

T.C
MİMAR SİNAN GÜZEL SANATLAR ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

REGRESYON ÇÖZÜMLEMESİNDE KELEBEK DAĞILAN
ARTIKLAR İÇİN DEĞİŞEN VARYANSLILIK SORUNU VE
DÜZELTİLMESİ

DOKTORA TEZİ

Reşit ÇELİK

İstatistik Anabilim Dalı

İstatistik Programı

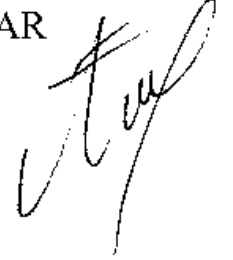
Tez Danışmanı: Prof. Dr. M. Aydın ERAR

OCAK 2012

Reşit ÇELİK tarafından hazırlanan REGRESYON ÇÖZÜMLEMESİNDE KELEBEK DAĞILAN ARTIKLAR İÇİN DEĞİŞEN VARYANSLILIK SORUNU VE DÜZELTİLMESİ adlı bu tezin ...DOKTORA..... tezi olarak uygun olduğunu onaylarım.

Prof. Dr. M. Aydın ERAR

Tez Yöneticisi



Bu çalışma, jürimiz tarafındanİstatistik..... Anabilim Dalında ..Doktora..... tezi olarak kabul edilmiştir.

Başkan:

: Prof. Dr. M. Aydın ERAR



Üye

: Prof. Dr. Malan CİNEMRE



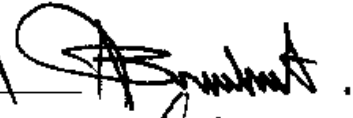
Üye

: Prof. Dr. Ali H. Büyüklü



Üye

: Prof. Dr. Sahamet Bülbal



Üye

: Prof. Dr. Gülay Koroğlu



Bu tez, Mimar Sinan Güzel Sanatlar Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygundur.

ÖZET

Bu çalışmanın amacı, doğrusal regresyon çözümlemesinde ortaya çıkan kelebek dağılan artıklar sorunu için değişen varyanslılığı dengelemede kullanılan yöntemlerin karşılaştırılması ve alternatif yöntemlerin araştırılmasıdır. Bu amaç doğrultusunda, dönüşümler, ağırlıklandırma ve her ikisini bir arada kullanan çeşitli yöntemler uygulama verisiyle karşılaştırılmıştır.

Giriş bölümünde, klasik doğrusal regresyon analizi ve varsayımları üzerinde durulmuştur.

İkinci bölümde, değişen varyanslılığın tanımı, nedenleri, belirlenmesi ve sonuçları, özel olarak da değişen varyanslılık kalıplarından biri olan kelebek dağılan artıklar anlatılmıştır.

Üçüncü bölümde, varyans fonksiyonları ve değişen varyanslılığın dengelenmesi konusunda literatürde var olan önemli ağırlıklandırma ve dönüşüm yöntemleri üzerinde durulduktan sonra bu çalışmanın önemli bir parçası olan alternatif yöntemler verilmiştir.

Dördüncü bölümde, önceki bölümlerde verilen yöntemler, kelebek dağılan artıkları olan bir veri kümesine uygulanarak sonuçlar değerlendirilmiştir. Bu bölümde, ayrıca, önerilen yöntemlerin geçerliliği farklı örneklem büyüklüğündeki yapay veriler ile de incelenmiştir.

Son bölümde, genel bir değerlendirme yapılarak sonuçlar özetlenmiştir.

STATING AND CORRECTING THE HETEROSCEDASTICITY FOR BUTTERFLY DISTRUBUTED ERRORS IN REGRESSION ANALYSIS

SUMMARY

The aim of this study is to compare general statistical methods for stabilizing variances of butterfly distributed errors, emerge in linear regression analysis and investigate the alternative methods to fulfill the homoscedatic errors. For this purpose, weighting, transformations and several methods which use both transformations and weighting were compared on the same data.

The the first part of this thesis focuses on the classical linear regression and its assumptions.

In the second part, definition, causes, specification and results of heteroscedasticity are emphasized and in particular, the butterfly distributed errors which are one of the heteroscedasticity patterns are explained.

In the third part, after emphasizing on variance functions and the important weighting and transformation methods in the literature about the stablizing heterogeneous errors variances, some alternative methods, which are also the important part of this study, are given.

In the fourth part, the methods mentioned in previous sections are applied with a specific data set which has butterfly distributed errors and the results are evaluated. Also, the validity of proposed methods are evaluated with artifical data sets with different sample sizes.

In the final part, the results were summarized with genaral evaluation.

ÖNSÖZ

Uzun soluklu bir çaba sonucu ortaya çıkan bu eserin oluşmasında, değerli fikirlerini ve zamanını esirgemeyen danışman hocam sayın Prof. Dr. Aydın ERAR'a, üzerimde çok emeği olan değerli hocam sayın Prof. Dr. Mehmet Genceli'ye, desteğini her zaman hissettiğim bölüm başkanım, sayın hocam Prof. Dr. Ali Hakan BÜYÜKLÜ'ye, anlayışı ve desteği için sayın hocam Prof.Dr. Nalan CİNEMRE'ye, çalışma arkadaşım sayın Yard. Doç. Dr. İbrahim DEMİR'e, çalışma arkadaşım sayın Araş. Gör. Ömer BİLEN'e, çalışma arkadaşım sayın Araş. Gör. Fulya GÖKALP'e, ve son olarak zor zamanlarda hep yanımda olan Aileme Teşekkürü borç bilirim.

Ocak 2012

Reşit Çelik

İÇİNDEKİLER

ÖZET.....	ii
SUMMARY	iii
ÖNSÖZ.....	iv
ÇİZELGE LİSTESİ.....	vii
ŞEKİL LİSTESİ.....	ix
KISALTMALAR LİSTESİ.....	x
1. GİRİŞ	1
1.1. Klasik Doğrusal Regresyon Modeli ve Varsayımları	1
1.2. Klasik Doğrusal Regresyonda Parametre Tahmin Edicileri ve Özellikleri	3
2. DEĞİŞEN VARYANSLILIK.....	5
2.1. Değişen Varyanslılığın Nedenleri	5
2.2. Değişen Varyanslılığın Saptanması	6
2.2.1. Grafikselle Yöntemler	6
2.2.1.1 Kelebek Dağılan Artıklar için Değişen Varyanslılık	9
2.2.2. Değişen Varyanslılığın Belirlenmesinde Kullanılan Sayısal Yöntemler	11
2.2.2.1. Spearman Sıra Korelasyonu	11
2.2.2.2. Değiştirilmiş Levene Testi	11
2.2.3.3. White Testi	12
2.3. Değişen Varyanslılığın Sonuçları	13
3. VARYANS FONKSİYONLARI ve DEĞİŞEN VARYANSLILIĞIN DENGELENMESİ	15
3.1 Varyans Fonksiyonu Tahmini	15
3.2. Karesel Artıklarla Ağırlıklı En Küçük Kareler	16
3.3. Mutlak Artıklara Dayanan Yöntemler	17
3.4. Ardışık Artıklara Dayanan Yöntemler	19
3.5. Değiştirilmiş (Modified) Ardışık Artıklar Yöntemi	20
3.6. Yeniden Ağırlıklandırılmış İteratif En Küçük Kareler Yöntemi	21
3.7. Chatterjee ve Machler Tarafından Önerilen İteratif Yöntem	22
3.8. Tekrarlı Gözlemler için Ortalama ve Varyans Fonksiyonları	23
3.9. Bootstrap Yöntemi	23
3.10. Jackknife Yöntemi	25
3.11. Parametrik Olmayan Düzleme	26
3.12. Dönüşümler	29
3.13. Ağırlıklandırma ve Dönüşümlerin Birleştirilmesi	32
3.14. Kelebek Dağılan Artıklar için Değişen Varyanslılığı Dengelemede Alternatif Yöntemler.....	32

