIVERSITY

GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

June 2023

ABSTRACT

One of the most fundamental problems in multiple linear regression analysis is the multicollinearity problem. In the case of multicollinearity in the model, the Ordinary Least Squares estimator is unbiased, but its variance is overgrown. Therefore, the parameter estimation value obtained from the Ordinary Least Squares estimator deviates from the actual value of the parameter. Using biased estimators to eliminate the problem of multicollinearity has been proposed as a solution. The Ridge Regression estimator is frequently preferred among these biased estimators. The Liu estimator was proposed as an alternative to the Ridge estimator. In this study, the Simulated Annealing algorithm, which performed better for certain conditions than the previously proposed Particle Swarm Optimization method, was proposed to find the optimal bias parameter for Ridge and Liu regression estimators. The bias parameters proposed with Particle Swarm Optimization and Simulated Annealing algorithms were compared with the bias parameters previously proposed by different researchers in the literature in terms of the Mean Square Error criteria with a simulation study by using different correlations, different variance values, different explanatory variable numbers, and different sample sizes. In this study Particle Swarm Optimization and Simulated Annealing optimization methods perform better than the classical methods proposed in the literature. In addition, when the Simulated Annealing Optimization algorithm and the Particle Swarm Optimization algorithm are compared among themselves, for the Liu estimator the Simulated Annealing Optimization algorithm and for Ridge estimator Particle Swarm Optimization gives better results in terms of the Mean Squared Error criterion. This study was supported by an application based on real-life data and as a result of the application, it was shown that Simulated Annealing algorithm gives better performance according to the Variance Inflation Factor criteria.

Science Code	:	20513
Key Words	:	Multicollinearity, biased estimation methods, ridge, liu, particle swarm optimization, simulated annealing optimization
Page Number	:	91
Supervisor	:	Prof. Dr. Meral EBEGİL

TEŞEKKÜR

Tez çalışmamın her aşamasında kıymetli bilgi, birikim ve tecrübeleri ile bana yol gösterici olan, desteğini ve hoşgörüsünü hiçbir zaman esirgemeyen danışman hocam Prof. Dr. Meral EBEGİL'e, değerli fikirleriyle tez çalışmamı yönlendiren ve tamamlanmasına katkı sağlayan saygıdeğer hocam Doç. Dr. Muhlis ÖZDEMİR'e, bu süreçte hiçbir konuda paylaşım ve yardımlarını esirgemeyen araştırma görevlisi arkadaşlarıma ve beni her zaman destekleyen sevgili aileme teşekkür ederim.

İÇİNDEKİLER

Sayfa

ÖZET iv

ABSTRACT v

TEŞEKKÜR vi

İÇİNDEKİLER vii

ÇİZELGELERİN LİSTESİ ix

ŞEKİLLERİN LİSTESİ xi

SİMGELER VE KISALTMALAR xii

1. GİRİŞ 1

2. GENEL BİLGİLER 7

2.1. Çoklu Bağlantı Problemi 9

2.1.1. Çoklu bağlantı probleminin kaynakları 9

2.1.2. Çoklu bağlantı probleminin belirlenmesi 10

2.1.3. Çoklu bağlantı probleminin ortadan kaldırılması 12

3. YANLI TAHMİN YÖNTEMLERİ 15

3.1. Ridge Regresyon 15

3.1.1. Ridge regresyon tahmin yöntemi için önerilen yanlılık parametreleri 17

3.2. Liu Regresyon 23

3.2.1. Liu regresyonu için önerilen yanlılık parametreleri 24

4. PARÇACIK SÜRÜ OPTİMİZASYONU 27

4.1. Parçacık Sürü Optimizasyonu ile Ridge Regresyonda Yanlılık Parametresinin Tahmin Edilmesi 30

4.2. Parçacık Sürü Optimizasyonu ile Liu Regresyonda Yanlılık Parametresinin Tahmin Edilmesi 32

Sayfa

5. TAVLAMA BENZETİMİ OPTİMİZASYONU ALGORİTMASI 35

5.1. Tavlama Benzetimi Optimizasyonu ile Ridge Regresyonda Yanlılık Parametresinin Tahmin Edilmesi..... 38

5.2. Tavlama Benzetimi Optimizasyonu ile Liu Regresyonda Yanlılık Parametresinin Tahmin Edilmesi..... 39

6. SİMÜLASYON ÇALIŞMASI..... 43

7. UYGULAMA..... 71

8. SONUÇLAR VE ÖNERİLER..... 83

KAYNAKLAR..... 85

ÖZGEÇMİŞ..... 91

ÇİZELGELERİN LİSTESİ

Çizelge **Sayfa**

Çizelge 3.1. Ridge regresyon için önerilen yanlılık parametreleri 18

Çizelge 3.2. Liu regresyonu için önerilen yanlılık parametreleri 25

Çizelge 6.1. Ridge tahmin edicilerinin $p = 2, \rho = 0{,}70, \sigma = 0{,}01; 0{,}5; 1; 5$ senaryosu için HKO değerleri 44

Çizelge 6.2. Ridge tahmin edicilerinin $p = 2, \rho = 0{,}80, \sigma = 0{,}01; 0{,}5; 1; 5$ senaryosu için HKO değerleri 47

Çizelge 6.3. Ridge tahmin edicilerinin $p = 2, \rho = 0{,}90, \sigma = 0{,}01; 0{,}5; 1; 5$ senaryosu için HKO değerleri 50

Çizelge 6.4. Ridge tahmin edicilerinin $p = 4, \rho = 0{,}70, \sigma = 0{,}01; 0{,}5; 1; 5$ senaryosu için HKO değerleri 53

Çizelge 6.5. Ridge tahmin edicilerinin $p = 4, \rho = 0{,}80, \sigma = 0{,}01; 0{,}5; 1; 5$ senaryosu için HKO değerleri 56

Çizelge 6.6. Ridge tahmin edicilerinin $p = 4, \rho = 0{,}90, \sigma = 0{,}01; 0{,}5; 1; 5$ senaryosu için HKO değerleri 59

Çizelge 6.7. Liu tahmin edicilerinin $p = 2, \rho = 0{,}70, \sigma = 0{,}01; 0{,}5; 1; 5$ senaryosu için HKO değerleri 62

Çizelge 6.8. Liu tahmin edicilerinin $p = 2, \rho = 0{,}80, \sigma = 0{,}01; 0{,}5; 1; 5$ senaryosu için HKO değerleri 63

Çizelge 6.9. Liu tahmin edicilerinin $p = 2, \rho = 0{,}90, \sigma = 0{,}01; 0{,}5; 1; 5$ senaryosu için HKO değerleri 64

Çizelge 6.10. Liu tahmin edicilerinin $p = 4, \rho = 0{,}70, \sigma = 0{,}01; 0{,}5; 1; 5$ senaryosu için HKO değerleri 65

Çizelge 6.11. Liu tahmin edicilerinin $p = 4, \rho = 0{,}80, \sigma = 0{,}01; 0{,}5; 1; 5$ senaryosu için HKO değerleri 66

Çizelge 6.12. Liu tahmin edicilerinin $p = 4, \rho = 0{,}90, \sigma = 0{,}01; 0{,}5; 1; 5$ senaryosu için HKO değerleri 67

Çizelge 7.1. ki yanlılık parametresi için uygulama sonuçları $i = 0{:}\,4$ 74

Çizelge 7.2. ki yanlılık parametresi için uygulama sonuçları $i = 5{:}\,9$ 74

Çizelge 7.3. ki yanlılık parametresi için uygulama sonuçları $i = 10{:}\,14$ 74

Çizelge 7.4. ki yanlılık parametresi için uygulama sonuçları $i = 15{:}\,19$ 75

Çizelge **Sayfa**

Çizelge 7.5. ki yanlılık parametresi için uygulama sonuçları $i = 20{:}\,24$ 75

Çizelge 7.6. ki yanlılık parametresi için uygulama sonuçları $i = 25{:}\,29$ 75

Çizelge 7.7. ki yanlılık parametresi için uygulama sonuçları $i = 30{:}\,34$ 76

Çizelge 7.8. ki yanlılık parametresi için uygulama sonuçları $i = 35{:}\,39$ 76

Çizelge 7.9. ki yanlılık parametresi için uygulama sonuçları $i = 40{:}\,44$ 76

Çizelge 7.10. ki yanlılık parametresi için uygulama sonuçları $i = 45{:}\,49$ 77

Çizelge 7.11. ki yanlılık parametresi için uygulama sonuçları $i = 50{:}\,54$ 77

Çizelge 7.12. ki yanlılık parametresi için uygulama sonuçları $i = 55{:}\,59$ 77

Çizelge 7.13. ki yanlılık parametresi için uygulama sonuçları $i = 60{:}\,64$ 78

Çizelge 7.14. ki yanlılık parametresi için uygulama sonuçları $i = 65{:}\,69$ 78

Çizelge 7.15. ki yanlılık parametresi için uygulama sonuçları $i = 70{:}\,74$ 78

Çizelge 7.16. $ki, kPSO, kTBO$ yanlılık parametresi uygulama sonuçları $i = 75{:}\,77$.... 79

Çizelge 7.17. di yanlılık parametresi için uygulama sonuçları $i = 1{:}\,5$..... 79

Çizelge 7.18. di yanlılık parametresi için uygulama sonuçları $i = 6{:}\,10$ 79

Çizelge 7.19. $di, dPSO, dTBO$ yanlılık parametresi uygulama sonuçları $i = 11{:}\,13$ ... 80

ŞEKİLLERİN LİSTESİ

Şekil **Sayfa**

Şekil 4.1. Parçacık sürü optimizasyonu akış şeması..... 30

Şekil 5.1. Tavlama benzetimi optimizasyonu akış şeması..... 37

SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler	**Açıklamalar**
$\widehat{\boldsymbol{\alpha}}_{\boldsymbol{EKK}}$	Kanonik formda parametre tahmin vektörü
$\boldsymbol{\Lambda}$	λ_j'lerden oluşan köşegen matris
$\boldsymbol{\beta}$	Bilinmeyen parametreler vektörü
$\widehat{\boldsymbol{\beta}}_{\boldsymbol{EKK}}$	En küçük kareler tahmin edicisi
$\widehat{\boldsymbol{\beta}}_{\boldsymbol{R}}$	Ridge regresyon tahmin edicisi
$\widehat{\boldsymbol{\beta}}_{\boldsymbol{Liu}}$	Liu regresyon tahmin edicisi
$\boldsymbol{d}$	Liu Regresyon Yanlılık Parametresi
$\boldsymbol{\varepsilon}$	$(nx1)$ boyutlu hata vektörü
$\boldsymbol{\lambda_j}$	$X'X$ matrisinin özdeğerleri
$\boldsymbol{k}$	Ridge Regresyon Yanlılık Parametresi
$\kappa\boldsymbol{s}$	Koşul sayısı
$\kappa\boldsymbol{i_j}$	Koşul indeksi
$\boldsymbol{pbest}$	Parçacıkların kendi içindeki en iyi çözümü
$\boldsymbol{gbest}$	Tüm parçacıkların en iyi çözümü
$\boldsymbol{R_j^2}$	Çoklu belirleme katsayısı
$\boldsymbol{\omega}$	Eylemsizlik ağırlığı
$\boldsymbol{X}$	(nxp) boyutlu açıklayıcı değişken matrisi
$\boldsymbol{Y}$	$(nx1)$ boyutlu bağımlı değişken vektörü
$\boldsymbol{Z}$	Kanonik formda açıklayıcı değişken matrisi
$\boldsymbol{Z'Z}$	$X'X$ matrisinin kanonik formu

Kısaltmalar	**Açıklamalar**
AKT	Artık Kareler Toplamı
EKK	En Küçük Kareler
HKO	Hata Kare Ortalaması

Kısaltmalar	**Açıklamalar**
$\boldsymbol{iter}$	İterasyon sayısı
MAPE	Ortalama Mutlak Yüzdesel Hata
VIF	Varyans Şişirme Faktörü

1. GİRİŞ

Çoklu doğrusal regresyon modelinde açıklayıcı değişkenler arasında ilişki bulunması çoklu bağlantı problemine neden olur. Buna bağlı olarak modelde regresyon parametrelerinin tahminleri doğru sonuçlar vermeyebilir. Çoklu bağlantı probleminin var olduğu modellerde parametre tahmininin doğruluğunu arttırmak için Hoerl ve Kennard (1970) Ridge regresyon tahmin yöntemini önermiştir. Bu tahmin yönteminde $X'X$ matrisinin köşegen elemanlarına yanlılık parametresi k'nın eklenmesiyle çoklu bağlantı probleminin derecesinin azaltılabileceği görülmüştür. Bu tahmin yöntemine alternatif olarak Ridge ve Stein-tip tahmin edicilerinin kombinasyonu olan ve çoklu bağlantı problemine çözüm sunan doğrusal bir metot Liu (1993) tarafından önerilmiştir (Saleh ve diğerleri, 2022: 263). Bu tahmin edici Akdeniz ve Kaçıranlar (1995) tarafından Liu tahmin edicisi olarak adlandırılmıştır. Liu tahmin edicisinin Hata Kare Ortalaması (HKO) kriteri açısından En Küçük Kareler (EKK) tahmin edicisine kıyasla üstün olduğu kanıtlanmıştır (Liu, 1993). Bununla birlikte tahmin edilen parametreler, Liu parametresi d yanlılık değerinin doğrusal bir fonksiyonu olduğundan Ridge tahmin edicisine kıyasla Liu tahmin yöntemi ile yanlılık parametresinin seçimi daha avantajlıdır (Qasim ve diğerleri, 2020).

Popülasyon tabanlı sezgisel optimizasyon yöntemlerinden biri olan Parçacık Sürü Optimizasyonu (PSO), Kennedy ve Eberhart (1955) tarafından önerilmiştir. Ridge ve Liu regresyonda optimal yanlılık parametresinin belirlenmesi için PSO daha önce literatürde farklı regresyon uygulamalarıyla çalışılmıştır.

Tavlama Benzetimi yüksek sıcaklıkta eritilmiş katıların yavaş ve kontrollü bir şekilde soğutularak düzenli kristal halde katılaşmasını amaçlayan ve mühendislik alanında sıklıkla tercih edilen bir yöntemdir. Bu yönteme dayalı sezgisel optimizasyon algoritması olan Tavlama Benzetimi Optimizasyonu Algoritması (TBO) Kirkpatrick ve diğerleri (1983) tarafından önerilmiştir.

Ridge regresyon modelinde yanlılık parametresini belirlemek için Hoerl ve Kennard (1970)'ten beri birçok farklı araştırmacı tarafından farklı yanlılık parametreleri önerilmiştir. Hoerl ve diğerleri (1975), HKO kriteri açısından önerdikleri yanlılık parametresinin EKK tahmin edicisinden daha üstün olduğunu göstermişlerdir. Lawless ve Wang (1976), önerdikleri yanlılık parametresinin HKO kriteri açısından hem EKK hem de diğer tahmin

edicilerden daha etkili olduğunu göstermiştir. Kibria (2003) aritmetik ortalama, geometrik ortalama ve medyana dayalı yeni yanlılık parametreleri önermiştir ve bir simülasyonda, önerilen yanlılık parametresiyle elde edilen tüm tahmin edicilerin EKK tahmin yönteminden daha iyi sonuçlar verdiğini ve bazı durumlarda diğer popüler tahmin edicilerden daha iyi olduğu gösterilmiştir. Khalaf ve Shukur (2005), Hoerl ve Kennard (1970) tarafından önerilen yanlılık parametrelerinin bir modifikasyonunu içeren yeni yanlılık parametresini önermişlerdir. Daha sonra Alkhamisi ve diğerleri (2006), Khalaf ve Shukur (2005) tarafından önerilen yanlılık parametrelerinin modifikasyonu da dahil olmak üzere dört farklı yanlılık parametresi önermişlerdir. Alkhamisi ve Shukur (2007); Hoerl ve Kennard (1970), Kibria (2003) ve Lawless ve Wang (1976) tarafından önerilen yanlılık parametrelerine dayanan altı farklı yeni yanlılık parametresi önermiştir ve önerilen yanlılık parametrelerinden elde edilen regresyon parametre tahmin değerlerinden en az biri, HKO kriterine dayanan parametre tahminlerinden daha iyi sonuçlar vermiştir.

Muniz ve Kibria (2009); Kibria (2003), Khalaf ve Shukur (2005) ve Alkhamisi ve Shukur (2008) tarafından önerilen yanlılık parametrelerine dayalı yedi farklı yeni yanlılık parametresi önermişlerdir. Önerilen parametrelerin performanslarını HKO açısından simülasyon ve gerçek verilerle karşılaştırıp önerilen yanlılık parametresi aracılığıyla elde edilen tüm parametre tahminlerinin EKK tahmin yöntemi ile elde edilen sonuçlardan daha iyi performans gösterdiğini ortaya koymuşlardır. Dorugade ve Kashid (2010); Hoerl ve Kennard (1970) tarafından önerilen yanlılık parametresinin bir modifikasyonu olarak yeni bir yanlılık parametresi önermişlerdir. Al-Hassan (2010); Alkhamisi ve Shukur (2007)'ün çalışmasında olduğu gibi Hocking ve diğerleri (1976) tarafından önerilen yanlılık parametresinin modifikasyonu olan yeni bir yanlılık parametresi önermiş ve simülasyon çalışması yardımıyla önerilen yanlılık parametresiyle elde edilen tahminlerin Hoerl ve Kennard (1970) ve Hocking ve diğerleri (1976) tarafından önerilen yanlılık parametreleri ve EKK tahmin edicisinden elde edilen tahminlerden daha iyi olduğunu doğrulamıştır. Khalaf (2012), Hoerl ve diğerleri (1975) tarafından önerilen yanlılık parametrelerinin bir modifikasyonunu önermiştir. Önerilen bu yanlılık parametresinin, Hoerl ve Kennard (1970) tarafından önerilen yanlılık parametresi aracılığıyla hesaplanan ve EKK tahmin yöntemi yardımıyla elde edilen tahminlerden daha üstün olduğunu göstermiştir. Ayrıca önerilen yanlılık parametresinin HKO açısından diğer yanlılık parametrelerinden daha etkili olduğu gösterilmiş ancak literatürde optimal bir yanlılık parametresinin belirlenemediği de belirtilmiştir.

Muniz ve diğerleri (2012), Khalaf ve Shukur (2005) tarafından önerilen yanlılık parametresine bağlı olarak Alkhamisi ve Shukur (2008) tarafından önerilen yanlılık parametrelerinin karekök dönüşümlerini kullanarak beş farklı yanlılık parametresi önermiştir. Bu yanlılık parametrelerinin de dahil olduğu on dokuz farklı yanlılık parametresi ile yapılan simülasyon çalışmasında, önerilen yanlılık parametresi ile elde edilen tahminlerin HKO açısından diğer yanlılık parametreleri ilde elde edilen tahminlerden üstün olduğu gösterilmiştir. Toker ve Kaçıranlar (2013), HKO kriteri açısından iki yanlılık parametresine sahip tahmin yöntemlerinin diğer yöntemlerden daha etkili olduğunu göstermiştir. Khalaf (2013); Hoerl ve diğerleri (1975) ve Khalaf ve Shukur (2005) tarafından önerilen yanlılık parametrelerinin türevleri olan iki yeni yanlılık parametresi önermiştir. Ayrıca simülasyon çalışması ile önerilen parametrelerin bazı durumlarda HKO açısından daha iyi performans gösterdiği ortaya konulmuştur. Daha sonra Dorugade (2014a), Kibria (2003) tarafından önerilen yanlılık parametrelerinin modifikasyonu dahil olmak üzere dört farklı yeni yanlılık parametresi önermiştir. Önerilen parametreler ile daha önce literatürde önerilen on beş farklı yanlılık parametresi ile elde edilen tahminler ve EKK tahmin edicisinden elde edilen tahminler arasındaki performanslar bir simülasyon çalışmasında karşılaştırılmıştır. Elde edilen sonuçlar önerilen tahmin edicinin diğer tahmin edicilere kıyasla HKO kriteri açısından daha iyi sonuçlar verdiğini göstermiştir.

Khalaf ve Iguernane (2014); Hoerl ve Kennard (1970) ve Hoerl ve diğerleri (1975) tarafından önerilen parametrelerin aritmetik, harmonik ve geometrik ortalamalarından oluşan dört farklı yeni yanlılık parametresi ve bir fonksiyon önermişlerdir. Asar ve diğerleri (2014) ; Kibria (2003) ve Dorugade (2014a) tarafından önerilen yanlılık parametrelerini temel alan beş farklı yanlılık parametresi önermiştir. Ayrıca simülasyondan çalışmanın sonuçlar, önerilen yanlılık parametresiyle elde edilen tahminlerin diğerlerinden daha iyi olduğunu ortaya çıkarırken, gerçek verilerden elde edilen sonuçlar önerilen yanlılık parametresinin çoklu bağlantı problemini çözmek için yeterli olmadığını ortaya koymuştur. Dorugade (2014b), Alkhamisi ve Shukur (2007) tarafından önerilen yanlılık parametresinin modifikasyonundan oluşan yeni bir parametre önermiştir. Bu yanlılık parametresi ile elde edilen tahminler HKO açısından, literatürdeki diğer yanlılık parametreleri ile gerçek veriler ve simülasyon çalışmaları yardımıyla karşılaştırdığında, önerilen yanlılık parametresinin performansının diğerlerine göre daha etkili olduğu sonucuna varmıştır. Dorugade (2016), hataların varyansını farklı bir şekilde hesaplamış ve önerdiği yanlılık parametresini bu hata varyansının karekökü olarak tanımlamıştır. Önerilen bu yeni parametre bir simülasyon

çalışmasında HKO kriteri açısından EKK tahmin yöntemi ve diğer yanlılık parametrelerinden elde edilen tahminlerle karşılaştırılmıştır. Sonuçlar, önerilen parametrenin diğerlerinden daha iyi performans gösterdiğini ortaya koymuştur.

Karaibrahimoğlu ve diğerleri (2016); Hoerl ve Kennard (1970) tarafından önerilen yanlılık parametresine bazı dönüşümler uygulayarak dört yeni yanlılık parametresi önermiştir. Simülasyon çalışmaları önerilen tahmin edicilerin performansının Hoerl & Kennard (1970), Lawless ve Wang (1976), Kibria (2003) ve Dorugade (2014a) tarafından önerilen yanlılık parametrelerinden HKO kriteri açısından üstün olduğunu göstermiştir. Bhat ve Vidya (2016), Hoerl ve diğerleri (1975)'den esinlenilen iki yanlılık parametresi ile birlikte, Lawless ve Wang (1976), Nomura (1988), Khalaf ve Shukur (2005), Dorugade ve Kashid (2010) ve Dorugade (2014a) tarafından önerilen yanlılık parametrelerini bir simülasyon çalışmasıyla karşılaştırmıştır. Sonuçlara göre, açıklayıcı değişkenler arasında yüksek korelasyon olması durumunda önerilen yanlılık parametreleri ile elde edilen tahminlerin hem EKK tahmin yöntemiyle elde edilen tahminlerden, hem de diğer yanlılık parametreleriyle elde edilen tahminlerden daha iyi performans gösterdiği sonucuna varılmıştır.

Lukman ve diğerleri (2017); Dorugade (2014a) ve Karaibrahimoğlu ve diğerleri (2016) tarafından önerilen yanlılık parametrelerine bazı dönüşümler uygulayarak farklı yanlılık parametreleri önermiştir. Lukman ve Olatunji (2017), Dorugade (2016) tarafından önerilen yanlılık parametresine bağlı olarak yeni bir yanlılık parametresi önermiştir. Önerilen parametre, Hoerl ve Kennard (1970), Hoerl ve diğerleri (1975) ve Dorugade (2016) tarafından önerilen yöntemlerle hem simülasyon hem de gerçek hayat verilerinde HKO kriteri açısından karşılaştırılmıştır. Sonuçlar önerilen yeni yanlılık parametresiyle elde edilen tahminlerin diğerlerinden daha etkili performans gösterdiğini ortaya koymuştur. Göktaş ve Sevinç (2016) iki yeni yanlılık parametresi önermiş ve bu parametreler dahil otuz yedi yanlılık parametresinin performanslarını HKO kriteri açısından karşılaştırmışlardır. Gökpınar ve diğerleri (2017) literatürde önerilen popüler yanlılık parametrelerini HKO kriteri açısından bir simülasyon çalışması aracılığı ile karşılaştırıp Ridge tahmin edicisi için bir test istatistiği analiz etmişlerdir. Schreiber-Gregory (2018) çoklu bağlantı probleminin Ridge regresyon yöntemi aracılığıyla azaltılabileceğine yönelik bir çalışma yapmıştır. Yasin ve diğerleri (2021) yeni yanlılık parametreleri önermiş ve bu parametrelerden elde edilen tahminlerin EKK tahmin yöntemiyle elde edilen tahminlerden daha iyi performans gösterdiğini ortaya koymuştur. Mermi ve diğerleri (2021) literatürde karşılaşılan tüm Ridge

regresyon yanlılık parametrelerini dağılımları ve HKO kriteri açısından karşılaştırmışlardır. Bu amaçla, bir simülasyon çalışması yapılarak karşılaştırmalarla 80 yanlılık parametresi karşılaştırmışlardır. Ayrıca her bir yanlılık parametresi için için bir dağılım elde edilerek ve çarpıklıklarını karşılaştırmıştır. Bu tez çalışmasında, Mermi ve diğerleri (2021) tarafından yapılan çalışmada tercih edilen Ridge regresyon yanlılık parametreleri kullanılmıştır. Uslu ve Demirci (2022) farklı yapay genetik algoritma ve diferansiyel gelişim algoritması kullanarak Ridge regresyon için yanlılık parametresi önermişlerdir.

Ridge regresyon tahmin yöntemine alternatif olarak Liu (1993) tarafından önerilen yöntem Akdeniz ve Kaçıranlar (1995) tarafından Liu tahmin yöntemi olarak adlandırılmıştır. Sakallıoğlu ve diğerleri (2001) Ridge regresyon ve Liu regresyon tahmin yöntemlerini HKO kriterleri açısından karşılaştırmıştır. Liu (1993) tarafından önerilen yaklaşım, Kaçıranlar (2003), Alheety ve Kibria (2009) vb. araştırmacılar tarafından da benimsenmiş ve benzer çalışmalar yapılmıştır. Aktaş (2007) Liu tahmin edicisi aracılığıyla çoklu bağıntıdan arındırılmış model ile enflasyon modeli için bir uygulama yapmıştır. Shukur ve diğerleri (2015) çoklu bağlantı problemine çözüm olarak Liu tahmin edicisine dayalı dokuz tane yanlılık parametresi önermişlerdir. Önerilen bu yanlılık parametreleri ile elde edilen tahminler EKK tahmin yönteminden elde edilen tahminlerde daha iyi sonuçlar verdiği bir simülasyon ve gerçek hayat verisi çalışmaları ile ortaya koyulmuştur. Huang ve diğerleri (2019) Liu ve EKK tahmin edicilerini bir simülasyon çalışması yardımıyla karşılaştırarak ve Liu tahmin yönteminin EKK tahmin yönteminden üstün olduğunu göstermişlerdir. Qasim ve diğerleri (2020), Shukur ve diğerleri (2015) tarafından önerilen yanlılık parametrelerine dayalı yeni yanlılık parametreleri önermişlerdir. Önerilen bu yanlılık parametreleri ve literatürde önerilen diğer parametreleri bir simülasyon çalışması aracılığıyla HKO, Ortalama Mutlak Yüzdesel Hata (MAPE) ve güven aralığı kriterlerine göre karşılaştırmışlardır. Bu çalışma sonucunda önerilen yanlılık parametresinin diğer yanlılık parametrelerinden daha iyi performans gösterdiği ortaya koyulmuştur.

PSO daha önce literatürde farklı regresyon uygulamalarıyla çalışılmıştır. Ahn ve diğerleri (2012) Ridge Regresyonu genetik algoritma ile kullanmayı önermişlerdir. Uslu ve diğerleri (2014) Ridge Regresyonda optimal k yanlılık değerini tahmin etmek için VIF değerlerini dikkate alan bir amaç fonksiyonu önermişlerdir. Cagcag ve diğerleri (2015) aykırı gözlem içeren veri setleri için PSO'ya dayalı yeni bir parametre tahmin metotu önermişlerdir. Bas ve diğerleri (2017) tek bir yanlılık parametresi önermek yerine her bir açıklayıcı değişken

için PSO'ya dayalı farklı yanlılık parametreleri önermişlerdir. İnan ve diğerleri (2017) iki yanlılık parametresine sahip Liu-tipi tahmin yönteminde farklı amaç fonksiyonları kullanarak yanlılık parametrelerini PSO algoritması aracılığıyla optimize etmişlerdir. İnan ve Sancar (2020) lojistik regresyonda yanlılık parametresinin belirlenmesi için PSO'ya dayalı yeni bir algoritma önermişlerdir. Qamar ve Algamal (2020) Liu regresyonda yanlılık parametresinin belirlenmesinde PSO algoritmasını tercih etmişlerdir. Simülasyon çalışması ile PSO algoritmasından elde edilen yanlılık parametreleri yardımıyla hesaplanan HKO değerlerinin ve EKK tahmin yöntemi kullanılarak elde edilen HKO değerlerinden daha iyi sonuçlar verdiğini göstermişlerdir.

Metallerin tavlama sürecine dayalı tavlama benzetiminin optimizasyon problemlerine uygulanması ile ilgili çalışmalar ilk olarak Metropolis ve diğerleri (1953) tarafından yapılan çalışmadan ilham alınarak Kirkpatrick ve diğerleri (1983) tarafından yapılmıştır. Strenski ve Kirkpatrick (1991) bazı problemlerin çözümü için tavlama benzetimi algoritmasını kullanarak tavlama süreçlerinin olasılık dağılımlarını incelemişlerdir. Bu çalışmada, Ridge ve Liu tahmin yöntemleri için optimal yanlılık parametresini elde etmek amacıyla TBO'ya dayalı yeni bir algoritma önerilmiştir. Önerilen yöntemle bulunan yanlılık parametreleri PSO ve klasik yöntemlerle elde edilen diğer yanlılık parametreleri ile; farklı bağımlılık yapıları, örnek çapları ve değişken sayıları dikkate alınarak HKO kriteri açısından karşılaştırılmıştır.

Bu amaçla çalışmanın ikinci bölümünde çoklu doğrusal regresyon modeli ve çoklu bağlantı problemi, üçüncü bölümde yanlı tahmin yöntemleri, dördüncü bölümde PSO yöntemi, beşinci bölümde TBO yöntemine ilişkin bilgiler verilmiştir. Altıncı bölümde yanlılık parametrelerinin performanslarının kıyaslanması için yapılan simülasyon çalışması, yedinci bölümde gerçek hayat veri seti uygulaması ve son bölümde sonuç ve öneriler verilmiştir.

2. GENEL BİLGİLER

Regresyon analizi bağımlı değişken ile açıklayıcı değişken arasındaki ilişkinin matematiksel modeller aracılığıyla açıklanması şeklinde özetlenebilir (Alpar, 2011: 405). Basit doğrusal regresyon analizinde model yeterli açıklama gücüne sahip olmadığı durumda modele farklı açıklayıcı değişkenlerin eklenmesi gerekir. Açıklayıcı değişken sayısı iki ve ikiden fazla olan regresyon modelleri çoklu doğrusal regresyon modeli olarak adlandırılır. Bu model, sıklıkla tercih edilen istatistiksel modellerden biridir. Çoklu doğrusal regresyon modelinin parametrelerini tahmin etmek için kullanılan en yaygın yöntem EKK tahmin yöntemidir. Klasik bir çoklu doğrusal regresyon modeli Eş. 2.1'deki gibi tanımlansın.

$$Y = X\beta + \varepsilon \tag{2.1}$$

Burada *n* gözlem sayısı, *p* açıklayıcı değişken sayısı olmak üzere; Y, $(n\ x\ 1)$ boyutlu bağımlı değişken vektörü $X, (n\ x\ p)$ boyutlu tam ranklı açıklayıcı değişken matrisi, $\beta, (p\ x\ 1)$ boyutlu bilinmeyen parametreler vektörü, ε ise $\varepsilon \sim N(0, \sigma^2 I_n)$ olan $(n\ x\ 1)$ boyutlu hata vektörüdür. Bu tanımlamalar göz önünde bulundurulduğunda, doğrusal model Eş. 2.2'deki gibi yazılabilir.

$$\begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{bmatrix} = \begin{bmatrix} X_{11} & X_{12} & X_{13} & \dots & X_{1p} \\ X_{21} & X_{22} & X_{21} & \dots & X_{2p} \\ \vdots & \vdots & \vdots & & \vdots \\ X_{n1} & X_{n2} & X_{n3} & \dots & X_{np} \end{bmatrix} \times \begin{bmatrix} \beta_1 \\ \vdots \\ \vdots \\ \beta_p \end{bmatrix} + \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_p \end{bmatrix} \tag{2.2}$$

EKK tahmin yöntemi, her bir Y_i değerinin ortalamasından sapmalarının kare toplamını en küçükleyecek çözümü veren denklem yardımıyla elde edilir (Rawlings, 1998: 3). β'nın tahmin edilmesinde en sık kullanılan yöntem EKK tahmin yöntemidir. $\hat{\beta}_{EKK}$ vektörü β'nın EKK tahmin edicisini temsil etmek üzere; $\hat{\beta}_{EKK}$ Eş.2.3'te gösterildiği gibi artık kareler toplamı (AKT)nın minimize edilmesiyle elde edilir (Saleh ve diğerleri, 2019: 1).

$$\hat{\beta}_{EKK} = \min_{\beta}\{(Y - X\beta)'(Y - X\beta)\} \tag{2.3}$$

Buradan $\hat{\beta}_{EKK}$ Eş. 2.4'teki gibi elde edilir.

$$\hat{\beta}_{EKK} = (X'X)^{-1}(X'Y) \tag{2.4}$$

EKK tahmin edicisinin istatistiksel özelliklerini ele aldığımızda:

$$E(\hat{\beta}_{EKK}) = E[(X'X)^{-1}X'Y] = E((X'X)^{-1}X'(X\beta + \varepsilon)) \\ = E[(X'X)^{-1}X'X\beta + (X'X)^{-1}X'\varepsilon] = \beta \quad (2.5)$$

olmak üzere,

$E(\varepsilon) = 0$ ve $(X'X)^{-1}X'X = I$ olduğundan $\hat{\beta}_{EKK}$, β'nın yansız tahmin edicisidir. $\hat{\beta}_{EKK}$'nın varyans-kovaryans matrisi ise Eş. 2.6'da verildiği gibidir.

$$Var(\hat{\beta}_{EKK}) = Var[(X'X)^{-1}(X'Y)] \\ = (X'X)^{-1}X'Var(Y)[(X'X)^{-1}X']' \\ = \sigma^2(X'X)^{-1}X'X(X'X)^{-1} = \sigma^2(X'X)^{-1} \quad (2.6)$$

Gauss-Markov teoremi $\hat{\beta}_{EKK}$'nın β'nın en iyi doğrusal yansız tahmin edicisi (BLUE) olduğunu kanıtlar. En iyi doğrusal yansız tahmin edici ifadesi $\hat{\beta}_{EKK}$'nın tüm yansız tahmin ediciler arasında en küçük varyansa sahip tahmin edici olduğu anlamına gelir (Montgomery ve diğerleri, 2012: 587). Ayrıca σ^2'nin tahmin edicisi Eş. 2.7'de verilmiştir.

$$\hat{\sigma}^2 = \frac{Y'Y - \hat{\beta}_{EKK}{}'X'Y}{n - p} \quad (2.7)$$

Klasik doğrusal regresyon modelinde EKK tahmin yöntemiyle elde edilen parametre tahminlerinin yansızlığının korunması için bazı varsayımların sağlanması gerekmektedir. Bu varsayımlar aşağıdaki gibi sıralanabilir:

i. Regresyon modeli doğrusaldır.
ii. Hata terimi ε_i değerinin beklenen değeri sıfırdır. $E(\varepsilon_i) = 0$
iii. Hata terimi ε_i tüm gözlemler için sabit varyanslıdır. $Var(\varepsilon_i) = \sigma^2$ veya $E(\varepsilon_i{}^2) = \sigma^2$
iv. Hata terimleri arasında otokorelasyon yoktur. Diğer bir gösterimle, $Kov(\varepsilon_i, \varepsilon_j) = 0$ veya $E(\varepsilon_{i,}\varepsilon_j) = 0$'dır.
v. Hata terimleri ve açıklayıcı değişkenler arasında ilişki yoktur. Diğer bir gösterimle, $Kov(\varepsilon_i, X_i) = 0$'dır.
vi. Açıklayıcı değişkenler arasında çoklu bağlantı (*multicollinearity)* yoktur.

Açıklayıcı değişkenler arasında çoklu iç ilişki olmaması varsayımının sağlanmaması durumunda çoklu bağlantı problemi ortaya çıkar (Frisch, 1935).

2.1. Çoklu Bağlantı Problemi

Aralarında doğrusal ilişki olmayan açıklayıcı değişkenler "dik" olarak kabul edilir ve bu durumda elde edilen parametre tahminlerini kullanarak yapılan çıkarsamalar gerçeği yansıtacak şekilde olur. Ancak regresyon uygulamalarında açıklayıcı değişkenler her zaman dik olmayabilirler. Bazı durumlarda değişkenler önemli ölçüde doğrusal ilişkilidir (Montgomery ve diğerleri, 2012: 285). Klasik doğrusal regresyon modelinde EKK tahmin yöntemiyle elde edilen parametre tahminlerinin yansızlığının korunması için sağlanması gereken varsayımlardan biri açıklayıcı değişkenler arasında ilişki olmamasıdır. Bu varsayımın sağlanmaması çoklu bağlantı problemine neden olur (Frisch, 1935).

Çoklu bağlantı durumunda regresyon modelleri üzerinden yapılacak çıkarsama ve kestirimler yanıltıcı sonuçlara neden olabilir (Alpar, 2011: 514). Bu nedenle, çoklu bağlantı probleminin hangi koşullarda, ne zaman ortaya çıktığını bilmek ve bu problemin olası sonuçlarının farkında olmak önemlidir (Chatterjee ve Hadi, 2012: 234).

2.1.1. Çoklu bağlantı probleminin kaynakları

Çoklu bağlantının nedenleri aşağıdaki gibi sıralanabilir:

i. Kullanılan veri toplama yöntemi,
ii. Seçilen örneklemin yığını temsil etmemesi,
iii. Açıklayıcı değişkenler arasında gerçekten ilişki bulunması,
iv. Gözlem sayısının değişken sayısından küçük ($n < p + 1$) olması,
v. Araştırmacıdan kaynaklı hataların oluşması, (Alpar, 2011: 516; Montgomery ve diğerleri, 2012: 286)

Çoklu bağlantı probleminin kaynağını tespit etmek her zaman mümkün olmasa da oluşan problemin yapısını kavramak araştırmacı için oldukça önemlidir. Çoklu bağlantı probleminin yapısı bilindiği zaman problemin üstesinden gelecek çözüm yollarını belirlemek daha kolay olacaktır (Rawlings ve diğerleri, 1998: 434).