3.14.1. Dışsal Değişken ve Merkezileştirme.....	32
3.14.2. Merkezi Dışsal Değişken ile Doğrudan Ağırlık Tahmini	36
4. UYGULAMA.....	38
4.1. Hava Kalitesi İndeksi	38
4.2. Model Seçimi ve Artıklar.....	40
4.3. Yeniden Ağırlıklandırılmış İteratif En Küçük Kareler	43
4.4. Chatterjee ve Machler Tarafından Önerilen İteratif Yöntemin Sonuçları	44
4.5. Değiştirilmiş Ardışık Artıklar Yöntemi Sonuçları.....	45
4.6. Parametrik Olmayan Düzleme	46
4.6.1. Mutlak Artıklarla Parametrik Olmayan Düzleme.....	46
4.6.2. Karesel Artıklarla Parametrik Olmayan Düzleme	48
4.7. Tekrarlı Gözlemler için Ortalama ve Varyans Fonksiyonları.....	50
4.7.1. Alt Gruplara Karşılık Gelen Bağımlı Değişken Değerlerinin Standart Sapmaları	50
4.7.2. Karesel Artıklar.....	51
4.8. Jackknife Yöntemi Sonuçları	52
4.9. Bootstrap Yöntemi Sonuçları.....	54
4.10. Box-Cox Dönüşümleri	55
4.11. Değişen Varyanslılığın İki Parçalı Ağırlıklandırma ile Dengelenmesi.....	57
4.12. Dışsal Değişken ve Merkezileştirme Sonuçları	58
4.13. Yapay Veriler ile Önerilen Yöntemlerin Sınanması.....	60
4.13.1. Yaklaşık Simetrik Veri n = 270	62
4.13.2. Yaklaşık Simetrik Veri n = 1339	65
4.13.3. Yaklaşık Simetrik Veri n = 8057	69
4.13.4. Sağa Asimetrik Veri n = 203.....	72
4.13.5. Sola Asimetrik Veri n = 223	75
4.13.6. Merkezi Dışsal Değişkenle Doğrudan Ağırlık Tahmini ve Ağırlıklı En Küçük Kareler	78
5. SONUÇ ve ÖNERİLER.....	81
KAYNAKLAR	83
ÖZGEÇMİŞ.....	86

ÇİZELGE LİSTESİ

Sayfa No

Çizelge 3.1. Çekirdek Fonksiyonları.....	28
Çizelge 4.1. Tam Küme Parametre Tahmin Edicileri ve Model Seçimi.....	40
Çizelge 4.2. En Küçük Kareler Analiz Sonuçları	42
Çizelge 4.3. Yeniden Ağırlıklandırılmış İteratif En Küçük Kareler Sonuçları.....	43
Çizelge 4.4. Chatterjee ve Machler İteratif Yöntemi Sonuçları.....	44
Çizelge 4.5. Değiştirilmiş Ardışık Artıklar ile Ağırlıklı En Küçük Kareler Sonuçları	45
Çizelge 4.6. Mutlak Artıklar İçin Parametrik Olmayan Regresyon ile Ağırlık Tahminleri ve Ağırlıklı En Küçük Kareler Sonuçları	47
Çizelge 4.7. Karesel Artıklar için Parametrik Olmayan Regresyon ile Ağırlık Tahminleri ve Ağırlıklı En Küçük Kareler Sonuçları	49
Çizelge 4.8. Bağımlı Değişken Standart Sapmaları için AEKK Sonuçları	50
Çizelge 4.9. Karesel Artık Standart Sapmaları için AEKK Sonuçları.....	52
Çizelge 4.10. Jackknife Parametre Tahmin Edicileri ve Artık Çizimleri	53
Çizelge 4.11. Bootstrap Yöntemi İçin Parametre Tahmin Edicileri ve Artık Çizimleri	54
Çizelge 4.12. Box-Cox $\lambda = 0 \rightarrow$ Logaritma Dönüşümü için Analiz Sonuçları	55
Çizelge 4.13. Box-Cox $\lambda = 0.5$ için Dönüşüm Sonuçları	56
Çizelge 4.14. İkiye Parçalama ile Elde Edilen Ağırlıklar ve AEKK Sonuçları.....	57
Çizelge 4.15. Merkezi Dışsal Değişken ile Tahmin Edilen Standart Sapma Fonksiyonu için Model Özeti ve Parametre Tahminleri	59
Çizelge 4.16. Merkezi Dışsal Değişken ile Ağırlık Tahmini ve AEKK Sonuçları....	59
Çizelge 4.17. $n = 270$ için En Küçük Kareler Sonuçları.....	63
Çizelge 4.18. Standart Sapma Fonksiyonu için Model Özeti ve Parametre Tahminleri	64
Çizelge 4.19. $n = 270$ Merkezi Dışsal Değişken ile Standart Sapma Fonksiyonu Tahmini ve AEKK Sonuçları	64
Çizelge 4.20. $n = 1339$ için En Küçük Kareler Sonuçları.....	66
Çizelge 4.21. Standart Sapma Fonksiyonu için Model Özeti ve Parametre Tahminleri	67
Çizelge 4.22. $n = 1339$ için Standart Sapma Fonksiyonu ile Ağırlık Tahmini ve AEKK Sonuçları.....	68
Çizelge 4.23. $n = 8057$ İçin En Küçük Kareler Sonuçları.....	69
Çizelge 4.24. Standart Sapma Fonksiyonu için Model Özeti ve Parametre Tahminleri	71
Çizelge 4.25. $n = 8057$ için Merkezi Dışsal Değişken ile Standart Sapma Fonksiyonu ile Ağırlık Tahminleri ve AEKK Sonuçları	71
Çizelge 4.26. Sağa Asimetrik Veri için En Küçük Kareler Sonuçları	73
Çizelge 4.27. Standart Sapma Fonksiyonu için Model Özeti ve Parametre Tahminleri	74

Çizelge 4.28. Sağa Asimetrik Veride Merkezi Dışsal Değişken ile Standart Sapma Fonksiyonu Tahmini ve AEKK Sonuçları.....	74
Çizelge 4.29. Sola Asimetrik Veri için EKK Sonuçları.....	76
Çizelge 4.30. Standart Sapma Fonksiyonu Tahmininin Özet İstatistikleri.....	77
Çizelge 4.31. Sola Asimetrik Veri için Merkezi Dışsal Değişken ile Standart Sapma Fonksiyonu Tahmini ve AEKK Sonuçları.....	78
Çizelge 4.32. Mutlak Merkezi Dışsal Değişken ile AEKK	79

ŞEKİL LİSTESİ

	<u>Sayfa No</u>
Şekil 2.1. Sağa Megafon	9
Şekil 2.2. Sola Megafon	10
Şekil 2.3. Galaksi Dağılan Artıklar	10
Şekil 2.4. Kelebek Dağılan Artıklar	11
Şekil 3.1. Ham Artıklar	33
Şekil 3.2. Karesel Artıklar	33
Şekil 3.3. Mutlak Artıklar	33
Şekil 3.4. Mutlak Artıklardan Merkezi Dışsal Değişken ile Standart Sapma Fonksiyonu	36
Şekil 4.1. Partiküller Maddenin Kükürt ve Sıcaklıkla Değişimi	41
Şekil 4.2. Sıcaklık- Partiküller Madde Değişimi	41
Şekil 4.3. Kükürt-Partiküller Madde Değişimi	42
Şekil 4.4. Mutlak Artıkların Bağımlının Tahmin Değerleriyle Çekirdek Düzlemesi	47
Şekil 4.5. Karesel Artıkların Bağımlı Tahminleri ile Çekirdek Düzlemesi	48
Şekil 4.6. Merkezi Dışsal Değişken ile Mutlak Artıkların Dağılımı	59
Şekil 4.7. Artık Dönüşümlerinin Merkezi Dışsal Değişken ile Fonksiyonları	61
Şekil 4.8. $n = 270$ için Yapay Veri Grafiği	62
Şekil 4.9. Standart Sapma Fonksiyonu	64
Şekil 4.10. $n = 1339$ için Yapay Veri Grafiği	66
Şekil 4.11. $n = 1339$ için Standart Sapma Fonksiyonu	67
Şekil 4.12. $n = 8057$ için Yapay Veri Grafiği	69
Şekil 4.13. $n = 8057$ için Standart Sapma Fonksiyonu	70
Şekil 4.14. $n = 203$ için Yapay Veri Grafiği	72
Şekil 4.15. Sağa Asimetrik Veri için Standart Sapma Fonksiyonu	74
Şekil 4.16. $n = 223$ Sola Asimetrik Veri Grafiği	76
Şekil 4.17. Sola Asimetrik Veri için Standart Sapma Fonksiyonu	77

KISALTMALAR LİSTESİ

AEKK	: Ağırlıklı En Küçük Kareler
AIC	: Akaike Bilgi Kriteri
AKT	: Artık Kareler Toplamı
AKO	: Artık Kareler Ortalaması
BIC	: Bayes Bilgi Kriteri
EKK	: En Küçük Kareler
HKİ	: Hava Kalitesi İndeksi
PM	: Partiküller Madde
ortc	: Ortanca
S.E	: Standart Hata
SBC	: Schwarz'ın Bayes Kriteri
VIF	: Varyans Şişme Değeri
YAIKK	: Yeniden Ağırlıklandırılmış İteratif En Küçük Kareler

1. GİRİŞ

Klasik doğrusal regresyon analizinde varsayımlar bozulduğunda, ağırlıklandırma ya da dönüşümler kullanılarak bu varsayım bozulmaları giderilmeye çalışılır. Değişen varyanslılık bu varsayım bozulmalarından biri olup, kelebek dağılan artıklar da değişen varyanslılığın özel bir halidir.

Bu çalışmanın amacı, kelebek dağılan artıklar için değişen varyanslılığın dengelenmesinde kullanılan yöntemlerin sınanması ve alternatif yöntemlerin araştırılmasıdır.

Çalışma kapsamında, giriş bölümünde, klasik doğrusal regresyon analizi ve varsayımları üzerinde durulmuştur. Çalışmanın ikinci bölümünde değişen varyanslılık, kaynakları, saptanması, özel olarak da kelebek dağılan artıklara değinildikten sonra değişen varyanslılığın sonuçları üzerinde durulmuştur. Üçüncü bölümde, varyans fonksiyonları ve değişen varyanslılığın dengelenmesi konusunda literatürde var olan önemli ağırlıklandırma ve dönüşüm yöntemleri üzerinde durulduktan sonra bu çalışmanın önemli bir parçası olan alternatif yöntemler verilmiştir. Dördüncü bölümde, önceki bölümlerde verilen yöntemler, kelebek dağılan artıkları olan bir veri kümesine uygulanarak sonuçları değerlendirilmiştir. Bu bölümde, ayrıca, önerilen yöntemlerin geçerliliği hem uygulama verisinde hem de farklı örneklem büyüklüğündeki yapay veriler ile incelenmiştir. Son bölümde, genel bir değerlendirme yapılarak sonuçlar özetlenmiştir.

1.1. KLASİK DOĞRUSAL REGRESYON MODELİ ve VARSAYIMLARI

p sayıda bağımsız değişken için çoklu doğrusal regresyon modeli

$$y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_p x_{ip} + \varepsilon_i \quad i = 1, \dots, n \quad (1.1)$$

şeklinde ya da matris biçiminde $Y = X\beta + \varepsilon$ olarak yazılır. Burada Y , $n \times 1$ boyutlu bağımlı değişken gözlem değerleri vektörü; X , $n \times p$ boyutlu tasarım matrisi; β ,

(p+1)x1 boyutlu parametre vektörü ve ε_i , nx1 boyutlu gözlenemeyen hata terimi vektörüdür.

(1.1) modelinin matris formunda, parametre tahmin edicileri,

$$\hat{\beta} = (X'X)^{-1} X'Y \quad (1.2)$$

ile ve uyum tahminleri de,

$$\hat{Y} = X\hat{\beta} \rightarrow \overbrace{X(X'X)^{-1}X'}^H Y \quad (1.3)$$

ile elde edilir. Artık değerleri ise $e = Y - \hat{Y}$ ile bulunur. Burada eşitlik (1.2) ve

$$H = X(X'X)^{-1}X' \quad (1.4)$$

matrisi kullanılarak

$$e = Y - HY$$

ya da

$$e = (I - H)Y \quad (1.5)$$

yazılabilir. Burada H, nxn boyutlu eşgüçlülük (idempotent) özelliği olan “şapka” matrisidir.

Parametre tahmin edicilerinin varyansı,

$$V(\hat{\beta}) = \hat{\sigma}^2 (X'X)^{-1} \quad (1.6)$$

ile ve $\hat{\sigma}^2$ 'nin tahmin edicisi, artık kareleri ortalaması (AKO),

$$\hat{\sigma}^2 = AKO = \frac{1}{n-p-1} (Y'Y - \hat{\beta}'X'Y) \quad (1.7)$$

ile verilir.

(1.1) modelindeki gözlenemeyen hata terimleri ε_i için,

- $E(\varepsilon_i) = 0$ olduğu,
- $cov(\varepsilon_i, \varepsilon_j) = 0$ $i \neq j$ için gözlemlerin bağımsız olduğu,
- $V(\varepsilon_i) = \sigma^2$ ile varyansların eşit olduğu,
- $\varepsilon \sim N(0, \sigma^2)$ sıfır ortalama ve σ^2 varyans ile normal dağıldığı,
- Bağımsız değişkenlerin rastlantı değişkeni olması durumunda $E(x_{ij}, \varepsilon_i) = 0$

olduđu varsayılr (Drapper ve Smith, 1998).

Herhangi bir regresyon problemine başlarken tam karma model tahmini yapılmalı ve artıklar incelenmelidir. Artık incelenmesi regresyondaki varsayımlardan sapmaları belirler (Bagnall ve diğ., 2006).

Varsayım bozulması tipine göre en küçük kareler ve en çok olabilirlik yöntemlerine alternatif bazı yöntemler aşağıdadır:

- Veride deđişen varyanslılık söz konusu ise *ağırlıklı en küçük karelere*,
- Hatalar ilişkili ise *genelleştirilmiş en küçük karelere*,
- Parametrelere bazı kısıtlamalar uygulanırsa *koşullu en küçük karelere*,
- Veri kümesinde çoklubađlantı varsa *ridge regresyonu* gibi yanlı tahmin yöntemlerine,
- Tüm deđişkenler rastgele bir hataya bađlı ise *genişletilmiş en küçük karelere (Expanded Least Squares)*,
- Veri normalden başka bir dađılım gösteriyorsa ya da deđişen varyanslılık, aykırı deđerler ya da yüksek kaldıraç noktaları söz konusu ise o zaman bazı sağlam (robust) yöntemlere başvurulur (Meloun ve diğ., 2002).

1.2. KLASİK DOĐRUSAL REGRESYONDA PARAMETRE TAHMİN EDİCİLERİ ve ÖZELLİKLERİ

En küçük kareler en eski ve en yaygın biçimde kullanılan tahmin sürecidir. En küçük kareler, çođunlukla hata kaynaklarına ilişkin bilgi olmadığında deterministtik modellerde kullanılır. En küçük kareler tahmin edicileri, gözlenen deđerler ile tahmin deđerleri arasındaki farkların kareleri toplamını minimize eder. En küçük kareler tahmin edicileri parametrelerin dođrusal fonksiyonlarının herhangi bir kümesi için minimum varyanslı, toplamsal ve yansız tahmin ediciler verir. Ortalama, parametrelerin dođrusal olmayan bir fonksiyonu olsa bile en küçük kareler tahmin edicileri tutarlı ve asimptotik olarak yansız kalır. Normallik varsayımının gerçekenmesi durumunda ise en küçük kareler tahmin edicileri en çok olabilirlik tahmin edicileridir.

En çok olabilirlik tahmin edicileri, tam bir olasılık yoğunluk fonksiyonu belirlenmesine dayanır. Bu tahmin ediciler küçük örneklem büyüklüğü için

optimal özelliklere sahip değildir; ama artan örneklem büyüklüğüne koşut olarak asimptotik olarak tutarlı, yansız ve etkindirler (Silverman ve Kot, 2000).

2. DEĞİŞEN VARYANSLILIK

Basit ve çoklu regresyon yöntemlerinde, bağımlı değişken Y 'nin $X = x_i$ 'ye göre koşullu dağılımlarının aynı varyansa sahip olduğu varsayılır.

Hata terimlerine ilişkin varyansların, \hat{y}_i ya da bağımsız değişkenlerden birinin çeşitli düzeyleri için istatistiksel olarak farklı olması değişen varyanslılık olarak tanımlanır. Değişen varyanslılık, sağlık, ekonomi ve biyoistatistik gibi pek çok alanda karşımıza çıkar (Basu, 2005).

Harvey (1976), hata terimlerine ilişkin varyansın aynı olmadığı regresyon modellerinde, hata terimlerine ilişkin varyansın bağımsız değişkenlerin bir ya da bir kısmının fonksiyonu olduğunu belirtmiştir.

Carroll ve Ruppert (1982), varyansların bağımsız değişkenlerin parametrik bir fonksiyonu olduğu değişen varyanslı doğrusal bir modelde, regresyon parametreleri tahmininin asimptotik varyanslarla ağırlıklandırılmış en küçük kareler ile yapılabileceğini belirtmiştir.