2.1.2. Çoklu bağlantı probleminin belirlenmesi

Çoklu bağlantının derecesi ne kadar yüksek olursa, çoklu bağlantının rahatsız edici sonuçlara neden olma olasılığı da o kadar yüksek olacaktır. Çoklu bağlantıyı saptayabilmek için bağlantının yapısı hakkında bilgi veren birçok gösterge vardır (Farrar ve Glauber, 1967). Bunlar aşağıda özetlenmiştir.

$X'X$ matrisinin incelenmesi

Çoklu bağlantının tespitindeki en basit ölçülerden biri $X'X$ matrisindeki r_{ij} köşegen dışı matris elemanlarının incelenmesidir. x_i ve x_j açıklayıcı değişkenleri doğrusal bağımlı ise $|r_{ij}|$ değerinin 1'e yakın çıkması beklenir. Açıklayıcı değişkenler arasındaki korelasyon katsayısı yüksekse modelde çoklu bağlantının varlığından söz edilebilir. Ancak ikili çoklu bağlantıdan daha kompleks çoklu bağlantıların incelenmesi için korelasyon katsayısı yeterli olmayacaktır.

Çoklu bağlantının tespitinde kullanılan bir diğer yöntem $X'X$ matrisinin determinantının incelenmesidir. $X'X$ matrisinin determinantının olası değer aralığı $0 \leq |X'X| \leq 1$'dir. $|X'X|$ değeri 0'a eşit olduğunda açıklayıcı değişkenler arasında yüksek derecede çoklu doğrusal bağımlılık olduğu yorumu yapılabilir. Çoklu bağlantı probleminin bu ölçüsü hesaplama kolaylığı sağlamasına karşın çoklu bağlantının nedenine ilişkin bilgi vermez (Montgomery ve diğerleri, 2012: 292).

Belirleme katsayısı ve tolerans değerinin incelenmesi

X_i değişkeninin $p-1$ açıklayıcı değişken üzerindeki regresyonundan elde edilen belirleme katsayısı R_j^2 ile temsil edilsin. R_j^2 değerinin 1'e yaklaşması durumunda çoklu bağlantı olduğu söylenir. $\left(1-R_j^2\right)$ değeri bir değişkenin "tolerans" değeri olarak adlandırılır. Eğer değişkenin tolerans değeri 0'a yaklaşıyorsa diğer değişkenler ile arasında çoklu bağlantı vardır yorumu yapılabilir.

Varyans şişirme faktörünün incelenmesi

Çoklu bağlantının belirlenmesi için *VIF* değerinin kullanılması Marquaridt (1970) tarafından önerilmiştir. *VIF* değeri sayesinde çoklu bağlantı probleminden dolayı varyans değerlerinin gerçek değerlerinden hangi ölçüde uzaklaştığı tespit edilir (Derman, 2019). X_i değişkeninin $p-1$ açıklayıcı değişken üzerindeki regresyonundan elde edilen belirleme katsayısı R_j^2 ile temsil edilsin. Varyans şişirme değeri Eş. 2.8'deki şekliyle tanımlamıştır (Marquaridt, 1970).

$$VIF_j = \left(1 - R_j^2\right)^{-1}, \qquad j = 1,2,\dots,p \tag{2.8}$$

Eğer X_j değeri diğer tahmin değerleriyle güçlü doğrusal bağlantı içindeyse R_j^2 değeri 1'e yakın olacaktır ve buna bağlı olarak VIF_j değeri büyüyecektir. VIF_j değerlerinin, 10'dan büyük değerler almaları, genelde güçlü çoklu bağlantının işareti olarak kabul edilmektedir (Chatterjee ve Hadi, 2012: 250).

$X'X$ matrisinin özdeğerlerinin incelenmesi

Açıklayıcı değişkenlere ilişkin $X'X$ matrisinin özdeğerleri $\lambda_1, \lambda_2, \dots, \lambda_p$ olmak üzere bu özdeğerler verideki çoklu bağlantının derecesini ölçmek için kullanılabilmektedir. Çoklu bağlantının varlığında en az bir özdeğer sıfıra eşit çıkmaktadır.

Koşul sayısı

Çoklu bağlantının belirlenmesinde kullanılan bir diğer yöntem koşul sayısıdır. λ_{min} ve λ_{max} değerleri sırasıyla $X'X$ matrisinin en küçük ve en büyük özdeğerini temsil etmek üzere koşul sayısı Eş. 2.9'daki gibi tanımlanabilir.

$$\text{KS} = \frac{\lambda_{max}}{\lambda_{min}} \tag{2.9}$$

Koşul sayısının 100'den küçük olması veride önemli derecede çoklu bağlantı problemi olmadığının göstergesidir. Ancak koşul sayısı değeri 1000'den büyükse güçlü çoklu bağlantı sorunu vardır yorumu yapılabilir.

Koşul sayısı değeri için bir diğer yaklaşım Eş. 2.9'da verilen ifadenin karekökünün alınmasıdır. Bu durumda ise $\sqrt{\kappa s}$ değerinin 10'u aşması çoklu bağlantı probleminin varlığına işaret ederken 30'dan büyük değer alması çoklu bağlantının giderilmesi konusunda önlem alınmasını gerektirir (Alpar, 2011: 521; Montgomery ve diğerleri, 2012: 298).

Koşul indeksi

λ_j; $X'X$ matrisinin j. özdeğerini temsil etmek üzere, Eş. 2.10'da verilen denklem koşul indeksini ifade etmektedir.

$$\kappa i_j = \frac{\lambda_{max}}{\lambda_j}\ ,\ \ j = 1,2,\dots,p \tag{2.10}$$

Koşul indeksi değerinin 1000'den büyük olması çoklu bağlantının varlığı konusunda bilgi verir. En büyük koşul indeksi değeri koşul sayısıdır.

Diğer tanılar

Yukarıda verilen çoklu bağlantı belirleme yöntemlerine ek olarak F ve t istatistikleri çoklu bağlantının varlığı hakkında fikir verebilir. Özellikle F istatistiği anlamlı ancak t istatistikleri anlamlı değilse çoklu bağlantı vardır yorumu yapılır. Regresyon parametrelerinin büyüklükleri ve işaretleri belli durumlarda modelde çoklu bağlantının var olduğunu göstermektedir. Özellikle bir açıklayıcı değişkenin modele eklenmesi ya da çıkarılması parametre tahmininde önemli değişikliklere neden oluyorsa çoklu bağlantıya işaret edilir (Montgomery ve diğerleri, 2012: 302).

2.1.3. Çoklu bağlantı probleminin ortadan kaldırılması

Çoklu bağlantı probleminin ortaya çıkardığı sorunları çözmek için farklı yaklaşımlar önerilmiştir. Bunlar aşağıda özetlenmiştir.

Ek veri toplama

Çoklu bağlantı problemini çözmek için önerilen en iyi yöntem ek veri toplanmasıdır (Farrar ve Glauber, 1967). Örneklem hacminin artırılması parametrelerin varyans değerlerini düşüreceğinden, buna bağlı olarak azalan standart hata doğru parametre tahmini yapılmasına olanak sağlayacaktır. Ancak ek veri toplama işlemi çoklu bağlantı problemine çözüm olarak önerilse de ekonomik kısıtlar mevcut olduğunda tercih edilebilecek bir çözüm yöntemi değildir (Aydın, 2014: 400).

Modelin yeniden tanımlanması

Çoklu bağlantı problemi korelasyonları birbirlerine çok yakın açıklayıcı değişkenlerin modele alınmasından kaynaklanmaktadır. Regresyon modelinin yeniden tanımlanması bazı durumlarda çoklu bağlantının derecesini azaltabilir. Eğer açıklayıcı değişkenler arasında doğrusal bağıntı varsa orijinal açıklayıcı değişkenlerdeki bilgiyi koruyan ve çoklu bağlantının derecesini azaltan bir fonksiyon elde etmek olasıdır. Tercih edilen bir diğer model tanımlama yöntemi modelden değişken çıkarılmasıdır. Yani aralarında çoklu bağlantı bulunan iki açıklayıcı değişkenden birinin model dışında bırakılmasıdır. Ancak açıklayıcı değişkenin modelden çıkarılması modelin kestirim gücünü azaltacağından modelden çıkarmak için seçilen açıklayıcı değişken konusunda özenli olunmalıdır. (Montgomery ve diğerleri, 2012: 304).

Yanlı tahmin yöntemleri

Regresyon parametrelerinin varyans değerlerini azaltmak ve modeldeki kararsızlığı yok etmek için EKK tahmin yöntemine alternatif yöntemler önerilmiştir. Temel bileşenler analizi, Ridge regresyon analizi ve türevleri, kısmi en küçük kareler yöntemleri gibi yöntemler çoklu bağlantı probleminin önüne geçilmesinde sıklıkla tercih edilir (Aydın, 2014: 402).

Bu yaklaşımlardan hangisinin seçileceği model-uygunluk çalışmalarının amacına bağlıdır. Asıl amaç kestirim yapmak olduğunda çoklu bağlantı X uzayında ciddi probleme yol açmaz. Ancak amaç regresyon parametrelerinin tahmin edilmesi olduğunda yanlı tahmin yöntemleri daha faydalı olur (Rawlings ve diğerleri, 1998: 334).

3. YANLI TAHMİN YÖNTEMLERİ

Gauss-Markov teoremine göre Eş. 2.1' de verilen regresyon modelinin parametrelerinin tahmin edilmesinde kullanılan EKK tahmin yöntemi en iyi doğrusal yansız tahmin edicileri veren bir tahmin yöntemidir. Verinin doğrusal fonksiyonu olan ve tahmin edilen parametreler için yansız tüm tahmin ediciler arasında EKK tahmin yöntemi en küçük varyanslı olandır. Ancak çoklu bağlantının varlığında bahsedilen en küçük varyans değeri kabul edilemeyecek kadar büyük olabilir. Buna bağlı olarak regresyon katsayılarının anlamlılığı testinde kullanılan *t testi* değeri olduğundan daha küçük çıkar ve modelin tahmin edilebilirliği azalır. Bu nedenle EKK tahmin edicisi yansız olmasına karşın daha iyi sonuçlar verebilecek yanlı tahmin yöntemleri tercih edilebilir. Diğer bir deyişle, yanlı tahmin yöntemlerinin tercih edilmesinde amaç EKK tahmin edicisine göre yanlı ancak daha küçük varyanslı ve yığın parametresine daha yakın tahminler elde etmektir (Khalaf ve Iguernane, 2014; Rawlings ve diğerleri, 1998: 443).

Özet olarak, çoklu bağlantı probleminin üstesinden gelebilmek için yanlı tahmin yöntemlerinin kullanılması bir çözüm olarak önerilmiştir. Buradan yola çıkarak bu bölümde tek yanlılık parametresine sahip Ridge regresyon ve Liu tahmin yöntemleri sırasıyla açıklanacaktır.

3.1. Ridge Regresyon

Çoklu doğrusal regresyon modelinde çoklu bağlantı problemine çözüm getirmek için en sık kullanılan yanlı tahmin yöntemlerinden biri Hoerl ve Kennard (1970) tarafından önerilen Ridge regresyon tahmin yöntemidir. Ridge regresyon tahmin edicisi regresyon tahminlerine "yanlılık" değeri ekleyerek standart hataları azaltır ve $X'X$ matrisinin determinantının 0 değerine eşit çıkmasını engeller. Buna bağlı olarak tahmin edicilerin varyansları önemli bir sorun yaratacak kadar büyük varyans değerleri vermez (Khalaf ve Iguernane, 2014).

k yanlılık parametresini ve I birim matrisini temsil etmek üzere; Ridge regresyon tahmin edicisi Eş. 3.1'de verildiği gibidir.

$$\hat{\beta}_R = (X'X + kI)^{-1}X'Y, \quad k \geq 0 \tag{3.1}$$

Eş. 3.1'de verilen denklemde $k = 0$ olduğu durumda Ridge regresyon tahmin edicisi EKK tahmin edicisine eşittir. Eş. 3.2'de Ridge regresyon tahmin edicisinin EKK tahmin edicisinin doğrusal dönüşümü olduğu gösterilmiştir.

$$\begin{aligned}\hat{\beta}_R &= (X'X + kI)^{-1}X'Y \\ &= (X'X + kI)^{-1}(X'X)\hat{\beta}_{EKK} \\ &= Z_k\hat{\beta}_{EKK}\end{aligned} \tag{3.2}$$

Burada Z_k, $(X'X + kI)^{-1}(X'X)$'i ifade etmek üzere; $\hat{\beta}_R$ tahmin edicisinin beklenen değeri $E(\hat{\beta}_R)$ Eş. 3.3'te verildiği gibidir.

$$\begin{aligned}E(\hat{\beta}_R) &= E[(X'X + kI)^{-1}X'Y] \\ &= E[(X'X + kI)^{-1}X'(X\beta + \varepsilon)] \\ &= [(X'X + kI)^{-1}X'X\beta + (X'X + kI)^{-1}X'E(\varepsilon)] \\ &= (X'X + kI)^{-1}X'X\beta\end{aligned} \tag{3.3}$$

Yukarıda gösterildiği gibi, $E(\hat{\beta}_R) = E(Z_k\hat{\beta}_{EKK}) \neq \beta$ olduğundan $\hat{\beta}_R$ tahmin edicisinin β'nın yanlı bir tahmin edicisi olduğu söylenebilir. Ayrıca Ridge regresyon tahmin edicisinin varyans-kovaryans matrisi Eş. 3.4'te verildiği gibidir:

$$Var(\hat{\beta}_R) = \sigma^2(X'X + kI)^{-1}(X'X)(X'X + kI)^{-1} \tag{3.4}$$

Tahmin edicinin HKO değeri tahmin edilen parametrenin gerçek parametre değerine uzaklığının bir ölçüsüdür. HKO değeri tahmin edicinin tahmin edilen parametreden sapmalarının kareleri ortalamasıdır. Yanlı tahmin ediciler aracılığıyla elde edilen parametre değerleri parametrenin gerçek değerine EKK tahmin edicisinden daha yakındır (Özbey ve Kaçıranlar, 2015; Rawlings ve diğerleri, 1998: 444). $\hat{\beta}_R$ tahmin edicisinin HKO değeri Eş. 3.5'te verilmiştir.

$$\begin{aligned}HKO(\hat{\beta}_R) &= E\|\hat{\beta}_R - \beta\|^2 = E[(\hat{\beta}_R - \beta)'(\hat{\beta}_R - \beta)] \\ &= E[(\hat{\beta}_R - E(\hat{\beta}_R) + E(\hat{\beta}_R) - \beta)'(\hat{\beta}_R - E(\hat{\beta}_R) + E(\hat{\beta}_R) - \beta)] \\ &= E\|\hat{\beta}_R - \beta\|^2 + 2E\{(\hat{\beta}_R - \beta)'(\hat{\beta}_R - \beta)\} + \|E(\hat{\beta}_R) - \beta\|^2 \\ &= E\|\hat{\beta}_R - E(\hat{\beta}_R)\|^2 + \|E(\hat{\beta}_R) - \beta\|^2 = Var(\hat{\beta}_R) + [Yan(\hat{\beta}_R)]^2 \\ &= \sigma^2 tr[(X'X + kI)^{-1}(X'X)(X'X + kI)^{-1}] + k^2\beta'(X'X + kI)^{-2}\beta \\ &= \sigma^2\sum_{j=1}^{p}\frac{\lambda_j}{(\lambda_j + k)^2} + k^2\beta(X'X + kI)^{-2}\beta\end{aligned} \tag{3.5}$$

Eş. 3.5'te $\lambda_1, \lambda_2, \dots, \lambda_p$ değerleri $X'X$ matrisinin öz değerlerini ifade etmek üzere, eşitliğin sağındaki ilk ifade parametrelerin varyans toplamını, ikinci ifade ise yan değerinin karesini ifade etmektedir. $k > 0$ olduğu durumda varyans azalırken yan değerinin artacağı açıkça görülmektedir. Ridge regresyon ile yapılan tahminlerde amaç varyanstaki azalmanın yandaki artıştan daha büyük olmasını sağlayacak şekilde bir k yan değerini seçmektir. Hoerl ve Kennard (1970) $\beta'\beta$ değerinin sınırlandırılması koşuluyla $HKO(\hat{\beta}_R) < HKO(\hat{\beta}_{EKK})$ olacak şekilde bir k yan değerinin var olduğunu kanıtlamıştır (Montgomery ve diğerleri, 2012: 306). Ridge regresyon tahmin edicisinin VIF değeri Eş. 3.6'da verilmiştir:

$$[VIF_1, \dots, VIF_p] = diag[(X'X + kI)^{-1}X'X(X'X + kI)^{-1}] \tag{3.6}$$

$C = X'X$ matrisinin $i.$ özdeğerine karşılık gelen λ_i değerleri $\lambda_1 \geq \lambda_2 \geq \lambda_3 \geq \cdots \geq \lambda_p$ şeklinde sıralansın. Bu özdeğerlere karşılık gelen özvektörleri sütun olarak kabul eden ortogonal matris $D'CD = \Lambda = diag(\lambda_1, \lambda_2, \dots, \lambda_p)$ eşitliğini sağlayan D matrisi olsun. Eş. 2.1'de verilen klasik çoklu doğrusal regresyon modelinin kanonik formu Eş. 3.7'deki gibidir.

$$Y = Z\alpha + \varepsilon \tag{3.7}$$

Burada $D'X'XD = Z'Z = \Lambda$, $\alpha = D'\beta$ ve $Z = XD$ olur. Buradan α'nın EKK tahmin edicisi Eş. 3.8'de verildiği gibidir (Montgomery ve diğerleri, 2012: 314).

$$\hat{\alpha}_{EKK} = (Z'Z)^{-1}Z'Y = \Lambda^{-1}Z'Y \tag{3.8}$$

$A = \Lambda + kI$ olmak üzere, $\hat{\beta}_R$'in kanonik formu $\hat{\alpha}_R$ Eş. 3.9'daki gibi tanımlanır (Mermi ve diğerleri, 2021; Sinan, 2003).

$$\hat{\alpha}_R = A^{-1}Z'Y \tag{3.9}$$

3.1.1. Ridge regresyon tahmin yöntemi için önerilen yanlılık parametreleri

Ridge regresyonda yanlılık parametresi k değerini belirlemek için Hoerl ve Kennard (1970)'dan beri birçok araştırmacı tarafından yeni metotlar önerilmiştir.

$m_i = \sqrt{\frac{\hat{\sigma}^2}{\hat{\alpha}_i^2}}$, $q_i = \frac{\lambda_{max}}{(n-p)\hat{\sigma}^2+\lambda_{max}\hat{\alpha}_i^2}$ ve $\alpha_i = D'\beta$, $i = 1,2,\dots,p$ olmak üzere, literatürde sıklıkla karşılaştırması yapılan 77 tahmin edici Çizelge 3.1'de listelenmiştir.

Çizelge 3.1. Ridge regresyon için önerilen yanlılık parametreleri

Önerilen Yanlılık Parametresi	*Yazar*
$k_1 = \frac{p\hat{\sigma}^2}{\hat{\beta}'\hat{\beta}}$	Hoerl ve diğerleri, 1975
$k_2 = \frac{p\hat{\sigma}^2}{\sum_{i=1}^{p}\lambda_i\hat{\alpha}_i^2}$	Lawless ve Wang, 1976
$k_3 = p\sigma^2 / \sum_{i=1}^{p}\{\hat{\alpha}_i^2/[1+(1+\lambda_i(\hat{\alpha}_i^2/\hat{\sigma}^2)^{1/2})]\}$	Nomura, 1988
$k_4 = (\lambda_{max}\hat{\sigma}^2)/\left((n-p-1)\hat{\sigma}^2+\lambda_{max}\hat{\beta}_{max}^2\right)$	Khalaf ve Shukur, 2005
$k_5 = \frac{\hat{\sigma}^2}{\left(\prod_{i=1}^{p}\hat{\alpha}_i^2\right)^{(1/p)}}$	Kibria, 2003
$k_6 = median\left(\frac{\hat{\sigma}^2}{\hat{\alpha}_i^2}\right)$	Kibria, 2003
$k_7 = \frac{1}{p}\sum_{i=1}^{p}\frac{\hat{\sigma}^2}{\hat{\alpha}_i^2}$	Kibria, 2003
$k_8 = \frac{\hat{\sigma}^2}{\hat{\alpha}_{max}^2}$	Hoerl ve Kennard, 1970
$k_9 = \frac{\hat{\sigma}^2}{max(\hat{\alpha}_i)}$	Hoerl ve Kennard, 1970
$k_{10} = \frac{\hat{\sigma}^2}{\sum_{i=1}^{p}\hat{\alpha}_i^2}$	Hoerl ve Kennard, 1970
$k_{11} = \frac{p\hat{\sigma}^2}{\hat{\alpha}'\hat{\alpha}} + \frac{1}{\lambda_{max}}$	Alkhamisi ve Shukur, 2007
$k_{12} = max\left(\frac{\hat{\sigma}^2}{\beta_i^2} + \frac{1}{\lambda_i}\right)$	Alkhamisi ve Shukur, 2007
$k_{13} = \frac{1}{p}\sum_{i=1}^{p}\left(\frac{\hat{\sigma}^2}{\beta_i^2} + \frac{1}{\lambda_i}\right)$	Alkhamisi ve Shukur, 2007

Çizelge 3.1. (devam) Ridge regresyon için önerilen yanlılık parametreleri

$k_{14} = median\left(\frac{\hat{\sigma}^2}{\beta_i^2} + \frac{1}{\lambda_i}\right)$	Alkhamisi ve Shukur, 2007
$k_{15} = \frac{p\hat{\sigma}^2}{\sum_{i=1}^{p} \lambda_i \beta_i^2} + \frac{1}{\lambda_{max}}$	Alkhamisi ve Shukur, 2007
$k_{16} = \frac{2}{p\lambda_{max}} \sum_{i=1}^{p} \frac{\hat{\sigma}^2}{\hat{\alpha}_i^2}$	Dorugade, 2014
$k_{17} = median\left(\frac{2\hat{\sigma}^2}{\lambda_{max}\hat{\alpha}_i^2}\right)$	Dorugade, 2014
$k_{18} = \frac{2\hat{\sigma}^2}{\lambda_{max}\left(\prod_{i=1}^{p} \hat{\alpha}_i^2\right)^{(1/p)}}$	Dorugade, 2014
$k_{19} = \frac{2p}{\lambda_{max}} \sum_{i=1}^{p} \frac{\hat{\sigma}^2}{\hat{\alpha}_i^2}$	Dorugade, 2014
$k_{20} = \left(\prod_{i=1}^{p} \frac{\lambda_i \hat{\sigma}^2}{(n-p)\hat{\sigma}^2 + \lambda_i \hat{\alpha}_i^2}\right)^{(1/p)}$	Muniz ve Kibria, 2009
$k_{21} = max\left(\frac{1}{m_i}\right)$	Muniz ve Kibria, 2009
$k_{22} = max(m_i)$	Muniz ve Kibria, 2009
$k_{23} = \left(\prod_{i=0}^{p} 1/m_i\right)^{(1/p)}$	Muniz ve Kibria, 2009
$k_{24} = \left(\prod_{i=0}^{p} m_i\right)^{(1/p)}$	Muniz ve Kibria, 2009
$k_{25} = median\left(\frac{1}{m_i}\right)$	Muniz ve Kibria, 2009
$k_{26} = median(m_i)$	Muniz ve Kibria, 2009
$k_{27} = max\left(\frac{1}{q_i}\right)$	Kibria ve diğerleri, 2012
$k_{28} = max(q_i)$	Kibria ve diğerleri, 2012

Çizelge 3.1. (devam) Ridge regresyon için önerilen yanlılık parametreleri

$k_{29} = \prod_{i=0}^{p} \left(\frac{1}{q_i}\right)^{1/p}$	Kibria ve diğerleri, 2012
$k_{30} = \prod_{i=0}^{p} (q_i)^{1/p}$	Kibria ve diğerleri, 2012
$k_{31} = median\left(\frac{1}{q_i}\right)$	Kibria ve diğerleri, 2012
$k_{32} = median(q_i)$	Kibria ve diğerleri, 2012
$k_{33} = \frac{p^2}{\lambda_{max}^2} \frac{\hat{\sigma}^2}{\sum_{i=1}^{p} \hat{\alpha}_i^2}$	Asar ve diğerleri, 2014
$k_{34} = \frac{p^3}{\lambda_{max}^3} \frac{\hat{\sigma}^2}{\sum_{i=1}^{p} \hat{\alpha}_i^2}$	Asar ve diğerleri, 2014
$k_{35} = \frac{p}{\lambda_{max}^{1/3}} \frac{\hat{\sigma}^2}{\sum_{i=1}^{p} \hat{\alpha}_i^2}$	Asar ve diğerleri, 2014
$k_{36} = \frac{p}{\left(\prod_{i=1}^{p} \sqrt{\lambda_i}\right)^{1/3}} \frac{\hat{\sigma}^2}{\sum_{i=1}^{p} \hat{\alpha}_i^2}$	Asar ve diğerleri, 2014
$k_{37} = \frac{2p}{\sqrt{\lambda_{max}}} \frac{\hat{\sigma}^2}{\sum_{i=1}^{p} \hat{\alpha}_i^2}$	Asar ve diğerleri, 2014
$k_{38} = \sqrt{median(m_i)}$	Göktaş ve Sevinç, 2016
$k_{39} = \frac{\hat{\sigma}^2}{(median(\alpha_i)^2}$	Göktaş ve Sevinç, 2016
$k_{40} = \frac{1}{\alpha_{max}^2}$	Schaefer ve diğerleri, 1984
$k_{41} = \hat{\sigma}^2 \frac{\sum_{i=1}^{p} (\lambda_i \alpha_i)^2}{\sum_{i=1}^{p} (\lambda_i \alpha_i^2)^2}$	Hocking ve diğerleri, 1976
$k_{42} = \frac{p\hat{\sigma}^2}{\hat{\alpha}'\hat{\alpha}} + \frac{1}{\lambda_{max}\hat{\alpha}'\hat{\alpha}}$	Bhat ve Vidya, 2016
$k_{43} = \frac{p\hat{\sigma}^2}{\hat{\alpha}'\hat{\alpha}} + \frac{1}{2(\lambda_{max}/\lambda_{min})^2}$	Bhat ve Vidya, 2016

Çizelge 3.1. (devam) Ridge regresyon için önerilen yanlılık parametreleri

$k_{44} = \hat{\sigma}^2 \frac{\sum_{i=1}^{p}(\lambda_i \alpha_i)^2}{\sum_{i=1}^{p}(\lambda_i \alpha_i^2)^2} + \frac{1}{\lambda_{max}}$	Al-Hassan, 2010
$k_{45} = max\left(\frac{\lambda_i \hat{\sigma}^2}{(n-p)\hat{\sigma}^2 + \lambda_i \beta_i^2}\right)$	Alkhamisi ve diğerleri, 2006
$k_{46} = \frac{1}{p}\sum_{i=1}^{p}\left(\frac{\lambda_i \hat{\sigma}^2}{(n-p)\hat{\sigma}^2 + \lambda_i \beta_i^2}\right)$	Alkhamisi ve diğerleri, 2006
$k_{47} = median\left(\frac{\lambda_i \hat{\sigma}^2}{(n-p)\hat{\sigma}^2 + \lambda_i \beta_i^2}\right)$	Alkhamisi ve diğerleri, 2006b
$k_{48} = \frac{p\hat{\sigma}^2}{\hat{\alpha}'\hat{\alpha}}, \hat{\sigma}^2 = \frac{AKT}{n-p+2}$	Khalaf, 2012
$k_{49} = \frac{\hat{\sigma}^2}{min\left(\frac{\hat{\sigma}^2}{\alpha_i^2} + \frac{1}{\lambda_i}\right)}$	Dorugade, 2014
$k_{50} = \frac{(\lambda_{max} + \lambda_{min})}{2\sum_{i=1}^{n}\lvert\hat{\beta}_i\rvert}\frac{p\hat{\sigma}^2}{\hat{\beta}'\hat{\beta}}$	Khalaf, 2013
$k_{51} = \frac{(\lambda_{max} + \lambda_{min})}{2\sum_{i=1}^{n}\lvert\hat{\beta}_i\rvert}\frac{(\lambda_{max}\hat{\sigma}^2)}{\left((n-p-1)\hat{\sigma}^2 + \lambda_{max}\hat{\beta}_{max}^2\right)}$	Khalaf, 2013
$k_{52} = \frac{\hat{\sigma}^2}{2}\left(\frac{1}{\hat{\beta}_{max}^2} + \frac{p}{\hat{\beta}'\hat{\beta}}\right)$	Khalaf ve Iguernane, 2014
$k_{53} = \frac{2\hat{\sigma}^2}{\hat{\beta}_{max}^2 + \frac{\hat{\beta}'\hat{\beta}}{p}}$	Khalaf ve Iguernane, 2014
$k_{54} = \hat{\sigma}^2\sqrt{\frac{p}{\hat{\beta}_{max}^2\hat{\beta}'\hat{\beta}}}$	Khalaf ve Iguernane, 2014
$k_{55} = \sigma, \hat{\sigma}^2 = \frac{Y'Y - \alpha' Z'Y}{n-p-1}$	Dorugade, 2016
$k_{56} = \sqrt{\frac{(\lambda_{max}\hat{\sigma}^2)}{\left((n-p-1)\hat{\sigma}^2 + \lambda_{max}\hat{\beta}_{max}^2\right)}}$	Khalaf ve Iguernane, 2016
$k_{57} = p\sigma, \hat{\sigma}^2 = \frac{Y'Y - \alpha' Z'Y}{n-p-1}$	Lukman ve Olatunji, 2017
$k_{58} = max\left(\frac{S^2}{\hat{\beta}_i^2}\right), S^2 = \frac{(Y - X\hat{\beta})'(Y - X\hat{\beta})}{n-p}$	Alkhamisi ve diğerleri, 2006

Çizelge 3.1. (devam) Ridge regresyon için önerilen yanlılık parametreleri

$k_{59} = \frac{S^2}{\hat{\beta}_{max}^2} + \frac{1}{\lambda_{max}}$	Alkhamisi ve Shukur, 2007
$k_{60} = max\left(\frac{1}{\sqrt{\frac{(\lambda_{max}\hat{\sigma}^2)}{\left((n-p)\hat{\sigma}^2+(\lambda_{max}\hat{\alpha}_i^2\right)}}}\right)$	Muniz ve diğerleri, 2012
$k_{61} = max\left(\sqrt{\frac{(\lambda_{max}\hat{\sigma}^2)}{\left((n-p)\hat{\sigma}^2+(\lambda_{max}\hat{\alpha}_i^2\right)}}\right)$	Muniz ve diğerleri, 2012
$k_{62} = \left(\prod_{i=1}^{p}\frac{1}{\sqrt{\frac{(\lambda_{max}\hat{\sigma}^2)}{\left((n-p)\hat{\sigma}^2+(\lambda_{max}\hat{\alpha}_i^2\right)}}}\right)^{1/p}$	Muniz ve diğerleri, 2012
$k_{63} = \left(\prod_{i=1}^{p}\sqrt{\frac{(\lambda_{max}\hat{\sigma}^2)}{\left((n-p)\hat{\sigma}^2+(\lambda_{max}\hat{\alpha}_i^2\right)}}\right)^{1/p}$	Muniz ve diğerleri, 2012
$k_{64} = median\left(\frac{1}{\sqrt{\frac{(\lambda_{max}\hat{\sigma}^2)}{\left((n-p)\hat{\sigma}^2+(\lambda_{max}\hat{\alpha}_i^2\right)}}}\right)$	Muniz ve diğerleri, 2012
$k_{65} = \frac{\sqrt{5}p}{\lambda_{max}}\frac{\hat{\sigma}^2}{\sum_{i=1}^{p}\hat{\alpha}_i^2}$	Karaibrahimoğlu ve diğerleri, 2016
$k_{66} = \frac{p}{\sqrt{\lambda_{max}}}\frac{\hat{\sigma}^2}{\sum_{i=1}^{p}\hat{\alpha}_i^2}$	Karaibrahimoğlu ve diğerleri, 2016
$k_{67} = \frac{2p}{\sum_{i=1}^{p}(\lambda_i{}^{1/4})}\frac{\hat{\sigma}^2}{\sum_{i=1}^{p}\hat{\alpha}_i^2}$	Karaibrahimoğlu ve diğerleri, 2016
$k_{68} = \frac{2p}{\sqrt{\sum_{i=1}^{p}\lambda_i}}\frac{\hat{\sigma}^2}{\sum_{i=1}^{p}\hat{\alpha}_i^2}$	Karaibrahimoğlu ve diğerleri, 2016
$k_{69} = max\left(\sqrt{\frac{2\hat{\sigma}^2}{\lambda_{max}\hat{\alpha}_i^2}}\right)$	Lukman ve diğerleri, 2017
$k_{70} = \sqrt{\frac{2\hat{\sigma}^2}{\lambda_{max}p}}\sum_{i=1}^{p}\frac{1}{\hat{\alpha}_i^2}$	Lukman ve diğerleri, 2017
$k_{71} = \frac{2\hat{\sigma}^2}{\sqrt{\sum_{i=1}^{p}\lambda_i}\,max(\hat{\alpha}_i^2)}$	Lukman ve diğerleri, 2017

Çizelge 3.1. (devam) Ridge regresyon için önerilen yanlılık parametreleri

$k_{72} = \sqrt{\frac{2\hat{\sigma}^2}{\sqrt{\sum_{i=1}^{p}\lambda_i}\, max(\hat{\alpha}_i^2)}}$	Lukman ve diğerleri, 2017
$k_{73} = \frac{2p\hat{\sigma}^2}{\sqrt{\sum_{i=1}^{p}\lambda_i}\sum_{i=1}^{p}\hat{\alpha}_i^2}$	Lukman ve diğerleri, 2017
$k_{74} = \sqrt{\frac{2p\hat{\sigma}^2}{\sqrt{\sum_{i=1}^{p}\lambda_i}\sum_{i=1}^{p}\hat{\alpha}_i^2}}$	Lukman ve diğerleri, 2017
$k_{75} = \frac{2\hat{\sigma}^2}{\sqrt{\sum_{i=1}^{p}\lambda_i}\left(\prod_{i=1}^{p}\hat{\alpha}_i^2\right)^{1/p}}$	Lukman ve diğerleri, 2017
$k_{76} = \sqrt{\frac{2\hat{\sigma}^2}{\sqrt{\sum_{i=1}^{p}\lambda_i}\left(\prod_{i=1}^{p}\hat{\alpha}_i^2\right)^{1/p}}}$	Lukman ve diğerleri, 2017
$k_{77} = median\left(\frac{2\hat{\sigma}^2}{\sqrt{\sum_{i=1}^{p}\lambda_i}\,\hat{\alpha}_i^2}\right)$	Lukman ve diğerleri, 2017

3.2. Liu Regresyon

Çoklu doğrusal regresyon modelinde çoklu bağlantı problemine çözüm getirmek için Ridge regresyon tahmin edicisine alternatif olarak Liu (1993) tarafından önerilen Liu tahmin edicisi Eş. 3.10'de verilmiştir.

$$\begin{aligned}\hat{\beta}_{Liu} &= (X'X+I)^{-1}\left(X'Y + d\hat{\beta}_{EKK}\right)\\ &= (X'X+I)^{-1}(X'X+dI)\hat{\beta}_{EKK}, \quad 0<d<1\end{aligned} \tag{3.10}$$

Burada d Liu tahmin edicisinin yanlılık parametresi olmak üzere; $d=1$ olduğu durumda $\hat{\beta}_{Liu}$ değeri $\hat{\beta}_{EKK}$ değerine eşittir. Eş. 3.11'de Liu tahmin edicisinin EKK tahmin edicisinin doğrusal dönüşümü olduğu gösterilmiştir.

$$\begin{aligned}\hat{\beta}_{Liu} &= (X'X+I)^{-1}(X'X+dI)\hat{\beta}_{EKK}\\ &= Z_d\hat{\beta}_{EKK}\end{aligned} \tag{3.11}$$

Burada $Z_d = (X'X+I)^{-1}(X'X+dI)$ olarak tanımlanır. $\hat{\beta}_{Liu}$ tahmin edicisinin beklenen değeri Eş. 3.12'te verildiği gibidir.

$$E(\hat{\beta}_{Liu}) = E[(X'X + I)^{-1}(X'X + dI)\hat{\beta}_{EKK}]$$
$$= (X'X + I)^{-1}(X'X + dI)E(\hat{\beta}_{EKK})$$
$$= (X'X + I)^{-1}(X'X + dI)\beta \quad (3.12)$$

$E(\hat{\beta}_{Liu}) = E(Z_d\hat{\beta}_{EKK}) \neq \beta$ olduğundan, Liu regresyon tahmin edicisi $\hat{\beta}_{Liu}$' nun β parametresinin yanlı tahmin edicisi olduğu söylenebilir. Ayrıca $\hat{\beta}_{Liu}$ tahmin edicisinin varyans-kovaryans matrisi Eş. 3.13'te verilmiştir.

$$Var(\hat{\beta}_{Liu}) = \sigma^2(X'X + I)^{-1}(X'X + dI)(X'X)^{-1}(X'X + dI)(X'X + I)^{-1} \quad (3.13)$$

Liu tahmin edicisinin *HKO* kriteri açısından EKK tahmin edicisine kıyasla daha üstün olduğu kanıtlanmıştır (Liu, 1993). Buna göre $\alpha = D'\beta$ olmak üzere, $\hat{\beta}_{Liu}$ tahmin edicisinin HKO değeri Eş. 3.14'teki gibidir.

$$HKO(\hat{\beta}_{Liu}) = E\|\hat{\beta}_{Liu} - \beta\|^2 = E[(\hat{\beta}_{Liu} - \beta)'(\hat{\beta}_{Liu} - \beta)]$$
$$= E[(\hat{\beta}_{Liu} - E(\hat{\beta}_{Liu}) + E(\hat{\beta}_{Liu}) - \beta)'(\hat{\beta}_{Liu} - E(\hat{\beta}_{Liu}) + E(\hat{\beta}_{Liu}) - \beta)]$$
$$= E\|\hat{\beta}_{Liu} - \beta\|^2 + 2E\{(\hat{\beta}_{Liu} - \beta)'(\hat{\beta}_{Liu} - \beta)\} + \|E(\hat{\beta}_{Liu}) - \beta\|^2$$
$$= E\|\hat{\beta}_{Liu} - E(\hat{\beta}_{Liu})\|^2 + \|E(\hat{\beta}_{Liu}) - \beta\|^2$$
$$= \sigma^2\sum_{i=1}^{p}\frac{(\lambda_i + d)^2}{\lambda_i(\lambda_i + 1)^2} + (d-1)^2\sum_{i=1}^{p}\frac{{\alpha_i}^2}{(\lambda_i + 1)^2} \quad (3.14)$$

Eş. 3.14'te $\lambda_1, \lambda_2, \dots, \lambda_p$ değerleri $X'X$ matrisinin öz değerlerini ifade etmek üzere Liu tahmin edicisi ile yapılan tahminlerde amaç varyanstaki azalmanın yandaki artıştan daha büyük olacağı şekilde bir d yan değeri seçmektir. Liu (1993) $HKO(\hat{\beta}_{Liu}) < HKO(\hat{\beta}_{EKK})$ olacak şekilde bir d yan değerinin var olduğunu kanıtlamıştır (Månsson ve diğerleri, 2012).

Liu tahmin edicisinin VIF değeri ise Eş. 3.15'te verilmiştir.

$$VIF_p = diag[(X'X + I)^{-1}(X'X + dI)(X'X)^{-1}((X'X + dI)(X'X + I)^{-1}))'] \quad (3.15)$$

3.2.1. Liu regresyonu için önerilen yanlılık parametreleri

Liu regresyonda yanlılık parametresi d değerini belirlemek için Liu (1993)'den beri birçok araştırmacı tarafından yeni metotlar önerilmiştir. $q_j = \frac{\alpha_j^2 - 1}{max\left(\frac{1}{\lambda_j}\right) + \alpha_j^2}$ ve $\alpha_i = D'\beta, i =$

$1,2,\dots,p$ olmak üzere, literatürde sıklıkla karşılaştırması yapılan 13 tahmin edici Çizelge 3.2'de listelenmiştir.

Çizelge 3.2. Liu regresyonu için önerilen yanlılık parametreleri

Önerilen Yanlılık Parametresi	*Yazar*
$d_1 = max\left(0, \frac{\alpha_{max}^2 - \hat{\sigma}^2}{\frac{1}{\lambda_{max}} + \alpha_{max}^2}\right)$	Shukur ve diğerleri, 2015
$d_2 = max\left(0, median\left(\frac{\alpha_j^2 - \hat{\sigma}^2}{\frac{1}{\lambda_j} + \alpha_j^2}\right)\right)$	Shukur ve diğerleri, 2015
$d_3 = max\left(0, mean\left(\frac{\alpha_j^2 - \hat{\sigma}^2}{\frac{1}{\lambda_j} + \alpha_j^2}\right)\right)$	Shukur ve diğerleri, 2015
$d_4 = max\left(0, max\left(\frac{\alpha_j^2 - \hat{\sigma}^2}{\frac{1}{\lambda_j} + \alpha_j^2}\right)\right)$	Shukur ve diğerleri, 2015
$d_5 = max\left(0, min\left(\frac{\alpha_j^2 - \hat{\sigma}^2}{\frac{1}{\lambda_j} + \alpha_j^2}\right)\right)$	Shukur ve diğerleri, 2015
$d_6 = max\left(0, median(q_j)\right)$	Shukur ve diğerleri, 2015
$d_7 = max\left(0, mean(q_j)\right)$	Shukur ve diğerleri, 2015
$d_8 = max\left(0, max(q_j)\right)$	Shukur ve diğerleri, 2015
$d_9 = max\left(0, min(q_j)\right)$	Shukur ve diğerleri, 2015
$d_{10} = max\left(0, median\left(\frac{\alpha_j^2 - \hat{\sigma}^2}{max\left(\frac{\hat{\sigma}^2}{\alpha_j^2}\right) + \alpha_{max}^2}\right)\right)$	Qasim ve diğerleri, 2020
$d_{11} = max\left(0, mean\left(\frac{\alpha_j^2 - \hat{\sigma}^2}{max\left(\frac{\hat{\sigma}^2}{\alpha_j^2}\right) + \alpha_{max}^2}\right)\right)$	Qasim ve diğerleri, 2020
$d_{12} = max\left(0, max\left(\frac{\alpha_j^2 - \hat{\sigma}^2}{max\left(\frac{\hat{\sigma}^2}{\alpha_j^2}\right) + \alpha_{max}^2}\right)\right)$	Qasim ve diğerleri, 2020
$d_{13} = max\left(0, min\left(\frac{\alpha_j^2 - \hat{\sigma}^2}{max\left(\frac{\hat{\sigma}^2}{\alpha_j^2}\right) + \alpha_{max}^2}\right)\right)$	Qasim ve diğerleri, 2020

4. PARÇACIK SÜRÜ OPTİMİZASYONU

Sürü zekâsı, sistemlerin doğal veya yapay olmasına bakılmaksızın kendi kendini organize eden ve merkezi olmayan sistemlerin kolektif davranışlarını araştırır. Doğa, bu tür zekâ teknikleri için ana ilham kaynağıdır (Kothari ve diğerleri, 2012). Sürü zekasının öne çıkan örneklerinden bazıları balık eğitimi, bakteriyel büyüme, hayvan sürüsü ve karınca kolonileridir. Kuş sürülerinin hareketine dayalı bir optimizasyon algoritması Kennedy ve Eberhart (1955) tarafından önerilmiş ve PSO olarak adlandırılmıştır. PSO, sürü halinde yaşayan doğal organizmaların yeterli yiyecek bulabilmek için yaptıkları sosyal davranışları esas alan popülasyon tabanlı bir sezgisel optimizasyon yöntemidir (Talbi, 2009: 247).

Bir grup kuşun rastgele bir bölgede yiyecek aradığı ve kuşların yiyeceğin nerede olduğunu bilmedikleri varsayılsın. Yiyecek bulmak için en etkili yöntem, kuşların yiyeceğe en yakın olduğu bilinen kuşu takip etmesidir. PSO da bu şekilde önceki örneğe göre hareket eder ve optimizasyon problemlerini çözmek için sayısal bir analoji kullanır. PSO, optimizasyon probleminin karar alanındaki her bir çözümü bir kuş olarak belirler ve "parçacık" olarak adlandırır. Tüm parçacıklar, optimize edilecek amaç fonksiyonu tarafından değerlendirilen ve yiyeceğe olan mesafelerini ölçen uygunluk değerlerine sahiptir. Bununla birlikte her parçacık aynı zamanda parçacığın hareketini yönlendiren hıza sahiptir. En iyi parçacık liderdir ve diğer parçacıklar lideri takip ederek problemin karar alanı boyunca uçarlar. Her parçacık iki pozisyon tarafından güncellenir. Birincisi, parçacığın şimdiye kadar elde ettiği en iyi konumdur ve en iyi bireysel pozisyon *(pbest)* olarak tanımlanır. Diğeri, parçacık popülasyonundaki herhangi bir parçacık tarafından şimdiye kadar elde edilen en iyi konumdur ve en iyi küresel pozisyon *(gbest)* olarak tanımlanır. PSO, arama alanı içinde rastgele başlatılan parçacıkların konumu ve hızı ile başlar. Öncelikle, parçacıkların uygunluk değerleri hesaplanır. Bu ilk uygunluk değerleri ve pozisyonları, sırasıyla en iyi bireysel uygunluk değerleri ve en iyi bireysel pozisyonlardır. Tüm parçacıklar arasında en iyi konum küresel en iyi konumdur. Her parçacığın konumu ve hızı, bireysel ve küresel en iyi konumlarına dayalı yeni çözümler üretmek için güncellenir. Bir sonraki yinelemede, güncellenen parçacıkların uygunluk değerleri yeniden hesaplanır ve bireysel ve küresel en iyi konumlar güncellenir. Bu şekilde yeni parçacıkların konumları ve hızları üretilir. PSO algoritması, bireysel ve küresel en iyi pozisyonları güncellemeye ve sonlandırma kriterleri karşılanana kadar yeni pozisyonlar oluşturmaya devam etmektedir (Bozorg-Haddad ve diğerleri, 2017: 105).

PSO, optimizasyon probleminin olası her çözümünü bir parçacık olarak belirler. X, optimizasyon probleminin olası bir çözümünü; x_i , X çözümünün i. karar değişkenini ve N, karar değişkenlerinin sayısını temsil etmek üzere; parçacıklar Eş. 4.1'deki gibi $N\ x\ 1$ boyutlu bir vektör olarak belirtilebilir.

$$X = (x_1, x_2, \dots, x_i, \dots, x_N) \tag{4.1}$$

PSO algoritması $M \times N$ boyutlu parçacıklardan oluşan rastgele bir matris oluşturarak başlar. $X_j = j$. çözüm ve $x_{j,i} = i$. karar değişkeninin j. çözümü ve M çözüm popülasyonunun boyutunu temsil etmek üzere çözüm matrisi Eş. 4.2'de verilmiştir.

$$Populasyon = \begin{bmatrix} X_1 \\ X_2 \\ \vdots \\ X_j \\ \vdots \\ X_M \end{bmatrix} = \begin{bmatrix} x_{1,1} & x_{1,2} & \cdots & x_{1,i} & \dots & x_{1,N} \\ x_{2,1} & x_{2,2} & \dots & x_{2,i} & \dots & x_{2,N} \\ \vdots & \vdots & & \vdots & & \vdots \\ x_{j,1} & x_{j,2} & \dots & x_{j,i} & \dots & x_{j,N} \\ \vdots & \vdots & & \vdots & & \vdots \\ x_{M,1} & x_{M,2} & \dots & x_{M,i} & \dots & x_{M,N} \end{bmatrix} \tag{4.2}$$

Her parçacık, bireysel ve küresel en iyi pozisyonlarına dayalı olarak karar uzayında hareket eder ve iki tür parametre ($pbest$ ve $gbest$) ile karar uzayında en uygun konumu elde etmeye çalışır. *pbest* parçacığın geçmişinde elde ettiği en iyi konumdur ve en iyi bireysel pozisyon olarak tanımlanır. Her j parçacığı için Eş. 4.3'teki gibi bir $pbest$ vardır.

$$pbest_j = \left(p_{j,1}, p_{j,2}, \dots, p_{j,i}, \dots, p_{j,N}\right), \quad j = 1,2, \dots, M \tag{4.3}$$

Eş. 4.4'te verilen $gbest$, parçacık popülasyonundaki herhangi bir parçacık tarafından şimdiye kadar elde edilen en iyi konumdur ve en iyi küresel pozisyon olarak tanımlanır.

$$gbest = (g_1, g_2, \dots, g_i, \dots, g_N) \tag{4.4}$$

Her parçacığın, parçacığın uçuşunu yönlendiren ve parçacığın bir sonraki konumunu belirleyen bir hızı vardır ve bu hızlar konumlarını güncellemek için kullanılır. Hız, *gbest* ve *pbest*'e göre hesaplanır. j. parçacığın hızı V_j Eş. 4.5'te gösterildiği gibidir.

$$V_j = (v_{j,1}, v_{j,2}, \dots, v_{j,i}, \dots, v_{j,N}), \qquad j = 1,2, \dots, M \tag{4.5}$$

Burada $v_{j,i}$; j. parçacığın i. boyuttaki hızını temsil eder. $v_{j,i}^{yeni}$; j. parçacığın i. boyuttaki yeni hızını, ω eylemsizlik ağırlığı parametresini, $Rand$ [0,1] aralığında rastgele bir değeri, C_1 bilişsel katsayıyı, C_2 sosyal parametreyi temsil etmek üzere, $v_{j,i}^{yeni}$ Eş. 4.6'daki gibi hesaplanır.

$$v_{j,i}^{yeni} = \omega \times v_{j,i} + C_1 \times Rand \times \left(p_{j,i} - x_{j,i}\right) + C_2 \times Rand \times (g_i - x_{j,i}) \tag{4.6}$$

Eylemsizlik ağırlığı parametresi ω, sürü yakınsamasında önemli bir role sahiptir ve bir önceki hızın mevcut hızlar üzerindeki etkilerini kontrol eder (Bozorg-Haddad ve diğerleri, 2017: 107-109). ω_{max} ve ω_{min} ifadeleri sırasıyla eylemsizlik ağırlığı parametresinin en büyük ve en küçük değerlerini temsil etmek üzere, Eberhart ve Yuhui Shi, (2001) tarafından önerilen ve erken iterasyonda algoritmanın en iyi çözüme yakınsamasını sağlayan eylemsizlik ağırlığı Eş. 4.7'de verildiği gibidir.

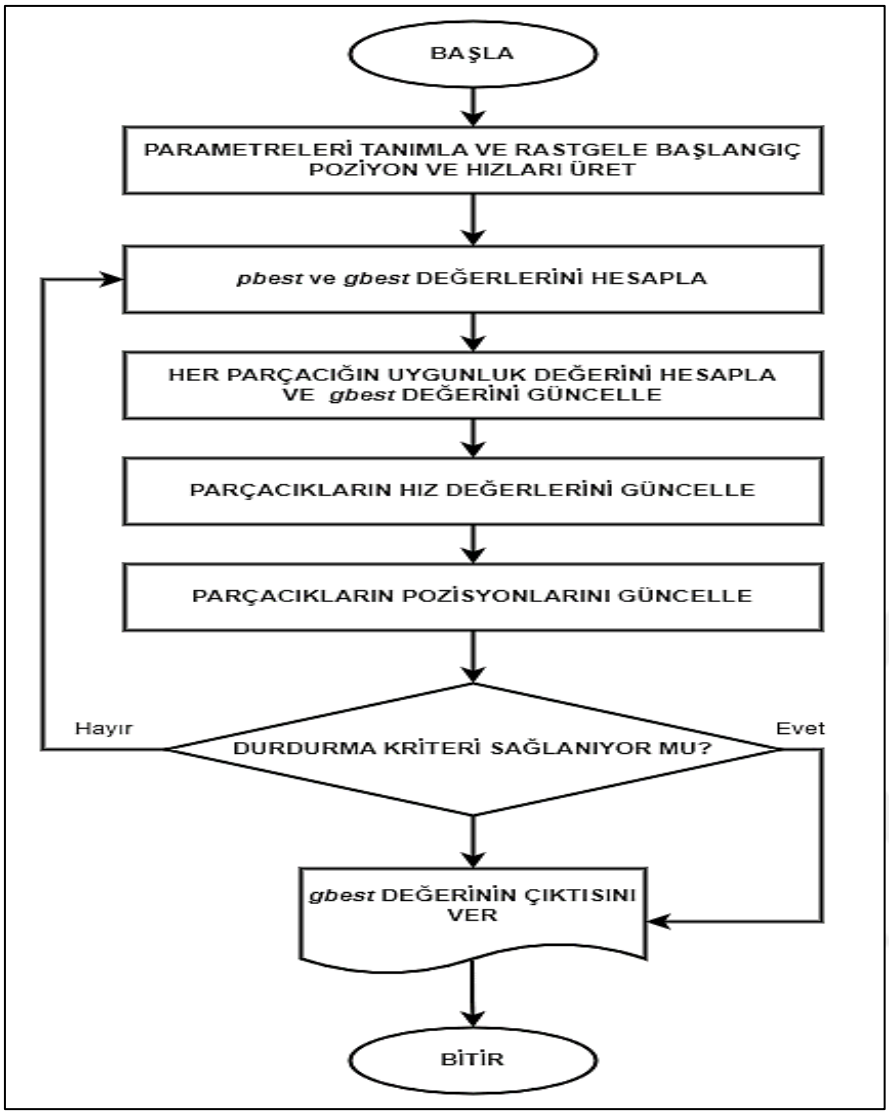
$$\omega = 0{,}5 + \frac{Rand}{2} \tag{4.7}$$

Parçacıklar eski konumlarından yeni konumlara hareket ederek konumlarını güncellerler. Parçacıkların bu hareketi hızlara bağlı olarak gerçekleştirilir. Bir parçacığın konumu Eş. 4.8'deki gibi güncellenir.

$$\begin{aligned} X_j^{yeni} &= (x'_{j,1}, x'_{j,2}, \dots, x'_{j,i}, \dots, x'_{j,N}) \\ x'_{j,i} &= x_{j,i} + v_{j,i}^{yeni} \end{aligned} \tag{4.8}$$

Sonlandırma kriterleri, algoritmanın ne zaman sonlandırılacağını belirler. Algoritmanın yakınsamasını düzeltmek için iyi bir sonlandırma kriterinin seçilmesi önemli bir role sahiptir. Yineleme sayısı, çalışma süresi ve ardışık yinelemeler arasındaki çözümün iyileştirilmesi, PSO algoritması için ortak sonlandırma kriterleridir.

PSO algoritmasının akış diyagramı Şekil 4.1'deki gibidir.



Şekil 4.1. Parçacık sürü optimizasyonu akış şeması

4.1. Parçacık Sürü Optimizasyonu ile Ridge Regresyonda Yanlılık Parametresinin Tahmin Edilmesi

Ridge regresyon çoklu doğrusal regresyonda çoklu bağlantı problemine çözüm olarak önerilmiş bir yanlı tahmin yöntemidir. Yanlı tahmin edicilerde yanlılık parametresinin seçimi önemli bir problemdir. PSO daha önce literatürde farklı regresyon uygulamalarıyla çalışılmıştır. Ahn ve diğerleri (2012) Ridge regresyonu genetik algoritma ile kullanmayı önermiştir. Uslu ve diğerleri (2014) Ridge Regresyonda optimal k yanlılık değerini tahmin etmek için VIF değerlerini dikkate alan şeklinde yeni bir amaç fonksiyonu önermişlerdir. Cagcag ve diğerleri (2015) aykırı gözlem içeren veri setleri için PSO'ya dayalı yeni bir parametre tahmin metotu önermişlerdir. Bas ve diğerleri (2017) tek bir yanlılık parametresi

önermek yerine her bir açıklayıcı değişken için PSO'ya dayalı farklı yanlılık parametrelerini önermişlerdir. İnan ve diğerleri (2017) iki yanlılık parametresine sahip Liu-tipi tahmin yönteminde farklı amaç fonksiyonları kullanarak yanlılık parametrelerini PSO algoritması aracılığıyla optimize etmişlerdir. İnan ve Sancar (2020) lojistik regresyonda yanlılık parametresinin belirlenmesi için PSO'ya dayalı yeni bir algoritma önermiştir. Qamar ve Algamal (2020) Liu regresyonda yanlılık parametresinin belirlenmesinde PSO algoritmasını tercih etmiştir. Ayrıca simülasyon çalışması ile PSO algoritmasından elde edilen yanlılık parametreleri yardımıyla hesaplanan HKO değerlerinin ve EKK tahmin yöntemi kullanılarak elde edilen HKO değerlerinden daha iyi sonuçlar verdiğini göstermiştir.

Uslu ve diğerleri (2014) tarafından önerilen Ridge regresyonda yanlılık parametresinin belirlenmesi için hem MAPE hem de VIF değerlerini göz önünde bulunduran amaç fonksiyonu Eş. 4.9.'da verilmiştir.

$$min_k MAPE(k) + \emptyset(k),\ k \geq 0 \tag{4.9}$$

Burada $MAPE(k)$ ve $\emptyset(k)$ ifadeleri sırasıyla Eş. 4.10 ve Eş.4.11'de tanımlanmıştır:

$$MAPE(k) = \frac{1}{n}\sum_{i=1}^{n}\left|\frac{y_i - \hat{y}_i}{y_i}\right| \tag{4.10}$$

$$\emptyset(k) = \begin{cases} 0, & \forall VIF < 10 \\ \sum_{j=1}^{p} VIF_j, & d.d. \end{cases} \qquad j = 1, \dots, p \tag{4.11}$$

Verilen amaç fonksiyonunda 10'dan büyük VIF değerleri elde etmek ve MAPE değerini minimize etmek amaçlanmıştır. Eş. 4.9'da tanımlanan amaç fonksiyonu standart PSO algoritmasıyla çözümlenmek istendiğinde algoritmanın adımları sırasıyla aşağıdaki gibidir:

Adım 1

Algoritmanın; M parçacık sayısı, C_1 bilişsel katsayıyı, C_2 sosyal katsayıyı, $iter_{max}$ maksimum iterasyon sayısı, durdurma koşulu ve ω eylemsizlik ağırlığı parametreleri belirlenir.

Adım2

Her bir parçacık rastgele hız ve konuma sahip olacak şekilde popülasyon rastgele başlatılır.

Adım 3

Parçacıkların Eş. 4.9'da verilen uygunluk değeri hesaplanır.

Adım 4

Parçacıkların sırasıyla Eş. 4.3 ve Eş. 4.4.'te verilen *pbest* ve *gbest* değerleri hesaplanır.

Adım 5

Parçacıkların sırasıyla Eş. 4.6 ve Eş. 4.8'de verilen hız ve konum değerleri güncellenir.

Adım 6

Maximum iterasyon sayısına ulaşılana kadar *Adım 3 – Adım 6* tekrarlanır.

Adım 7

Optimum k değeri *gbest* olarak kabul edilir.

4.2. Parçacık Sürü Optimizasyonu ile Liu Regresyonda Yanlılık Parametresinin Tahmin Edilmesi

Liu regresyon çoklu doğrusal regresyonda çoklu bağlantı problemine çözüm olarak önerilen Ridge regresyon tahmin yöntemine alternatif olarak Liu (1993) tarafından önerilmiş bir yanlı tahmin yöntemidir. Liu tahmin yönteminin EKK tahmin edicisi üzerindeki avantajı, tahmin edilen katsayıların doğrusal olmayan bir fonksiyon yerine Liu parametresinin doğrusal bir fonksiyonu olmasıdır (Qasim ve diğerleri, 2020). Yanlı tahmin edicilerde yanlılık parametresinin seçimi oldukça önemli bir problemdir. İnan ve diğerleri (2017) Liu-tipi tahmin edicisi için k ve d değerlerini farklı amaç fonksiyonları kullanarak PSO ile optimize

etmiştir. Qamar ve Algamal (2020) Liu regresyonda yanlılık parametresinin tahmin edilebilmesi için HKO'nı amaç fonksiyonu kabul eden bir PSO algoritması kullanmayı önermiştir.

Uslu ve diğerleri (2014) tarafından önerilen Ridge regresyonda yanlılık parametresinin belirlenmesi için MAPE ve VIF değerlerini göz önünde bulunduran amaç fonksiyonu Eş. 4.12.'de Liu regresyona uyarlanmıştır. Liu regresyonda PSO ile d yanlılık parametresi tahmininde kullanılacak olan amaç fonksiyonu Eş. 4.12.'deki gibidir.

$$min_d MAPE(d) + \emptyset(d),\ 0 \leq d \leq 1 \tag{4.12}$$

Burada $MAPE(d)$ ve $\emptyset(d)$ ifadeleri sırasıyla Eş. 4.13 ve Eş.4.14'te tanımlanmıştır:

$$MAPE(d) = \frac{1}{n}\sum_{i=1}^{n}\left|\frac{y_i - \hat{y}_i}{y_i}\right| \tag{4.13}$$

$$\emptyset(d) = \begin{cases} 0, & \forall VIF < 10 \\ \sum_{j=1}^{p} VIF_j, & d.d. \end{cases} \qquad j = 1, \dots, p \tag{4.14}$$

Eş. 4.12'de tanımlanan amaç fonksiyonunu standart PSO algoritmasıyla çözümlenmek istendiğinde algoritmanın adımları sırasıyla aşağıdaki gibidir.

Adım1

Algoritmanın; M parçacık sayısı, C_1 bilişsel katsayıyı, C_2 sosyal katsayıyı, $iter_{max}$ maksimum iterasyon sayısı, durdurma koşulu ve ω eylemsizlik ağırlığı parametreleri belirlenir.

Adım2

Her bir parçacık rastgele hız ve konuma sahip olacak şekilde popülasyon rastgele başlatılır.

Adım 3

Parçacıkların Eş. 4.12'de verilen uygunluk değeri hesaplanır.

Adım 4

Parçacıkların sırasıyla Eş. 4.3 ve Eş. 4.4.'te verilen *pbest* ve *gbest* değerleri hesaplanır.

Adım 5

Parçacıkların sırasıyla Eş. 4.6 ve Eş. 4.8'de verilen hız ve konum değerleri güncellenir.

Adım 6

Maximum iterasyon sayısına ulaşılana kadar *Adım 3 – Adım 6* tekrarlanır.

Adım 7

Optimum d değeri *gbest* olarak kabul edilir.

5. TAVLAMA BENZETİMİ OPTİMİZASYONU ALGORİTMASI

TBO algoritması optimizasyon problemlerinin çözümü için sıklıkla tercih edilen sezgisel yöntemlerden biridir. TBO, yüksek sıcaklıkta ısıtılmış katıların termal tavlamasının simülasyonuna dayanan bir sezgisel optimizasyon yöntemidir. Bir metal yüksek bir sıcaklıkta ısıtılarak eritildiğinde, erimiş metaldeki atomlar serbestçe hareket ederler. Ancak, sıcaklık azaldıkça atomların hareketleri kısıtlanacağından atomlar sıralanma eğiliminde olurlar ve mümkün olan en düşük iç enerjiye sahip kristalleri oluştururlar. Bu kristallerin oluşumu süreci esas olarak soğutma hızına bağlıdır. Erimiş metal çok hızlı bir şekilde soğutulduğunda kristal hale geçemeyebilir ve bu hızlı soğutma malzemenin içinde kusurlara neden olabilir. Bu nedenle, erimiş metalin düzenli kristal halde katılaşmasını sağlamak için sıcaklığının yavaş ve kontrollü bir şekilde azaltılması gerekir. Bu yavaş soğutma işlemine "tavlama" adı verilir (Rao, 2009). Bu algoritmanın optimizasyon problemlerine uygulanması ile ilgili çalışmalar ilk olarak Metropolis ve diğerleri (1953) tarafından yapılan çalışmadan ilham alan Kirkpatrick ve diğerleri (1983) tarafından yapılmıştır.

Basit bir optimizasyon algoritması, etki alanındaki mevcut ve komşu nokta ile çalışan amaç fonksiyonlarının çıktılarını yinelemeli olarak karşılaştırır. Böylece komşu nokta mevcut olandan daha iyi sonuç üretirse, sonraki yineleme için temel çözüm olarak kaydedilir. Aksi takdirde, algoritma daha iyi sonuçlar için daha geniş etki alanını aramadan prosedürü sonlandırır. Bu nedenle, algoritma yerel minimum veya maksimuma takılmaya eğilimlidir. Bunun yerine TBO algoritması, tavlama işlemi için "soğutma prosedürü" ve "Metropolis kriteri" gibi iki yinelemeli döngüyü birleştirerek bu soruna etkili bir çözüm önerir. Metropolis kriterinin arkasındaki temel fikir, yerel uç noktalara takılmaktan kaçınmak için aday çözümün komşuluğunda ekstra arama yapmak için algoritmanın rastgele ilerlemesidir.

$f(x_i)$ bir minimizasyon probleminin amaç fonksiyonu olarak tanımlansın. $n \in R$ olmak üzere optimizasyon probleminin çözüm kümesi Eş. 5.1'de verildiği gibidir.

$$x_i = (x_1, x_2, \dots, x_n) \tag{5.1}$$

$f(x_{i+1}) < f(x_i)$ koşulu sağlandığı durumda x_{i+1} yeni aday çözüm olarak belirlenir. Aksi halde, T_c mevcut sıcaklığı temsil etmek üzere Eş. 5.2'de verilen kriter hesaplanır.

$$\varphi = exp[-\{f(x_{i+1}) - f(x_i)\}/T_c)] \quad (5.2)$$

θ; tekdüze dağılımdan $(0,1)$ aralığında üretilen rastgele bir sayı olmak üzere $\varphi > \theta$ ise yine x_{i+1} yeni çözüm adayı olarak kabul edilir. $\varphi < \theta$ olduğu durumda ise yeni bir θ üretilir.

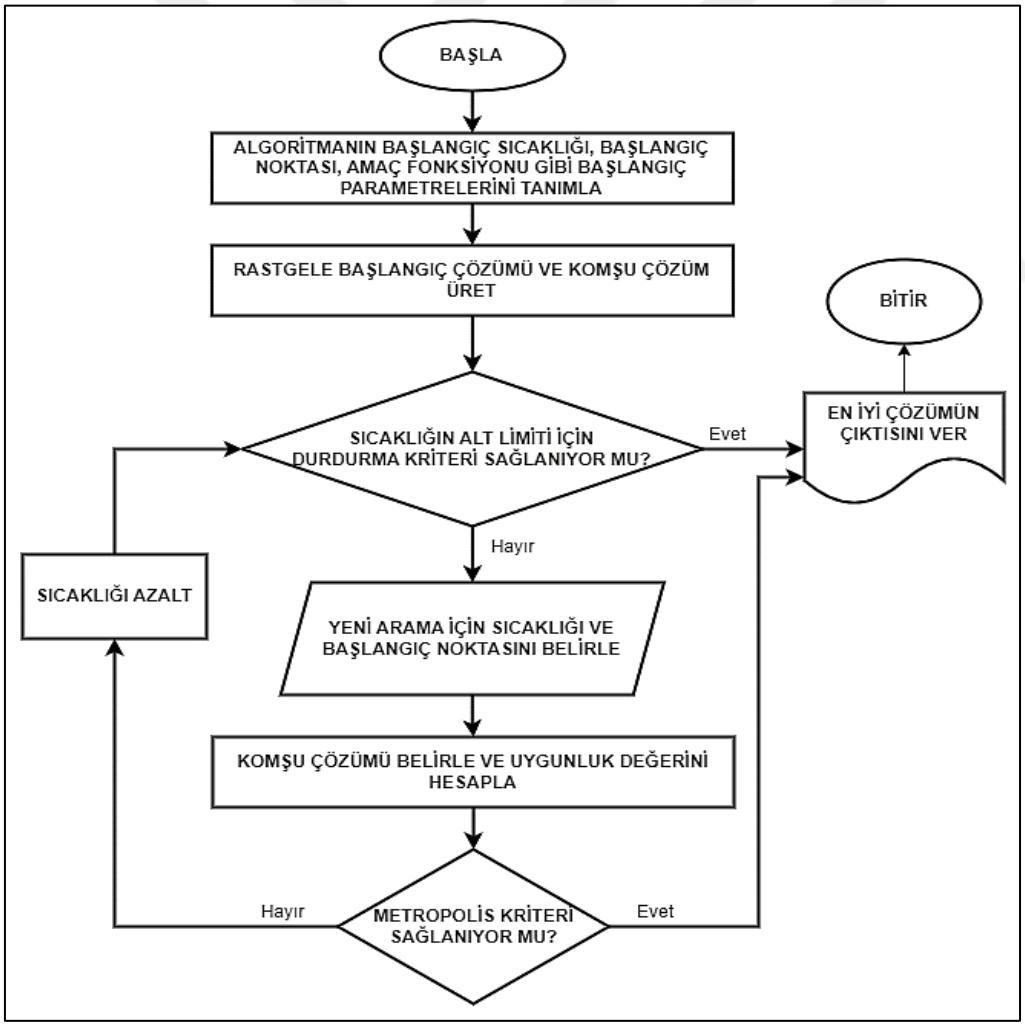
Metropolis algoritması sabit bir sıcaklık için çözüm önermektedir. Bu sayede algoritma, daha büyük T_c değerleri için daha geniş arama alanı gerektirdiğinden algoritmanın küresel minimuma ulaşma olasılığını yükseltir. Bunun yanı sıra, algoritmanın yinelemeli hareketi rastgele başlatıldığından, global minimumları atlamasına veya uç noktalar için hassas olmayan bir yaklaşım benimsemesine neden olabilir. Aksine, daha küçük T_c değerleri için daha küçük arama alanı gerektirir ve bu durum yerel minimumlara hapsolmaya neden olabilir. Bu problemi ortadan kaldıran TBO, sıcaklık parametresini ve çözüm noktasını değiştirmek için iç içe döngüler içeren yinelemeli bir çözüm sunar. TBO algoritmasının hareketi, iç döngüdeki hareketinde daha büyük bir sıcaklık değeri ile başlar ve hemen, mevcut iç döngüdeki en iyi amaç fonksiyonuna götüren nokta, yeni aday çözümü olarak atanır. Ardından, sıcaklığın artırılması ve başlangıç noktasının güncellenmesi ile dış döngü çalıştırılır. Bu iteratif süreç, sıcaklığın en düşük sınırına ulaşana veya önceden belirlenmiş sayıda yinelemeyi gerçekleştirene kadar devam eder. Burada kritik nokta, dış döngüdeki sıcaklık değiştirme adımlarını ve iç döngüdeki rastgele adım boyutlarının seçiminin kritik olmasıdır. T_c çok büyük seçilirse $\varphi > \theta$ şartı herhangi bir yinelemede sağlanır ve sonuç olarak algoritma büyük olasılıkla optimize edilecek fonksiyon alanında rastgele bir minimumda sonlandırılır. Ayrıca, T_c çok küçük seçilirse, $\varphi > \theta$ şartı asla sağlanmaz ve hareket ilk minimumda sona erer. Bununla birlikte, sıcaklık değişimi derecesinin seçilmesi, çözümün kalitesi üzerinde çok önemli bir etkiye sahiptir. Bu dezavantajları önlemek için TBO algoritması, sıcaklık değeri büyük olan optimizasyon problemini ele alır ve amaç fonksiyonu alanında çok sayıda noktayı dolaşır. Sonraki adımlar için sıcaklığı kademeli olarak düşürür ve önceki iç döngüdeki yerel minimum noktayı benimseyerek arama alanını daraltır. Bu sayede hem yerel minimum noktaları arama uzayından çıkarır hem de global minimum noktalara duyarlı bir şekilde yakınsar. Sonuç olarak, yerel uç noktalardan kaçınmak için aramaya pratik rastgelelik sağladığı için TBO'nun diğer sezgisel yaklaşımlar arasında çok tercih edilen bir teknik olduğu söylenebilir (Erdinç, 2017: 49).

TBO'da soğutma işlemi yapılırken literatürde önerilen sıcaklık azaltma fonksiyonlarından yararlanılır. α soğutma oranını temsil eden 1'e çok yakın bir sabit sayı olmak üzere en sık tercih edilen sıcaklık azaltma fonksiyonu Eş. 5.3'te verilmiştir.

$$T_i = T_{i-1}\alpha \tag{5.3}$$

TBO algoritmasının durdurma kriteri için kullanılan en yaygın yöntemler: Maksimum iterasyon sayısına ulaşılması, belirli bir deneme sayısı için kabul edilen çözüm sayısına ulaşılması, önceden belirlenmiş sıcaklık değerine ulaşılmasıdır (Şahin, 2004).

TBO algoritmasının akış diyagramı Şekil 5.1'deki gibidir:



Şekil 5.1. Tavlama benzetimi optimizasyonu akış şeması

5.1. Tavlama Benzetimi Optimizasyonu ile Ridge Regresyonda Yanlılık Parametresinin Tahmin Edilmesi

Ridge regresyonda regresyon modelinin etkinliği yanlılık parametresinin seçimiyle doğrudan ilişkilidir. Yanlılık parametresinin çok küçük seçilmesi aşırı uyum problemine neden olurken, çok büyük seçilmesi yan ve varyans dengesini bozarak model parametrelerinin çok küçülmesine neden olur (Qamar ve Algamal, 2020). Sezgisel optimizasyon yöntemleri daha önce literatürde farklı regresyon uygulamalarıyla çalışılmıştır. TBO algoritması ile Ridge regresyonda yanlılık parametresi tahmini için kullanılacak amaç fonksiyonu Eş. 5.4'te verildiği gibidir.

$$min_k MAPE(k) + \emptyset(k),\ k \geq 0 \tag{5.4}$$

Burada $MAPE(k)$ ve $\emptyset(k)$ ifadeleri sırasıyla Eş. 5.5 ve Eş. 5.6'da tanımlanmıştır.

$$MAPE(k) = \frac{1}{n}\sum_{i=1}^{n}\left|\frac{y_i - \hat{y}_i}{y_i}\right| \tag{5.5}$$

$$\emptyset(k) = \begin{cases} 0, & \forall VIF < 10 \\ \sum_{j=1}^{p} VIF_j, & o.w. \end{cases} \qquad j = 1, \dots, p \tag{5.6}$$

Eş. 5.4'te tanımlanan amaç fonksiyonunu TBO algoritmasıyla çözümlenmek istendiğinde algoritmanın adımları sırasıyla aşağıdaki gibidir:

Adım 1

Algoritmanın; T_0 başlangıç sıcaklığı, α soğutma oranı, mutasyon oranı, mutasyon aralığı, durdurma kriteri gibi parametreleri belirlenir.

Adım 2

Rastgele başlangıç çözümü ve komşu çözüm üretilir.

Adım 3

Parçacıkların Eş. 5.4'te verilen uygunluk değeri hesaplanır.

Adım 4

i. Komşu çözüm, ilk çözüm değerinden küçükse en iyi çözüm olarak kabul edilir.
ii. Komşu çözüm, ilk çözüm değerinden büyükse $(0,1)$ aralığından rastgele bir θ belirlenir ve bu komşu çözüm ancak $\theta < e^{-\Delta f(x)/T}$ eşitliği sağlandığı sürece en iyi çözüm olarak kabul edilir.

Adım 5

T sıcaklığı Eş. 5.3'te verilen sıcaklık azaltma fonksiyonu yardımıyla azaltılır.

Adım 6

Maksimum iterasyon sayısına ulaşılana kadar *Adım 3-5* tekrarlanır.

Adım 7

Optimum k değeri çıktı olarak verilir ve algoritma sonlandırılır.

5.2. Tavlama Benzetimi Optimizasyonu ile Liu Regresyonda Yanlılık Parametresinin Tahmin Edilmesi

TBO algoritması ile Liu regresyonda yanlılık parametresi tahmini için kullanılacak amaç fonksiyonu Eş. 5.7'de verildiği gibidir.

$$min_d MAPE(d) + \emptyset(d),\ 0 \leq d \leq 1 \tag{5.7}$$

Burada $MAPE(d)$ ve $\emptyset(d)$ ifadeleri sırasıyla Eş. 5.8 ve Eş.5.9'da tanımlanmıştır.

$$MAPE(d) = \frac{1}{n}\sum_{i=1}^{n}\left|\frac{y_i - \hat{y}_i}{y_i}\right| \tag{5.8}$$

$$\emptyset(d) = \begin{cases} 0, & \forall VIF < 10 \\ \sum_{j=1}^{p} VIF_j, & o.w. \end{cases} \qquad j = 1, \dots, p \tag{5.9}$$

Eş. 5.7'de tanımlanan amaç fonksiyonunu TBO algoritmasıyla çözümlenmek istendiğinde algoritmanın adımları sırasıyla aşağıdaki gibidir:

Adım 1

Algoritmanın; T_0 başlangıç sıcaklığı, α soğutma oranı, mutasyon oranı, mutasyon aralığı, durdurma kriteri gibi parametreleri belirlenir.

Adım 2

Rastgele başlangıç çözümü ve komşu çözüm üretilir.

Adım 3

Parçacıkların Eş. 5.7'de verilen uygunluk değeri hesaplanır.