2.1. DEĞİŞEN VARYANSLILIĞIN NEDENLERİ

Değişen varyanslılık aşağıdaki nedenlerle ortaya çıkabilir:

1. Bağımsız değişken değerleri değiştikçe, $V(y_i)$ 'nin de değişmesi sonucu değişen varyanslılık ortaya çıkabilir. Örneğin, gelir arttıkça kişilerin istedikleri gibi harcayabilecekleri miktar da artar ve gelirlerini harcayabilecekleri seçenekler genişler; dolayısıyla, harcamanın varyansı artan gelire bağlı olarak büyür.
2. Bağımlı değişkenin kesikli olması durumunda ortalama ile varyansın ilişkili olması değişen varyanslılığa neden olabilir.
3. Değişen varyanslılığın bir diğer nedeni modelleme hatasıdır. Farklı bir model tahmini ya da bazı önemli değişkenlerin model dışı bırakılması değişen varyanslılığın kaynağı olabilir (Gujaratti, 2001).

4. Değişen varyanslılık aykırı değerlerin örnekleme öteki gözlemlerden, çok küçük ya da çok büyük olması sonucunda da ortaya çıkabilir. Bu tip gözlemlerin atılması özellikle örneklem büyüklüğü küçükse regresyon çözümlerinin bulgularını önemli ölçüde değiştirebilir.
5. Veri derleme teknikleri ya da ölçme araçları geliştikçe varyans küçülebilir.
6. Oberg ve Davidian'a (2000) göre, normal dağılım ve eş varyanslılık varsayımlarının bozulması daha çok tekrarlı ölçümlü verilerde görülmektedir.
7. Kişilerin herhangi bir konudaki deneyimleri arttıkça davranış hataları da zamanla azalmakta dolayısıyla varyans da küçülmektedir.

2.2. DEĞİŞEN VARYANSLILIĞIN SAPTANMASI

Artık grafikleri, değişen varyanslılığın saptanmasında en çok kullanılan araçlardır. Artık grafiklerine ek olarak, özellikle ekonometride kullanılan, pek çok sayısal test bulunmaktadır.

2.2.1. Grafikselle Yöntemler

Değişen varyanslılığın saptanması ve modellenmesi konusunda kullanılan pek çok grafikselle yöntem vardır. Değişen varyanslılığın saptanması konusunda kullanılan en yaygın araç, ağırlıklı olmayan en küçük kareler artık çizimleridir.

1. (1.3) Eşitliğinden elde edilen \hat{y}_i tahmin değerleri yatay ekseninde ve bunlara karşılık gelen $(y_i - \hat{y}_i)$ 'den elde edilen artıklar dikey ekseninde gösterildiği grafikte megafon biçimindeki bir görüntü, artık varyanslarının bağımlı değişkenin tahmin değerleri ile değiştiğinin kanıtıdır. Değişen varyanslılığın saptanmasında çoğu zaman artıkların, bağımsız değişkenlerle olan grafiklerinden de yararlanır.
2. Değişen varyanslılığın belirlenmesinde ham artıklarla yapılan çizimler çoğu zaman yeterli olmaz ve değişen varyanslılığın modellenmesi konusunda bilgi vermez. Cook ve Weisberg (1982) kare artıkların \hat{y}_i değerlerine karşı çizimlerini tartışmış; ilk maddede yer alan genel çizimlerin yorumunun kolay olmadığını, pozitif ve negatif artıklarla belli bir kalıbın ortaya çıkmasının her zaman olası olmadığını belirtmişlerdir. Cook ve Weisberg'e (1982) göre sorun karesel artıklarla çalışıldığında ortadan kalkar ve örneklem büyüklüğü göreceli olarak ikiye katlanır. "Kama" şeklinde bir karesel artıklar görüntüsü varyans değişkenliğinin ortalamayla

arttığına göstergesidir. Bununla birlikte bu tür durumlarda büyük artık değerleri ölçek sorununa yol açar.

3. Carroll ve Ruppert'e (1988) göre, ölçek sorununu gidermek için mutlak artıkları, mutlak artıkların logaritmalarını ve artıkların karelerinin küp köklerini kullanmak daha yararlıdır. Artıkların kareleri varyans tahmini gibi düşünülürse mutlak artıklar da standart sapmanın tahmini gibi düşünülebilir. Buradaki amaç değişkenliğin yapısının mutlak artıklar ve onların dönüşümleriyle analiz edilerek anlaşılması ve modellenmesidir.

4. Değişen varyanslılığın belirlenmesi için, çoğu zaman, mutlak artıkların logaritmasına karşı \hat{y}_i tahmin değerlerinin logaritmasının çizimi yararlı olur (Carroll ve Ruppert, 1988). Mutlak artıkların logaritması standart sapmanın logaritmasının yerine; tahmin değerlerinin logaritması ise ortalamasının logaritması yerine geçer. Eğer, standart sapma için

$$\sigma_i = \sigma \mu_i(\beta)^\theta \quad (2.1)$$

gibi ortalama üslü bir fonksiyon söz konusu ise çizim nadiren θ parametresi ile doğrusal bir ilişki gösterir. Burada σ ortak standart sapma, σ_i i'inci kitle bağımlı değişken değerlerinin standart sapması; $\mu_i(\beta)$, i'inci kitle için \hat{y}_i tahmin değerlerinin ortalaması θ , üs parametresidir.

5. Veriler eş varyanslı olsa bile, H matrisi eşgüçlü olduğundan artıklar $(1-h_{ii})$ ile orantılıdır. Kaldıraç (Leverage) özelliğine sahip büyük h_{ii} değerleri ortalama ile yakından ilişkilirse, artık grafiklerinde tamamen değişen varyanslı bir görünüm ortaya çıkar. Bu nedenle ham artıkların yerine, kendi varyansları ile ölçeklenen,

$$r_i = e_i / [\hat{\sigma}(1-h_{ii})^{1/2}] \quad (2.2)$$

Student-türü artıkları kullanmak daha duyarlı ve doğru olur. Buradaki amaç, yatay eksen boyunca çizilen bileşendeki hafif değişmelerle değişen varyanslılığı ortaya çıkarmaktır. Carroll ve Ruppert (1988), varyansların θ skaleri ile,

$$\sigma_i^2 = \sigma^2 g^2(\mu_i(\beta), z_i, \theta)$$

modeline uygun olduğunu düşünmüşlerdir. Burada σ_i^2 , i'inci kitlenin artık varyansı; g , varyans fonksiyonu; $\mu_i(\beta)$, i'inci kitle ortalaması; z_i , varyansın fonksiyonu

olduğu bağımsız değişken ve θ , eşitlik (2.1)'deki standart sapma fonksiyonundaki üs parametresidir. θ 'nın sıfır olması değişen varyanslılığın söz konusu olmadığı anlamına gelmektedir. Öte yandan,

$$s_i = \frac{\partial}{\partial \theta} \{g^2[\mu_i(\beta), z_i, \theta]\}_{\theta=0} \quad (2.3)$$

tanımlanırsa, küçük θ için,

$$\begin{aligned} \text{varyans}(\hat{\sigma}r_i) &= (1-h_{ii})\sigma_i^2 + \sum_{i \neq k} \sigma_k^2 h_{ik}^2 / (1-h_{ii}) \\ &\simeq \sigma^2 \left[1 + \theta \left((1-h_{ii}) + \sum_{i \neq k} s_k h_{ik}^2 / (1-h_{ii}) \right) \right] \end{aligned} \quad (2.4)$$

olur. Burada H matrisinin köşegen öğeleri dışındaki h_{ik} değerleri küçük ise, $\text{varyans}(r_i) \simeq 1 + \theta(1-h_{ii})s_i$ yazılabilir. Burada önerilen; ham, mutlak ya da Student-türü artıkların $(1-h_{ii})s_i$ 'lere karşı grafiklerinin çizimidir. Örneğin (2.1)'deki standart sapma fonksiyonunun karesi alındığında, $\sigma_i^2 = \sigma^2 \exp[2\theta f(x_i, \beta)]$ üstel varyans modeline ulaşılır. Bu nedenle \hat{y}_i değerlerine karşılık çizilecek Student-türü artıkların grafiği üstel varyans modelinin algılanmasında; \hat{y}_i değerlerinin logaritmalarına karşı Student-türü artıklarla çizimi ise (2.1) formülüyle verilen ortalama-üslü varyans modelinin belirlenmesinde kullanılabilir. Çizim, artıkların bağımsız değişkenlerden birine ya da bağımsız değişkenlerin fonksiyonlarından her herhangi birine karşı çizimi için de geçerlidir.