Adım 4

i. Komşu çözüm, ilk çözüm değerinden küçükse en iyi çözüm olarak kabul edilir.
ii. Komşu çözüm, ilk çözüm değerinden büyükse $(0-1)$ aralığında rastgele bir θ belirlenir ve bu komşu çözüm ancak $\theta < e^{-\Delta f(x)/T}$ eşitliği sağladığı sürece en iyi çözüm olarak kabul edilir.

Adım 5

T sıcaklığı Eş. 5.3'te verilen sıcaklık azaltma fonksiyonu yardımıyla azaltılır.

Adım 6

Maksimum iterasyon sayısına ulaşılana kadar *Adım 3-5* tekrarlanır.

Adım 7

Optimum d değeri çıktı olarak verilir ve algoritma sonlandırılır.

6. SİMÜLASYON ÇALIŞMASI

Bu bölümde Ridge ve Liu regresyonda TBO'ya dayalı önerilen yeni bir algoritma ile elde edilen yanlılık parametrelerinin performansları PSO ve klasik yöntemlerle elde edilen diğer yanlılık parametreleri ile HKO kriteri açısından karşılaştırılmıştır. Açıklayıcı değişkenlerin üretiminde farklı derecelerde çoklu bağlantı elde etmek için Gibbons (1981) tarafından önerilen ve sıklıkla tercih edilen Eş. 6.1'de verilen denklem kullanılmıştır.

$$X_{ij} = (1-\rho^2)^{1/2} z_{ij} + \rho z_{ij} \qquad i = 1,2,\dots,n \quad j = 1,2,\dots,p \tag{6.1}$$

Burada ρ, herhangi iki açıklayıcı değişken arasındaki korelasyon katsayısını, z_{ij} standart normal dağılım ile elde edilen değerleri, p ise açıklayıcı değişken sayısını ifade etmektedir. Bağımlı değişken Y, Eş. 6.2'de verilen denklem ile elde edilmiştir.

$$Y_i = \beta_0 + \beta_1 X_{j1} + \beta_2 X_{j2} + \cdots + \beta_p X_{jp} + \varepsilon_j, \qquad j = 1,2,\dots,n \tag{6.2}$$

Bu ifadede ε_j ortalaması 0, varyansı σ^2 olan normal dağılım ile elde edilen hata terimini ifade etmektedir. Simülasyonda farklı parametre seçim senaryoları, tahmin yöntemlerinin performanslarını etkileyebilmektedir. Bu çalışmada, simülasyon için farklı örnek çapları $(n = 10; 20; 50; 100)$, farklı açıklayıcı değişken sayıları $(p = 2, 4)$, farklı hataların standart sapma değerleri $(\sigma = 0{,}01;\ 0{,}05;\ 1;\ 4)$ ve farklı derecelerde bağlılık yapıları $(\rho = 0{,}70;\ 0{,}80;\ 0{,}90)$ kullanılarak toplamda 96 farklı senaryo ile gerçekleştirilmiştir. Deney $N = 1000$ defa tekrarlanmıştır. Ridge regresyon için simülasyon sonuçları Çizelge 6.1 - Çizelge 6.6'da verilen tablolarda; Liu regresyon için simülasyon sonuçları ise Çizelge 6.7 - Çizelge 6.12'de verilen tablolarda listelenmiştir.

Çizelge 6.1. Ridge tahmin edicilerinin $p = 2, \rho = 0{,}70, \sigma = 0{,}01; 0{,}5; 1; 5$ senaryosu için HKO değerleri

	$n = 10$				$n = 20$				$n = 50$				$n = 100$			
	0,01	0,5	1	5	0,01	0,5	1	5	0,01	0,5	1	5	0,01	0,5	1	5
EKK	0,8861	0,9806	0,8130	12,354	0,8867	0,8673	0,6602	8,5981	0,8896	0,9071	0,8870	1,0437	0,8889	0,9251	0,8838	1,3967
$\hat{k}_1$	0,8861	0,9762	0,8047	1,0297	0,8867	0,8669	0,6596	7,6410	0,8896	0,9064	0,8859	0,9971	0,8890	0,9250	0,8835	1,3608
$\hat{k}_2$	0,8861	0,9797	0,8111	8,1989	0,8867	0,8672	0,6601	8,3654	0,8896	0,9071	0,8870	1,0415	0,8890	0,9251	0,8837	1,3959
$\hat{k}_3$	0,8858	0,7972	0,6076	0,0659	0,8861	0,8122	0,6253	2,3916	0,8882	0,7627	0,7433	0,3662	0,8890	0,8753	0,7951	0,4480
$\hat{k}_4$	0,8861	0,9784	0,8089	7,7196	0,8867	0,8671	0,6599	8,1154	0,8896	0,9068	0,8865	1,0228	0,8875	0,9251	0,8836	1,3816
$\hat{k}_5$	0,8860	0,8940	0,6115	1,0296	0,8867	0,8348	0,5235	1,4971	0,8896	0,8909	0,4498	0,3871	0,8890	0,9174	0,8565	0,9044
$\hat{k}_6$	0,5327	0,1913	0,0070	1,0296	0,8850	0,0700	0,1735	0,0452	0,8891	0,6054	0,2125	0,0951	0,8890	0,4457	0,0974	0,0066
$\hat{k}_7$	0,5327	0,1913	0,0070	1,0296	0,8850	0,0700	0,1735	0,0452	0,8891	0,6054	0,2125	0,0951	0,8888	0,4457	0,0974	0,0066
$\hat{k}_8$	0,8861	0,9784	0,8088	1,0473	0,8867	0,8671	0,6599	8,0987	0,8896	0,9067	0,8865	1,0199	0,8888	0,9251	0,8836	1,3785
$\hat{k}_9$	0,8877	1,6885	0,7891	0,2953	0,8867	0,8657	0,6557	5,0821	0,8896	0,9054	0,8830	0,8828	0,8890	0,9247	0,8824	1,2795
$\hat{k}_{10}$	0,8861	0,9784	0,8088	2,7304	0,8867	0,8671	0,6599	8,0990	0,8896	0,9067	0,8865	1,0199	0,8890	0,9251	0,8836	1,3785
$\hat{k}_{11}$	0,8855	0,9636	0,7963	1,0184	0,8851	0,8654	0,6586	7,5831	0,8894	0,9059	0,8857	0,9967	0,8890	0,9249	0,8834	1,3606
$\hat{k}_{12}$	0,8855	0,9679	0,8044	1,0473	0,8851	0,8658	0,6592	8,0987	0,8894	0,9066	0,8865	1,0199	0,8889	0,9250	0,8836	1,3785
$\hat{k}_{13}$	0,8858	0,9731	0,8066	2,7412	0,8859	0,8664	0,6596	8,3100	0,8895	0,9067	0,8866	1,0314	0,8889	0,9250	0,8837	1,3875
$\hat{k}_{14}$	0,8858	0,9731	0,8066	2,7412	0,8859	0,8664	0,6596	8,3100	0,8895	0,9067	0,8866	1,0314	0,8889	0,9250	0,8837	1,3875
$\hat{k}_{15}$	0,8855	0,9670	0,8026	8,0125	0,8851	0,8657	0,6591	8,2994	0,8894	0,9066	0,8867	1,0410	0,8889	0,9250	0,8837	1,3957
$\hat{k}_{16}$	0,8861	0,9804	0,8128	9,0408	0,8867	0,8673	0,6602	8,5893	0,8896	0,9071	0,8870	1,0435	0,8889	0,9251	0,8838	1,3966
$\hat{k}_{17}$	0,8861	0,9135	0,6257	0,2215	0,8866	0,8501	0,4853	0,1750	0,8896	0,9045	0,8734	0,6349	0,8890	0,9240	0,8784	1,2280
$\hat{k}_{18}$	0,8861	0,9693	0,7893	6,8209	0,8867	0,8658	0,6534	7,8826	0,8896	0,9067	0,8747	1,0204	0,8890	0,9250	0,8836	1,3901
$\hat{k}_{19}$	0,8861	0,9800	0,8122	4,2612	0,8867	0,8672	0,6602	8,5632	0,8896	0,9071	0,8870	1,0430	0,8890	0,9251	0,8837	1,3964
$\hat{k}_{20}$	0,0032	0,0689	0,0320	0,1351	0,0588	0,0982	0,0436	0,0114	0,2087	0,2331	0,2543	0,1091	0,8890	0,2936	0,2516	0,1697
$\hat{k}_{21}$	0,1761	0,1812	0,2662	11,234	0,1852	0,2700	0,3186	3,0030	0,0764	0,5980	0,7305	0,9578	0,2950	0,6937	0,7750	1,3406
$\hat{k}_{22}$	0,7176	0,4387	0,1802	4,6879	0,8704	0,4697	0,0621	0,2889	0,8846	0,7536	0,0089	0,2602	0,0338	0,7904	0,6766	0,7688

Çizelge 6.1. (devam) Ridge tahmin edicilerinin $p = 2, \rho = 0{,}70, \sigma = 0{,}01; 0{,}5; 1; 5$ senaryosu için HKO değerleri

$\hat{k}_{23}$	0,4023	0,7274	0,6812	11,240	0,0136	0,7801	0,6346	7,0744	0,2331	0,8506	0,8818	1,0324	0,8868	0,9050	0,8752	1,3876
$\hat{k}_{24}$	0,8841	0,8549	0,6374	4,7070	0,8857	0,8219	0,5793	3,4641	0,8892	0,8824	0,7690	0,8038	0,3478	0,9144	0,8651	1,2434
$\hat{k}_{25}$	0,1380	0,3930	0,4373	11,239	0,1539	0,4668	0,4464	4,7241	0,0194	0,7274	0,8043	0,9983	0,8888	0,7954	0,8248	1,3674
$\hat{k}_{26}$	0,7967	0,6363	0,3525	4,7069	0,8784	0,6274	0,1874	0,9168	0,8871	0,8236	0,1004	0,4532	0,0067	0,8527	0,7651	0,9936
$\hat{k}_{27}$	0,8861	0,9569	0,7644	12,176	0,8867	0,8623	0,6399	7,4680	0,8896	0,9027	0,8739	1,0145	0,8878	0,9238	0,8801	1,3908
$\hat{k}_{28}$	0,2214	0,0923	0,1059	0,0794	0,2208	0,1305	0,1683	0,1418	0,2162	0,0927	0,1184	0,1260	0,8890	0,1376	0,1489	0,1168
$\hat{k}_{29}$	0,8861	0,9741	0,8053	12,225	0,8867	0,8664	0,6591	8,4882	0,8896	0,9065	0,8865	1,0426	0,2130	0,9250	0,8836	1,3964
$\hat{k}_{30}$	0,2214	0,0051	0,0205	0,1448	0,2208	0,0078	0,0566	0,0292	0,2161	0,0833	0,2668	0,2104	0,8890	0,0968	0,2650	0,2119
$\hat{k}_{31}$	0,8861	0,9678	0,7875	12,218	0,8867	0,8647	0,6497	7,9996	0,8896	0,9048	0,8804	1,0289	0,2127	0,9244	0,8819	1,3938
$\hat{k}_{32}$	0,2214	0,0367	0,0467	0,1297	0,2208	0,0750	0,1269	0,0912	0,2161	0,0337	0,0575	0,0668	0,8890	0,0812	0,0974	0,0558
$\hat{k}_{33}$	0,8861	0,9805	0,8129	11,703	0,8867	0,8673	0,6602	8,5975	0,8896	0,9071	0,8870	1,0437	0,2127	0,9251	0,8838	1,3967
$\hat{k}_{34}$	0,8861	0,9806	0,8130	12,245	0,8867	0,8673	0,6602	8,5981	0,8896	0,9071	0,8870	1,0437	0,8890	0,9251	0,8838	1,3967
$\hat{k}_{35}$	0,8861	0,9788	0,8100	3,2003	0,8867	0,8672	0,6600	8,3370	0,8896	0,9069	0,8868	1,0343	0,8890	0,9251	0,8837	1,3907
$\hat{k}_{36}$	0,8861	0,9795	0,8112	5,4534	0,8867	0,8672	0,6601	8,4369	0,8896	0,9070	0,8870	1,0403	0,8890	0,9251	0,8837	1,3950
$\hat{k}_{37}$	0,8861	0,9784	0,8094	2,3353	0,8867	0,8671	0,6600	8,3339	0,8896	0,9069	0,8868	1,0354	0,8890	0,9251	0,8837	1,3918
$\hat{k}_{38}$	0,8279	0,7287	0,5330	7,0464	0,8616	0,7409	0,4886	2,9992	0,8819	0,8509	0,6840	0,8244	0,8890	0,8922	0,8435	1,2619
$\hat{k}_{39}$	0,8861	0,9762	0,8047	1,0297	0,8867	0,8669	0,6596	7,6410	0,8896	0,9064	0,8859	0,9971	0,8850	0,9250	0,8835	1,3608
$\hat{k}_{40}$	0,8859	0,9715	0,8077	11,292	0,8862	0,8662	0,6599	8,5553	0,8892	0,9056	0,8865	1,0427	0,8890	0,9249	0,8836	1,3959
$\hat{k}_{41}$	0,8861	0,9780	0,8082	8,3734	0,8867	0,8671	0,6599	8,3608	0,8896	0,9068	0,8865	1,0242	0,8887	0,9251	0,8836	1,3828
$\hat{k}_{42}$	0,8861	0,9757	0,8045	1,0282	0,8867	0,8668	0,6596	7,6404	0,8896	0,9064	0,8859	0,9971	0,8890	0,9250	0,8835	1,3608
$\hat{k}_{43}$	0,8860	0,9717	0,8027	1,0206	0,8864	0,8664	0,6595	7,6364	0,8894	0,9057	0,8856	0,9968	0,8890	0,9249	0,8834	1,3604
$\hat{k}_{44}$	0,8855	0,9654	0,7997	8,1814	0,8851	0,8656	0,6589	8,2948	0,8894	0,9063	0,8862	1,0237	0,8888	0,9250	0,8836	1,3826
$\hat{k}_{45}$	0,6756	0,6831	0,4983	8,0911	0,8833	0,7261	0,5414	2,6318	0,8886	0,8484	0,8340	0,8979	0,8889	0,8923	0,8462	1,3125
$\hat{k}_{46}$	0,7726	0,8136	0,6255	9,9048	0,8850	0,7916	0,5933	4,4051	0,8891	0,8770	0,8600	0,9653	0,8886	0,9084	0,8644	1,3533
$\hat{k}_{47}$	0,7726	0,8128	0,6243	8,8610	0,8850	0,7915	0,5932	4,3409	0,8891	0,8768	0,8598	0,9599	0,8888	0,9084	0,8644	1,3491
$\hat{k}_{48}$	0,6263	0,6591	0,4562	1,0013	0,6935	0,7470	0,5461	1,3721	0,8603	0,8847	0,8721	0,9018	0,8888	0,9119	0,8643	1,2374

Çizelge 6.1. (devam) Ridge tahmin edicilerinin $p = 2, \rho = 0{,}70, \sigma = 0{,}01; 0{,}5; 1; 5$ senaryosu için HKO değerleri

$\hat{k}_{49}$	0,8860	0,7851	0,4486	4,5628	0,8866	0,7795	0,4667	0,0384	0,8895	0,7646	0,5755	0,1932	0,8799	0,8344	0,6121	0,5696
$\hat{k}_{50}$	0,8860	0,4382	0,0931	0,2103	0,8866	0,6099	0,2213	0,1245	0,8894	0,4473	0,1196	0,1549	0,8889	0,6559	0,2167	0,1518
$\hat{k}_{51}$	0,8851	0,9803	0,8129	12,354	0,8807	0,8673	0,6602	8,5981	0,8876	0,9071	0,8870	1,0437	0,8888	0,9251	0,8838	1,3967
$\hat{k}_{52}$	0,8858	0,9623	0,0971	0,0747	0,8853	0,5765	0,0263	0,1608	0,8887	0,8053	0,4207	0,0795	0,8880	0,8114	0,4526	0,0071
$\hat{k}_{53}$	0,8861	0,9777	0,8075	1,0385	0,8867	0,8670	0,6598	7,9418	0,8896	0,9066	0,8863	1,0122	0,8884	0,9250	0,8836	1,3725
$\hat{k}_{54}$	0,8861	0,9775	0,8071	1,0385	0,8867	0,8670	0,6598	7,9044	0,8896	0,9066	0,8862	1,0103	0,8890	0,9250	0,8836	1,3711
$\hat{k}_{55}$	0,7811	0,8290	0,6013	2,1526	0,7819	0,8193	0,6113	4,2129	0,8808	0,9009	0,8830	0,9654	0,8890	0,9215	0,8782	1,3112
$\hat{k}_{56}$	0,8860	0,9596	0,7863	8,3974	0,8866	0,8636	0,6562	7,3170	0,8895	0,9035	0,8832	1,0091	0,8865	0,9243	0,8825	1,3724
$\hat{k}_{57}$	0,5810	24,164	7,3429	0,0938	4,0800	828,96	3,2024	2,1386	3,3879	3,7247	2,5389	0,8486	0,8889	2,3029	2,1236	1,0735
$\hat{k}_{58}$	0,8861	0,9806	0,8130	12,354	0,8867	0,8673	0,6602	8,5981	0,8896	0,9071	0,8870	1,0437	75,413	0,9251	0,8838	1,3967
$\hat{k}_{59}$	0,8855	0,9679	0,8044	12,021	0,8851	0,8658	0,6592	8,5293	0,8894	0,9066	0,8868	1,0433	0,8890	0,9250	0,8837	1,3966
$\hat{k}_{60}$	0,1761	0,1657	0,2329	7,6423	0,1852	0,2596	0,2814	1,3236	0,0764	0,5838	0,6992	0,8152	0,8889	0,6857	0,7597	1,2271
$\hat{k}_{61}$	0,7176	0,4568	0,2120	10,038	0,8704	0,4792	0,0874	1,0591	0,8846	0,7615	0,0238	0,5821	0,0338	0,7953	0,7000	1,1280
$\hat{k}_{62}$	0,4023	0,7245	0,6689	1,3630	0,0136	0,7795	0,6290	2,9436	0,2331	0,8499	0,8805	0,8978	0,8868	0,9048	0,8736	1,2719
$\hat{k}_{63}$	0,8051	0,6595	0,4748	9,5599	0,8520	0,6997	0,4520	3,1266	0,8788	0,8321	0,6380	0,8617	0,3478	0,8802	0,8321	1,2906
$\hat{k}_{64}$	0,1380	0,3745	0,4059	7,6592	0,1539	0,4571	0,4181	2,7523	0,0194	0,7180	0,7866	0,9138	0,8834	0,7905	0,8159	1,3045
$\hat{k}_{65}$	0,8861	0,9800	0,8121	6,4144	0,8867	0,8672	0,6602	8,5591	0,8896	0,9071	0,8870	1,0429	0,0067	0,9251	0,8837	1,3964
$\hat{k}_{66}$	0,8861	0,9795	0,8112	4,7123	0,8867	0,8672	0,6601	8,4645	0,8896	0,9070	0,8869	1,0396	0,8890	0,9251	0,8837	1,3943
$\hat{k}_{67}$	0,8861	0,9781	0,8084	2,2921	0,8867	0,8671	0,6599	8,1243	0,8896	0,9068	0,8866	1,0265	0,8890	0,9251	0,8837	1,3854
$\hat{k}_{68}$	0,8857	0,4046	0,0299	0,1611	0,8862	0,5564	0,0282	0,1609	0,8895	0,8284	0,5137	0,0390	0,8890	0,8659	0,6404	0,0347
$\hat{k}_{69}$	0,8852	0,8287	0,5902	3,2878	0,8850	0,8210	0,5378	1,2736	0,8893	0,8931	0,8608	0,8217	0,8889	0,9194	0,8722	1,2832
$\hat{k}_{70}$	0,8635	0,7889	0,5471	7,9955	0,8844	0,7834	0,4495	3,8714	0,8891	0,8881	0,5597	0,8637	0,8889	0,9149	0,8679	1,3272
$\hat{k}_{71}$	0,8861	0,9796	0,8113	3,0075	0,8867	0,8672	0,6601	8,4690	0,8896	0,9070	0,8869	1,0398	0,8888	0,9251	0,8837	1,3945
$\hat{k}_{72}$	0,8861	0,9666	0,7960	6,1816	0,8866	0,8653	0,6582	7,9083	0,8896	0,9055	0,8854	1,0287	0,8890	0,9248	0,8833	1,3873
$\hat{k}_{73}$	0,8861	0,9787	0,8097	2,9744	0,8867	0,8672	0,6600	8,3429	0,8896	0,9070	0,8868	1,0360	0,8889	0,9251	0,8837	1,3922
$\hat{k}_{74}$	0,8861	0,9609	0,7891	6,1628	0,8866	0,8645	0,6573	7,6463	0,8896	0,9048	0,8847	1,0226	0,8890	0,9247	0,8832	1,3834
$\hat{k}_{75}$	0,8860	0,9414	0,7216	2,9742	0,8867	0,8581	0,6163	4,8270	0,8896	0,9039	0,7805	0,8368	0,8889	0,9241	0,8807	1,3113
$\hat{k}_{76}$	0,8851	0,8949	0,6945	6,1627	0,8862	0,8430	0,6152	5,2116	0,8894	0,8961	0,8344	0,9327	0,8890	0,9213	0,8775	1,3390
$\hat{k}_{77}$	0,7853	0,4567	0,0580	2,9741	0,8862	0,4073	0,0832	0,0575	0,8895	0,8339	0,1729	0,0193	0,8889	0,8340	0,6479	0,5682
$\hat{k}_{PSO}$	0,0001	0,0011	0,1311	4,3861	0,0000	0,0013	0,0159	3,5312	0,0000	0,0002	0,0137	0,1500	0,0001	0,0023	0,0000	0,0988
$\hat{k}_{TBO}$	0,0001	0,0012	0,1308	4,3928	0,0000	0,0013	0,0159	3,5631	0,0000	0,0002	0,0137	0,1511	0,0001	0,0023	0,0000	0,0989

Çizelge 6.2. Ridge tahmin edicilerinin $p = 2, \rho = 0{,}80, \sigma = 0{,}01; 0{,}5; 1; 5$ senaryosu için HKO değerleri

	$n = 10$				$n = 20$				$n = 50$				$n = 100$			
	0,01	0,5	1	5	0,01	0,5	1	5	0,01	0,5	1	5	0,01	0,5	1	5
EKK	0,8874	1,1231	1,0879	2,6310	0,8844	0,9417	0,8710	19,151	0,8861	0,9038	1,2197	5,0564	0,8895	0,8861	0,7944	1,5954
$\hat{k}_1$	0,8874	1,1231	1,0827	0,8825	0,8844	0,9386	0,8699	15,359	0,8861	0,9036	1,2190	4,9885	0,8895	0,8861	0,7943	1,5646
$\hat{k}_2$	0,8874	1,1231	1,0851	1,2453	0,8844	0,9413	0,8708	18,487	0,8861	0,9037	1,2196	5,0506	0,8895	0,8861	0,7944	1,5940
$\hat{k}_3$	0,8811	1,1184	0,9575	0,1491	0,8837	0,7611	0,7727	3,3756	0,8852	0,8642	1,0768	2,7447	0,8891	0,8669	0,7622	0,6668
$\hat{k}_4$	0,8874	1,1231	1,0853	1,5271	0,8844	0,9402	0,8705	17,376	0,8861	0,9037	1,2193	5,0228	0,8895	0,8861	0,7943	1,5804
$\hat{k}_5$	0,8874	1,0541	0,8947	0,0778	0,8844	0,8787	0,7958	8,8500	0,8861	0,8860	1,1526	2,6625	0,8895	0,8750	0,6755	0,5401
$\hat{k}_6$	0,8870	0,1838	0,0108	0,2158	0,8823	0,2545	0,0457	2,2830	0,8850	0,1356	0,1724	0,0031	0,8882	0,0334	0,2065	0,1069
$\hat{k}_7$	0,8870	0,1838	0,0108	0,2158	0,8823	0,2545	0,0457	2,2830	0,8850	0,1356	0,1724	0,0031	0,8882	0,0334	0,2065	0,1069
$\hat{k}_8$	0,8874	1,1231	1,0853	1,4227	0,8844	0,9402	0,8705	17,067	0,8861	0,9037	1,2193	5,0223	0,8895	0,8861	0,7943	1,5799
$\hat{k}_9$	0,8874	1,1222	1,0680	0,1358	0,8844	0,9348	0,8651	10,121	0,8861	0,9030	1,2145	4,4572	0,8895	0,8859	0,7937	1,3860
$\hat{k}_{10}$	0,8874	1,1231	1,0853	1,4228	0,8844	0,9402	0,8705	17,097	0,8861	0,9037	1,2193	5,0223	0,8895	0,8861	0,7943	1,5799
$\hat{k}_{11}$	0,8704	1,1187	1,0382	0,8564	0,8822	0,9329	0,8680	15,229	0,8858	0,9033	1,2185	4,9839	0,8895	0,8860	0,7943	1,5642
$\hat{k}_{12}$	0,8704	1,1188	1,0430	1,4227	0,8822	0,9359	0,8690	17,067	0,8858	0,9034	1,2192	5,0223	0,8895	0,8860	0,7943	1,5799
$\hat{k}_{13}$	0,8788	1,1209	1,0637	1,8525	0,8833	0,9380	0,8697	17,980	0,8859	0,9036	1,2193	5,0370	0,8895	0,8861	0,7943	1,5874
$\hat{k}_{14}$	0,8788	1,1209	1,0637	1,8525	0,8833	0,9380	0,8697	17,980	0,8859	0,9036	1,2193	5,0370	0,8895	0,8861	0,7943	1,5874
$\hat{k}_{15}$	0,8704	1,1187	1,0405	1,2024	0,8822	0,9355	0,8689	18,315	0,8858	0,9034	1,2191	5,0459	0,8895	0,8860	0,7943	1,5936
$\hat{k}_{16}$	0,8874	1,1231	1,0877	2,5597	0,8844	0,9416	0,8710	19,083	0,8861	0,9038	1,2197	5,0562	0,8895	0,8861	0,7944	1,5954
$\hat{k}_{17}$	0,8874	0,4493	0,5934	0,1432	0,8844	0,9144	0,7611	1,2334	0,8861	0,8949	1,1326	0,6059	0,8895	0,8822	0,7876	0,5660
$\hat{k}_{18}$	0,8874	1,1182	1,0461	0,2118	0,8844	0,9360	0,8683	18,105	0,8861	0,9034	1,2188	5,0041	0,8895	0,8860	0,7934	1,5778
$\hat{k}_{19}$	0,8874	1,1231	1,0869	2,3620	0,8844	0,9414	0,8710	18,881	0,8861	0,9038	1,2197	5,0556	0,8895	0,8861	0,7944	1,5952
$\hat{k}_{20}$	0,0610	0,0193	0,0394	0,0346	0,0616	0,1583	0,0402	0,1204	0,1656	0,1657	0,1028	0,0494	0,2275	0,2312	0,2386	0,0580
$\hat{k}_{21}$	0,1802	0,0152	0,0302	0,7361	0,1861	0,2979	0,2979	12,053	0,1200	0,4553	0,6550	2,8900	0,0684	0,5960	0,6770	1,3019
$\hat{k}_{22}$	0,8735	0,0492	0,1739	0,0984	0,8642	0,5167	0,3840	6,1162	0,8776	0,6175	0,6971	0,9177	0,8841	0,6430	0,1001	0,2301
$\hat{k}_{23}$	0,0824	0,9887	0,6370	2,1968	0,0160	0,7752	0,7486	16,049	0,1748	0,8577	1,1362	4,7540	0,4979	0,8705	0,7919	1,5695

Çizelge 6.2. (devam) Ridge tahmin edicilerinin $p = 2, \rho = 0{,}80, \sigma = 0{,}01; 0{,}5; 1; 5$ senaryosu için HKO değerleri

$\hat{k}_{24}$	0,8843	1,0366	0,8255	0,0743	0,8832	0,8538	0,7822	11,800	0,8856	0,8792	1,1475	3,7013	0,8893	0,8737	0,7606	1,1523
$\hat{k}_{25}$	0,1484	0,0685	0,1517	1,2597	0,1555	0,5071	0,4513	14,561	0,0606	0,6235	0,8306	3,7011	0,0134	0,7179	0,7330	1,4348
$\hat{k}_{26}$	0,8801	0,2098	0,3847	0,0538	0,8741	0,6847	0,5283	9,3041	0,8818	0,7363	0,8673	1,5697	0,8868	0,7475	0,2718	0,4185
$\hat{k}_{27}$	0,8874	1,1146	0,9853	0,3000	0,8844	0,9188	0,8533	18,867	0,8861	0,9003	1,2019	4,8841	0,8895	0,8846	0,7909	1,5443
$\hat{k}_{28}$	0,2211	0,2020	0,1297	0,1412	0,2205	0,0860	0,1521	0,1225	0,2162	0,1497	0,1653	0,1782	0,2128	0,1695	0,1639	0,1675
$\hat{k}_{29}$	0,8874	1,1223	1,0662	2,1756	0,8844	0,9372	0,8694	19,067	0,8861	0,9035	1,2190	5,0510	0,8895	0,8860	0,7943	1,5943
$\hat{k}_{30}$	0,2211	0,0689	0,0112	0,0817	0,2204	0,0315	0,0153	0,1263	0,2159	0,0281	0,0931	0,1052	0,2120	0,0749	0,2362	0,1205
$\hat{k}_{31}$	0,8874	1,1188	1,0320	0,6865	0,8844	0,9297	0,8619	18,996	0,8861	0,9020	1,2107	4,9689	0,8895	0,8853	0,7927	1,5695
$\hat{k}_{32}$	0,2211	0,1837	0,0754	0,0957	0,2204	0,0299	0,1028	0,0940	0,2159	0,0982	0,1212	0,1416	0,2120	0,1278	0,1193	0,1253
$\hat{k}_{33}$	0,8874	1,1231	1,0878	2,6198	0,8844	0,9417	0,8710	19,143	0,8861	0,9038	1,2197	5,0564	0,8895	0,8861	0,7944	1,5954
$\hat{k}_{34}$	0,8874	1,1231	1,0879	2,6302	0,8844	0,9417	0,8710	19,151	0,8861	0,9038	1,2197	5,0564	0,8895	0,8861	0,7944	1,5954
$\hat{k}_{35}$	0,8874	1,1231	1,0855	1,7031	0,8844	0,9406	0,8707	17,833	0,8861	0,9037	1,2196	5,0438	0,8895	0,8861	0,7944	1,5908
$\hat{k}_{36}$	0,8874	1,1231	1,0860	1,8028	0,8844	0,9411	0,8709	18,414	0,8861	0,9037	1,2196	5,0509	0,8895	0,8861	0,7944	1,5938
$\hat{k}_{37}$	0,8874	1,1231	1,0847	1,5984	0,8844	0,9404	0,8707	17,690	0,8861	0,9037	1,2196	5,0455	0,8895	0,8861	0,7944	1,5919
$\hat{k}_{38}$	0,8458	0,7571	0,5752	0,1036	0,8532	0,7630	0,6700	12,003	0,8743	0,8263	1,0431	3,2153	0,8841	0,8403	0,7087	1,0923
$\hat{k}_{39}$	0,8874	1,1231	1,0827	0,8825	0,8844	0,9386	0,8699	15,359	0,8861	0,9036	1,2190	4,9885	0,8895	0,8861	0,7943	1,5646
$\hat{k}_{40}$	0,8717	1,1230	1,0795	2,5872	0,8838	0,9352	0,8700	19,001	0,8858	0,9035	1,2193	5,0545	0,8894	0,8860	0,7943	1,5949
$\hat{k}_{41}$	0,8874	1,1231	1,0850	1,7271	0,8844	0,9404	0,8705	14,695	0,8861	0,9037	1,2194	5,0294	0,8895	0,8861	0,7943	1,5822
$\hat{k}_{42}$	0,8863	1,1231	1,0819	0,8821	0,8844	0,9384	0,8699	15,356	0,8861	0,9036	1,2190	4,9885	0,8895	0,8861	0,7943	1,5646
$\hat{k}_{43}$	0,8809	1,1230	1,0789	0,8818	0,8841	0,9355	0,8695	15,322	0,8859	0,9035	1,2188	4,9875	0,8895	0,8860	0,7943	1,5644
$\hat{k}_{44}$	0,8704	1,1187	1,0403	1,6582	0,8822	0,9347	0,8685	14,573	0,8858	0,9034	1,2189	5,0247	0,8895	0,8860	0,7943	1,5818
$\hat{k}_{45}$	0,8866	0,7794	0,6685	0,2563	0,8803	0,7967	0,6099	11,822	0,8839	0,8332	1,0020	3,3339	0,8870	0,8537	0,7709	1,2703
$\hat{k}_{46}$	0,8870	0,9200	0,8332	0,6143	0,8823	0,8650	0,7120	14,822	0,8850	0,8668	1,0969	4,0393	0,8883	0,8694	0,7825	1,4166
$\hat{k}_{47}$	0,8870	0,9200	0,8324	0,5856	0,8823	0,8644	0,7118	14,460	0,8850	0,8668	1,0968	4,0295	0,8883	0,8694	0,7825	1,4126
$\hat{k}_{48}$	0,5673	0,2082	0,3307	0,0433	0,6650	0,8223	0,5449	5,3297	0,8198	0,8332	0,8252	1,3449	0,8692	0,8618	0,7895	1,2717
$\hat{k}_{49}$	0,8870	1,0807	0,8569	0,0601	0,8843	0,7622	0,5973	0,6298	0,8860	0,8107	0,7067	0,1146	0,8895	0,8165	0,6206	0,0566

Çizelge 6.2. (devam) Ridge tahmin edicilerinin $p = 2, \rho = 0{,}80, \sigma = 0{,}01; 0{,}5; 1; 5$ senaryosu için HKO değerleri

$\hat{k}_{50}$	0,8868	1,0262	0,5348	0,1992	0,8843	0,4195	0,3265	0,1519	0,8859	0,6512	0,3549	0,0316	0,8894	0,6967	0,3323	0,1265
$\hat{k}_{51}$	0,2407	1,1231	1,0877	2,6310	0,8774	0,9415	0,8710	19,151	0,8851	0,9038	1,2197	5,0564	0,8894	0,8861	0,7944	1,5954
$\hat{k}_{52}$	0,8563	0,0769	0,0896	0,2142	0,8825	0,6726	0,1257	0,1347	0,8853	0,5876	0,1524	0,1639	0,8893	0,5794	0,2852	0,1433
$\hat{k}_{53}$	0,8874	1,1231	1,0844	1,1990	0,8844	0,9397	0,8703	16,461	0,8861	0,9037	1,2192	5,0110	0,8895	0,8861	0,7943	1,5747
$\hat{k}_{54}$	0,8874	1,1231	1,0842	1,1525	0,8844	0,9395	0,8702	16,323	0,8861	0,9037	1,2192	5,0083	0,8895	0,8861	0,7943	1,5735
$\hat{k}_{55}$	0,7233	0,5828	0,5901	0,1022	0,7570	0,9013	0,6348	8,6494	0,8593	0,8768	1,0210	2,6859	0,8828	0,8775	0,7932	1,4981
$\hat{k}_{56}$	0,8867	1,1212	1,0526	1,2463	0,8844	0,9276	0,8630	16,146	0,8860	0,9022	1,2142	4,9011	0,8895	0,8856	0,7937	1,5531
$\hat{k}_{57}$	1267,9	0,3119	2,0817	0,1003	4,3252	5,8432	11,853	1,1981	8,2642	7,1743	19,778	118,24	3,7536	3,5831	2,5271	3,7286
$\hat{k}_{58}$	0,8874	1,1231	1,0879	2,6310	0,8844	0,9417	0,8710	19,151	0,8861	0,9038	1,2197	5,0564	0,8895	0,8861	0,7944	1,5954
$\hat{k}_{59}$	0,8704	1,1188	1,0430	2,5038	0,8822	0,9359	0,8690	18,969	0,8858	0,9034	1,2192	5,0517	0,8895	0,8860	0,7943	1,5950
$\hat{k}_{60}$	0,1802	0,0154	0,0217	0,1256	0,1861	0,2718	0,2812	6,0283	0,1200	0,4418	0,6235	1,7030	0,0684	0,5845	0,6587	0,9154
$\hat{k}_{61}$	0,8735	0,0529	0,2025	0,0305	0,8642	0,5406	0,4000	12,136	0,8776	0,6275	0,7275	1,8420	0,8841	0,6527	0,1342	0,5843
$\hat{k}_{62}$	0,0824	0,9880	0,6271	0,2328	0,0160	0,7721	0,7445	4,7124	0,1748	0,8572	1,1279	3,0740	0,4979	0,8703	0,7915	1,2525
$\hat{k}_{63}$	0,8308	0,6593	0,4838	0,1766	0,8413	0,7124	0,6223	13,256	0,8696	0,8008	0,9981	3,3539	0,8819	0,8247	0,6846	1,1712
$\hat{k}_{64}$	0,1484	0,0641	0,1266	0,3527	0,1555	0,4823	0,4360	9,2105	0,0606	0,6134	0,8026	2,5855	0,0134	0,7105	0,7229	1,1703
$\hat{k}_{65}$	0,8874	1,1231	1,0868	2,3329	0,8844	0,9414	0,8710	18,854	0,8861	0,9038	1,2197	5,0555	0,8895	0,8861	0,7944	1,5952
$\hat{k}_{66}$	0,8874	1,1231	1,0863	2,0211	0,8844	0,9410	0,8709	18,399	0,8861	0,9037	1,2196	5,0510	0,8895	0,8861	0,7944	1,5936
$\hat{k}_{67}$	0,8874	1,1231	1,0844	1,2917	0,8844	0,9401	0,8705	17,086	0,8861	0,9037	1,2194	5,0311	0,8895	0,8861	0,7944	1,5856
$\hat{k}_{68}$	0,8870	0,1000	0,0108	0,2170	0,8836	0,5934	0,1335	0,1494	0,8859	0,6539	0,2896	0,1340	0,8894	0,7080	0,4798	0,0787
$\hat{k}_{69}$	0,8834	0,7539	0,5689	0,0300	0,8819	0,8606	0,7285	5,0142	0,8855	0,8794	1,1074	2,0145	0,8894	0,8757	0,7833	1,0415
$\hat{k}_{70}$	0,8837	0,6063	0,5498	0,0320	0,8813	0,8241	0,7394	14,851	0,8853	0,8654	1,1404	3,8324	0,8892	0,8646	0,6893	1,2393
$\hat{k}_{71}$	0,8874	1,1231	1,0864	2,0358	0,8844	0,9411	0,8709	18,448	0,8861	0,9037	1,2196	5,0512	0,8895	0,8861	0,7944	1,5937
$\hat{k}_{72}$	0,8869	1,1220	1,0612	1,5589	0,8844	0,9331	0,8670	17,211	0,8861	0,9031	1,2176	4,9942	0,8895	0,8859	0,7942	1,5809
$\hat{k}_{73}$	0,8874	1,1231	1,0850	1,6195	0,8844	0,9406	0,8707	17,802	0,8861	0,9037	1,2196	5,0459	0,8895	0,8861	0,7944	1,5920
$\hat{k}_{74}$	0,8867	1,1216	1,0506	1,2968	0,8844	0,9297	0,8654	16,512	0,8860	0,9028	1,2167	4,9688	0,8895	0,8859	0,7941	1,5750
$\hat{k}_{75}$	0,8874	1,0966	0,9704	0,0314	0,8844	0,9181	0,8513	14,462	0,8861	0,9005	1,2090	4,4791	0,8895	0,8847	0,7790	1,3346
$\hat{k}_{76}$	0,8853	1,0680	0,8792	0,1677	0,8838	0,8873	0,8244	14,359	0,8859	0,8931	1,1904	4,4362	0,8894	0,8817	0,7825	1,4195
$\hat{k}_{77}$	0,8872	0,1220	0,0505	0,2058	0,8838	0,5645	0,3333	7,4068	0,8859	0,6009	0,7029	0,4789	0,8893	0,5568	0,1176	0,0284
$\hat{k}_{PSO}$	0,0001	0,0139	0,2248	1,5401	0,0001	0,0035	0,0414	9,3160	0,0001	0,0073	0,1104	1,5520	0,0001	0,0011	0,0346	0,4776
$\hat{k}_{TBO}$	0,0001	0,0138	0,2273	1,5309	0,0001	0,0035	0,0414	9,3825	0,0001	0,0072	0,1106	1,5532	0,0039	0,0011	0,0346	0,4774

Çizelge 6.3. Ridge tahmin edicilerinin $p = 2, \rho = 0{,}90, \sigma = 0{,}01; 0{,}5; 1; 5$ senaryosu için HKO değerleri

	$n = 10$				$n = 20$				$n = 50$				$n = 100$			
	0,01	0,5	1	5	0,01	0,5	1	5	0,01	0,5	1	5	0,01	0,5	1	5
EKK	0,8885	1,3700	1,2820	4,6001	0,8924	0,8075	1,4001	1,6141	0,8872	1,0230	0,8311	2,6682	0,8876	1,0470	0,9401	1,3536
$\hat{k}_1$	0,8885	1,3694	1,2809	2,2676	0,8924	0,8074	1,3997	1,6052	0,8872	1,0229	0,8310	2,6647	0,8876	1,0470	0,9401	1,3525
$\hat{k}_2$	0,8885	1,3692	1,2799	3,0907	0,8924	0,8074	1,3999	1,6121	0,8872	1,0229	0,8310	2,6677	0,8876	1,0470	0,9401	1,3535
$\hat{k}_3$	0,8885	1,3435	1,2475	1,0732	0,8924	0,8020	1,3572	1,4348	0,8870	1,0088	0,8200	2,4909	0,8875	1,0380	0,9230	1,2677
$\hat{k}_4$	0,8885	1,3697	1,2815	3,3170	0,8924	0,8074	1,3999	1,6097	0,8872	1,0229	0,8310	2,6665	0,8876	1,0470	0,9401	1,3530
$\hat{k}_5$	0,8885	1,0503	0,6997	0,7362	0,8924	0,7415	1,1518	0,1011	0,8871	0,9656	0,7582	1,6879	0,8876	1,0333	0,8937	0,7758
$\hat{k}_6$	0,7881	0,1847	0,2103	0,2931	0,7164	0,1939	0,1202	0,2202	0,8752	0,0814	0,1918	0,2056	0,8818	0,0271	0,1089	0,2156
$\hat{k}_7$	0,7881	0,1847	0,2103	0,2931	0,7164	0,1939	0,1202	0,2202	0,8752	0,0814	0,1918	0,2056	0,8818	0,0271	0,1089	0,2156
$\hat{k}_8$	0,8885	1,3697	1,2815	2,9863	0,8924	0,8074	1,3999	1,6097	0,8872	1,0229	0,8310	2,6665	0,8876	1,0470	0,9401	1,3530
$\hat{k}_9$	0,8885	1,3564	1,2507	0,1022	0,8924	0,8068	1,3916	1,5295	0,8872	1,0219	0,8303	2,6007	0,8876	1,0468	0,9393	1,3360
$\hat{k}_{10}$	0,8885	1,3697	1,2815	2,9894	0,8924	0,8074	1,3999	1,6097	0,8872	1,0229	0,8310	2,6665	0,8876	1,0470	0,9401	1,3530
$\hat{k}_{11}$	0,8837	1,3306	1,2039	2,2239	0,8919	0,8059	1,3941	1,6034	0,8869	1,0221	0,8308	2,6640	0,8876	1,0469	0,9400	1,3524
$\hat{k}_{12}$	0,8837	1,3311	1,2047	2,9863	0,8919	0,8060	1,3944	1,6097	0,8869	1,0221	0,8309	2,6665	0,8876	1,0469	0,9400	1,3530
$\hat{k}_{13}$	0,8861	1,3497	1,2411	3,5438	0,8922	0,8067	1,3971	1,6109	0,8870	1,0225	0,8309	2,6669	0,8876	1,0469	0,9401	1,3532
$\hat{k}_{14}$	0,8861	1,3497	1,2411	3,5438	0,8922	0,8067	1,3971	1,6109	0,8870	1,0225	0,8309	2,6669	0,8876	1,0469	0,9401	1,3532
$\hat{k}_{15}$	0,8837	1,3304	1,2031	2,9996	0,8919	0,8059	1,3943	1,6102	0,8869	1,0221	0,8308	2,6670	0,8876	1,0469	0,9400	1,3534
$\hat{k}_{16}$	0,8885	1,3700	1,2820	4,4255	0,8924	0,8075	1,4001	1,6140	0,8872	1,0230	0,8311	2,6682	0,8876	1,0470	0,9401	1,3536
$\hat{k}_{17}$	0,8869	0,0048	0,0879	0,4427	0,8923	0,5708	0,4044	0,0019	0,8871	0,7761	0,7326	0,0547	0,8876	1,0342	0,8595	0,5314
$\hat{k}_{18}$	0,8885	1,3166	1,1310	2,0219	0,8924	0,8040	1,3908	1,4106	0,8872	1,0219	0,8298	2,6351	0,8876	1,0469	0,9397	1,3436
$\hat{k}_{19}$	0,8885	1,3699	1,2819	3,9744	0,8924	0,8075	1,4001	1,6138	0,8872	1,0230	0,8311	2,6682	0,8876	1,0470	0,9401	1,3536
$\hat{k}_{20}$	0,0255	0,0113	0,0318	0,7901	0,0011	0,0138	0,0036	0,0660	0,0769	0,0418	0,0623	0,1565	0,1489	0,1905	0,1350	0,2013
$\hat{k}_{21}$	0,2137	0,0044	0,0187	2,6865	0,2011	0,0311	0,1751	1,2552	0,1747	0,2196	0,3981	2,1473	0,1299	0,5961	0,5968	1,2025
$\hat{k}_{22}$	0,7621	0,0110	0,0238	0,6993	0,7804	0,0195	0,2333	0,0442	0,8623	0,3555	0,1065	0,2074	0,8753	0,6390	0,4124	0,0562
$\hat{k}_{23}$	0,0129	0,9616	0,7228	3,9165	0,2347	0,7519	1,1005	1,6020	0,2406	0,9240	0,8151	2,6439	0,4736	1,0302	0,9224	1,3495

Çizelge 6.3. (devam) Ridge tahmin edicilerinin $p = 2, \rho = 0{,}90, \sigma = 0{,}01; 0{,}5; 1; 5$ senaryosu için HKO değerleri

$\hat{k}_{24}$	0,8856	1,0220	0,7074	1,4920	0,8913	0,7452	1,1352	1,0674	0,8867	0,9536	0,7861	2,3096	0,8874	1,0323	0,9061	1,2076
$\hat{k}_{25}$	0,2055	0,0482	0,0201	3,3202	0,1816	0,1558	0,3933	1,4174	0,1359	0,4247	0,5566	2,3434	0,0713	0,7764	0,7219	1,2678
$\hat{k}_{26}$	0,8094	0,1202	0,0149	0,9815	0,8324	0,1255	0,4567	0,0015	0,8743	0,5466	0,2802	0,6361	0,8813	0,8052	0,5928	0,2516
$\hat{k}_{27}$	0,8885	1,2138	0,9282	3,0006	0,8924	0,7999	1,3201	1,1644	0,8872	1,0071	0,8241	2,3418	0,8876	1,0452	0,9305	1,2290
$\hat{k}_{28}$	0,2212	0,2028	0,2079	0,3817	0,2199	0,1923	0,2028	0,1790	0,2179	0,2007	0,1930	0,2007	0,2142	0,1899	0,1949	0,1955
$\hat{k}_{29}$	0,8885	1,3588	1,2564	4,2588	0,8924	0,8069	1,3973	1,6085	0,8872	1,0225	0,8309	2,6661	0,8876	1,0469	0,9400	1,3530
$\hat{k}_{30}$	0,2212	0,0249	0,0332	0,9926	0,2198	0,0181	0,0032	0,6892	0,2176	0,0065	0,0414	1,0290	0,2129	0,0467	0,1320	0,7593
$\hat{k}_{31}$	0,8885	1,2791	1,0509	3,6035	0,8924	0,8036	1,3579	1,3630	0,8872	1,0148	0,8276	2,4753	0,8876	1,0461	0,9353	1,2840
$\hat{k}_{32}$	0,2212	0,1849	0,1944	0,5164	0,2198	0,1661	0,1849	0,1425	0,2177	0,1811	0,1671	0,1807	0,2130	0,1616	0,1705	0,1715
$\hat{k}_{33}$	0,8885	1,3700	1,2820	4,5490	0,8924	0,8075	1,4001	1,6141	0,8872	1,0230	0,8311	2,6682	0,8876	1,0470	0,9401	1,3536
$\hat{k}_{34}$	0,8885	1,3700	1,2820	4,5927	0,8924	0,8075	1,4001	1,6141	0,8872	1,0230	0,8311	2,6682	0,8876	1,0470	0,9401	1,3536
$\hat{k}_{35}$	0,8885	1,3698	1,2816	3,1731	0,8924	0,8074	1,4000	1,6117	0,8872	1,0230	0,8310	2,6675	0,8876	1,0470	0,9401	1,3534
$\hat{k}_{36}$	0,8885	1,3698	1,2815	3,4098	0,8924	0,8075	1,4000	1,6126	0,8872	1,0230	0,8310	2,6679	0,8876	1,0470	0,9401	1,3535
$\hat{k}_{37}$	0,8885	1,3697	1,2816	2,9224	0,8924	0,8074	1,4000	1,6116	0,8872	1,0230	0,8310	2,6676	0,8876	1,0470	0,9401	1,3534
$\hat{k}_{38}$	0,7998	0,6361	0,3609	1,7143	0,8450	0,5584	0,8323	0,8746	0,8687	0,8021	0,6858	2,0924	0,8785	0,9810	0,8339	1,1161
$\hat{k}_{39}$	0,8885	1,3694	1,2809	2,2676	0,8924	0,8074	1,3997	1,6052	0,8872	1,0229	0,8310	2,6647	0,8876	1,0470	0,9401	1,3525
$\hat{k}_{40}$	0,8885	1,3695	1,2814	4,4847	0,8924	0,8074	1,3999	1,6139	0,8871	1,0229	0,8310	2,6681	0,8876	1,0470	0,9401	1,3535
$\hat{k}_{41}$	0,8885	1,3697	1,2814	2,3858	0,8924	0,8074	1,3999	1,6097	0,8872	1,0229	0,8310	2,6665	0,8876	1,0470	0,9401	1,3530
$\hat{k}_{42}$	0,8885	1,3694	1,2809	2,2659	0,8924	0,8074	1,3997	1,6052	0,8872	1,0229	0,8310	2,6647	0,8876	1,0470	0,9401	1,3525
$\hat{k}_{43}$	0,8885	1,3691	1,2807	2,2638	0,8924	0,8074	1,3996	1,6050	0,8871	1,0229	0,8310	2,6646	0,8876	1,0470	0,9401	1,3525
$\hat{k}_{44}$	0,8837	1,3309	1,2043	2,3363	0,8919	0,8059	1,3943	1,6079	0,8869	1,0221	0,8308	2,6657	0,8876	1,0469	0,9400	1,3529
$\hat{k}_{45}$	0,7622	0,7611	0,5107	2,2084	0,7873	0,6758	0,8374	1,3784	0,8695	0,8576	0,7580	2,3975	0,8788	1,0075	0,8833	1,2861
$\hat{k}_{46}$	0,8095	0,9204	0,6410	2,9310	0,8362	0,7348	0,9710	1,4884	0,8781	0,9185	0,7909	2,5118	0,8831	1,0264	0,9089	1,3175
$\hat{k}_{47}$	0,8095	0,9204	0,6409	2,8167	0,8362	0,7348	0,9709	1,4868	0,8781	0,9185	0,7908	2,5113	0,8831	1,0264	0,9089	1,3173
$\hat{k}_{48}$	0,1029	0,0617	0,0186	1,0729	0,5388	0,5015	0,5938	1,2292	0,8148	0,7802	0,7277	2,1925	0,8538	1,0065	0,8509	1,2298
$\hat{k}_{49}$	0,8885	1,1039	0,8419	0,6867	0,8924	0,7698	0,9742	0,0743	0,8871	0,8943	0,7242	0,2360	0,8876	0,9889	0,7770	0,1701

Çizelge 6.3. (devam) Ridge tahmin edicilerinin $p = 2, \rho = 0{,}90, \sigma = 0{,}01; 0{,}5; 1; 5$ senaryosu için HKO değerleri

$\hat{k}_{50}$	0,8885	0,9351	0,6395	0,2549	0,8924	0,7056	0,7669	0,0176	0,8871	0,7799	0,5772	0,0123	0,8876	0,9022	0,6014	0,0065
$\hat{k}_{51}$	0,8884	1,3700	1,2820	4,6000	0,8924	0,8075	1,4001	1,6141	0,8871	1,0230	0,8311	2,6682	0,8876	1,0470	0,9401	1,3536
$\hat{k}_{52}$	0,8622	0,1783	0,2070	2,8322	0,8870	0,0147	0,1308	0,2009	0,8863	0,0141	0,0090	0,2096	0,8871	0,3467	0,0045	0,1906
$\hat{k}_{53}$	0,8885	1,3696	1,2813	2,6904	0,8924	0,8074	1,3998	1,6082	0,8872	1,0229	0,8310	2,6659	0,8876	1,0470	0,9401	1,3528
$\hat{k}_{54}$	0,8885	1,3696	1,2812	2,6290	0,8924	0,8074	1,3998	1,6078	0,8872	1,0229	0,8310	2,6657	0,8876	1,0470	0,9401	1,3528
$\hat{k}_{55}$	0,3858	0,3697	0,1897	1,4036	0,7637	0,6973	0,8178	1,4757	0,8560	0,8379	0,7684	2,3533	0,8678	1,0253	0,8744	1,2794
$\hat{k}_{56}$	0,8885	1,3533	1,2501	3,0616	0,8924	0,8062	1,3911	1,5938	0,8871	1,0213	0,8302	2,6541	0,8876	1,0467	0,9393	1,3496
$\hat{k}_{57}$	0,2874	0,3063	0,2815	0,4585	0,4555	0,7521	0,4748	1,8336	9,2935	2,1881	6,9481	2,0761	43,115	38,020	130,14	128,86
$\hat{k}_{58}$	0,8885	1,3700	1,2820	4,6001	0,8924	0,8075	1,4001	1,6141	0,8872	1,0230	0,8311	2,6682	0,8876	1,0470	0,9401	1,3536
$\hat{k}_{59}$	0,8837	1,3311	1,2047	4,3899	0,8919	0,8060	1,3944	1,6122	0,8869	1,0221	0,8309	2,6674	0,8876	1,0469	0,9400	1,3535
$\hat{k}_{60}$	0,2137	0,0070	0,0267	1,4571	0,2011	0,0259	0,1502	0,8417	0,1747	0,1993	0,3697	1,6262	0,1299	0,5801	0,5603	1,0162
$\hat{k}_{61}$	0,7621	0,0183	0,0164	1,3820	0,7804	0,0238	0,2618	0,0118	0,8623	0,3770	0,1297	0,9587	0,8753	0,6536	0,4582	0,4108
$\hat{k}_{62}$	0,0129	0,9494	0,7001	1,4154	0,2347	0,7511	1,0857	1,4886	0,2406	0,9216	0,8138	2,4069	0,4736	1,0299	0,9196	1,3054
$\hat{k}_{63}$	0,7764	0,5346	0,2899	2,0168	0,8274	0,4907	0,7714	0,9521	0,8615	0,7634	0,6497	2,1642	0,8748	0,9596	0,8115	1,1483
$\hat{k}_{64}$	0,2055	0,0341	0,0128	2,0118	0,1816	0,1431	0,3635	1,1482	0,1359	0,4038	0,5352	1,9902	0,0713	0,7654	0,6975	1,1495
$\hat{k}_{65}$	0,8885	1,3699	1,2819	3,9137	0,8924	0,8075	1,4001	1,6137	0,8872	1,0230	0,8311	2,6681	0,8876	1,0470	0,9401	1,3536
$\hat{k}_{66}$	0,8885	1,3699	1,2818	3,5598	0,8924	0,8075	1,4000	1,6129	0,8872	1,0230	0,8311	2,6679	0,8876	1,0470	0,9401	1,3535
$\hat{k}_{67}$	0,8885	1,3696	1,2813	2,7436	0,8924	0,8074	1,3999	1,6098	0,8872	1,0229	0,8310	2,6668	0,8876	1,0470	0,9401	1,3532
$\hat{k}_{68}$	0,8563	0,1941	0,2125	0,2390	0,8876	0,0229	0,1216	0,2023	0,8866	0,0042	0,0141	0,2025	0,8874	0,5950	0,0608	0,1602
$\hat{k}_{69}$	0,8670	0,3213	0,0991	0,9583	0,8890	0,6467	0,7442	0,6864	0,8863	0,8358	0,7602	1,6393	0,8873	1,0273	0,8790	1,1144
$\hat{k}_{70}$	0,8541	0,4179	0,1447	1,4006	0,8774	0,4482	0,8301	0,2541	0,8848	0,8287	0,6643	1,9083	0,8869	1,0067	0,8568	1,0206
$\hat{k}_{71}$	0,8885	1,3699	1,2818	3,6136	0,8924	0,8075	1,4000	1,6129	0,8872	1,0230	0,8311	2,6679	0,8876	1,0470	0,9401	1,3535
$\hat{k}_{72}$	0,8885	1,3592	1,2615	3,2324	0,8924	0,8068	1,3958	1,6035	0,8872	1,0223	0,8307	2,6625	0,8876	1,0469	0,9399	1,3522
$\hat{k}_{73}$	0,8885	1,3697	1,2816	2,9955	0,8924	0,8074	1,4000	1,6117	0,8872	1,0230	0,8310	2,6676	0,8876	1,0470	0,9401	1,3534
$\hat{k}_{74}$	0,8885	1,3549	1,2534	2,8925	0,8924	0,8065	1,3940	1,5991	0,8872	1,0220	0,8306	2,6602	0,8876	1,0468	0,9397	1,3516
$\hat{k}_{75}$	0,8885	1,1815	0,8649	1,0663	0,8924	0,7862	1,3262	0,7059	0,8872	1,0116	0,8171	2,3779	0,8876	1,0453	0,9336	1,2284
$\hat{k}_{76}$	0,8868	1,0938	0,7881	1,7838	0,8919	0,7718	1,2469	1,2927	0,8870	0,9905	0,8116	2,4900	0,8876	1,0418	0,9273	1,2936
$\hat{k}_{77}$	0,8436	0,1388	0,1934	0,3621	0,8463	0,1369	0,0043	0,2147	0,8850	0,0428	0,0835	0,1313	0,8869	0,3132	0,0475	0,1716
$\hat{k}_{PSO}$	0,0001	0,0874	0,4277	3,5233	0,0001	0,0037	0,1404	0,0536	0,0001	0,0324	0,0854	0,2602	0,0001	0,0032	0,0070	0,1311
$\hat{k}_{TBO}$	0,0001	0,0787	0,3985	3,5114	0,0001	0,0037	0,1479	0,0537	0,0001	0,0330	0,0853	0,2609	0,0001	0,0032	0,0070	0,1311

Çizelge 6.4. Ridge tahmin edicilerinin $p = 4, \rho = 0{,}70, \sigma = 0{,}01; 0{,}5; 1; 5$ senaryosu için HKO değerleri

	$n = 10$				$n = 20$				$n = 50$				$n = 100$			
	0,01	0,5	1	5	0,01	0,5	1	5	0,01	0,5	1	5	0,01	0,5	1	5
EKK	2,5772	3,2344	2,8876	22,338	2,5627	3,1195	2,9099	20,060	2,5593	2,8818	2,7843	16,743	2,5566	2,4674	2,7639	5,9775
$\hat{k}_1$	2,5772	3,2344	2,8874	22,117	2,5627	3,1193	2,9096	19,502	2,5593	2,8817	2,7841	16,681	2,5566	2,4673	2,7635	5,9641
$\hat{k}_2$	2,5772	3,2344	2,8872	22,027	2,5627	3,1194	2,9098	19,951	2,5593	2,8818	2,7843	16,737	2,5566	2,4674	2,7639	5,9770
$\hat{k}_3$	2,5771	3,2235	2,8761	18,928	2,5624	3,0766	2,8656	9,2090	2,5585	2,8109	2,6950	12,383	2,5553	2,4268	2,5670	4,4682
$\hat{k}_4$	2,5772	3,2344	2,8876	22,282	2,5627	3,1194	2,9098	19,918	2,5593	2,8818	2,7842	16,727	2,5566	2,4674	2,7638	5,9741
$\hat{k}_5$	2,5766	2,8556	1,8818	5,0083	2,5627	2,9528	0,0400	4,5141	2,5592	2,6640	2,5996	9,3089	2,5565	2,2608	2,3989	4,3644
$\hat{k}_6$	2,5744	2,5431	0,3200	1,3251	2,5626	2,0910	0,1466	1,0252	2,5590	1,4495	2,4287	10,755	2,5547	0,9388	0,6874	3,5564
$\hat{k}_7$	1,7510	0,1144	0,1546	0,1293	2,5497	0,0787	0,1600	0,5848	2,5568	1,4159	0,0162	0,0938	2,5538	0,3408	0,3646	0,0453
$\hat{k}_8$	2,5772	3,2344	2,8876	22,282	2,5627	3,1194	2,9098	19,918	2,5593	2,8818	2,7842	16,727	2,5566	2,4674	2,7638	5,9741
$\hat{k}_9$	2,5772	3,2331	2,8815	18,553	2,5627	3,1176	2,9073	16,827	2,5593	2,8811	2,7824	16,039	2,5566	2,4671	2,7622	5,8851
$\hat{k}_{10}$	2,5772	3,2344	2,8876	22,282	2,5627	3,1194	2,9098	19,918	2,5593	2,8818	2,7842	16,728	2,5566	2,4674	2,7638	5,9741
$\hat{k}_{11}$	2,5715	3,2237	2,8662	21,474	2,5606	3,1151	2,9085	19,412	2,5590	2,8812	2,7838	16,675	2,5565	2,4673	2,7634	5,9638
$\hat{k}_{12}$	2,5715	3,2237	2,8664	21,679	2,5606	3,1153	2,9087	19,918	2,5590	2,8813	2,7840	16,727	2,5565	2,4673	2,7638	5,9741
$\hat{k}_{13}$	2,5758	3,2317	2,8820	22,155	2,5622	3,1184	2,9096	20,001	2,5592	2,8817	2,7842	16,738	2,5566	2,4673	2,7638	5,9765
$\hat{k}_{14}$	2,5772	3,2344	2,8876	22,310	2,5627	3,1195	2,9099	20,013	2,5593	2,8818	2,7843	16,740	2,5566	2,4674	2,7638	5,9773
$\hat{k}_{15}$	2,5715	3,2237	2,8660	21,391	2,5606	3,1152	2,9087	19,858	2,5590	2,8813	2,7840	16,730	2,5565	2,4673	2,7638	5,9767
$\hat{k}_{16}$	2,5772	3,2344	2,8876	22,338	2,5627	3,1195	2,9099	20,059	2,5593	2,8818	2,7843	16,743	2,5566	2,4674	2,7639	5,9775
$\hat{k}_{17}$	2,5772	3,2340	2,8776	4,1789	2,5627	3,1152	2,9099	19,051	2,5593	2,8818	2,7841	15,372	2,5566	2,4674	2,7639	5,9688
$\hat{k}_{18}$	2,5772	3,2132	2,7432	18,446	2,5627	3,1147	1,7723	18,525	2,5593	2,8791	2,7829	16,622	2,5566	2,4661	2,7611	5,9623
$\hat{k}_{19}$	2,5772	3,2344	2,8876	22,329	2,5627	3,1195	2,9099	20,044	2,5593	2,8818	2,7843	16,742	2,5566	2,4674	2,7639	5,9774
$\hat{k}_{20}$	1,1763	1,4618	1,1626	0,0803	1,3924	1,1727	2,1887	1,2729	1,9468	2,2317	1,5923	0,7809	2,2258	2,1259	2,3986	2,5773
$\hat{k}_{21}$	0,1532	0,0092	0,0307	0,5397	0,1422	0,3061	1,1068	5,5057	0,0908	1,1423	1,6299	9,2427	0,0336	1,4984	2,3120	5,3350
$\hat{k}_{22}$	1,8924	0,2143	0,0349	0,0409	2,4741	1,2884	0,1392	3,2419	2,5351	2,2899	1,2568	1,1405	2,5410	1,8583	2,1147	2,9396
$\hat{k}_{23}$	0,9748	2,8575	2,7037	13,577	0,4344	2,7941	2,9064	18,016	1,5276	2,8206	2,7343	16,299	2,1256	2,4552	2,7558	5,9504

Çizelge 6.4. (devam) Ridge tahmin edicilerinin $p = 4, \rho = 0{,}70, \sigma = 0{,}01; 0{,}5; 1; 5$ senaryosu için HKO değerleri

$\hat{k}_{24}$	2,5631	2,8562	2,3080	7,7244	2,5602	2,9088	1,4120	9,6463	2,5577	2,7362	2,6626	13,330	2,5548	2,3811	2,6529	5,4736
$\hat{k}_{25}$	1,4036	2,9696	2,7367	12,313	0,7163	2,7036	2,9075	19,05	1,9639	2,8665	2,7371	16,182	2,4039	2,4641	2,7609	5,9574
$\hat{k}_{26}$	2,5485	2,7168	1,8504	5,8734	2,5586	2,6559	0,4556	5,8005	2,5554	2,4275	2,6237	13,841	2,5492	2,1802	2,4299	5,3065
$\hat{k}_{27}$	2,5772	3,2198	2,7756	9,3793	2,5627	3,1005	2,8903	18,725	2,5593	2,8769	2,7717	14,207	2,5566	2,4655	2,7550	5,9067
$\hat{k}_{28}$	0,1591	0,1535	0,1538	0,1507	0,1588	0,1460	0,1403	0,1334	0,1553	0,1362	0,1435	0,1439	0,1497	0,1387	0,1232	0,1348
$\hat{k}_{29}$	2,5772	3,2309	2,8657	21,374	2,5627	3,1159	2,9066	19,829	2,5593	2,8808	2,7831	16,729	2,5566	2,4671	2,7628	5,9756
$\hat{k}_{30}$	0,1590	0,0215	0,4623	0,3231	0,1588	0,3006	1,3490	1,5290	0,1543	0,8125	1,3281	1,6100	0,1457	1,1857	2,1212	2,9730
$\hat{k}_{31}$	2,5772	3,2199	2,7823	18,480	2,5627	3,1048	2,8904	19,042	2,5593	2,8770	2,7771	16,727	2,5566	2,4656	2,7567	5,9715
$\hat{k}_{32}$	0,1590	0,6511	1,9105	0,1813	0,1588	1,3235	2,5288	5,8809	0,1539	1,9498	2,1859	1,3735	0,1441	2,0662	2,6405	4,2790
$\hat{k}_{33}$	2,5772	3,2344	2,8876	22,338	2,5627	3,1195	2,9099	20,060	2,5593	2,8818	2,7843	16,743	2,5566	2,4674	2,7639	5,9775
$\hat{k}_{34}$	2,5772	3,2344	2,8876	22,338	2,5627	3,1195	2,9099	20,060	2,5593	2,8818	2,7843	16,743	2,5566	2,4674	2,7639	5,9775
$\hat{k}_{35}$	2,5772	3,2344	2,8875	22,277	2,5627	3,1195	2,9098	19,922	2,5593	2,8818	2,7843	16,733	2,5566	2,4674	2,7638	5,9756
$\hat{k}_{36}$	2,5772	3,2344	2,8876	22,316	2,5627	3,1195	2,9099	20,046	2,5593	2,8818	2,7843	16,742	2,5566	2,4674	2,7639	5,9774
$\hat{k}_{37}$	2,5772	3,2344	2,8875	22,274	2,5627	3,1195	2,9098	19,924	2,5593	2,8818	2,7843	16,734	2,5566	2,4674	2,7638	5,9760
$\hat{k}_{38}$	2,4875	2,7903	2,2983	8,1975	2,5358	2,7658	2,2401	10,494	2,5436	2,6618	2,6712	14,791	2,5410	2,3629	2,6583	5,6824
$\hat{k}_{39}$	2,5755	2,5490	1,7623	9,1436	2,5627	3,0665	0,0604	1,0495	2,5591	1,4904	2,6116	11,422	2,5555	1,3148	1,4423	3,7316
$\hat{k}_{40}$	2,5772	3,2344	2,8876	22,334	2,5627	3,1194	2,9098	20,050	2,5592	2,8817	2,7842	16,742	2,5565	2,4673	2,7638	5,9773
$\hat{k}_{41}$	2,5772	3,2344	2,8876	22,316	2,5627	3,1194	2,9098	19,954	2,5593	2,8818	2,7842	16,734	2,5566	2,4674	2,7638	5,9738
$\hat{k}_{42}$	2,5772	3,2344	2,8874	22,117	2,5627	3,1193	2,9096	19,502	2,5593	2,8817	2,7841	16,681	2,5566	2,4673	2,7635	5,9641
$\hat{k}_{43}$	2,5772	3,2343	2,8873	22,116	2,5627	3,1192	2,9095	19,493	2,5592	2,8816	2,7841	16,680	2,5565	2,4673	2,7634	5,9639
$\hat{k}_{44}$	2,5715	3,2237	2,8663	21,659	2,5606	3,1152	2,9087	19,860	2,5590	2,8813	2,7840	16,728	2,5565	2,4673	2,7637	5,9735
$\hat{k}_{45}$	1,7295	1,9080	1,8872	2,3617	2,5156	2,3519	2,5070	7,7007	2,5501	2,5679	2,3986	12,068	2,5513	2,3437	2,6641	5,5666
$\hat{k}_{46}$	2,2023	2,5978	2,5226	7,4511	2,5504	2,8031	2,8011	14,659	2,5570	2,7854	2,6585	15,287	2,5553	2,4327	2,7377	5,8657
$\hat{k}_{47}$	2,5745	3,0123	2,7224	12,508	2,5626	2,9657	2,8589	15,581	2,5590	2,8311	2,7553	16,111	2,5548	2,4486	2,7480	5,9241
$\hat{k}_{48}$	0,0482	0,0348	0,0891	0,0353	0,3804	0,3691	0,5859	0,8102	1,8523	1,9800	1,8333	2,4197	2,2644	2,1435	2,5068	4,0768
$\hat{k}_{49}$	2,5768	3,1040	2,6776	1,2841	2,5626	2,8759	2,5248	0,4829	2,5591	2,6681	2,1874	0,5689	2,5565	2,3224	2,0954	0,7111

Çizelge 6.4. (devam) Ridge tahmin edicilerinin $p = 4, \rho = 0{,}70, \sigma = 0{,}01; 0{,}5; 1; 5$ senaryosu için HKO değerleri

$\hat{k}_{50}$	2,5770	2,8683	2,2916	0,0824	2,5626	2,4585	1,6938	0,0272	2,5590	2,2554	1,4503	0,0115	2,5562	2,0152	0,9520	0,0222
$\hat{k}_{51}$	2,5772	3,2344	2,8876	22,338	2,5626	3,1195	2,9099	20,060	2,5593	2,8818	2,7843	16,743	2,5566	2,4674	2,7639	5,9775
$\hat{k}_{52}$	2,2932	0,1077	0,1545	0,1589	2,5501	0,0195	0,0457	0,1410	2,5549	0,8704	0,0121	0,1471	2,5550	1,0768	0,8022	0,0967
$\hat{k}_{53}$	2,5772	3,2344	2,8875	22,249	2,5627	3,1194	2,9098	19,833	2,5593	2,8818	2,7842	16,718	2,5566	2,4674	2,7637	5,9721
$\hat{k}_{54}$	2,5772	3,2344	2,8875	22,227	2,5627	3,1194	2,9098	19,777	2,5593	2,8818	2,7842	16,712	2,5566	2,4674	2,7637	5,9708
$\hat{k}_{55}$	0,4288	0,5843	0,1948	0,2459	1,9477	2,1682	2,5155	2,6420	2,3287	2,4882	2,2887	6,5367	2,4724	2,3326	2,7228	5,4985
$\hat{k}_{56}$	2,5771	3,2318	2,8819	21,067	2,5627	3,1159	2,9074	19,128	2,5593	2,8803	2,7824	16,597	2,5566	2,4669	2,7622	5,9571
$\hat{k}_{57}$	0,1667	0,1686	0,1683	0,1726	0,2292	0,2251	0,2592	0,3364	0,5875	0,7790	0,4877	0,4913	5,1321	2,4621	24,766	4,5466
$\hat{k}_{58}$	2,5772	3,2344	2,8876	22,338	2,5627	3,1195	2,9099	20,060	2,5593	2,8818	2,7843	16,743	2,5566	2,4674	2,7639	5,9775
$\hat{k}_{59}$	2,5715	3,2237	2,8664	21,679	2,5606	3,1153	2,9087	19,966	2,5590	2,8813	2,7840	16,736	2,5565	2,4673	2,7638	5,9771
$\hat{k}_{60}$	0,1532	0,0091	0,0284	0,2329	0,1422	0,2920	1,0149	2,9589	0,0908	1,1234	1,5885	5,3966	0,0336	1,4828	2,2637	4,6404
$\hat{k}_{61}$	1,8924	0,2195	0,0312	0,1454	2,4741	1,3112	0,1371	5,9572	2,5351	2,2988	1,3061	2,9118	2,5410	1,8687	2,1747	4,1347
$\hat{k}_{62}$	0,9748	2,8569	2,6863	6,8574	0,4344	2,7923	2,9060	10,675	1,5276	2,8203	2,7307	12,654	2,1256	2,4552	2,7547	5,6955
$\hat{k}_{63}$	2,2586	2,5257	2,0622	6,3487	2,4281	2,6507	2,2595	12,916	2,5110	2,7230	2,5800	13,646	2,5295	2,3916	2,6962	5,7121
$\hat{k}_{64}$	1,4036	2,9674	2,7237	10,204	0,7163	2,6959	2,9072	18,054	1,9639	2,8661	2,7338	15,385	2,4039	2,4640	2,7604	5,9254
$\hat{k}_{65}$	2,5772	3,2344	2,8876	22,328	2,5627	3,1195	2,9099	20,042	2,5593	2,8818	2,7843	16,742	2,5566	2,4674	2,7639	5,9774
$\hat{k}_{66}$	2,5772	3,2344	2,8876	22,368	2,5627	3,1195	2,9099	19,992	2,5593	2,8818	2,7843	16,739	2,5566	2,4674	2,7639	5,9767
$\hat{k}_{67}$	2,5772	3,2344	2,8875	22,271	2,5627	3,1194	2,9098	19,922	2,5593	2,8818	2,7843	16,731	2,5566	2,4674	2,7638	5,9752
$\hat{k}_{68}$	2,1601	0,1313	0,1580	0,1595	2,5440	0,0371	0,0763	0,1478	2,5553	0,8685	0,0211	0,1469	2,5555	1,3393	1,0534	0,0799
$\hat{k}_{69}$	2,4887	1,8799	0,3489	0,0784	2,5525	2,4230	2,4194	2,5078	2,5571	2,7526	2,5401	5,5670	2,5558	2,4296	2,7187	5,0382
$\hat{k}_{70}$	2,4381	2,0602	0,5742	2,4888	2,5553	2,6729	0,0178	13,721	2,5581	2,8132	2,5645	10,705	2,5558	2,4222	2,7206	5,6736
$\hat{k}_{71}$	2,5772	3,2344	2,8876	22,324	2,5627	3,1195	2,9099	20,032	2,5593	2,8818	2,7843	16,741	2,5566	2,4674	2,7639	5,9771
$\hat{k}_{72}$	2,5772	3,2331	2,8842	21,669	2,5627	3,1179	2,9088	19,636	2,5593	2,8813	2,7837	16,692	2,5566	2,4672	2,7634	5,9712
$\hat{k}_{73}$	2,5772	3,2344	2,8875	22,281	2,5627	3,1195	2,9098	19,948	2,5593	2,8818	2,7843	16,735	2,5566	2,4674	2,7638	5,9762
$\hat{k}_{74}$	2,5771	3,2318	2,8809	21,051	2,5627	3,1163	2,9077	19,227	2,5593	2,8808	2,7831	16,641	2,5566	2,4671	2,7629	5,9650
$\hat{k}_{75}$	2,5770	3,1019	2,4196	10,892	2,5627	3,0825	0,1577	12,482	2,5593	2,8494	2,7615	15,301	2,5566	2,4448	2,7226	5,7444
$\hat{k}_{76}$	2,5703	3,0020	2,4965	10,759	2,5616	3,0154	2,0686	13,771	2,5588	2,8259	2,7417	15,381	2,5560	2,4400	2,7284	5,8085
$\hat{k}_{77}$	2,5765	2,9346	1,1282	5,3121	2,5627	2,7349	0,1006	4,8428	2,5593	2,4743	2,7334	15,704	2,5564	2,1450	2,2983	5,5320
$\hat{k}_{PSO}$	0,1994	0,0857	0,0723	4,4571	0,0001	0,0100	0,0557	4,6399	0,0001	0,0268	0,0626	3,2217	0,0001	0,0009	0,0042	0,7855
$\hat{k}_{TBO}$	0,1998	0,0848	0,0675	4,5166	0,0001	0,0103	0,0557	4,6343	0,0001	0,0267	0,0628	3,2462	0,0001	0,0009	0,0042	0,7868

Çizelge 6.5. Ridge tahmin edicilerinin $p = 4, \rho = 0{,}80, \sigma = 0{,}01; 0{,}5; 1; 5$ senaryosu için HKO değerleri