6. Örneklem büyüklüğü çok büyük olduğunda standart sapmanın yapısını anlamak için tahmin değerlerinin logaritmasının yatay ekseninde yer aldığı artık çizimleri ile çalışılabilir. Standart sapmaların yapısının belirlenmesindeki yollardan biri de veri kümesini yatay ekseninde sıraladıktan sonra eşit gruplara bölmek, her bir gruba karşılık gelen mutlak artık ortalamalarını bulmak ve bu ortalamalara karşılık çizim yapmaktır (Carroll ve Ruppert, 1988).


7. Büyük veri kümelerinde yoğunluk etkisinin giderilmesi konusunda ikinci yol, aynı zamanda değişkenlik ile ilgili olarak parametrik olmayan regresyon teknikleriyle model hakkında bilgi edinilmesidir. Parametrik olmayan yöntemler kullanıldığında değişkenlik hakkında bilgi edinme yollarından biri saçılım grafiği "scatter plot"tur. Artıkların mutlak, log-mutlak ve karelerinin küp köklerinin çizimi, varyans yapısının anlaşılmasında ve ortaya konmasında serpilme diyagramı gibi işlev görür. Mutlak

artıkların çeşitli dönüşümlerine uydurulacak fonksiyonlar (eğriler) standart sapmanın davranışının anlaşılmasına yardımcı olur. Mutlak artıkların logaritması kullanıldığında göz önünde tutulması gereken husus, çok küçük mutlak artıkların logaritmalarının büyük negatif değerlere neden olması dolayısıyla yanlış ve aşırı yorumlara yol açmasıdır. Bundan kaçınmanın yollarından biri en küçük mutlak artıkların az bir kısmının atılmasıdır (Carroll ve Ruppert, 1988).


8. Artık varyanslarının davranışını ortaya koyabilmenin bir başka yolu, hareketli ortalama, medyanlar ve budanmış ortalamalar kullanılarak yapılabilir. Düzleyici olarak “spline” ya da “çekirdek” (kernel) düzlemesi kullanılabilir. Çekirdek düzlemesi yapılırken fonksiyon olarak uniform çekirdek kullanılabilir; bant genişliği ise deneme ya da hataya bağlı olarak seçilebilir. Çizimlere kabaca göz atılması, genelde şiddetli değişen varyans yargısına neden olur. Pratikte, birkaç büyük artık yokmuş gibi çizime bakıldığında, çizime ilişkin izlenim aynı kalıyorsa, ilk teşhise güvenilebilir (Carroll ve Ruppert, 1988).

2.2.1.1 Kelebek Dağılan Artıklar için Değişen Varyanslılık

Değişen varyanslılıkta en çok karşılaşılan durum, artık grafiklerindeki megafon biçiminde görüntüdür. Megafon biçimindeki şekiller (Şekil 2.1 ve 2.2); “galaksi” biçimindeki (Şekil 2.3) ya da “kelebek” biçimindeki (Şekil 2.4) diğer iki kalıp kadar istatistiksel çıkarsamayı bozamaz. Kelebek şeklindeki bir saçılım grafiğinin iki ucu geniş, ortası ise dardır. Galaksi ise bunun tersine orta kısım geniş ve uçlar dardır (Darlington,1997).



Şekil 2.1. Sağa Megafon




Şekil 2.2. Sola Megafon


A değişkeni, B ve C değişkenlerinin bir fonksiyonu olsun. A, B'nin doğrusal artan ve C'nin de doğrusal azalan bir fonksiyonu olduğunda modelin artıkları kelebek şeklinde bir dağılıma gösterir.

Örneğin, bilgisayar tecrübesinin bir fonksiyonu olarak standart olmayan bilgisayar klavyeleriyle çalışma durumu göz önüne alınsın. Tecrübenin sağ el ya da sol el kullanıyor olmakla etkileşimli olduğunu varsayalım. Böyle bir durumda solaklar standart olmayan klavyeler kullanımı konusunda deneyimleri artıkça daha olumlu; sağ ellerini kullananlar ise daha az olumlu gelişme kaydederler. İki regresyon doğrusunun ortalama tecrübe civarında birleştiği varsayalım. O zaman durum-tecrübe saçılım grafiğinin doğruların birleştiği orta kısmı daha dar, sağ ve sol uçlarda ise çok daha geniş olacaktır. Araştırmacı el kullanma durumunu gözden kaçırıp yer vermez ise regresyon modelinde kelebek dağılan artıklar nedeniyle değişen varyanslılık ortaya çıkar. Bundan dolayı tecrübe için $V(\hat{\beta})$ olduğundan çok daha küçük tahmin edilecektir.

Regresyon modelinde yer alan bir değişkenle ilişkili olan başka değişkenlerin dışlanması da kelebek dağılan artıklara neden olabilir (Darlington, 1997). Kelebek dağılan artıklar için değişen varyanslılığı ortaya koyan yapı örneklerinden biri de atmosferik verilerin aylara göre sıralanarak modellenmesidir.



Şekil 2.3. Galaksi Dağılan Artıklar



Şekil 2.4. Kelebek Dağılan Artıklar

2.2.2. Değişen Varyanslılığın Belirlenmesinde Kullanılan Sayısal Yöntemler

Değişen varyanslılığın belirlenmesi konusunda özellikle ekonometri ve zaman serileri literatüründe geçen pek çok skor testi vardır. Burada, bu testlerin üç tanesine değinilecektir.

2.2.2.1. Spearman Sıra Korelasyonu

Carroll ve Ruppert (1988), sayısal tanı için Student-türü artıklarla yatay ekseninde yer alacak değişkenlerin Spearman sıra korelasyonu katsayılarının çok kullanılışlı olduğunu belirtmişlerdir. Bu korelasyon, değişken değerlerinin büyükten küçüğe sıralanması ve küçükten başlanarak sıra numarası verilmesine dayanır. Böylece Spearman korelasyonu iki değişkenin sıra numaraları korelasyonudur. Spearman korelasyonu monoton dönüşümlerden etkilenmez; dolayısıyla artıkların kareleri ya da logaritmalarıyla çalışıldığı gibi, \hat{y} değerleri ya da bağımsız değişkenlerin logaritmaları ile de çalışılabilir. Pozitif katsayılar artan varyansı işaret eder. Sıra korelasyonuna benzer olarak artık çizimlerinden görsel yorumlar edinilebilir.

2.2.2.2. Değiştirilmiş Levene Testi

Değişen varyanslılığın saptanmasında kullanılan bu test, hata terimlerinin normal dağılıma uymasını gerektirmemektedir. Hata terimleri normal dağılımsa bile hataların büyüklüğüne dayanan çok sağlam bir testtir. Karesel artıkların (e_i^2) büyük olması büyük sapmalara neden olacağından s_y^2 de büyük olacaktır. Veri kümesi, n_1 ve n_2 şeklinde en az 2 gruba bölünür. Varyanslar, bağımsız değişkenin artan değerlerine karşılık büyürse, o zaman birinci grup artık kareleri toplamının ikinci

grup artık kareleri toplamından daha küçük ya da büyük olması beklenir. Test, birden çok değişken için de yapılabilmesine rağmen tek bağımsız değişken için uygulanması daha kolaydır. Testte, pozitif ya da mutlak değerli artıklar kullanıldığından sağlamdır. Testin işleyişi iki örneklem t testine dayanır. Mutlak sapmalar genellikle normal dağılıma uymaz; ancak tek tek her bir gruptaki birim sayısının 10'dan fazla olması durumunda yaklaşık olarak t dağılımına uyarlar.

H_0 : İki grubun varyansı arasında istatistiksel olarak anlamlı bir fark yoktur hipotezinin testi için,

n_1 : küçük x_i değerlerine karşılık gelen gruptaki birim sayısı,

n_2 : büyük x_i değerlerine karşılık gelen gruptaki birim sayısı,

\tilde{e}_1 : 1. gruptaki artıkların ortancası,

\tilde{e}_2 : 2. gruptaki artıkların ortancası,

$d_{i1} = |e_{i1} - \tilde{e}_1|$ 1. grubun mutlak sapması,

$d_{i2} = |e_{i2} - \tilde{e}_2|$ 2. grubun mutlak sapması,

olmak üzere,

$$s^2 = \frac{\sum_{i=1}^{n_1} (d_{i1} - \bar{d}_1)^2 + \sum_{i=1}^{n_2} (d_{i2} - \bar{d}_2)^2}{n_1 + n_2 - 2} \text{ iken}$$

$$t = \frac{\bar{d}_1 - \bar{d}_2}{s \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}} \quad (2.5)$$

test istatistiği kullanılır. Burada, $t > t_{\alpha, n_1+n_2-2}$ ise H_0 hipotezi ret edilir.