	$n = 10$				$n = 20$				$n = 50$				$n = 100$			
	0,01	0,5	1	5	0,01	0,5	1	5	0,01	0,5	1	5	0,01	0,5	1	5
EKK	2,5536	2,8775	4,5571	6,1313	2,5757	3,4710	3,6703	17,0876	2,5617	2,6419	2,5023	4,6120	2,5573	2,4710	2,7607	2,8283
$\hat{k}_1$	2,5536	2,8772	4,5561	6,0975	2,5757	3,4704	3,6689	15,9551	2,5617	2,6419	2,5021	4,5966	2,5573	2,4710	2,7606	2,8176
$\hat{k}_2$	2,5536	2,8771	4,5561	6,1003	2,5757	3,4707	3,6698	16,4630	2,5617	2,6419	2,5023	4,6107	2,5573	2,4710	2,7607	2,8277
$\hat{k}_3$	2,5534	2,8574	4,4633	5,4606	2,5753	3,3732	3,4902	7,4654	2,5608	2,6211	2,4343	3,5754	2,5569	2,4535	2,7270	2,1047
$\hat{k}_4$	2,5536	2,8774	4,5569	6,1228	2,5757	3,4708	3,6699	16,7938	2,5617	2,6419	2,5023	4,6082	2,5573	2,4710	2,7606	2,8256
$\hat{k}_5$	2,5530	2,3613	2,6755	1,3769	2,5755	2,5898	3,0163	0,2655	2,5616	2,4661	2,2433	1,5755	2,5569	2,3469	2,5651	0,7808
$\hat{k}_6$	2,5428	1,5834	1,5279	1,4659	2,5736	1,2443	2,2609	0,0909	2,5611	1,7217	2,0824	0,0271	2,5461	1,6371	2,1385	0,0073
$\hat{k}_7$	2,4886	0,0637	0,1384	0,1566	2,5539	0,1467	0,2980	0,1018	2,5589	0,0972	0,0648	0,0718	2,5059	0,3555	0,0929	0,0304
$\hat{k}_8$	2,5536	2,8774	4,5569	6,1228	2,5757	3,4708	3,6699	16,7923	2,5617	2,6419	2,5023	4,6082	2,5573	2,4710	2,7606	2,8256
$\hat{k}_9$	2,5536	2,8734	4,5409	5,5606	2,5757	3,4630	3,6571	10,0200	2,5617	2,6415	2,5005	4,4437	2,5573	2,4708	2,7602	2,7564
$\hat{k}_{10}$	2,5536	2,8774	4,5569	6,1228	2,5757	3,4708	3,6699	16,7924	2,5617	2,6419	2,5023	4,6082	2,5573	2,4710	2,7606	2,8256
$\hat{k}_{11}$	2,5442	2,8271	4,4841	6,0286	2,5712	3,4539	3,6561	15,6607	2,5614	2,6414	2,5017	4,5955	2,5572	2,4709	2,7606	2,8172
$\hat{k}_{12}$	2,5442	2,8272	4,4851	6,0615	2,5712	3,4545	3,6575	16,7583	2,5614	2,6414	2,5019	4,6082	2,5572	2,4709	2,7606	2,8256
$\hat{k}_{13}$	2,5512	2,8641	4,5388	6,1116	2,5746	3,4668	3,6670	16,9303	2,5616	2,6418	2,5022	4,6108	2,5573	2,4710	2,7606	2,8275
$\hat{k}_{14}$	2,5536	2,8774	4,5570	6,1271	2,5757	3,4709	3,6701	16,9389	2,5617	2,6419	2,5023	4,6115	2,5573	2,4710	2,7606	2,8281
$\hat{k}_{15}$	2,5442	2,8269	4,4841	6,0314	2,5712	3,4542	3,6570	16,1531	2,5614	2,6414	2,5019	4,6096	2,5572	2,4709	2,7606	2,8273
$\hat{k}_{16}$	2,5536	2,8775	4,5571	6,1312	2,5757	3,4710	3,6703	17,0846	2,5617	2,6419	2,5023	4,6120	2,5573	2,4710	2,7607	2,8283
$\hat{k}_{17}$	2,5536	2,8759	4,5388	3,8321	2,5757	3,4706	3,6678	13,2118	2,5617	2,6419	2,5023	4,5971	2,5573	2,4710	2,7606	2,8280
$\hat{k}_{18}$	2,5536	2,7843	4,3173	4,9093	2,5757	3,4059	3,6366	6,5091	2,5617	2,6391	2,4984	4,4569	2,5573	2,4701	2,7596	2,7413
$\hat{k}_{19}$	2,5536	2,8774	4,5571	6,1298	2,5757	3,4709	3,6702	17,0395	2,5617	2,6419	2,5023	4,6119	2,5573	2,4710	2,7607	2,8282
$\hat{k}_{20}$	1,2728	0,9211	0,9953	0,4557	1,6269	1,7609	1,6993	0,8619	2,1022	2,1620	1,7842	2,4406	2,2741	2,1279	2,2301	1,9965
$\hat{k}_{21}$	0,1541	0,0233	0,0133	0,9195	0,1436	0,2106	0,5459	1,5097	0,0813	0,7272	1,3489	3,2556	0,0718	1,1870	2,0061	2,3491
$\hat{k}_{22}$	2,3470	0,1796	0,0167	0,0268	2,4521	1,2771	1,4458	0,1990	2,5381	1,5486	0,7451	1,2398	2,4830	1,8504	1,0305	1,1336
$\hat{k}_{23}$	0,6327	2,3597	3,3809	5,3521	0,7420	3,0031	3,1867	14,6077	1,7113	2,6003	2,4660	4,5775	2,3340	2,4514	2,7528	2,8186

Çizelge 6.5. (devam) Ridge tahmin edicilerinin $p = 4, \rho = 0{,}80, \sigma = 0{,}01; 0{,}5; 1; 5$ senaryosu için HKO değerleri

$\hat{k}_{24}$	2,5393	2,3607	2,9187	2,6586	2,5677	2,7391	3,0766	1,8872	2,5598	2,5307	2,3611	3,2725	2,5535	2,4013	2,6906	2,1374
$\hat{k}_{25}$	1,6746	2,5482	3,4451	5,2540	1,5382	3,2720	3,3832	15,6571	2,1432	2,6266	2,4758	4,5899	2,5006	2,4649	2,7550	2,8253
$\hat{k}_{26}$	2,4980	2,0620	2,4633	2,7529	2,5526	2,2437	2,7552	0,5496	2,5562	2,3716	2,3165	2,2482	2,5379	2,2745	2,6385	1,5659
$\hat{k}_{27}$	2,5536	2,8060	4,3742	3,2793	2,5757	3,3612	3,5437	2,4530	2,5617	2,6365	2,4853	3,9249	2,5573	2,4680	2,7552	2,6783
$\hat{k}_{28}$	0,1595	0,1496	0,1481	0,1500	0,1580	0,1460	0,1406	0,1404	0,1544	0,1440	0,1394	0,1440	0,1531	0,1468	0,1443	0,1334
$\hat{k}_{29}$	2,5536	2,8573	4,5140	5,9609	2,5757	3,4489	3,6465	15,1201	2,5617	2,6410	2,5002	4,5920	2,5573	2,4706	2,7602	2,8173
$\hat{k}_{30}$	0,1595	0,0310	0,1086	0,9839	0,1577	0,5817	0,8723	1,4720	0,1531	0,8653	1,3909	2,8747	0,1493	1,2449	1,9488	2,1872
$\hat{k}_{31}$	2,5536	2,8070	4,3882	5,6203	2,5757	3,3625	3,5553	11,0557	2,5617	2,6365	2,4890	4,4321	2,5573	2,4681	2,7569	2,7237
$\hat{k}_{32}$	0,1595	0,6190	0,9527	2,0135	0,1577	1,8780	2,1848	3,3301	0,1526	2,0519	2,1783	3,8166	0,1476	2,1546	2,6056	2,7269
$\hat{k}_{33}$	2,5536	2,8775	4,5571	6,1313	2,5757	3,4710	3,6703	17,0857	2,5617	2,6419	2,5023	4,6120	2,5573	2,4710	2,7607	2,8283
$\hat{k}_{34}$	2,5536	2,8775	4,5571	6,1313	2,5757	3,4710	3,6703	17,0875	2,5617	2,6419	2,5023	4,6120	2,5573	2,4710	2,7607	2,8283
$\hat{k}_{35}$	2,5536	2,8774	4,5568	6,1217	2,5757	3,4708	3,6699	16,7669	2,5617	2,6419	2,5023	4,6096	2,5573	2,4710	2,7606	2,8266
$\hat{k}_{36}$	2,5536	2,8774	4,5570	6,1269	2,5757	3,4709	3,6702	17,0203	2,5617	2,6419	2,5023	4,6119	2,5573	2,4710	2,7607	2,8282
$\hat{k}_{37}$	2,5536	2,8774	4,5568	6,1211	2,5757	3,4708	3,6699	16,7533	2,5617	2,6419	2,5023	4,6101	2,5573	2,4710	2,7606	2,8270
$\hat{k}_{38}$	2,4356	2,2284	2,8130	3,4794	2,5044	2,5822	2,9577	2,4519	2,5442	2,5021	2,3844	3,5397	2,5318	2,3810	2,7061	2,3671
$\hat{k}_{39}$	2,5450	1,6469	2,7936	1,7073	2,5737	1,3362	2,3496	0,0522	2,5613	1,8003	2,0826	1,1759	2,5463	1,7946	2,4714	0,0072
$\hat{k}_{40}$	2,5535	2,8772	4,5565	6,1308	2,5756	3,4706	3,6698	17,0751	2,5616	2,6419	2,5023	4,6119	2,5573	2,4710	2,7606	2,8281
$\hat{k}_{41}$	2,5536	2,8774	4,5569	6,1228	2,5757	3,4708	3,6699	16,6545	2,5617	2,6419	2,5023	4,6081	2,5573	2,4710	2,7606	2,8255
$\hat{k}_{42}$	2,5536	2,8772	4,5561	6,0975	2,5757	3,4704	3,6689	15,9549	2,5617	2,6419	2,5021	4,5966	2,5573	2,4710	2,7606	2,8176
$\hat{k}_{43}$	2,5535	2,8770	4,5556	6,0970	2,5756	3,4700	3,6684	15,9500	2,5616	2,6419	2,5021	4,5965	2,5573	2,4710	2,7606	2,8175
$\hat{k}_{44}$	2,5442	2,8272	4,4849	6,0533	2,5712	3,4544	3,6571	16,3387	2,5614	2,6414	2,5018	4,6070	2,5572	2,4709	2,7606	2,8251
$\hat{k}_{45}$	2,3830	1,7422	1,7218	1,8004	2,5053	2,3380	2,5120	3,4362	2,5521	2,4432	2,2700	3,5351	2,5442	2,3533	2,6632	2,5608
$\hat{k}_{46}$	2,4979	2,3816	2,9024	3,4214	2,5565	2,9206	3,1748	9,2668	2,5593	2,5825	2,4325	4,2319	2,5540	2,4362	2,7349	2,7517
$\hat{k}_{47}$	2,5436	2,4722	3,8719	4,9422	2,5736	3,1160	3,4544	11,3109	2,5612	2,6171	2,4808	4,5225	2,5495	2,4557	2,7510	2,7865
$\hat{k}_{48}$	0,0331	0,0668	0,0320	0,0240	0,1722	0,1624	0,3328	0,1891	1,9112	1,6380	1,6964	2,1766	2,2176	2,1024	2,4017	1,9217
$\hat{k}_{49}$	2,5535	2,7337	3,7820	1,0262	2,5755	2,8918	2,8056	0,1885	2,5616	2,5341	2,1082	0,3918	2,5573	2,3635	2,4345	0,3373

Çizelge 6.5. (devam) Ridge tahmin edicilerinin $p = 4, \rho = 0{,}80, \sigma = 0{,}01; 0{,}5; 1; 5$ senaryosu için HKO değerleri

$\hat{k}_{50}$	2,5535	2,4878	2,6298	0,1005	2,5755	2,2777	1,9329	0,0477	2,5614	2,2910	1,4334	0,0142	2,5571	2,1457	1,7704	0,0216
$\hat{k}_{51}$	2,5534	2,8775	4,5571	6,1313	2,5756	3,4710	3,6703	17,0876	2,5617	2,6419	2,5023	4,6120	2,5573	2,4710	2,7607	2,8283
$\hat{k}_{52}$	2,4907	0,1128	0,1124	0,1586	2,5417	0,0594	0,0393	0,1568	2,5578	0,1165	0,0095	0,1460	2,5534	0,2374	0,0291	0,1122
$\hat{k}_{53}$	2,5536	2,8774	4,5567	6,1177	2,5757	3,4707	3,6697	16,6191	2,5617	2,6419	2,5023	4,6058	2,5573	2,4710	2,7606	2,8240
$\hat{k}_{54}$	2,5536	2,8773	4,5566	6,1143	2,5757	3,4707	3,6696	16,5053	2,5617	2,6419	2,5022	4,6043	2,5573	2,4710	2,7606	2,8229
$\hat{k}_{55}$	0,5320	0,2453	0,5047	0,5934	1,8599	1,9702	2,2019	0,9528	2,3743	2,4579	2,2471	2,8781	2,4200	2,3423	2,6856	2,4445
$\hat{k}_{56}$	2,5536	2,8693	4,5327	5,9729	2,5757	3,4591	3,6543	15,0777	2,5617	2,6411	2,5003	4,5784	2,5573	2,4706	2,7602	2,8115
$\hat{k}_{57}$	0,1730	0,1743	0,1764	0,1737	0,2266	0,2244	0,2571	0,2890	0,6642	0,4664	0,6293	0,4938	1,1065	0,9145	1,1867	8,4548
$\hat{k}_{58}$	2,5536	2,8775	4,5571	6,1313	2,5757	3,4710	3,6703	17,0876	2,5617	2,6419	2,5023	4,6120	2,5573	2,4710	2,7607	2,8283
$\hat{k}_{59}$	2,5442	2,8272	4,4851	6,0615	2,5712	3,4545	3,6575	16,7583	2,5614	2,6414	2,5019	4,6109	2,5572	2,4709	2,7606	2,8279
$\hat{k}_{60}$	0,1541	0,0252	0,0111	0,4866	0,1436	0,1860	0,4847	0,4924	0,0813	0,6997	1,2811	2,6183	0,0718	1,1604	1,9477	1,9370
$\hat{k}_{61}$	2,3470	0,1925	0,0199	0,0119	2,4521	1,3256	1,5186	0,8030	2,5381	1,5735	0,8187	2,0349	2,4830	1,8658	1,1180	1,7292
$\hat{k}_{62}$	0,6327	2,3572	3,3675	3,5196	0,7420	2,9942	3,1649	4,4342	1,7113	2,6000	2,4629	4,2630	2,3340	2,4512	2,7519	2,7248
$\hat{k}_{63}$	2,3285	2,0100	2,1940	2,6086	2,4015	2,5898	2,8333	5,1124	2,5174	2,4944	2,3106	4,0076	2,5163	2,3881	2,6794	2,6162
$\hat{k}_{64}$	1,6746	2,5415	3,4157	4,7674	1,5382	3,2616	3,3618	13,3753	2,1432	2,6261	2,4731	4,5597	2,5006	2,4647	2,7544	2,8201
$\hat{k}_{65}$	2,5536	2,8774	4,5571	6,1296	2,5757	3,4709	3,6702	17,0339	2,5617	2,6419	2,5023	4,6119	2,5573	2,4710	2,7607	2,8282
$\hat{k}_{66}$	2,5536	2,8774	4,5569	6,1262	2,5757	3,4709	3,6701	16,9191	2,5617	2,6419	2,5023	4,6111	2,5573	2,4710	2,7607	2,8276
$\hat{k}_{67}$	2,5536	2,8774	4,5568	6,1205	2,5757	3,4708	3,6699	16,7585	2,5617	2,6419	2,5023	4,6089	2,5573	2,4710	2,7606	2,8263
$\hat{k}_{68}$	2,4308	0,1418	0,1398	0,1594	2,5177	0,0966	0,0815	0,1584	2,5580	0,0803	0,0063	0,1446	2,5545	0,3789	0,0946	0,1032
$\hat{k}_{69}$	2,5063	0,9071	1,1589	0,1619	2,5513	2,0066	2,2152	0,2545	2,5597	2,4813	2,2832	2,6222	2,5562	2,3943	2,6853	2,1655
$\hat{k}_{70}$	2,5184	1,5504	1,0878	0,5895	2,5617	2,6415	2,9514	2,0506	2,5605	2,5187	2,2225	3,6103	2,5542	2,4201	2,6242	2,5082
$\hat{k}_{71}$	2,5536	2,8774	4,5570	6,1290	2,5757	3,4709	3,6702	17,0148	2,5617	2,6419	2,5023	4,6116	2,5573	2,4710	2,7607	2,8280
$\hat{k}_{72}$	2,5536	2,8726	4,5433	6,0465	2,5757	3,4652	3,6625	16,0407	2,5617	2,6416	2,5016	4,6006	2,5573	2,4709	2,7605	2,8228
$\hat{k}_{73}$	2,5536	2,8774	4,5568	6,1219	2,5757	3,4708	3,6700	16,7995	2,5617	2,6419	2,5023	4,6103	2,5573	2,4710	2,7606	2,8272
$\hat{k}_{74}$	2,5536	2,8678	4,5296	5,9647	2,5757	3,4595	3,6548	15,0956	2,5617	2,6413	2,5009	4,5892	2,5573	2,4708	2,7604	2,8174
$\hat{k}_{75}$	2,5534	2,6089	3,6034	2,7315	2,5757	3,1227	3,4621	1,3309	2,5617	2,6115	2,4569	3,2900	2,5573	2,4563	2,7410	2,0850
$\hat{k}_{76}$	2,5459	2,5009	3,3902	3,4680	2,5719	3,0101	3,3278	3,6294	2,5610	2,5960	2,4447	3,9507	2,5562	2,4474	2,7390	2,5206
$\hat{k}_{77}$	2,5505	2,1813	2,4945	2,8482	2,5752	2,2336	3,0323	0,0224	2,5616	2,4297	2,4191	0,6157	2,5563	2,3166	2,6847	0,7242
$\hat{k}_{PSO}$	0,0001	0,0352	0,6298	1,1452	0,0001	0,0921	0,0858	3,9531	0,0001	0,0041	0,0097	0,7111	0,0001	0,0062	0,0471	0,1260
$\hat{k}_{TBO}$	0,0001	0,0356	0,6286	1,1785	0,0001	0,0925	0,0852	3,9846	0,0001	0,0041	0,0097	0,7102	0,0001	0,0062	0,0471	0,1257

Çizelge 6.6. Ridge tahmin edicilerinin $p = 4, \rho = 0{,}90, \sigma = 0{,}01; 0{,}5; 1; 5$ senaryosu için HKO değerleri

	$n = 10$				$n = 20$				$n = 50$				$n = 100$			
	0,01	0,5	1	5	0,01	0,5	1	5	0,01	0,5	1	5	0,01	0,5	1	5
EKK	2,5595	2,7451	4,9773	55,938	2,5548	3,0124	2,1208	96,307	2,5544	2,5881	2,6900	12,078	2,5618	2,4459	2,4107	5,5998
$\hat{k}_1$	2,5595	2,7450	4,9769	53,971	2,5548	3,0124	2,1206	96,238	2,5544	2,5881	2,6900	12,068	2,5618	2,4459	2,4107	5,5971
$\hat{k}_2$	2,5595	2,7450	4,9761	53,795	2,5548	3,0124	2,1207	96,153	2,5544	2,5881	2,6900	12,075	2,5618	2,4459	2,4107	5,5994
$\hat{k}_3$	2,5594	2,7416	4,9388	34,828	2,5547	3,0068	2,1061	94,199	2,5543	2,5864	2,6864	11,171	2,5617	2,4402	2,4052	5,2063
$\hat{k}_4$	2,5595	2,7450	4,9772	55,434	2,5548	3,0124	2,1207	96,290	2,5544	2,5881	2,6900	12,076	2,5618	2,4459	2,4107	5,5991
$\hat{k}_5$	2,5580	2,1916	2,3474	2,8808	2,5547	2,7892	1,4153	19,088	2,5543	2,4938	2,2460	1,8934	2,5602	2,3380	2,2062	1,6177
$\hat{k}_6$	2,4996	1,2083	0,1343	3,4701	2,5531	2,5371	1,0397	44,567	2,5532	2,4089	0,9841	0,0324	2,4686	1,7895	0,4429	0,1218
$\hat{k}_7$	0,2149	0,1588	0,1420	0,1264	2,4350	0,0880	0,1589	0,1596	2,5249	0,1493	0,1583	0,1587	2,0528	0,0075	0,1134	0,1462
$\hat{k}_8$	2,5595	2,7450	4,9772	55,434	2,5548	3,0124	2,1207	96,290	2,5544	2,5881	2,6900	12,076	2,5618	2,4459	2,4107	5,5991
$\hat{k}_9$	2,5595	2,7436	4,9517	28,076	2,5548	3,0118	2,1188	90,414	2,5544	2,5881	2,6896	11,713	2,5618	2,4458	2,4106	5,5311
$\hat{k}_{10}$	2,5595	2,7450	4,9772	55,435	2,5548	3,0124	2,1207	96,290	2,5544	2,5881	2,6900	12,076	2,5618	2,4459	2,4107	5,5991
$\hat{k}_{11}$	2,5362	2,7315	4,7589	52,177	2,5507	3,0053	2,1180	95,163	2,5540	2,5879	2,6897	12,060	2,5617	2,4458	2,4107	5,5961
$\hat{k}_{12}$	2,5362	2,7316	4,7592	54,041	2,5507	3,0053	2,1181	95,231	2,5540	2,5879	2,6897	12,070	2,5617	2,4458	2,4107	5,5987
$\hat{k}_{13}$	2,5531	2,7416	4,9187	55,329	2,5538	3,0106	2,1201	96,032	2,5543	2,5881	2,6899	12,075	2,5617	2,4459	2,4107	5,5994
$\hat{k}_{14}$	2,5595	2,7451	4,9772	55,685	2,5548	3,0124	2,1207	96,299	2,5544	2,5881	2,6900	12,077	2,5618	2,4459	2,4107	5,5994
$\hat{k}_{15}$	2,5362	2,7315	4,7583	52,010	2,5507	3,0053	2,1180	95,080	2,5540	2,5879	2,6897	12,067	2,5617	2,4458	2,4107	5,5984
$\hat{k}_{16}$	2,5595	2,7451	4,9773	55,933	2,5548	3,0124	2,1208	96,307	2,5544	2,5881	2,6900	12,078	2,5618	2,4459	2,4107	5,5998
$\hat{k}_{17}$	2,5595	2,7400	4,6729	0,9539	2,5548	3,0121	2,1202	1,7973	2,5544	2,5881	2,6899	8,6852	2,5618	2,4459	2,4107	5,5934
$\hat{k}_{18}$	2,5594	2,6814	3,9926	40,874	2,5548	3,0037	2,0760	88,160	2,5544	2,5872	2,6829	11,277	2,5617	2,4452	2,4089	5,3098
$\hat{k}_{19}$	2,5595	2,7451	4,9773	55,863	2,5548	3,0124	2,1208	96,305	2,5544	2,5881	2,6900	12,078	2,5618	2,4459	2,4107	5,5998
$\hat{k}_{20}$	0,9014	1,3250	1,1073	0,1444	1,5592	1,7639	1,3992	0,0571	2,1514	2,0462	1,9474	1,6985	2,3389	2,1696	2,1010	3,6765
$\hat{k}_{21}$	0,1577	0,0252	0,0304	1,0158	0,1512	0,0104	0,1873	0,9432	0,1314	0,1775	0,4375	2,7093	0,1210	0,7799	1,0051	3,7419
$\hat{k}_{22}$	1,0445	0,0560	0,0568	0,0716	2,3135	0,4517	0,0534	0,0748	2,4744	0,1441	0,0046	0,0086	2,3430	1,5761	0,7423	0,5568
$\hat{k}_{23}$	0,5780	2,5233	3,3008	27,962	0,6381	2,6746	2,0688	69,209	1,7123	2,5584	2,6723	11,808	2,4405	2,4256	2,4003	5,5723

Çizelge 6.6. (devam) Ridge tahmin edicilerinin $p = 4, \rho = 0{,}90, \sigma = 0{,}01; 0{,}5; 1; 5$ senaryosu için HKO değerleri

$\hat{k}_{24}$	2,5281	2,3345	2,6683	6,9940	2,5485	2,7540	1,7968	34,372	2,5516	2,5233	2,5255	5,6177	2,5543	2,3811	2,3275	4,1228
$\hat{k}_{25}$	0,2104	2,5062	3,0512	26,581	0,9900	2,7621	2,0662	50,228	2,1796	2,5674	2,6717	11,255	2,5331	2,4393	2,4044	5,5785
$\hat{k}_{26}$	2,4528	2,1398	0,5291	7,6870	2,5380	2,6442	1,7375	50,639	2,5454	2,4974	2,3714	2,5442	2,5103	2,2805	2,1514	2,3634
$\hat{k}_{27}$	2,5594	2,7064	4,2635	8,4139	2,5548	2,9916	2,0886	10,755	2,5544	2,5861	2,6771	6,6102	2,5618	2,4439	2,4049	4,5522
$\hat{k}_{28}$	0,1589	0,1564	0,1572	0,1519	0,1583	0,1557	0,1488	0,1579	0,1562	0,1549	0,1547	0,1547	0,1560	0,1529	0,1539	0,1527
$\hat{k}_{29}$	2,5594	2,7382	4,8466	52,647	2,5548	3,0087	2,1156	95,599	2,5544	2,5879	2,6889	12,004	2,5618	2,4457	2,4102	5,5734
$\hat{k}_{30}$	0,1582	0,0790	0,1303	0,4598	0,1579	0,0973	0,6459	0,4387	0,1544	0,5345	1,3182	2,7705	0,1495	1,0046	1,5512	4,0978
$\hat{k}_{31}$	2,5594	2,7071	4,3057	49,121	2,5548	2,9919	2,0905	95,637	2,5544	2,5862	2,6794	9,1978	2,5618	2,4439	2,4053	5,2092
$\hat{k}_{32}$	0,1579	1,1914	1,5422	0,9898	0,1578	1,2628	1,6274	0,2838	0,1536	1,9568	2,4216	1,5886	0,1456	2,0931	2,2699	4,9281
$\hat{k}_{33}$	2,5595	2,7451	4,9773	55,935	2,5548	3,0124	2,1208	96,307	2,5544	2,5881	2,6900	12,078	2,5618	2,4459	2,4107	5,5998
$\hat{k}_{34}$	2,5595	2,7451	4,9773	55,937	2,5548	3,0124	2,1208	96,307	2,5544	2,5881	2,6900	12,078	2,5618	2,4459	2,4107	5,5998
$\hat{k}_{35}$	2,5595	2,7450	4,9772	55,408	2,5548	3,0124	2,1207	96,290	2,5544	2,5881	2,6900	12,077	2,5618	2,4459	2,4107	5,5994
$\hat{k}_{36}$	2,5595	2,7450	4,9772	55,504	2,5548	3,0124	2,1208	96,298	2,5544	2,5881	2,6900	12,078	2,5618	2,4459	2,4107	5,5998
$\hat{k}_{37}$	2,5595	2,7450	4,9772	55,393	2,5548	3,0124	2,1207	96,290	2,5544	2,5881	2,6900	12,077	2,5618	2,4459	2,4107	5,5995
$\hat{k}_{38}$	2,3933	2,3160	2,0197	11,183	2,4976	2,6813	1,8876	51,686	2,5294	2,5246	2,5529	6,3509	2,5201	2,3633	2,3167	4,2830
$\hat{k}_{39}$	2,5592	2,3719	3,1609	3,4773	2,5545	2,6282	1,5562	61,234	2,5536	2,4090	2,3952	8,4345	2,5251	1,9387	2,0992	1,7354
$\hat{k}_{40}$	2,5595	2,7450	4,9772	55,925	2,5548	3,0124	2,1207	96,307	2,5544	2,5881	2,6900	12,078	2,5618	2,4459	2,4107	5,5998
$\hat{k}_{41}$	2,5595	2,7450	4,9772	55,582	2,5548	3,0124	2,1207	96,290	2,5544	2,5881	2,6900	12,076	2,5618	2,4459	2,4107	5,5991
$\hat{k}_{42}$	2,5595	2,7450	4,9769	53,971	2,5548	3,0124	2,1206	96,238	2,5544	2,5881	2,6900	12,068	2,5618	2,4459	2,4107	5,5971
$\hat{k}_{43}$	2,5595	2,7450	4,9768	53,964	2,5548	3,0124	2,1206	96,237	2,5544	2,5881	2,6900	12,068	2,5618	2,4459	2,4107	5,5971
$\hat{k}_{44}$	2,5362	2,7316	4,7591	53,704	2,5507	3,0053	2,1181	95,214	2,5540	2,5879	2,6897	12,068	2,5617	2,4458	2,4107	5,5980
$\hat{k}_{45}$	1,6813	1,7022	1,8903	1,5667	2,3218	2,3158	1,7261	18,562	2,4822	2,4045	2,4988	6,5369	2,4902	2,3178	2,3097	4,8228
$\hat{k}_{46}$	2,2312	2,3010	2,6867	6,8515	2,4766	2,6669	1,9867	51,583	2,5338	2,5332	2,6359	9,9424	2,5396	2,4033	2,3789	5,3290
$\hat{k}_{47}$	2,5107	2,6561	3,8850	37,852	2,5532	2,9102	2,0896	82,827	2,5533	2,5784	2,6760	11,749	2,5550	2,4378	2,4050	5,5294
$\hat{k}_{48}$	0,1248	0,0919	0,1071	0,0261	0,0254	0,0098	0,0909	0,0472	1,2349	0,9739	0,8100	1,1439	1,9061	1,9529	1,8449	3,2440
$\hat{k}_{49}$	2,5590	2,6307	3,3142	0,3452	2,5547	2,9219	1,9500	1,9768	2,5544	2,5591	2,5807	1,2632	2,5617	2,3843	2,3073	1,5903

Çizelge 6.6. (devam) Ridge tahmin edicilerinin $p = 4, \rho = 0{,}90, \sigma = 0{,}01; 0{,}5; 1; 5$ senaryosu için HKO değerleri

$\hat{k}_{50}$	2,5593	2,4692	3,0409	0,0160	2,5547	2,7679	1,5815	1,4345	2,5543	2,4829	2,3224	0,1712	2,5617	2,2663	2,0987	0,2862
$\hat{k}_{51}$	2,5595	2,7451	4,9773	55,938	2,5548	3,0124	2,1208	96,307	2,5544	2,5881	2,6900	12,078	2,5618	2,4459	2,4107	5,5998
$\hat{k}_{52}$	0,9815	0,1542	0,1576	0,1596	2,4681	0,1202	0,1162	0,1599	2,5316	0,0570	0,1319	0,1587	2,5282	0,0107	0,0763	0,1546
$\hat{k}_{53}$	2,5595	2,7450	4,9771	55,136	2,5548	3,0124	2,1207	96,280	2,5544	2,5881	2,6900	12,074	2,5618	2,4459	2,4107	5,5987
$\hat{k}_{54}$	2,5595	2,7450	4,9771	54,939	2,5548	3,0124	2,1207	96,273	2,5544	2,5881	2,6900	12,073	2,5618	2,4459	2,4107	5,5984
$\hat{k}_{55}$	0,0069	0,0927	0,0306	0,4309	1,5092	1,4181	1,4706	0,8550	2,3610	2,3291	2,3413	2,5713	2,4675	2,3152	2,3065	4,2112
$\hat{k}_{56}$	2,5594	2,7430	4,9469	49,300	2,5548	3,0110	2,1186	95,194	2,5544	2,5880	2,6896	12,007	2,5618	2,4457	2,4105	5,5845
$\hat{k}_{57}$	0,1628	0,1647	0,1635	0,1712	0,1929	0,1770	0,2096	0,1682	0,3004	0,2264	0,2300	0,2324	0,3404	0,4210	0,3725	0,4322
$\hat{k}_{58}$	2,5595	2,7451	4,9773	55,938	2,5548	3,0124	2,1208	96,307	2,5544	2,5881	2,6900	12,078	2,5618	2,4459	2,4107	5,5998
$\hat{k}_{59}$	2,5362	2,7316	4,7592	54,041	2,5507	3,0053	2,1181	95,231	2,5540	2,5879	2,6897	12,070	2,5617	2,4458	2,4107	5,5987
$\hat{k}_{60}$	0,1577	0,0272	0,0336	0,3992	0,1512	0,0109	0,1548	0,1121	0,1314	0,1694	0,3745	1,5703	0,1210	0,7620	0,9446	2,8708
$\hat{k}_{61}$	1,0445	0,0538	0,0667	0,3759	2,3135	0,4634	0,0472	0,0253	2,4744	0,1515	0,0033	0,1301	2,3430	1,5900	0,8017	1,7402
$\hat{k}_{62}$	0,5780	2,5207	3,2824	2,2459	0,6381	2,6740	2,0651	10,432	1,7123	2,5583	2,6707	9,4736	2,4405	2,4255	2,3997	5,3245
$\hat{k}_{63}$	2,1517	1,9674	2,4122	6,2836	2,3696	2,4966	1,6644	17,692	2,4858	2,4266	2,4444	6,9367	2,5062	2,3555	2,3172	4,8281
$\hat{k}_{64}$	0,2104	2,5010	3,0275	13,659	0,9900	2,7596	2,0614	23,781	2,1796	2,5669	2,6698	10,211	2,5331	2,4391	2,4039	5,5441
$\hat{k}_{65}$	2,5595	2,7451	4,9773	55,854	2,5548	3,0124	2,1208	96,305	2,5544	2,5881	2,6900	12,078	2,5618	2,4459	2,4107	5,5998
$\hat{k}_{66}$	2,5595	2,7451	4,9772	55,664	2,5548	3,0124	2,1207	96,299	2,5544	2,5881	2,6900	12,078	2,5618	2,4459	2,4107	5,5996
$\hat{k}_{67}$	2,5595	2,7450	4,9772	55,256	2,5548	3,0124	2,1207	96,286	2,5544	2,5881	2,6900	12,076	2,5618	2,4459	2,4107	5,5993
$\hat{k}_{68}$	0,3097	0,1575	0,1590	0,1598	2,4107	0,1350	0,1357	0,1600	2,5286	0,0569	0,1347	0,1587	2,5352	0,0497	0,0587	0,1534
$\hat{k}_{69}$	2,2480	0,5734	0,2985	0,0288	2,5165	1,9252	1,3262	0,0267	2,5479	2,3592	2,1288	1,5709	2,5579	2,3433	2,2508	3,3518
$\hat{k}_{70}$	2,1972	0,2933	1,4036	1,7350	2,5214	2,2717	0,3718	0,5162	2,5491	2,1066	1,4776	1,9675	2,5469	2,3653	2,2497	3,9615
$\hat{k}_{71}$	2,5595	2,7451	4,9773	55,805	2,5548	3,0124	2,1208	96,303	2,5544	2,5881	2,6900	12,078	2,5618	2,4459	2,4107	5,5997
$\hat{k}_{72}$	2,5595	2,7439	4,9607	52,375	2,5548	3,0118	2,1197	95,770	2,5544	2,5881	2,6899	12,053	2,5618	2,4459	2,4107	5,5949
$\hat{k}_{73}$	2,5595	2,7450	4,9772	55,411	2,5548	3,0124	2,1207	96,291	2,5544	2,5881	2,6900	12,077	2,5618	2,4459	2,4107	5,5995
$\hat{k}_{74}$	2,5594	2,7428	4,9444	49,163	2,5548	3,0111	2,1186	95,239	2,5544	2,5880	2,6897	12,028	2,5618	2,4458	2,4106	5,5900
$\hat{k}_{75}$	2,5590	2,4857	2,9576	12,336	2,5548	2,9443	1,8705	54,501	2,5544	2,5746	2,6087	5,9368	2,5616	2,4326	2,3798	3,9657
$\hat{k}_{76}$	2,5404	2,4641	2,9656	13,942	2,5517	2,8574	1,9345	53,617	2,5533	2,5635	2,6227	8,5230	2,5594	2,4235	2,3798	4,7532
$\hat{k}_{77}$	2,5356	2,0081	0,0845	14,505	2,5544	2,8120	1,7068	77,485	2,5542	2,5601	2,2368	0,4458	2,5492	2,3216	1,9341	0,0045
$\hat{k}_{PSO}$	0,0001	0,0631	0,6979	13,382	0,0001	0,0326	0,0531	23,629	0,0001	0,0315	0,0360	2,4983	0,0001	0,0052	0,0208	0,2978
$\hat{k}_{TBO}$	0,0001	0,0631	0,6725	13,551	0,0001	0,0330	0,0531	23,661	0,0001	0,0315	0,0360	2,4891	0,0001	0,0052	0,0208	0,2972

Çizelge 6.7. Liu tahmin edicilerinin $p = 2, \rho = 0{,}70, \sigma = 0{,}01; 0{,}5; 1; 5$ senaryosu için HKO değerleri

	$n = 10$				$n = 20$				$n = 50$				$n = 100$			
	0,01	0,5	1	5	0,01	0,5	1	5	0,01	0,5	1	5	0,01	0,5	1	5
EKK	0,8861	0,9806	0,8130	12,354	0,8867	0,8673	0,6602	8,5981	0,8896	0,9071	0,8870	1,0437	0,8890	0,9251	0,8838	1,3967
$\hat{d}_1$	0,8861	0,9781	0,8091	9,0067	0,8867	0,8670	0,6599	8,1784	0,8896	0,9067	0,8865	1,0204	0,8890	0,9251	0,8836	1,3787
$\hat{d}_2$	0,8671	0,8005	0,6606	9,0067	0,8524	0,8042	0,6140	5,5753	0,8805	0,8696	0,8615	0,9872	0,8850	0,9105	0,8711	1,3580
$\hat{d}_3$	0,8671	0,8005	0,6606	9,0067	0,8524	0,8042	0,6140	5,5753	0,8805	0,8696	0,8615	0,9872	0,8850	0,9105	0,8711	1,3580
$\hat{d}_4$	0,8860	0,9769	0,8083	9,0067	0,8866	0,8669	0,6599	8,1721	0,8896	0,9067	0,8865	1,0204	0,8889	0,9250	0,8836	1,3787
$\hat{d}_5$	0,8485	0,8005	0,6606	9,0067	0,8200	0,8042	0,6140	5,5753	0,8715	0,8696	0,8615	0,9872	0,8810	0,9105	0,8711	1,3580
$\hat{d}_6$	0,8485	0,8005	0,6606	11,280	0,8151	0,8042	0,6140	5,5753	0,8661	0,8696	0,8615	0,9872	0,8752	0,9105	0,8711	1,3580
$\hat{d}_7$	0,8485	0,8005	0,6606	11,280	0,8151	0,8042	0,6140	5,5753	0,8661	0,8696	0,8615	0,9872	0,8752	0,9105	0,8711	1,3580
$\hat{d}_8$	0,8859	0,9706	0,8073	11,291	0,8861	0,8661	0,6599	8,5553	0,8892	0,9055	0,8865	1,0427	0,8887	0,9249	0,8836	1,3959
$\hat{d}_9$	0,8485	0,8005	0,6606	11,270	0,8151	0,8042	0,6140	5,5753	0,8661	0,8696	0,8615	0,9872	0,8752	0,9105	0,8711	1,3580
$\hat{d}_{10}$	0,8655	0,8468	0,6801	9,0067	0,8499	0,8174	0,6158	5,8667	0,8778	0,8797	0,8615	0,9873	0,8820	0,9136	0,8723	1,3581
$\hat{d}_{11}$	0,8655	0,8468	0,6801	9,0067	0,8499	0,8174	0,6158	5,8667	0,8778	0,8797	0,8615	0,9873	0,8820	0,9136	0,8723	1,3581
$\hat{d}_{12}$	0,8827	0,8956	0,7009	9,0067	0,8866	0,8308	0,6178	6,2682	0,8896	0,8899	0,8616	0,9882	0,8889	0,9167	0,8734	1,3593
$\hat{d}_{13}$	0,8485	0,8005	0,6606	9,0067	0,8151	0,8042	0,6140	5,5753	0,8661	0,8696	0,8615	0,9872	0,8752	0,9105	0,8711	1,3580
$\hat{d}_{PSO}$	0,0000	0,0015	0,1317	3,0711	0,0001	0,0038	0,0158	2,2987	0,0000	0,0004	0,0139	0,1372	0,0000	0,0018	0,0001	0,0906
$\hat{d}_{TBO}$	0,0000	0,0015	0,1319	3,0643	0,0001	0,0038	0,0158	2,2917	0,0000	0,0004	0,0139	0,1362	0,0000	0,0018	0,0001	0,0906