Veri kümesinde aykırı değerlerin (outliers) olması, çoğu zaman maskeleyme (gizleme) yüzünden değişen varyanslılık hakkında görsel olarak yanlış kararlara neden olabilir. Aşırı aykırı değerler atıldıktan ya da düzeltildikten sonra değişen varyanslılık olup olmadığı konusunda yargıya varılabilir. Değiştirilmiş Levene testinin aykırı değerler ve pürüzler olması durumunda bile doğru sonuç verdiği Paulson (2006), tarafından gösterilmiştir.

2.2.3.3. White Testi

Test, eş varyanslılık varsayımının geçerli olup olmadığının incelenmesinde en çok kullanılan testlerden biridir. Normallik varsayımına dayanmayan yardımcı bir

regresyon modelinin tahminini gerektirir. Model belirlenerek, en küçük kareler tahminlerinden artıklar bulunur. Bulunan artıkların karelerinin bağımlı değişken, bağımsız değişkenlerin, kendilerinin, karelerinin ve çarpımlarının bağımsız değişken olduğu bir yardımcı regresyon modeli kurulur:

$$e_i^2 = \alpha_0 + \alpha_1 x_{i1} + \dots + \alpha_p x_{ip} + \gamma_1 x_{i1}^2 + \dots + \gamma_p x_{ip}^2 + \dots + \theta_1 x_{i1} x_{i2} + \dots + \theta_p x_{ip-1} x_{ip} \quad (2.6)$$

$$H_0 : \forall (\alpha_i, \gamma_j, \theta_l) = 0 \text{ (Eş Varyans)}$$

$$H_1 : \exists (\alpha_i, \gamma_j, \theta_l) \neq 0$$

k , yardımcı regresyon modelindeki parametre sayısı olmak üzere, yardımcı regresyon modelinin belirtme katsayısı n ile çarpılarak

$$nR_{yard.}^2 \approx \chi_{k,\alpha}^2$$

test istatistiği hesaplanır. $nR_{yard.}^2$ İstatistiğinin $\chi_{k,\alpha}^2$ değerinden küçük olması eş varyanslılık hipotezini; büyük olması ise değişen varyanslılığı öne süren hipotezi doğrulayacaktır (Güriş ve Çağlayan, 2001).

2.3. DEĞİŞEN VARYANSLILIĞIN SONUÇLARI

Dağılım kuramı, güven aralıkları ve hipotez testleri standart regresyon varsayımlarının geçerliliği halinde anlam taşır. Varsayımlardan sapma olduğunda sonuçlara ilişkin uygulamalar ciddi hatalara neden olmaktadır (Hadi ve Chatterjee, 2006). Basit ve çoklu regresyonda regresyon katsayılarının anlamlılığı ve testlerinin kesinliği eş varyanslılık varsayımına bağlıdır. Regresyon katsayılarının testi için Jackknife ve bootstrap gibi sağlam yöntemler kullanılsa bile değişen varyanslılık söz konusu olduğunda sonuçlar çok hatalı olabilir.

Değişen varyanslılık durumunda $\hat{\beta}$ kendi parametresinin yansız bir tahmin edicisidir; ancak standart hatası ($\hat{\sigma}_{\hat{\beta}}$) çok büyük ya da çok küçük olduğundan etkinliğini yitirir. Burada, $\hat{\sigma}_{\hat{\beta}} = \sigma \sqrt{köşegen(X'X)^{-1}}$ dir.

Eğer $\hat{\sigma}_{\hat{\beta}}$ olduğundan çok daha büyük tahmin edilirse $\hat{\beta}$ kendi parametresinin etkin bir tahmin edicisi olmaz ve $t = \hat{\beta} / \hat{\sigma}_{\hat{\beta}}$ istatistiği küçülür. Bu durumda, doğru olan alternatif hipotezin ret olasılığı olan II. Tip hata ortaya çıkar. Eğer $\hat{\sigma}_{\hat{\beta}}$ olduğundan

çok daha küçük tahmin edilirse $\hat{\beta}$ kendi parametresinin etkin bir tahmin edicisi olmaz ve $t = \hat{\beta} / \hat{\sigma}_{\hat{\beta}}$ hesap değeri büyür ve doğru olan bir yokluk hipotezinin ret olasılığı olan I. Tip hata ortaya çıkar (Friel, 2009).

3. VARYANS FONKSİYONLARI ve DEĞİŞEN VARYANSLILIĞIN DENGELENMESİ

Pek çok alanda, örneğin ekonomi, sağlık ve biyoistatistikte doğrusal modeldeki eş varyanslılık varsayımı geçerli değildir ve etkinlik açısından düzeltme gerektirir. Bu konudaki temel yaklaşım, bağımlı değişkenin dönüşümüne dayanan Box-Cox dönüşümüdür (Aitkin, 1987).

Pardoe ve Cook (2007), standart doğrusal ve daha karmaşık regresyon modellerinde tahmin belirsizliğinin doğru değerlendirilmesi için varyans fonksiyonunun belirlenmesinin çok önemli olduğunu belirtmişlerdir. Varyans fonksiyonu tahmini, regresyon analizinde olduğu gibi eğri uydurma ile yapılır. Regresyon analizinin pek çok boyutu olmasına rağmen üç tanesi göze çarpar. İlki, standart grafik tekniği olan saçılım grafiğidir. İkincisi, kanonik tahmin yönteminin varlığı olarak en küçük karelerdir. Aykırı değerlere ve etkili gözlemlere duyarlı olmasına karşın, en küçük kareler hemen hemen tüm regresyon analizlerinde temel olarak kullanılan ve anlaşılması kolay bir yöntemdir. Regresyon analizinin üçüncü bileşeni, doğrusal modeldir.

3.1 VARYANS FONKSİYONU TAHMİNİ

Eş varyanslılık varsayımı geçerli olmadığında varyansları dengelemek için en çok başvurulan yol dönüşümdür. Dönüşüm yeterli olmadığında varyansların modellenmesi gereklidir (Verbyla, 1993). Varyanslar, varyans fonksiyonları ile modellenir. Varyans fonksiyonu tahmininde, değişkenlerin bir fonksiyonu olarak varyansların yapısı anlaşılmaya çalışılır. Varyans fonksiyonu, regresyona benzer şekilde ele alınır. Tıpkı regresyonda olduğu gibi, yapıyı anlamak için basit çizim teknikleri yararlıdır. Burada amaç, ilk olarak konum (location) etkilerine uygun bir fonksiyon uydurduktan sonra artıkları düzgünleştirmektir. Carroll ve Ruppert (1982)'e göre, tahminin standart sapması hakkındaki bilgi artıkça regresyon parametrelerinin etkinliği artar.

Tahminin varyansının yapısını anlamada ilk adım varyansların logaritmalarının modellenmesidir. Modelleme ile ilgili bazı örnekler aşağıdadır:

$$\log(e_i^2) = \theta_0 + \theta_1 x + \theta_2 x^{-1}$$

ya da

$$\log(e_i^2) = \theta_0 + \theta_1 \mu(\beta)$$

ya da

$$\log(e_i^2) = \theta_0 + \theta_1 \log[\mu(\beta)].$$

Son model ortalama üslü bir modeldir. Varyansların logaritmalarını doğrusal olarak dikkate almanın avantajı, tahminle elde edilen varyansların da pozitifliğinin garanti olmasıdır. Log-doğrusal varyans modellerine alternatif modellerin çoğunda pozitif varyans garantisi yoktur. Bazı örneklerde varyans, sabite ve ortalamaya bağlı iki bileşene sahiptir. Bu durum

$$\sigma^2 g^2 [\mu_i(\beta), z_i, \theta] = \theta_1 + \theta_2 [\mu_i(\beta)]^{\theta_3} \quad (3.1)$$

şeklinde gösterilir. Alternatif olarak standart sapmanın, bağımsız değişkenlerin karesel bir fonksiyonu biçiminde görsel olarak modellenmesine sıklıkla rastlanabilir:

$$\sigma_i = \sigma g [x_i, \theta] = 1 + \theta_1 x_i + \theta_2 x_i^2 \quad (3.2)$$

Eğer burada birden çok bağımsız değişken varsa, model, bu değişkenlerin kendilerinin, karelerinin ve çapraz çarpımlarının yer aldığı bir doğrusal regresyona dönüşebilir.