Çizelge 6.8. Liu tahmin edicilerinin $p = 2, \rho = 0{,}80, \sigma = 0{,}01; 0{,}5; 1; 5$ senaryosu için HKO değerleri

	$n = 10$				$n = 20$				$n = 50$				$n = 100$			
	0,01	0,5	1	5	0,01	0,5	1	5	0,01	0,5	1	5	0,01	0,5	1	5
EKK	0,8874	1,1231	1,0879	2,6310	0,8844	0,9417	0,8710	19,151	0,8861	0,9038	1,2197	5,0564	0,8895	0,8861	0,7944	1,5954
$\hat{d}_1$	0,8864	1,1231	1,0853	1,6051	0,8844	0,9400	0,8705	17,242	0,8861	0,9037	1,2193	5,0248	0,8895	0,8861	0,7943	1,5804
$\hat{d}_2$	0,8152	1,0151	0,7395	0,9578	0,8424	0,8201	0,7665	14,254	0,8724	0,8701	1,1420	4,3905	0,8845	0,8722	0,7853	1,4789
$\hat{d}_3$	0,8152	1,0151	0,7395	0,9578	0,8424	0,8201	0,7665	14,254	0,8724	0,8701	1,1420	4,3905	0,8845	0,8722	0,7853	1,4789
$\hat{d}_4$	0,8844	1,1230	1,0825	1,5995	0,8843	0,9394	0,8704	17,232	0,8860	0,9037	1,2193	5,0246	0,8895	0,8861	0,7943	1,5804
$\hat{d}_5$	0,7496	1,0151	0,7395	0,9578	0,8032	0,8201	0,7665	14,254	0,8590	0,8701	1,1420	4,3905	0,8795	0,8722	0,7853	1,4789
$\hat{d}_6$	0,6806	1,0151	0,7395	0,9578	0,7966	0,8201	0,7665	15,438	0,8546	0,8701	1,1420	4,3905	0,8787	0,8722	0,7853	1,4789
$\hat{d}_7$	0,6806	1,0151	0,7395	0,9578	0,7966	0,8201	0,7665	15,438	0,8546	0,8701	1,1420	4,3905	0,8787	0,8722	0,7853	1,4789
$\hat{d}_8$	0,8705	1,1230	1,0780	2,5872	0,8837	0,9347	0,8700	19,001	0,8858	0,9035	1,2193	5,0545	0,8894	0,8860	0,7943	1,5949
$\hat{d}_9$	0,6806	1,0151	0,7395	0,9578	0,7966	0,8201	0,7665	14,254	0,8546	0,8701	1,1420	4,3905	0,8787	0,8722	0,7853	1,4789
$\hat{d}_{10}$	0,7797	1,0355	0,8323	0,9578	0,8389	0,8483	0,7928	14,644	0,8701	0,8777	1,1627	4,4951	0,8841	0,8742	0,7853	1,4812
$\hat{d}_{11}$	0,7797	1,0355	0,8323	0,9578	0,8389	0,8483	0,7928	14,644	0,8701	0,8777	1,1627	4,4951	0,8841	0,8742	0,7853	1,4812
$\hat{d}_{12}$	0,8873	1,0577	0,9334	0,9683	0,8844	0,8776	0,8202	16,105	0,8860	0,8854	1,1839	4,6120	0,8895	0,8763	0,7853	1,4843
$\hat{d}_{13}$	0,6811	1,0151	0,7395	0,9578	0,7966	0,8201	0,7665	14,254	0,8546	0,8701	1,1420	4,3905	0,8787	0,8722	0,7853	1,4789
$\hat{d}_{PSO}$	0,0001	0,0138	0,1448	0,7939	0,0001	0,0062	0,0283	6,9993	0,9934	0,0052	0,0901	1,2730	0,0001	0,0016	0,0353	0,4773
$\hat{d}_{TBO}$	0,0001	0,0138	0,1438	0,7921	0,0001	0,0062	0,0283	6,9819	0,0001	0,0052	0,0901	1,2727	0,0001	0,0016	0,0353	0,4784

Çizelge 6.9. Liu tahmin edicilerinin $p = 2, \rho = 0{,}90, \sigma = 0{,}01; 0{,}5; 1; 5$ senaryosu için HKO değerleri

	$n = 10$				$n = 20$				$n = 50$				$n = 100$			
	0,01	0,5	1	5	0,01	0,5	1	5	0,01	0,5	1	5	0,01	0,5	1	5
EKK	0,8885	1,3700	1,2820	4,6001	0,8924	0,8075	1,4001	1,6141	0,8872	1,0230	0,8311	2,6682	0,8876	1,0470	0,9401	1,3536
$\hat{d}_1$	0,8885	1,3698	1,2818	3,0567	0,8924	0,8074	1,3999	1,6098	0,8872	1,0229	0,8310	2,6666	0,8876	1,0470	0,9401	1,3530
$\hat{d}_2$	0,8325	0,9925	0,7151	2,7877	0,8733	0,7486	1,1181	1,5237	0,8737	0,9397	0,8040	2,5640	0,8810	1,0313	0,9155	1,3266
$\hat{d}_3$	0,8325	0,9925	0,7151	2,7877	0,8733	0,7486	1,1181	1,5237	0,8737	0,9397	0,8040	2,5640	0,8810	1,0313	0,9155	1,3266
$\hat{d}_4$	0,8885	1,3695	1,2814	3,0526	0,8924	0,8074	1,3999	1,6098	0,8872	1,0229	0,8310	2,6666	0,8876	1,0470	0,9401	1,3530
$\hat{d}_5$	0,7890	0,9925	0,7151	2,7877	0,8551	0,7486	1,1181	1,5237	0,8607	0,9397	0,8040	2,5640	0,8744	1,0313	0,9155	1,3266
$\hat{d}_6$	0,7918	1,0233	0,8157	2,7877	0,8551	0,7486	1,1181	1,5237	0,8607	0,9397	0,8040	2,5640	0,8743	1,0313	0,9155	1,3266
$\hat{d}_7$	0,7918	1,0233	0,8157	2,7877	0,8551	0,7486	1,1181	1,5237	0,8607	0,9397	0,8040	2,5640	0,8743	1,0313	0,9155	1,3266
$\hat{d}_8$	0,8884	1,3694	1,2814	4,4828	0,8924	0,8074	1,3998	1,6138	0,8871	1,0229	0,8310	2,6681	0,8876	1,0470	0,9401	1,3535
$\hat{d}_9$	0,7890	0,9925	0,7151	2,7877	0,8551	0,7486	1,1181	1,5237	0,8607	0,9397	0,8040	2,5640	0,8743	1,0313	0,9155	1,3266
$\hat{d}_{10}$	0,8326	1,0743	0,8062	2,7877	0,8733	0,7536	1,1883	1,5239	0,8737	0,9595	0,8050	2,5664	0,8809	1,0334	0,9177	1,3267
$\hat{d}_{11}$	0,8326	1,0743	0,8062	2,7877	0,8733	0,7536	1,1883	1,5239	0,8737	0,9595	0,8050	2,5664	0,8809	1,0334	0,9177	1,3267
$\hat{d}_{12}$	0,8884	1,1757	0,9175	2,8113	0,8923	0,7586	1,2661	1,5241	0,8871	0,9803	0,8060	2,5688	0,8876	1,0356	0,9200	1,3268
$\hat{d}_{13}$	0,7890	0,9925	0,7151	2,7877	0,8551	0,7486	1,1181	1,5237	0,8607	0,9397	0,8040	2,5640	0,8743	1,0313	0,9155	1,3266
$\hat{d}_{PSO}$	0,0004	0,0092	0,1346	2,7064	0,0000	0,0112	0,1491	0,0429	0,0000	0,0147	0,0768	0,2303	0,0001	0,0028	0,0041	0,1207
$\hat{d}_{TBO}$	0,0004	0,0092	0,1318	2,7040	0,0000	0,0113	0,1496	0,0426	0,0000	0,0145	0,0767	0,2303	0,0001	0,0028	0,0041	0,1207

Çizelge 6.10. Liu tahmin edicilerinin $p = 4, \rho = 0{,}70, \sigma = 0{,}01; 0{,}5; 1; 5$ senaryosu için HKO değerleri

	$n = 10$				$n = 20$				$n = 50$				$n = 100$			
	0,01	0,5	1	5	0,01	0,5	1	5	0,01	0,5	1	5	0,01	0,5	1	5
EKK	2,5772	3,2344	2,8876	22,338	2,5627	3,1195	2,9099	20,060	2,5593	2,8818	2,7843	16,743	2,5566	2,4674	2,7639	5,9775
$\hat{d}_1$	2,5772	3,2344	2,8876	22,312	2,5627	3,1195	2,9098	19,939	2,5593	2,8818	2,7842	16,728	2,5566	2,4674	2,7638	5,9742
$\hat{d}_2$	2,3657	2,8569	2,5608	10,626	2,4855	2,8561	2,8212	14,922	2,5226	2,7866	2,7057	15,457	2,5319	2,4343	2,7334	5,8556
$\hat{d}_3$	2,4054	2,8569	2,5608	10,626	2,4847	2,8561	2,8212	14,922	2,5272	2,7866	2,7057	15,457	2,5362	2,4343	2,7334	5,8556
$\hat{d}_4$	2,5772	3,2344	2,8875	22,309	2,5627	3,1194	2,9098	19,938	2,5593	2,8818	2,7842	16,728	2,5566	2,4674	2,7638	5,9742
$\hat{d}_5$	2,3379	2,8569	2,5608	10,626	2,4105	2,8561	2,8212	14,922	2,5050	2,7866	2,7057	15,457	2,5247	2,4343	2,7334	5,8556
$\hat{d}_6$	2,3379	2,8569	2,5608	13,340	2,4088	2,8561	2,8212	14,922	2,4988	2,7866	2,7057	16,376	2,5240	2,4343	2,7334	5,8556
$\hat{d}_7$	2,3379	2,8569	2,5608	12,604	2,4088	2,8561	2,8212	14,922	2,4988	2,7866	2,7057	15,457	2,5240	2,4343	2,7334	5,8556
$\hat{d}_8$	2,5771	3,2343	2,8875	22,333	2,5627	3,1193	2,9098	20,050	2,5592	2,8817	2,7842	16,742	2,5565	2,4673	2,7638	5,9773
$\hat{d}_9$	2,3379	2,8569	2,5608	10,626	2,4088	2,8561	2,8212	14,922	2,4988	2,7866	2,7057	15,457	2,5240	2,4343	2,7334	5,8556
$\hat{d}_{10}$	2,3379	2,8569	2,5608	10,626	2,4088	2,8562	2,8212	14,922	2,4989	2,7866	2,7057	15,457	2,5240	2,4343	2,7334	5,8556
$\hat{d}_{11}$	2,3907	2,9096	2,5806	11,789	2,4452	2,9039	2,8212	15,805	2,5136	2,8076	2,7104	15,489	2,5321	2,4383	2,7355	5,8595
$\hat{d}_{12}$	2,5768	3,0880	2,6453	16,198	2,5627	3,0599	2,8212	18,903	2,5593	2,8724	2,7244	15,590	2,5566	2,4503	2,7420	5,8725
$\hat{d}_{13}$	2,3379	2,8569	2,5608	10,626	2,4088	2,8561	2,8212	14,922	2,4988	2,7866	2,7057	15,457	2,5240	2,4343	2,7334	5,8556
$\hat{d}_{PSO}$	0,1999	0,0848	0,1231	4,4222	0,0001	0,0100	0,0569	3,3719	0,0001	0,0214	0,0564	3,2455	0,0000	0,0007	0,0041	0,7868
$\hat{d}_{TBO}$	0,1999	0,0863	0,1255	4,5598	0,0001	0,0104	0,0569	3,3652	0,0001	0,0003	0,0563	3,2533	0,0000	0,0007	0,0041	0,7880

Çizelge 6.11. Liu tahmin edicilerinin $p = 4, \rho = 0{,}80, \sigma = 0{,}01; 0{,}5; 1; 5$ senaryosu için HKO değerleri

	$n = 10$				$n = 20$				$n = 50$				$n = 100$			
	0,01	0,5	1	5	0,01	0,5	1	5	0,01	0,5	1	5	0,01	0,5	1	5
EKK	2,5536	2,8775	4,5571	6,1313	2,5757	3,4710	3,6703	17,087	2,5617	2,6419	2,5023	4,6120	2,5573	2,4710	2,7607	2,8283
$\hat{d}_1$	2,5536	2,8774	4,5569	6,1253	2,5757	3,4709	3,6700	16,891	2,5617	2,6419	2,5023	4,6084	2,5573	2,4710	2,7606	2,8257
$\hat{d}_2$	2,3246	2,3602	3,1562	4,2021	2,3995	2,8780	3,1335	8,0723	2,5182	2,5733	2,4294	4,3411	2,5253	2,4335	2,7369	2,7273
$\hat{d}_3$	2,3741	2,3602	3,1562	4,2021	2,4358	2,8780	3,1335	8,0723	2,5275	2,5733	2,4294	4,3411	2,5328	2,4335	2,7369	2,7273
$\hat{d}_4$	2,5536	2,8772	4,5565	6,1249	2,5757	3,4707	3,6699	16,887	2,5617	2,6419	2,5023	4,6084	2,5573	2,4710	2,7606	2,8257
$\hat{d}_5$	2,3222	2,3602	3,1562	4,2021	2,3834	2,8780	3,1335	8,0723	2,5125	2,5733	2,4294	4,3411	2,5239	2,4335	2,7369	2,7273
$\hat{d}_6$	2,3220	2,3602	3,1562	4,6228	2,3813	2,8780	3,1335	8,0723	2,5073	2,5733	2,4294	4,3411	2,5239	2,4335	2,7369	2,7273
$\hat{d}_7$	2,3220	2,3602	3,1562	4,3698	2,3813	2,8780	3,1335	8,0723	2,5073	2,5733	2,4294	4,3411	2,5239	2,4335	2,7369	2,7273
$\hat{d}_8$	2,5535	2,8771	4,5563	6,1306	2,5756	3,4706	3,6697	17,075	2,5616	2,6419	2,5023	4,6119	2,5573	2,4710	2,7606	2,8281
$\hat{d}_9$	2,3220	2,3602	3,1562	4,2021	2,3813	2,8780	3,1335	8,0723	2,5073	2,5733	2,4294	4,3411	2,5239	2,4335	2,7369	2,7273
$\hat{d}_{10}$	2,3220	2,3602	3,1562	4,2021	2,3813	2,8780	3,1335	8,0723	2,5073	2,5733	2,4294	4,3411	2,5239	2,4335	2,7369	2,7273
$\hat{d}_{11}$	2,3726	2,4460	3,2521	4,2306	2,4256	2,9932	3,2365	8,8091	2,5206	2,5843	2,4318	4,3512	2,5321	2,4400	2,7373	2,7301
$\hat{d}_{12}$	2,5536	2,7727	3,5591	4,3181	2,5757	3,3987	3,5804	11,450	2,5617	2,6182	2,4392	4,3832	2,5573	2,4601	2,7384	2,7396
$\hat{d}_{13}$	2,3220	2,3602	3,1562	4,2021	2,3813	2,8780	3,1335	8,0723	2,5073	2,5733	2,4294	4,3411	2,5239	2,4335	2,7369	2,7273
$\hat{d}_{PSO}$	0,0001	0,0315	0,6271	0,7065	0,0001	0,0277	0,0718	1,9391	0,0001	0,0052	0,0070	0,6353	0,0001	0,0079	0,0464	0,1112
$\hat{d}_{TBO}$	0,0001	0,0312	0,6271	0,7065	0,0001	0,0273	0,0718	1,9420	0,0001	0,0052	0,0070	0,6352	0,0001	0,0079	0,0464	0,1112

Çizelge 6.12. Liu tahmin edicilerinin $p = 4, \rho = 0{,}90, \sigma = 0{,}01; 0{,}5; 1; 5$ senaryosu için HKO değerleri

	$n = 10$				$n = 20$				$n = 50$				$n = 100$			
	0,01	0,5	1	5	0,01	0,5	1	5	0,01	0,5	1	5	0,01	0,5	1	5
EKK	2,5595	2,7451	4,9773	55,938	2,5548	3,0124	2,1208	96,307	2,5544	2,5881	2,6900	12,078	2,5618	2,4459	2,4107	5,5998
$\hat{d}_1$	2,5595	2,7451	4,9773	55,682	2,5548	3,0124	2,1207	96,295	2,5544	2,5881	2,6900	12,076	2,5618	2,4459	2,4107	5,5992
$\hat{d}_2$	2,3392	2,4411	2,9737	15,665	2,4198	2,7159	1,9839	52,727	2,4939	2,5440	2,6345	10,370	2,5283	2,4089	2,3797	5,2978
$\hat{d}_3$	2,3711	2,4411	2,9737	15,665	2,4417	2,7159	1,9839	52,727	2,5071	2,5440	2,6345	10,370	2,5360	2,4089	2,3797	5,2978
$\hat{d}_4$	2,5595	2,7450	4,9772	55,676	2,5548	3,0124	2,1207	96,294	2,5544	2,5881	2,6900	12,076	2,5618	2,4459	2,4107	5,5992
$\hat{d}_5$	2,2967	2,4411	2,9737	15,665	2,3854	2,7159	1,9839	52,727	2,4892	2,5440	2,6345	10,370	2,5283	2,4089	2,3797	5,2978
$\hat{d}_6$	2,2967	2,4411	2,9737	46,365	2,3854	2,7159	1,9839	90,065	2,4892	2,5440	2,6345	10,370	2,5283	2,4089	2,3797	5,2978
$\hat{d}_7$	2,3327	2,4468	3,1498	29,758	2,3854	2,7159	1,9839	76,012	2,4892	2,5440	2,6345	10,370	2,5283	2,4089	2,3797	5,2978
$\hat{d}_8$	2,5595	2,7450	4,9771	55,925	2,5548	3,0124	2,1207	96,306	2,5544	2,5881	2,6900	12,078	2,5618	2,4459	2,4107	5,5998
$\hat{d}_9$	2,2967	2,4411	2,9737	15,665	2,3854	2,7159	1,9839	52,727	2,4892	2,5440	2,6345	10,370	2,5283	2,4089	2,3797	5,2978
$\hat{d}_{10}$	2,2967	2,4411	2,9737	15,665	2,3854	2,7159	1,9839	52,727	2,4892	2,5440	2,6345	10,370	2,5283	2,4089	2,3797	5,2978
$\hat{d}_{11}$	2,3468	2,4512	3,2625	19,562	2,4236	2,7656	1,9844	53,631	2,5048	2,5456	2,6349	10,378	2,5362	2,4149	2,3817	5,3027
$\hat{d}_{12}$	2,5590	2,4830	4,6730	34,396	2,5548	2,9557	1,9857	56,397	2,5544	2,5505	2,6362	10,400	2,5615	2,4336	2,3876	5,3174
$\hat{d}_{13}$	2,2967	2,4411	2,9737	15,665	2,3854	2,7159	1,9839	52,727	2,4892	2,5440	2,6345	10,370	2,5283	2,4089	2,3797	5,2978
$\hat{d}_{PSO}$	0,0001	0,0442	0,7134	3,9130	0,0001	0,0327	0,0525	13,002	0,0001	0,0302	0,0344	2,4785	0,0001	0,0052	0,0217	0,2436
$\hat{d}_{TBO}$	0,0001	0,0442	0,7184	3,8563	0,0001	0,0336	0,0525	13,031	0,0001	0,0302	0,0344	2,5050	0,0001	0,0052	0,0217	0,2436

Simülasyon çalışması sonuçları Ridge regresyon için incelendiğinde, sezgisel optimizasyon yöntemleriyle elde edilen k_{PSO} ve k_{TBO}, literatürde önerilen 77 farklı k yanlılık parametresinden ve EKK tahmin yönteminden HKO kriteri bakımından tüm durumlarda daha iyi performans göstermiştir.

Ridge regresyonda sonuçlar açıklayıcı değişken sayısı bakımından incelendiğinde, p arttıkça hem k_{PSO} hem de k_{TBO} parametrelerinin performansında iyileşme görülmektedir. Çalışmada hem $p = 2$ hem de $p = 4$ senaryoları için k_{PSO} yanlılık parametresi k_{TBO} parametresinden HKO kriteri bakımından çoğunlukla daha iyi performans göstermiştir. Bununla birlikte HKO değerleri birbirlerine oldukça yakındır.

Ridge regresyonda sonuçlar korelasyon katsayısı bakımından incelendiğinde, $\rho = 0{,}70$ değerini aldığı senaryolarda k_{PSO} yanlılık parametresi çoğunlukla daha iyi sonuçlar verirken, $\rho = 0{,}80$ ve $\rho = 0{,}90$ değerini aldığı senaryolarda k_{TBO} parametresi çoğunlukla daha iyi performans göstermektedir. Bu sonuç bize bağımlılık yapısının arttığı durumlarda k_{TBO} yanlılık parametresinin daha iyi performans gösterdiğini kanıtlamaktadır.

Ridge regresyonda sonuçlar örnek çapı bakımından incelendiğinde, n arttıkça k_{PSO} yanlılık parametresinin performansında iyileşme görülmektedir. $n = 20$ ve $n = 30$ örnek çapları için k_{TBO} genellikle daha iyi performans gösterirken $n = 50$ ve $n = 100$ örnek çapları için k_{PSO} daha iyi sonuç vermektedir. Bununla birlikte HKO değerleri birbirlerine oldukça yakındır.

Simülasyon çalışması sonuçları Liu regresyon için incelendiğinde, sezgisel optimizasyon yöntemleriyle elde edilen d_{PSO} ve d_{TBO}, literatürde önerilen 13 farklı d yanlılık parametresinden ve EKK tahmin yönteminden HKO kriteri bakımından tüm durumlarda daha iyi performans göstermiştir.

Liu regresyonda sonuçlar açıklayıcı değişken sayısı bakımından incelendiğinde: p arttıkça hem d_{PSO} hem de d_{TBO} parametrelerinin performansında iyileşme görülmektedir. Çalışmada hem $p = 2$ hem de $p = 4$ senaryoları için d_{TBO} yanlılık parametresi d_{PSO} parametresinden HKO kriteri bakımından çoğunlukla daha iyi performans göstermiştir.

Liu regresyonda sonuçlar korelasyon katsayısı bakımından incelendiğinde, ρ değeri arttıkça hem d_{PSO} hem de d_{TBO} yanlılık parametrelerinin performanslarında düşüş görülmektedir. Bununla birlikte $\rho = 0{,}90$ senaryosunda HKO kriteri bakımından çoğunlukla d_{PSO} parametresi daha iyi sonuç verirken, ρ'nun diğer senaryolarında çoğunlukla d_{TBO} daha iyi performans göstermiştir.

Liu regresyonda sonuçlar örnek çapı bakımından incelendiğinde, $n = 20$, $n = 30$ ve $n = 50$ örnek çapları için d_{TBO} genellikle daha iyi performans gösterirken $n = 100$ örnek çapı senaryosu için genellikle d_{PSO} daha iyi sonuç vermektedir.

7. UYGULAMA

Bu çalışmada Woods ve diğerleri (1932) tarafından yapılan Portland çimentolarının sertleştirilmesi sırasındaki ısı değişiminin ölçüldüğü deneysel bir çalışmadan alınan veri seti "Portland Cement" veri seti kullanılmıştır. Bu veri seti ile hem literatürde önerilen yanlılık parametrelerinin hem de PSO ve TBO sezgisel optimizasyon yöntemleriyle önerilen yanlılık parametrelerinin performansları Ridge ve Liu regresyon tahmin yöntemleri kullanılarak HKO ve VIF kriterleri bakımından karşılaştırılmıştır. Veri setinde 13 gözlem, 1 bağımlı değişken ve 4 açıklayıcı değişken bulunmaktadır. Açıklayıcı değişkenler sırasıyla tricalcium aluminate (X_1), tricalcium silicate (X_2), tetracalcium aluminaferrite (X_3) ve beta-dicalcium silicate (X_4); bağımlı değişken ise çimentodan gram başına açığa çıkan ısı miktarı (Y) olarak tanımlanmıştır. Portland Cement veri setindeki bağımlı ve açıklayıcı değişkenlerin matris formu Eş.7.1'deki gibidir:

$$Y = \begin{bmatrix} 78{,}5 \\ 74{,}3 \\ 104{,}3 \\ 87{,}6 \\ 95{,}9 \\ 109{,}2 \\ 102{,}7 \\ 72{,}5 \\ 93{,}1 \\ 115{,}9 \\ 83{,}8 \\ 113{,}3 \\ 109{,}4 \end{bmatrix} \qquad X = \begin{bmatrix} 7 & 26 & 6 & 60 \\ 1 & 29 & 15 & 52 \\ 11 & 56 & 8 & 20 \\ 11 & 31 & 8 & 47 \\ 7 & 52 & 6 & 33 \\ 11 & 55 & 9 & 22 \\ 3 & 71 & 17 & 6 \\ 1 & 31 & 22 & 44 \\ 2 & 54 & 18 & 22 \\ 21 & 47 & 4 & 26 \\ 1 & 40 & 23 & 34 \\ 11 & 66 & 9 & 12 \\ 10 & 68 & 8 & 12 \end{bmatrix} \tag{7.1}$$

Regresyon parametrelerinin karşılaştırılabilir sayısal birimlerle ifade edilebilmesi için veriler birim uzunluk ölçeklendirme yöntemiyle ölçeklendirilmiştir. Birim uzunluk ölçeklendirme yöntemi ile X açıklayıcı değişkeni ve Y bağımlı değişkeni ölçeklendirmek için kullanılan eşitlikler sırasıyla Eş. 7.2 ve Eş. 7.3'teki gibidir.

$$x_j = \frac{x_j - \bar{x}_j}{\sqrt{\sum_{i=1}^{n}(x_j - \bar{x}_j)^2}}, \quad j = 1,2,\dots,p \tag{7.2}$$

$$y_j = \frac{y_j - \bar{y}_j}{\sqrt{\sum_{i=1}^{n}(y - \bar{y}_j)^2}}, \quad j = 1,2,\dots,p \tag{7.3}$$

Ölçeklendirilmiş $X'X$ matrisinin sıralanmış özdeğerlerinden elde edilen köşegen matris λ ve bu özdeğer matrisine karşılık gelen özvektörlerin oluşturduğu özvektör matrisi D sırasıyla Eş. 7.4 ve Eş. 7.5'te verilmiştir:

$$\lambda = \begin{bmatrix} 2{,}235704 & 0 & 0 & 0 \\ 0 & 1{,}576066 & 0 & 0 \\ 0 & 0 & 1{,}186660 & 0 \\ 0 & 0 & 0 & 0{,}001623 \end{bmatrix} \tag{7.4}$$

$$D = \begin{bmatrix} -0{,}475955 & 0{,}508979 & 0{,}675500 & 0{,}241052 \\ -0{,}563870 & -0{,}413991 & -0{,}314420 & 0{,}641756 \\ 0{,}394067 & -0{,}604969 & 0{,}637691 & 0{,}268466 \\ 0{,}547931 & 0{,}451235 & -0{,}195421 & 0{,}676734 \end{bmatrix} \tag{7.5}$$

Bu durumda Eş.3.7'de verilen kanonik form elde edilmektedir ve $\hat{\alpha}$'nın EKK tahmin yöntemiyle elde edilen katsayıları Eş.7.6'da verildiği gibidir:

$$\hat{\alpha}_{EKK} = \begin{bmatrix} -0{,}656957 \\ -0{,}008339 \\ 0{,}302771 \\ 0{,}387961 \end{bmatrix} \tag{7.6}$$

Bununla birlikte σ^2'nin EKK tahmin edicisi $\hat{\sigma}^2 = 0{,}0019852$ olarak elde edilmiştir. Regresyon modelinde çoklu bağlantının testi için tercih edilen koşul sayısı $K.S = \frac{\lambda_{max}}{\lambda_{min}} =$ 1377,5132 olarak hesaplanmıştır. $K.S > 1000$ olduğundan modelde güçlü çoklu bağlantı vardır yorumu yapılabilir. Bu durumda EKK tahmin yöntemiyle elde edilen parametre tahminleri gerçek parametre tahmin değerlerinden uzak sonuçlar verecektir. Bu nedenle yanlı tahmin yöntemlerinden Ridge ve Liu regresyon kullanılarak parametre tahminleri yapılmıştır. Ayrıca bu veri seti için PSO ve TBO algoritmaları aracılığıyla yanlılık parametreleri önerilmiş ve önerilen bu parametreler Çizelge 3.1 ve Çizelge 3.2'de listelenen Ridge ve Liu yanlılık parametreleri ile elde edilen modeller ile HKO ve VIF kriterleri bakımından kıyaslanmıştır.

$S.K$ standartlaştırılmış katsayıları, $\hat{k}_{PSO}$ PSO algoritması ile önerilen Ridge regresyon yanlılık parametresini, $\hat{k}_{TBO}$ TBO algoritması ile önerilen Ridge regresyon yanlılık parametresini, $\hat{d}_{PSO}$ PSO algoritması ile önerilen Liu regresyon yanlılık parametresini, $\hat{d}_{TBO}$

TBO algoritması ile önerilen Liu regresyon yanlılık parametresini ifade etmek üzere, uygulama sonuçları Çizelge 7.1 - Çizelge 7.12’de listelenmiştir.

Çizelge 7.1. k_i yanlılık parametresi için uygulama sonuçları $i = 0:4$

	EKK (k = 0)		$\hat{k}_1 = 0{,}0116$		$\hat{k}_2 = 0{,}0080$		$\hat{k}_3 = 0{,}0681$		$\hat{k}_4 = 0{,}0045$	
Değişken	*S.K.*	*VIF*	*S.K.*	*VIF*	*S.K.*	*VIF*	*S.K.*	*VIF*	*S.K.*	*VIF*
X_1	0,6065	38,4962	0,5109	2,9667	0,5193	3,5366	0,4514	1,5782	0,5325	5,1418
X_2	-0,0083	254,4232	0,3128	4,5276	0,3234	7,9964	0,2988	0,6556	0,3466	18,7948
X_3	0,3028	46,8684	-0,0580	2,8955	-0,0502	3,5737	-0,1025	1,4724	-0,0370	5,5356
X_4	0,3880	282,5129	-0,3853	4,6784	-0,3747	8,5228	-0,3902	0,5079	-0,3570	20,5172
HKO	1,2186		0,0549		0,0689		0,0473		0,1154	

Çizelge 7.2. k_i yanlılık parametresi için uygulama sonuçları $i = 5:9$

	$\hat{k}_5 = 0{,}0772$		$\hat{k}_6 = 0{,}0172$		$\hat{k}_7 = 7{,}0489$		$\hat{k}_8 = 0{,}0045$		$\hat{k}_9 = 0{,}0050$	
Değişken	*S.K.*	*VIF*	*S.K.*	*VIF*	*S.K.*	*VIF*	*S.K.*	*VIF*	*S.K.*	*VIF*
X_1	0,4448	1,4828	0,5015	2,5775	0,0798	0,0130	0,5322	5,0805	0,5297	4,7023
X_2	0,2991	0,6044	0,3053	2,5807	0,0874	0,0122	0,3458	18,3724	0,3410	15,7776
X_3	-0,1067	1,3852	-0,0662	2,4535	-0,0564	0,0132	-0,0374	5,4601	-0,0399	4,9953
X_4	-0,3880	0,4650	-0,3924	2,5320	-0,0888	0,0123	-0,3515	20,0478	-0,3566	17,1643
HKO	0,0485		0,0477		0,4518		0,1135		0,1021	

Çizelge 7.3. k_i yanlılık parametresi için uygulama sonuçları $i = 10:14$

	$\hat{k}_{10} = 0{,}0029$		$\hat{k}_{11} = 0{,}4589$		$\hat{k}_{12} = 0{,}4518$		$\hat{k}_{13} = 0{,}1130$		$\hat{k}_{14} = 17{,}0857$	
Değişken	S.K.	VIF	S.K.	VIF	S.K.	VIF	S.K.	VIF	S.K.	VIF
X_1	0,5430	7,2337	0,3156	0,3731	0,3169	0,3788	0,4224	1,1910	0,0380	0,0028
X_2	0,3689	33,3545	0,2834	0,2105	0,2839	0,2126	0,3001	0,4800	0,0421	0,0027
X_3	-0,0261	8,1169	-0,1547	0,3698	-0,1546	0,3751	0,0434	1,1197	-0,0274	0,0028
X_4	-0,3274	36,7012	-0,3177	0,1905	-0,3187	0,1921	-0,1603	0,3702	-0,0426	0,0027
HKO	0,1806		0,1055		0,1046		0,0541		0,5611	

Çizelge 7.4. k_i yanlılık parametresi için uygulama sonuçları $i = 15:19$

	$\hat{k}_{15} = 0{,}4553$		$\hat{k}_{16} = 0{,}0010$		$\hat{k}_{17} = 0{,}0002$		$\hat{k}_{18} = 0{,}0691$		$\hat{k}_{19} = 0{,}0162$	
Değişken	*S.K.*	*VIF*	*S.K.*	*VIF*	*S.K.*	*VIF*	*S.K.*	*VIF*	*S.K.*	*VIF*
X_1	0,3163	0,3760	0,5693	16,2372	0,5954	30,6986	0,4507	1,5678	0,5029	2,6262
X_2	0,2836	0,2116	0,4323	96,8365	0,4990	199,1928	0,2989	0,6497	0,3062	2,7917
X_3	-0,1547	0,3725	0,0024	19,2678	0,0312	37,1982	-0,1030	1,4629	-0,0650	2,5072
X_4	-0,3182	0,1913	-0,2608	107,2842	-0,1905	221,0988	-0,3899	0,5028	-0,3916	2,7635
HKO	0,1051		0,4741		0,9564		0,0474		0,0484	

Çizelge 7.5. k_i yanlılık parametresi için uygulama sonuçları $i = 20:24$

	$\hat{k}_{20} = 0{,}0430$		$\hat{k}_{21} = 14{,}8457$		$\hat{k}_{22} = 5{,}3063$		$\hat{k}_{23} = 3{,}5992$		$\hat{k}_{24} = 0{,}2778$	
Değişken	*S.K.*	*VIF*	*S.K.*	*VIF*	*S.K.*	*VIF*	*S.K.*	*VIF*	*S.K.*	*VIF*
X_1	0,4723	1,9159	0,0431	0,0036	0,0987	0,0203	0,1286	0,0361	0,3572	0,5949
X_2	0,2985	0,9257	0,0477	0,0035	0,1074	0,0188	0,1384	0,0323	0,2956	0,2852
X_3	-0,0884	1,7851	-0,0310	0,0037	-0,0609	0,0208	-0,0881	0,0370	-0,1478	0,5761
X_4	-0,3954	0,7604	-0,0482	0,0035	-0,1095	0,0188	-0,1419	0,0323	-0,3456	0,2422
HKO	0,0446		0,5471		0,4075		0,3435		0,0807	

Çizelge 7.6. k_i yanlılık parametresi için uygulama sonuçları $i = 25:29$

	$\hat{k}_{25} = 7{,}8045$		$\hat{k}_{26} = 0{,}1301$		$\hat{k}_{27} = 0{,}0079$		$\hat{k}_{28} = 127{,}0978$		$\hat{k}_{29} = 0{,}0079$	
Değişken	*S.K.*	*VIF*	*S.K.*	*VIF*	*S.K.*	*VIF*	*S.K.*	*VIF*	*S.K.*	*VIF*
X_1	0,0737	0,0110	0,4132	1,0850	0,5196	3,5583	0,0056	0,0001	0,5196	3,5620
X_2	0,0809	0,0104	0,3002	0,4422	0,3238	8,1357	0,0063	0,0001	0,3238	8,1595
X_3	-0,0523	0,0112	-0,1250	1,0234	-0,0499	3,5998	-0,0041	0,0001	-0,0499	3,6043
X_4	-0,0821	0,0104	-0,3753	0,3441	-0,3744	8,6773	-0,0063	0,0001	-0,3743	8,7037
HKO	0,4669		0,0570		0,0694		0,6564		0,0695	

Çizelge 7.7. k_i yanlılık parametresi için uygulama sonuçları $i = 30:34$

	$\hat{k}_{30} = 127{,}8616$		$\hat{k}_{31} = 0{,}0079$		$\hat{k}_{32} = 126{,}8616$		$\hat{k}_{33} = 0{,}0093$		$\hat{k}_{34} = 0{,}0166$	
Değişken	*S.K.*	*VIF*	*S.K.*	*VIF*	*S.K.*	*VIF*	*S.K.*	*VIF*	*S.K.*	*VIF*
X_1	0,0057	0,0001	0,5196	3,5584	0,0057	0,0001	0,5159	3,2718	0,5023	2,6047
X_2	0,0063	0,0001	0,3238	8,1365	0,0063	0,0001	0,3187	6,3308	0,3058	2,6972
X_3	-0,0041	0,0001	-0,0499	3,6000	-0,0041	0,0001	-0,0534	3,2558	-0,0655	2,4834
X_4	-0,0064	0,0001	-0,3743	8,6783	-0,0064	0,0001	-0,3795	6,6754	-0,3920	2,6598
HKO	0,6563		0,0694		0,6563		0,0620		0,0481	