Değişen varyanslı regresyon modellerinde hata terimlerine ilişkin varyanslar bilinirse, parametre tahminleri ağırlıklı en küçük kareler kullanılarak yapılabilir. Ancak pratikte hata terimlerinin varyansları bilinmez. İstatistik literatüründe ağırlık tahminlerinin kullanıldığı, asimptotik olarak ağırlıklı en küçük kareler tahminlerine denk sonuçlar veren pek çok çalışma vardır (Shick, 1999).

3.2. KARESEL ARTIKLARLA AĞIRLIKLI EN KÜÇÜK KARELER

Bu yöntem için hareket noktası, $E(e_i^2)$ 'nin yaklaşık olarak varyansa eşit olmasıdır. Bağımlı değişkenin karesel artıklar olduğu ve bu durum için regresyon

fonksiyonunun beklenen değerinin yaklaşık $\sigma^2 g^2(\mu(\beta), z, \theta)$ olduğu doğrusal olmayan bir regresyon fonksiyonu düşünülebilir. Böylece θ ve σ 'nın tahmini için

$$\sum_{i=1}^N \left\{ \left[y_i - f(x_i, \hat{\beta}_*) \right]^2 - \sigma^2 g^2(\mu_i(\hat{\beta}_*), z_i, \theta) \right\}^2 \quad (3.3)$$

eşitliği minimize edilir. Normal dağılan veri için karesel artıkların varyans fonksiyonu yaklaşık $\sigma^4 g^4(\mu_i(\hat{\beta}_*), z_i, \theta)$ ile orantılıdır. Bu nedenle genelleştirilmiş en küçük kareler yöntemine başvurulabilir. β 'nin ağırlıklı en küçük kareler ve genelleştirilmiş en küçük kareler tahmini, aşağıda verilen modellemeye paralel olarak elde edilebilir:

$$\text{Bağımlı Değişken} \quad : \left[y_i - f(x_i, \hat{\beta}) \right]^2 \rightarrow e_i^2 \quad (3.4)$$

$$\text{Parametreler} \quad : (\sigma, \theta)$$

$$\text{Regresyon Fonksiyonu} \quad : \sigma^2 g^2(\mu_i(\hat{\beta}_*), z_i, \theta)$$

$$\text{Varyanslar} \quad : \sigma^4 g^4(\mu_i(\hat{\beta}_*), z_i, \theta)$$

Burada β_* varyans fonksiyonunun parametresinin tahmini, z , varyansın fonksiyonu olduğu bağımsız değişken ve θ üs parametresidir. Bu eşitlikten elde edilecek \hat{e}_i^2 tahmin değerleri $\hat{w}_i = 1/\hat{e}_i^2$ şeklinde ağırlık elde etmek için kullanılır. Karesel artıklarla çalışmanın dezavantajı dağılımlarının oldukça çarpık olması ve bunun sonucunda da normal dağılım özelliklerinin kullanılamamasıdır. Örneğin, artıkların dağılımı yaklaşık normal varsayıldığında karesel artıklar yaklaşık 1 serbestlik dereceli Ki-Kare dağılımına uyar. Bu durumda karesel artıkların küp kökleri, küp kök Ki-Kare (χ^2) rasgele değişkeni dolayısıyla yaklaşık normal dağılımlı değişken olur (Carroll ve Ruppert, 1988).

3.3. MUTLAK ARTIKLARA DAYANAN YÖNTEMLER

En küçük karelerin uygulanmasında, aykırı değerlerin varlığı durumunda, aykırı değerler karesel artıklarda daha etkin olduklarından mutlak artıkların kullanılması önerilmektedir. Pardoe ve Cook (2007), varyans fonksiyonunun karekökünün

standart sapma fonksiyonunun tahmini olarak düşünölebileceğini belirtmişlerdir. Burada hareket noktası,

$$E\left(\left|y_i - f(x_i, \hat{\beta})\right|\right) = c_f g(\mu_i(\hat{\beta}), z_i, \theta) \quad (3.5)$$

beklenen değere sahip mutlak sapma olarak adlandırılan moment varsayımıdır. Burada c_f , x_i tasarım noktasından bağımsız bir orantı sabitidir. Birçok amaç için (2.1) ve (3.5)'deki ortalama ve varyans varsayımları eşanlı olarak sağlandığında (3.5) hataları bağımsız ve türdeş dağılır. Çarpık veri için ortanca, ortalamaya göre daha kolay yorumlanabilir bir ölçü olduğundan ortancanın tercih edilmesi önerilmektedir. Mutlak artıklar, yaklaşık olarak (3.5) ile verilen beklenen değere ve g^2 ile orantılı varyansa sahiptir. Bu, genelleştirilmiş en küçük karelerin mutlak artıklara uygulanmasının bir sonucudur. $\hat{\beta}$ için ağırlıklı en küçük kareler hesaplamaları,

$$\text{Bağımlı Değişken} = \left|y_i - f(x_i, \hat{\beta})\right|$$

$$\text{Parametreler} = (c_f, \theta)$$

$$\text{Regresyon Fonksiyonu} = c_f g\left[\mu_i(\hat{\beta}), z_i, \theta\right]$$

$$\text{Varyans Fonksiyonu} = g^2\left[\mu_i(\hat{\beta}), z_i, \theta\right]$$

olmak üzere,

$$\left|y_i - f(x_i, \hat{\beta})\right| = c_f g\left[\mu_i(\hat{\beta}), z_i, \theta\right]$$

regresyonundan elde edilen mutlak sapma tahminleri, ağırlıkların elde edilmesinde kullanılır. Öte yandan $\hat{\theta}$ tahmin edicisi elde edildikten sonra $\hat{\beta}$ tahmin edicisi genelleştirilmiş en küçük kareler ile güncelleştirilir. Bu işlem birkaç kez tekrarlanabilir; yeni bir $\hat{\theta}$ tahmin edicisi ve sonrasında $\hat{\beta}$ tahmin edicisi vb. şekilde sürdürölür. Yakınsama garanti değildir. Ancak simetrik dağılan hatalar için $\hat{\theta}$ 'nın iterasyonla tahmini çok daha etkin olur. Öte yandan Harvey (1976), mutlak artıkların logaritmasının mutlak artıkların yaklaşık beklenen değerlerinin logaritmasında regresyonu önermiştir:

$$\log\left(\left|y_i - f(x_i, \hat{\beta})\right|\right) = \log\left[\sigma g\left(\mu_i(\hat{\beta}), z_i, \theta\right)\right]. \quad (3.6)$$

Hataların bağımsız ve türdeş dağıldığı varsayımıyla bu yaklaşık eş varyanslı bir regresyondur. Yürütölmesi yalnızca sıradan doğrusal olmayan en küçük kareler

gerektirdiğinden kolaydır. Buna karşılık artıklar sifira çok yakın ise, sifira çok yakın değerlerin logaritması büyüyeceğinden, sahte aykırı değerler sorunu çıkar ortaya. Bu potansiyel zorluktan kaçınmak için varyans modellemesi yapılırken birkaç çok küçük artışın silinmesi yoluna gidilmelidir

Carroll ve Davidain (1987), ağırlıklı artık karelerinin etkinliğini ya da θ 'nın sözde olabilirlik tahminini ağırlıklı mutlak artıkları kullanarak uygulamışlardır. Eğer varyans fonksiyonu ortalama ile ilgili değilse ya da hatalar simetrik ya da σ küçükse

$$\text{Mutlak artık tahmininin asimptotik bağıl etkinliği} = \frac{[2 + \kappa][1 - \delta]}{4\delta} \quad (3.7)$$

olduğunu göstermişlerdir. Burada κ hataların basıklığı, δ ise

$$r_i = \frac{[y_i - f(x_i, \beta)]}{[\sigma g(\mu_i), z_i, \theta]}$$

şeklindeki standardize artıkların varyansıdır.