Çizelge 7.8. k_i yanlılık parametresi için uygulama sonuçları $i = 35:39$

	$\hat{k}_{35} = 0{,}0089$		$\hat{k}_{36} = 0{,}1137$		$\hat{k}_{37} = 0{,}0155$		$\hat{k}_{38} = 0{,}3607$		$\hat{k}_{39} = 0{,}0162$	
Değişken	*S.K.*	*VIF*	*S.K.*	*VIF*	*S.K.*	*VIF*	*S.K.*	*VIF*	*S.K.*	*VIF*
X_1	0,5169	3,3445	0,4220	1,1858	0,5040	2,6646	0,3360	0,4689	0,5030	2,6297
X_2	0,3200	6,7812	0,3001	0,4781	0,3070	2,9660	0,2904	0,2441	0,3063	2,8071
X_3	-0,0525	3,3428	-0,1202	1,1149	-0,1202	2,5499	-0,1525	0,4595	-0,0649	2,5110
X_4	-0,3782	7,1748	-0,3791	0,3689	-0,3791	2,9552	-0,3320	0,2146	-0,3916	2,7805
HKO	0,0638		0,0543		0,0491		0,0926		0,0485	

Çizelge 7.9. k_i yanlılık parametresi için uygulama sonuçları $i = 40:44$

	$\hat{k}_{40} = 2{,}3170$		$\hat{k}_{41} = 0{,}0041$		$\hat{k}_{42} = 0{,}6754$		$\hat{k}_{43} = 0{,}0116$		$\hat{k}_{44} = 0{,}4514$	
Değişken	*S.K.*	*VIF*	*S.K.*	*VIF*	*S.K.*	*VIF*	*S.K.*	*VIF*	*S.K.*	*VIF*
X_1	0,1671	0,0650	0,5344	5,4660	0,2817	0,2551	0,5109	2,9667	0,3170	0,3791
X_2	0,1764	0,0552	0,3505	21,0335	0,2669	0,1634	0,3128	4,5275	0,2839	0,2127
X_3	-0,1106	0,0669	-0,0350	5,9347	-0,1533	0,2571	-0,0580	2,8954	-0,1546	0,3754
X_4	-0,1825	0,0548	-0,3467	23,0052	-0,2913	0,1537	-0,3853	4,6784	-0,3188	0,1922
HKO	0,2726		0,1253		0,1313		0,0549		0,1046	

Çizelge 7.10. k_i yanlılık parametresi için uygulama sonuçları $i = 45:49$

	$\hat{k}_{45} = 0{,}1740$		$\hat{k}_{46} = 0{,}0435$		$\hat{k}_{47} = 0{,}0075$		$\hat{k}_{48} = 0{,}1601$		$\hat{k}_{49} = 0{,}0043$	
Değişken	*S.K.*	*VIF*	*S.K.*	*VIF*	*S.K.*	*VIF*	*S.K.*	*VIF*	*S.K.*	*VIF*
X_1	0,3930	0,8783	0,4718	1,9075	0,5207	3,6599	0,3990	0,9356	0,5332	5,2579
X_2	0-2998	0,3741	0,2985	0,9165	0,3255	8,7921	0,3001	0,3925	0,3480	19,5955
X_3	-0,1348	0,8353	-0,0887	1,7772	-0,0488	3,7226	-0,1321	0,8876	-0,0363	5,6785
X_4	-0,3644	0,2993	-0,3953	0,7512	-0,3726	9,4058	-0,3685	0,3111	-0,3493	21,4071
HKO	0,0643		0,0446		0,0722		0,0620		0,1189	

Çizelge 7.11. k_i yanlılık parametresi için uygulama sonuçları $i = 50:54$

	$\hat{k}_{50} = 0{,}0705$		$\hat{k}_{51} = 19{,}1588$		$\hat{k}_{52} = 5{,}9362$		$\hat{k}_{53} = 0{,}0065$		$\hat{k}_{54} = 0{,}0073$	
Değişken	*S.K.*	*VIF*	*S.K.*	*VIF*	*S.K.*	*VIF*	*S.K.*	*VIF*	*S.K.*	*VIF*
X_1	0,4496	1,5517	0,0038	0,0654	0,0909	0,0171	0,5238	3,9667	0,5214	3,7239
X_2	0,2989	0,6407	0,0042	0,0264	0,0992	0,0159	0,3304	10,8101	0,3265	9,2087
X_3	-0,1037	1,4481	-0,0027	0,0789	-0,0639	0,0174	-0,0458	4,0954	-0,0482	3,8001
X_4	-0,3896	0,4952	-0,0042	0,0201	-0,1010	0,0159	-0,3675	11,6462	-0,3715	9,8683
HKO	0,0476		0,6621		0,4254		0,0807		0,0739	

Çizelge 7.12. k_i yanlılık parametresi için uygulama sonuçları $i = 55:59$

	$\hat{k}_{55} = 0{,}0469$		$\hat{k}_{56} = 0{,}0668$		$\hat{k}_{57} = 0{,}0088$		$\hat{k}_{58} = 0{,}00001$		$\hat{k}_{59} = 0{,}4473$	
Değişken	*S.K.*	*VIF*	*S.K.*	*VIF*	*S.K.*	*VIF*	*S.K.*	*VIF*	*S.K.*	*VIF*
X_1	0,4687	1,8534	0,4524	1,5927	0,5117	3,3592	0,6065	38,4962	0,3178	0,3825
X_2	0,2984	0,8608	0,2988	0,6641	0,0302	6,8724	0,5277	254,4232	0,2842	0,2139
X_3	-0,0909	1,7265	-0,1019	1,4857	-0,0523	3,3603	0,0434	46,8684	-0,1546	0,3786
X_4	-0,3947	0,6967	-0,3905	0,5152	-0,3779	7,2760	-0,1603	282,5129	-0,3193	0,1931
HKO	0,0449		0,0471		0,0642		1,2186		0,1041	

Çizelge 7.13. k_i yanlılık parametresi için uygulama sonuçları $i = 60:64$

	$\hat{k}_{60} = 14{,}9041$		$\hat{k}_{61} = 5{,}2855$		$\hat{k}_{62} = 3{,}5993$		$\hat{k}_{63} = 1{,}5163$		$\hat{k}_{64} = 7{,}8352$	
Değişken	*S.K.*	*VIF*	*S.K.*	*VIF*	*S.K.*	*VIF*	*S.K.*	*VIF*	*S.K.*	*VIF*
X_1	0,0429	0,0036	0,0990	0,0205	0,1286	0,0361	0,2067	0,1081	0,0735	0,0109
X_2	0,0475	0,0035	0,1077	0,0189	0,1384	0,0323	0,2123	0,0854	0,0806	0,0104
X_3	-0,0309	0,0036	-0,0692	0,0209	-0,0881	0,0370	-0,1304	0,1112	-0,0521	0,0111
X_4	-0,0408	0,0035	-0,1098	0,0189	-0,1419	0,0323	-0,2226	0,0840	-0,0819	0,0104
HKO	0,5476		0,4068		0,3435		0,2128		0,4674	

Çizelge 7.14. k_i yanlılık parametresi için uygulama sonuçları $i = 65:69$

	$\hat{k}_{65} = 0{,}0116$		$\hat{k}_{66} = 0{,}0078$		$\hat{k}_{67} = 0{,}0073$		$\hat{k}_{68} = 0{,}0053$		$\hat{k}_{69} = 0{,}0275$	
Değişken	*S.K.*	*VIF*	*S.K.*	*VIF*	*S.K.*	*VIF*	*S.K.*	*VIF*	*S.K.*	*VIF*
X_1	0,5109	2,9665	0,5199	3,5852	0,5214	3,7239	0,5286	4,5573	0,4882	2,2264
X_2	0,3128	4,5265	0,3242	8,3086	0,3265	9,2088	0,3390	14,7885	0,3002	1,4348
X_3	-0,0580	2,8952	-0,0496	3,6323	-0,0482	3,8001	-0,0410	4,8174	-0,0767	2,0855
X_4	-0,3853	4,6772	-0,3739	8,8692	-0,3715	9,8683	-0,3586	16,0654	-0,3962	1,2882
HKO	0,0549		0,0701		0,0739		0,0978		0,0445	

Çizelge 7.15. k_i yanlılık parametresi için uygulama sonuçları $i = 70:74$

	$\hat{k}_{70} = 2{,}5111$		$\hat{k}_{71} = 0{,}0045$		$\hat{k}_{72} = 0{,}0674$		$\hat{k}_{73} = 0{,}0116$		$\hat{k}_{74} = 0{,}1078$	
Değişken	*S.K.*	*VIF*	*S.K.*	*VIF*	*S.K.*	*VIF*	*S.K.*	*VIF*	*S.K.*	*VIF*
X_1	0,1598	0,0586	0,5322	5,0805	0,4520	1,5866	0,5109	2,9667	0,4254	1,2264
X_2	0,1694	0,0504	0,3458	18,3724	0,2988	0,6606	0,3128	4,5276	0,3000	0,4933
X_3	-0,1066	0,0604	-0,0374	5,4601	-0,1022	1,4801	-0,0580	2,8955	-0,1184	1,1518
X_4	-0,1749	0,0501	-0,3515	20,0478	-0,3903	0,5121	-0,3853	4,6784	-0,3805	0,3797
HKO	0,2851		0,1135		0,0472		0,0549		0,0533	

Çizelge 7.16. k_i, k_{PSO}, k_{TBO} yanlılık parametresi uygulama sonuçları $i = 75{:}\,77$

	$\hat{k}_{75} = 0{,}0772$		$\hat{k}_{76} = 0{,}2778$		$\hat{k}_{77} = 0{,}0172$		$\hat{k}_{PSO} = 0{,}0188$		$\hat{k}_{TBO} = 0{,}0084$	
Değişken	*S.K.*	*VIF*	*S.K.*	*VIF*	*S.K.*	*VIF*	*S.K.*	*VIF*	*S.K.*	*VIF*
X_1	0,4448	1,4828	0,3572	0,5949	0,5015	2,5775	0,4991	2,5045	0,5182	3,4414
X_2	0,2991	0,6040	0,2956	0,2852	0,6053	2,5807	0,3041	2,2865	0,3217	7,3896
X_3	-0,1067	1,3852	-0,1478	0,5761	-0,0662	2,4535	-0,0681	2,3742	-0,0513	3,4590
X_4	-0,3880	0,4650	-0,3456	0,2422	-0,3924	2,5320	-0,3935	2,2098	-0,3764	7,8496
HKO	0,0485		0,0807		0,0477		0,0468		0,0663	

Çizelge 7.17. d_i yanlılık parametresi için uygulama sonuçları $i = 1{:}\,5$

	$\hat{d}_1 = 0{,}4888$		$\hat{d}_2 = 0{,}0084$		$\hat{d}_3 = 0{,}1256$		$\hat{d}_4 = 0{,}4888$		$\hat{d}_5 = 0$	
Değişken	*S.K.*	*VIF*	*S.K.*	*VIF*	*S.K.*	*VIF*	*S.K.*	*VIF*	*S.K.*	*VIF*
X_1	0,4221	0,8333	0,2488	0,3822	0,2911	0,4763	0,4221	0,8333	0,2458	0,3759
X_2	0,3824	0,9634	0,2459	0,4419	0,2792	0,5507	0,3824	0,9634	0,2435	0,4346
X_3	-0,0530	0,8106	-0,1437	0,3718	-0,1216	0,4634	-0,0530	0,8106	-0,1453	0,3657
X_4	-0,2112	0,9692	-0,2591	0,4446	-0,2474	0,5540	-0,2112	0,9692	-0,2599	0,4372
HKO	0,3610		0,2534		0,2172		0,3610		0,2575	

Çizelge 7.18. d_i yanlılık parametresi için uygulama sonuçları $i = 6{:}\,10$

	$\hat{d}_6 = 0$		$\hat{d}_7 = 0$		$\hat{d}_8 = 0$		$\hat{d}_9 = 0$		$\hat{d}_{10} = 0{,}0042$	
Değişken	*S.K.*	*VIF*	*S.K.*	*VIF*	*S.K.*	*VIF*	*S.K.*	*VIF*	*S.K.*	*VIF*
X_1	0,2458	0,3759	0,2458	0,3759	0,2458	0,3759	0,2458	0,3759	0,2473	0,3791
X_2	0,2435	0,4346	0,2435	0,4346	0,2435	0,4346	0,2435	0,4346	0,2447	0,4383
X_3	-0,1453	0,3657	-0,1453	0,3657	-0,1453	0,3657	-0,1453	0,3657	-0,1445	0,3687
X_4	-0,2599	0,4372	-0,2599	0,4372	-0,2599	0,4372	-0,2599	0,4372	-0,2595	0,4409
HKO	0,2575		0,2575		0,2575		0,2575		0,2554	

Çizelge 7.19. d_i, d_{PSO}, d_{TBO} yanlılık parametresi uygulama sonuçları $i = 11{:}13$

	$\hat{d}_{11} = 0{,}0058$		$\hat{d}_{12} = 0{,}0150$		$\hat{d}_{13} = 0$		$\hat{d}_{PSO} = 0{,}1855$		$\hat{d}_{TBO} = 0{,}1852$	
Değişken	*S.K.*	*VIF*	*S.K.*	*VIF*	*S.K.*	*VIF*	*S.K.*	*VIF*	*S.K.*	*VIF*
X_1	0,2479	0,3803	0,2512	0,3873	0,2458	0,3759	0,3126	0,5284	0,3127	0,5281
X_2	0,2451	0,4397	0,2478	0,4478	0,2435	0,4346	0,2961	0,6109	0,2962	0,6106
X_3	-0,1442	0,3700	-0,1424	0,3768	-0,1453	0,3657	-0,1103	0,5140	-0,1103	0,5137
X_4	-0,2593	0,4423	-0,2584	0,4505	-0,2599	0,4372	-0,2414	0,6145	-0,2414	0,6142
HKO	0,2546		0,2503		0,2575		0,2143		0,2143	

Ridge regresyon için incelenen uygulama sonuçları Çizelge 7.1 - Çizelge 7.16'da verilen tablolarda listelenmiştir. Sonuçlar incelendiğinde, $\hat{k}_{58}$ yanlılık parametresi dışında literatürde önerilen k yanlılık parametreleri kullanılarak elde edilen tahminler HKO kriteri bakımından, EKK tahmin yöntemine kıyasla daha iyi performans göstermiştir.

Literatürde önerilen k yanlılık parametreleri kendi aralarında kıyaslandığında incelenen veri seti için en iyi performans gösteren yanlılık parametrelerinin, Muniz ve Kibria (2009) tarafından önerilen $\hat{k}_{20}$, Alkhamisi ve diğerleri (2006) tarafından önerilen $\hat{k}_{46}$, Dorugade (2016) tarafından önerilen $\hat{k}_{55}$, Lukman ve diğerleri (2017) tarafından önerilen $\hat{k}_{69}$ olduğu görülmektedir.

İki farklı optimizasyon algoritması kullanılarak önerilen $\hat{k}_{PSO}$ ve $\hat{k}_{TBO}$ yanlılık parametreleri ile elde edilen tahminler EKK tahmin yönteminden daha iyi performans göstermektedir. PSO algoritması ile önerilen $\hat{k}_{PSO}$, klasik yöntemlerle önerilen $\hat{k}_{20}$, $\hat{k}_{46}$, $\hat{k}_{55}$, $\hat{k}_{57}$ ve $\hat{k}_{69}$ yanlılık parametreleri dışında önerilen diğer yanlılık parametrelerinden daha iyi performans göstermiştir. TBO algoritması ile önerilen $\hat{k}_{TBO}$ ise klasik yöntemlerle önerilen $\hat{k}_1$, $\hat{k}_3$, $\hat{k}_5$, $\hat{k}_6$, $\hat{k}_7$, $\hat{k}_{13}$, $\hat{k}_{18}$, $\hat{k}_{19}$, $\hat{k}_{20}$, $\hat{k}_{26}$, $\hat{k}_{33}$, $\hat{k}_{34}$, $\hat{k}_{36}$, $\hat{k}_{37}$, $\hat{k}_{39}$, $\hat{k}_{43}$, $\hat{k}_{46}$, $\hat{k}_{50}$, $\hat{k}_{55}$, $\hat{k}_{56}$, $\hat{k}_{57}$, $\hat{k}_{65}$, $\hat{k}_{73}$, $\hat{k}_{74}$, $\hat{k}_{75}$, $\hat{k}_{77}$ yanlılık parametreleri dışında önerilen diğer yanlılık parametrelerinden daha iyi performans göstermiştir.

PSO algoritması ve TBO algoritması ile önerilen yanlılık parametreleri kendi aralarında kıyaslandığında bu veri seti için $\hat{k}_{PSO}$, $\hat{k}_{TBO}$'dan daha iyi performans göstermiştir.

Liu regresyon için incelenen uygulama sonuçları Çizelge 7.17 - Çizelge 7.19'da verilen tablolarda listelenmiştir. Bu sonuçlar HKO kriteri bakımından incelendiğinde literatürde önerilen d yanlılık parametreleri kullanılarak elde edilen tahminler, EKK tahmin yöntemine kıyasla daha iyi performans göstermiştir.

Bununla birlikte literatürde önerilen d yanlılık parametreleri kendi içinde kıyaslandığında bu veri seti için en iyi performans gösteren yanlılık parametresinin, Shukur ve diğerleri (2015) tarafından önerilen $\hat{d}_3$ olduğu görülmektedir.

İki farklı optimizasyon algoritması kullanılarak önerilen $\hat{d}_{PSO}$ ve $\hat{d}_{TBO}$ yanlılık parametreleri ile elde edilen tahminler hem EKK tahmin yönteminden hem de klasik yöntemlerle önerilen yanlılık parametrelerinden bu veri seti için daha iyi performans göstermektedir.

PSO algoritması ve TBO algoritması ile önerilen yanlılık parametreleri kendi aralarında kıyaslandığında $\hat{d}_{PSO}$ ve $\hat{d}_{TBO}$ HKO kriteri bakımından benzer sonuçları vermektedir. Ancak $\hat{d}_{TBO}$ yanlılık parametresi VIF kriteri bakımından $\hat{d}_{PSO}$ yanlılık parametresinden daha iyi performans göstermiştir.

Ayrıca bu veri seti için Ridge regresyon ve Liu regresyon yanlı tahmin yöntemleri kıyaslandığında, Ridge regresyon tahmin yöntemi Liu regresyona kıyasla daha iyi performans göstermiştir.

8. SONUÇLAR VE ÖNERİLER

Çoklu doğrusal regresyon analizinde en temel problemlerden biri çoklu bağlantıdır. Modelde çoklu bağlantı probleminin olması durumunda, EKK tahmin edicisi yansız olmasına karşın varyansı aşırı büyür. Bu nedenle, EKK tahmin edicisiyle elde edilen parametre tahmin değeri parametrenin gerçek değerinden uzaklaşır. Çoklu bağlantı problemini ortadan kaldırmak için yanlı tahmin yöntemlerini kullanmak bir çözüm olarak önerilmiştir. Bu yanlı tahmin edicilerden sıklıkla tercih edileni Ridge regresyon tahmin edicisidir. Daha sonra bu tahmin ediciye alternatif olarak Liu tahmin edicisi önerilmiştir. Bu tahmin ediciler için optimum yanlılık parametresini belirlemek önemli bir problemdir ve literatürde bu amaçla yapılan pek çok çalışma vardır.

Bununla birlikte bir optimizasyon tekniği olan PSO yöntemiyle Ridge ve Liu Regresyon tahmin edicileri için optimal yanlılık parametrelerinin belirlenmesine ilişkin çalışmalar yapılmıştır. Literatürde bulunan bir başka optimizasyon yöntemi ise TBO yöntemidir. Bu yöntemin PSO'ya göre avantajı yerel minimum noktalarına takılmamasıdır. Buradan hareketle bu çalışmada, Ridge ve Liu tahmin yöntemleri için optimal yanlılık parametrelerini elde etmek amacıyla TBO' ya dayalı yeni bir algoritma önerilmiştir. Bu algoritma yardımıyla Ridge ve Liu tahmin yöntemleri için optimal yanlılık parametreleri elde edilmiş ve daha önce literatürde önerilen yanlılık parametreleri ile simülasyon yardımıyla karşılaştırılmıştır. Ayrıca simülasyon çalışması bir gerçek veri seti uygulaması ile desteklenmiştir.

Ridge regresyon için simülasyon sonuçları Çizelge 6.1 - Çizelge 6.6'da verilen tablolarda özetlenmiştir. Sonuçları incelendiğinde sezgisel optimizasyon yöntemleriyle elde edilen k_{PSO} ve k_{TBO}, literatürde önerilen 77 farklı k yanlılık parametresinden ve EKK tahmin yönteminden HKO kriteri bakımından tüm durumlarda daha iyi performans göstermiştir. Ayrıca p arttıkça hem k_{PSO} hem de k_{TBO} parametrelerinin performansında iyileşme görülmektedir. Çalışmada hem $p = 2$ hem de $p = 4$ senaryoları için k_{PSO} yanlılık parametresi k_{TBO} parametresinden HKO kriteri bakımından çoğunlukla daha iyi performans göstermiştir. Bununla birlikte HKO değerleri birbirlerine oldukça yakındır. Ayrıca $\rho = 0{,}70$ değerini aldığı senaryolarda k_{PSO} yanlılık parametresi çoğunlukla daha iyi sonuçlar verirken, $\rho = 0{,}80$ ve $\rho = 0{,}90$ değerini aldığı senaryolarda ise k_{TBO} parametresi çoğunlukla daha iyi performans göstermektedir. Bu sonuca göre, Ridge regresyonda bağımlılık yapısının arttığı

durumlarda k_{TBO} yanlılık parametresi tercih edilebilir. Ayrıca n arttıkça k_{PSO} yanlılık parametresinin performansında iyileşme görülmektedir.

Liu regresyon için simülasyon sonuçları Çizelge 6.7 - Çizelge 6.12'de verilen tablolarda özetlenmiştir. Sonuçlar incelendiğinde, sezgisel optimizasyon yöntemleriyle elde edilen d_{PSO} ve d_{TBO}, literatürde önerilen 13 farklı d yanlılık parametresinden ve EKK tahmin yönteminden HKO kriteri bakımından tüm durumlarda daha iyi performans göstermiştir. Liu regresyonda sonuçlar açıklayıcı değişken sayısı bakımından incelendiğinde: p arttıkça hem d_{PSO} hem de d_{TBO} parametrelerinin performansında iyileşme görülmektedir. Çalışmada hem $p = 2$ hem de $p = 4$ senaryoları için d_{TBO} yanlılık parametresi d_{PSO} parametresinden HKO kriteri bakımından çoğunlukla daha iyi performans göstermiştir.

Liu regresyonda sonuçlar korelasyon katsayısı bakımından incelendiğinde, ρ değeri arttıkça hem d_{PSO} hem de d_{TBO} yanlılık parametrelerinin performanslarında düşüş görülmektedir. Bununla birlikte $\rho = 0{,}90$ senaryosunda HKO kriteri bakımından çoğunlukla d_{PSO} parametresi daha iyi sonuç verirken, ρ'nun diğer senaryolarında çoğunlukla d_{TBO} daha iyi performans göstermiştir. Liu regresyonda sonuçlar örnek çapı bakımından incelendiğinde, $n = 20$, $n = 30$ ve $n = 50$ örnek çapları için d_{TBO} genellikle daha iyi performans gösterirken $n = 100$ örnek çapı senaryosu için genellikle d_{PSO} daha iyi sonuç vermektedir.

Sonuç olarak, HKO kriterine göre Ridge regresyon için en iyi performansı çoğunlukla PSO algoritması ile önerilen $\hat{k}_{PSO}$ yanlılık parametresi vermiştir. Bununla birlikte $\hat{k}_{TBO}$ ile hesaplanan HKO değerleri, $\hat{k}_{PSO}$ ile hesaplanan HKO değerlerine oldukça yakın sonuçlar vermiştir. Liu tahmin edicisi için ise TBO algoritması ile önerilen $\hat{d}_{TBO}$ yanlılık parametresi genellikle $\hat{d}_{PSO}$'dan daha iyi performans göstermiştir. Bu nedenle Liu tahmin yöntemi için, TBO algoritması ile önerilen $\hat{d}_{TBO}$'nun kullanılması daha uygundur.

KAYNAKLAR

Abdul Kareem, Q., and Zakariya Algamal, Y. (2020). Generalized ridge estimator shrinkage estimation based on particle swarm optimization algorithm. *Iraqi Journal of Statistical Science*, 32, 37-52.

Abdulkareem Abdulazeez, Q., and Yahya Algamal, Z. (2020). Employing particle swarm optimization algorithm for shrinkage parameter estimation in generalized Liu estimator. *International Journal of Advanced Statistics and Probability*, 8(1), 10-15.

Ahn, J. J., Byun, H. W., Oh, K. J., and Kim, T. Y. (2012). Using ridge regression with genetic algorithm to enhance real estate appraisal forecasting. *Expert Systems with Applications*, 39(9), 8369-8379.

Akdeniz, F., and Kaçıranlar, S. (1995). On the almost unbiased generalized liu estimator and unbiased estimation of the bias and MSE. *Communications in Statistics - Theory and Methods*, 24(7), 1789-1797.

Aktaş, C. (2007). Çoklu bağıntı ve LIU kestiricisiyle enflasyon modeli için bir uygulama. *ZKÜ Sosyal Bilimler Dergisi,* 3(2), 67-79.

Al-Hassan, Y. M. (2010). Performance of a new ridge regression estimator. *Journal of the Association of Arab Universities for Basic and Applied Sciences*, 9(1), 23-26.

Alkhamisi, M. A., and Shukur, G. (2007). A monte carlo study of recent ridge parameters. *Communications in Statistics - Simulation and Computation*, 36(3), 535-547.

Alkhamisi, M. A., and Shukur, G. (2008). Developing ridge parameters for SUR model. *Communications in Statistics - Theory and Methods*, 37(4), 544-564.

Alkhamisi, M., Khalaf, G., and Shukur, G. (2006a). Some modifications for choosing ridge parameters. *Communications in Statistics - Theory and Methods*, 35(11), 2005-2020.

Alkhamisi, M., Khalaf, G., and Shukur, G. (2006b). Some modifications for choosing ridge parameters. *Communications in Statistics - Theory and Methods*, 35(11), 2005-2020.

Alpar, R. (2011). *Uygulamalı çok değişkinli istatistiksel yöntemler* (3. baskı). Ankara: Detay Yayıncılık, 35-48.

Asar, Y., Karaibrahimoglu, A., and Genc, A. (2014). Modified ridge regression parameters: a comparative monte carlo study. *Hacettepe Journal of Matgematics and Statistics*, 43(5), 827-841.

Aydın, D. (2014). *Uygulamalı regresyon analizi kavramlar ve R hesaplamaları* (1. baskı). İstanbul: Nobel Yayıncılık, 85-93.

Bas, E., Egrioglu, E., and Rezan Uslu, V. (2017). Shrinkage parameters for each explanatory variable found via particle swarm optimization in ridge regression. *Trends in Computer Science and Information Technology*, 2(1), 12-20.

Bhat, S., and Vidya, R. (2016). A comparative study on the performance of new ridge estimators. *Pakistan Journal of Statistics and Operation Research*, 12(2), 317.

Bozorg-Haddad, O., Solgi, M., and Loaiciga, H. A. (2017). *Meta-heuristic and evolutionary algorithms for engineering optimization*. New York: John Wiley & Sons, 122-125.

Cagcag, O., Yolcu, U., and Egrioglu, E. (2015). A new robust regression method based on particle swarm optimization. *Communications in Statistics - Theory and Methods*, 44(6), 1270-1280.

Chatterjee, S., and Hadi, A. S. (2012). *Regression Analysis by Example* (5. Edition). New York: Wiley, 102-105.

Derman, D. A. (2019). *Çoklu bağlantı durumunda yanlı regresyon yöntemlerinin incelenmesi*. Yüksek Lisans Tezi, Ordu Üniversitesi Fen Bilimleri Enstitüsü, Ordu, 122-135.

Dorugade, A. V. (2014a). New ridge parameters for ridge regression. Içinde *Journal of the Association of Arab Universities for Basic and Applied Sciences*, 15(1), 94-99.

Dorugade, A. V. (2014b). On Comparison of Some Ridge Parameters in Ridge Regression. *Sri Lankan Journal of Applied Statistics*, 15(1), 31-36.

Dorugade, A. V. (2016). Improved Ridge Estimator in Linear Regression with Multicollinearity, Heteroscedastic Errors and Outliers. *Journal of Modern Applied Statistical Methods*, 15(2), 362-381.

Dorugade, A. V., and Kashid, D. N. (2010). Alternative method for choosing ridge parameter for regression. *Applied Mathematical Sciences*, 4(9), 447-456.

Erdinç, O. (2017). *Optimization in renewable energy systems*. Amsterdam: Elsevier, 45-52.

Farrar, D. E. and Glauber, R. R. (1967). Multicollinearity in regression analysis: the problem revisited. *The Review of Economic and Statistics*,5(1), 92-107.

Frisch, R. (1935). Statistical confluence analysis by means of complete regression system. *The Economic Journal*, 45(180), 741-742.

Gibbons, D. G. (1981). A simulation study of some ridge estimators. *Journal of the American Statistical Association*, 76(373), 131.

Gökpınar, E., Ebegil, M. and Gökpınar, F. (2017). A review on shrinkage parameters in ridge regression. *Gazi University Journal of Science*, 30(4), 565-582.

Göktaş, A., and Sevinç, V. (2016). Two new ridge parameters and a guide for selecting an appropriate ridge parameter in linear regression. *Gazi University Journal of Science*, 29(1), 15-32.

Hocking, R. R., Speed, F. M., and Lynn, M. J. (1976). A class of biased estimators in linear regression. *Technometrics*, 18(4), 425.

Hoerl, A. E., and Kennard, R. W. (1970). *Ridge Regression: Biased Estimation for Nonorthogonal Problems*. 12(1), 55-67.

Hoerl, A. E., Kannard, R. W., and Baldwin, K. F. (1975). Ridge regression: Some Simulations. *Communications in Statistics*, 4(2), 105-123.

Huang, J., Ma, L., and Li, R. (2019). Retracted: study on measurement reliability based on liu estimator. *Concurrency and Computation: Practice and Experience*, 31(12), 32-38.

İnan, D. and Sancar, N. (2020). Particle swarm optimization based ridge logistic estimator. *Communications in Statistics - Simulation and Computation*, 49(3), 669-683.

İnan, D., Egrioglu, E., Sarica, B., Askin, O. E., and Tez, M. (2017). Particle swarm optimization based Liu-type estimator. *Communications in Statistics - Theory and Methods*, 46(22), 11358-11369.

İnternet: Alheety, M. I., and Golam Kibria, B. M. (2009). *On the liu and almost unbiased liu estimators in the presence of multicollinearity with heteroscedastic or correlated errors*. Web: http://www.utgjiu.ro/math/sma, Son Erişim Tarihi: 06.03.2023.

Kaçıranlar, S. (2003). Liu estimator in general linear regression model. *Journal of Applied Statistical Science*, 13, 229-234.

Karaibrahimoğlu, A., Asar, Y., and Genç, A. (2016). Some new modifications of Kibria's and Dorugade's methods: An application to Turkish GDP data. *Journal of the Association of Arab Universities for Basic and Applied Sciences*, 20, 89-99.

Kennedy, J., and Eberhart, R. (1955). *Particle swarm optimization*. Proceedings of ICNN'95-International Conference on Neural Networks, New York, 45-52.

Khalaf, G. (2012). A proposed ridge parameter to ımprove the least square estimator. *Journal of Modern Applied Statistical Methods*, 11(2), 443-449.

Khalaf, G. (2013). A comparison between biased and unbiased estimators in ordinary least squares regression. *Journal of Modern Applied Statistical Methods*, 12(2), 293-

Khalaf, G., and Iguernane, M. (2014). Ridge regression and III-Conditioning. *Journal of Modern Applied Statistical Methods*, 13(2), 355-363.

Khalaf, G., and Iguernane, M. (2016). Multicollinearity and a ridge parameter estimation approach. *Journal of Modern Applied Statistical Methods*, 15(2), 400-410.

Khalaf, G., and Shukur, G. (2005). Choosing ridge parameter for regression problems. *Communications in Statistics - Theory and Methods*, 34(5), 1177-1182.

Kibria, B. M. (2003). Performance of some new ridge regression estimators. *Communications in Statistics Part B: Simulation and Computation*, 32(2), 419-435.

Kibria, G., Månsson, K., and Shukur, G. (2012). Performance of Some Logistic Ridge Regression Estimators. *Computational Economics*, 40(4), 401-414.

Kirkpatrick, S., Gelatt Jr, C. D. and Vecchi, M. P. (1983). Optimization by simulated annealing. *Science*, 220(4598), 671-680.

Kothari, V., Anuradha, J., Shah, S. and Mittal, P. (2011). *A survey on particle swarm optimization in feature selection.* International Conference on Computing and Communication Systems, Berlin, 192-201.

Kumar, K., Zindani, D., and Davim Paulo, J. (2020). *Optimizing engineering problems through Heuristic Techniques*. New York: CRC Press, 65-78.

Lawless, F. F., and Wang, P. (1976). A simulation study of ridge and other regression estimators. *Communications in Statistics - Theory and Methods*, 5(4), 307-323.

Liu, K. (1993). A new class of blased estimate in linear regression. *Communications in Statistics - Theory and Methods*, 22(2), 393-402.

Lukman, A. F., and Olatunji, A. (2017). Newly proposed estimator for ridge parameter an application to the nigerian economy. *Pakistan Journal of Statistics*, 34(2), 91-98.

Lukman, A. F., Ayinde, K., and Ajiboye, A. S. (2017). Monte Carlo study of some classification-based ridge parameter estimators. *Journal of Modern Applied Statistical Methods*, 16(1), 428-451.

Månsson, K., Kibria, B. M. G., and Shukur, G. (2012). On Liu estimators for the logit regression model. *Economic Modelling*, 29(4), 1483-1488.

Marquaridt, D. W. (1970). Generalized inverses, ridge regression, biased linear estimation, and nonlinear estimation. *Technometrics*, 12(3), 591-612.

Mermi, S., Göktaş, A., and Akkuş, Ö. (2021). Are most proposed ridge parameter estimators skewed and do they have any effect on MSE values? *Journal of Statistical Computation and Simulation*, 91(10), 2074-2093.

Metropolis, N., Rosenbluth, A. W., Rosenbluth, M. N., Teller, A. H., and Teller, E. (1953). Equation of state calculations by fast computing machines. *The Journal of Chemical Physics*, 21(6), 1087-1092.

Montgomery C., D., Peck, E. A., and Vining, G. G. (2012). *Introduction to linear regression analysis* (5. Edition). New York: Wiley, 85-92.

Muniz, G. and Kibria, B. M. G. (2009). On Some Ridge Regression Estimators: An Empirical Comparisons. *Communications in Statistics - Simulation and Computation*, *38*(3), 621-630.

Muniz, G., Golam Kibria, B. M., Mansson, K., and Shukur, G. (2012). On developing ridge regression parameters: a graphical investigation. *Statistics & Operations Research Transactions SORT*, 36(2), 115-138.

Nomura, M. (1988). On the almost unbiased ridge regression estimator. *Communications in Statistics - Simulation and Computation*, 17(3), 729-743.

Özbey, F. and Kaçıranlar, S. (2015). Evaluation of the predictive performance of the liu estimator. *Communications in Statistics - Theory and Methods*, 44(10), 1981-1993.

Qasim, M., Amin, M., and Omer, T. (2020). Performance of some new Liu parameters for the linear regression model. *Communications in Statistics - Theory and Methods*, 49(17), 4178-4196.

Rao, S. S. (2009). *Engineering Optimization Theory and Practice* (4. edition). New York: Wiley & Sons, 112-115.

Rawlings, J. O., Pantula, S. G., and Dickey, D. A. (1998). *Applied Regression Analysis: A Reasearch Tool*. (2. edition). New York: Springer, 42-45.

Sakallioğlu, S., Kaçıranlar, S., and Akdeniz, F. (2001). Mean squared error comparısons of some bıased regressıon estımators. *Communications in Statistics - Theory and Methods*, 30(2), 347-361.

Saleh, A. K. Md. E., Arashi, M., Saleh, R. A., and Norouzirad, M. (2022). *Rank-Based Methods for Shrinkage and Selection*. New York: Wiley & Sons, 102-105.

Saleh, A. K. Md. E., Kibria, B. M. G., Arashi, M. (Mohammad), and Kibria, G. (2019). *Theory of ridge regression estimation with applications*. New York: Wiley, 15-22.

Schaefer, R. L., Roi, L. D., and Wolfe, R. A. (1984). A ridge logistic estimator. *Communications in Statistics - Theory and Methods*, 13(1), 99-113.

Schreiber-Gregory, D. N. (2018). Ridge Regression and multicollinearity: An in-depth review. *Model Assisted Statistics and Applications*, 13(4), 359-365.

Shukur, G., Månsson, K., and Sjölander, P. (2015). Developing interaction shrinkage parameters for the liu estimator — with an application to the electricity retail market. *Computational Economics*, *46*(4), 539-550.

Sinan, A. (2003). *Lineer regresyonda ridge tahmin edicileri ve bir uygulama*. Yüksek Lisans Tezi, Selçuk Üniversitesi Fen Bilimleri Enstitüsü, Konya.

Strenski, P. N., and Kirkpatrick, S. (1991). Analysis of finite length annealing schedules. *Algorithmica*, 6, 346-366.

Şahin, R. (2004). *Çok kriterli dinamik tesis düzenleme probleminin tavlama benzetimi ile çözülmesi*. Yüksek Lisans Tezi, Gazi Üniversitesi Fen Bilimleri Enstitüsü, Ankara.

Talbi, E.-G. (2009). *Metaheuristics : from design to implementation*. New York: John Wiley & Sons, 26-35.

Toker, S., and Kaçıranlar, S. (2013). On the performance of two parameter ridge estimator under the mean square error criterion. *Applied Mathematics and Computation*, 219(9), 4718-4728.

Uslu, V. R., Egrioglu, E., and Bas, E. (2014). Finding optimal value for the shrinkage parameter in ridge regression via particle swarm optimization. *American Journal of Intelligent Systems*, 3(4), 142-147.

Uslu, V. R., ve Demirci, M. A. (2022). A comparison on performances of differential evolution algorithm and genetic algorithm in determining the biasing parameter k of ridge regression. *İstatistik Araştırma Dergisi*, 12(2), 26-38.

Woods, H., Steinour, H. H., and Starke, H. R. (1932). Effect of Composition of Portland Cement on Heat Evolved during hardening. *Industrial & Engineering Chemistry*, 24(11), 1207-1214.

Yasin, S., Kamal, S., and Suhail, M. (2021). Performance of some new ridge parameters in two-parameter ridge regression model. *Iranian Journal of Science and Technology, Transactions A: Science*, 45(1), 327-341.



Gazili olmak ayrıcalıktır