3.4. ARDIŞIK ARTIKLARA DAYANAN YÖNTEMLER

Temelde en küçük kareler artıkları e_i , ($i = 1, \dots, n$) varyansların tahmini amacıyla kullanılabilir. Alternatif olarak Student-türü artıklar da $r_i = e_i / \sqrt{1 - h_{ii}}$,

$h_{ii} = \text{köşegen}(X(X'X)^{-1}X')$ ile hesaplanarak kullanılabilir. Student-türü artıklar hala korelasyonlu olabilir, ancak model doğru belirlenmiş ise eş varyanslıdır. Bir başka artıklar sınıfı da ardışık artıklardır. Kianifard ve Swallow (1996), en küçük kareler artıkları ya da Student-türü artıklardan farklı olarak ardışık artıkların eş varyanslı ve bağımsız olduğunu belirtmişlerdir. Model doğru olarak kurulmuş ise ardışık artıklar bağımsız ve türdeş dağılır. Ardışık artıklar, gözlemlerin ilk p baz ile (p parametre sayısıdır) ile başlanarak her adımda bir gözlemin eklenmesi ile hesaplanır. Her adımda hesaplanan regresyon eşitliği bir sonraki adımda eklenecek gözlem için artışın hesaplanmasında kullanılır. Bu süreç son artık hesaplanıncaya kadar devam eder (Rawlings ve diğ., 1998). Ardışık artıklar korelasyonsuz artıklar sınıfına girer ve en küçük kareler artıklarına göre hata varyanslarını daha kesin yansıtır.

ω_i , i 'inci ardışık artığı göstermek üzere, algoritma aşağıdaki gibidir:

i = p to n-1

$$\hat{\beta}_i = (X_i' X_i)^{-1} X_i' Y_i$$

$$\hat{y}_{i+1} = x'_{i+1} \hat{\beta}_i \quad (3.8)$$

$$\omega_{i+1} = \frac{y_{i+1} - \hat{y}_{i+1}}{\sqrt{1 + x'_{i+1} (X'X)^{-1} x_{i+1}}} \quad (3.9)$$

end;

Burada, x_{i+1} : X matrisinin (i+1)'inci satırına karşılık gelen vektördür. Bu işlem her defasında 1 gözlem eklenerek (n-p) kez tekrarlanır ve (n-p) tane ardışık artık elde edilir. Ardışık artıklardan ilk p tane ardışık artık sıfırdır. Ardışık artıkların varyansı,

$$\hat{\sigma}_\omega^2 = \frac{\sum_{i=p+1}^n (\omega_i - \hat{\omega})^2}{(n-p-1)} \quad (3.10)$$

dir. Burada $\hat{\omega} = \sum_{i=p+1}^n \omega_i / (n-p)$ dir. Varyansların tahmini için $\sigma_1^2, \dots, \sigma_n^2$ 'nin bilindiği ve ilk iterasyon için en küçük karelerin kullanıldığı göz önünde tutulmalıdır. Daha çok iterasyon için σ_i^2 mevcut tahmini $\hat{\sigma}_i^2$ ile yer değiştirir (Rawlings ve diğ., 1998).

3.5. DEĞİŞTİRİLMİŞ (MODIFIED) ARDIŞIK ARTIKLAR YÖNTEMİ

Bischoff ve diğ. (2006) tarafından önerilen yöntemin algoritması kesim 3.4'de açılan algoritmayla aynıdır. Ek olarak, simetri için artık dönüşümleri kullanılmaktadır. İlk p gözlem (p, parametre sayısıdır) kullanılarak (p+1)'inci artık tahmin edilir. Daha sonra, her adımda bir gözlem eklenerek bu işlem (n-p) defa tekrarlanır ve (n-p) sayıda bağımsız artık elde edilir. Bu yöntemde, hatalar normal dağılımlı varsayıldığından 'ω' ardışık artık vektörü, "0" ortalamayla normal dağılıma sahip olur. Bundan dolayı karesel artıklar sifıra çok yakın olduğundan $Ln(\omega^2)$ dönüşümü uygulandığında negatif değerlerin sayısı fazlalaşır ve artık dağılımındaki simetri bozulur. Bu problemden kaçınmak için alternatif Box-Cox dönüşümü kullanılabilir.

T(.) dönüşüm, z, dönüştürülecek ögeyi göstermek üzere,

$$T(z) = \ln(z + M), M = (M, \dots, M)^T \in R^n; z = \omega^2 \quad (3.11)$$

$$M = \frac{(\text{ortc}(\omega_i^2))^2}{\max(\omega_i^2)} \quad (3.12)$$

biçiminde verilir. Örneğin, mutlak ardışık artıklar dönüştürülecekse $z = |\omega|$ karesel ardışık artıklar dönüştürülecekse $z = \omega^2$ olur.

Bu işlemde dikkat edilmesi gereken nokta, varyansların, p sayıda bilinmeyen parametre vektörü $\hat{\beta}$ ile tahmin edildikleridir. Bu işlem, n - q (n >> q) tane ardışık artık ile yapılabileceği gibi n tane standart en küçük kareler artığı ile de yapılabilir. Bu durumda, p < (n-q) parametreye bağlı n tane $\hat{\sigma}_1^2, \dots, \hat{\sigma}_n^2$ varyans tahmini elde edilir.

Ardışık artıklar ile ilgili en büyük eleştiri, çok hesaplama gerektirmeleri ve başlangıç en küçük kareler artıklarıyla ortak bir taraflarının olmamasıdır.

3.6. YENİDEN AĞIRLIKLANDIRILMIŞ İTERATİF EN KÜÇÜK KARELER YÖNTEMİ

Meloun ve diğ. (2002), tarafından önerilen yöntem, verinin normalden başka bir dağılıma uyması, değişen varyanslılık, aykırı değerler ya da yüksek kaldıraç noktalarının varlığı durumunda kullanılmaktadır.

Regresyon parametreleri, yeniden ağırlıklandırılmış iteratif en küçük kareler yöntemi (YAIKK) ile aşağıda verildiği gibi hesaplanır:

$$\sum_{i=1}^n w_i(r) y_i x_{ij} = \sum_{i=1}^n \sum_{k=1}^m w_i(r) x_{ij} x_{ik} \hat{\beta}_k, \quad r_i = e_i / \sigma, \quad j = 1, \dots, p \quad (3.13)$$

Ortancaları kullanan sağlam yöntemin aşamaları aşağıdadır:

- En küçük karelerden elde edilen artıklarının ortancası bulunur
- j, iterasyon indisini göstermek üzere,

$$\hat{\sigma}^{(j)} = \frac{\text{ortc}|\hat{e}^{(j)} - \text{ortc}(\hat{e}^{(j)})|}{0.6745} \quad (3.14)$$

ya da $\hat{\sigma}^{(j)} = 2.1 \text{ortc}|\hat{e}^{(j)}|$ alınır.

Burada,

$e^{(j)}$: j'inci iterasyon için elde edilen artıklar vektörü,

$\hat{\sigma}^{(j)}$: j'inci iterasyon için (3.14)'den hesaplanan standart sapma tahminidir. 0.6745 değeri hataları normal dağılıma sahip büyük örneklem için $\hat{\sigma}$ 'yı artık standart sapmasına eşit kılma sabitidir.

- Ağırlıklar, $w_i^{(j)} = k\ddot{s}egen(r_i^{(j)} / \hat{\sigma}^{(j)})$ olarak alındığında, ağırlıklı en küçük kareler regresyonundan,

$$\hat{\beta}^{(j)} = (X'W^{(j)}X)^{-1}X'W^{(j)}Y \text{ hesaplanır.}$$

δ çok küçük bir sayı iken, $\hat{\beta}^{(j)}, \hat{\beta}^{(j-1)}$ ardışık iki parametre tahmini olmak üzere,

$$|\hat{\beta}^{(j)} - \hat{\beta}^{(j-1)}| < \delta \text{ olmadıkça adımlar tekrarlanır.}$$

3.7. CHATTERJEE ve MACHLER TARAFINDAN ÖNERİLEN ITERATİF YÖNTEM

Chatterjee ve Machler (1997) tarafından önerilen bu yöntemde en küçük kareler tahminlerine başvurulmaksızın doğrudan iteratif ağırlıklı en küçük kareler ile başlanır.

- İlk adımda, h_{ii} , $H = X(X'X)^{-1}X'$ matrisinin i'nci köşegen değeri ve $\tilde{h} = p / n$ olmak üzere $w_i^{(0)} = 1 / \max(h_{ii}, \tilde{h})$, ağırlık olarak seçilir. Bu başlangıç ağırlıkları ile

$$\hat{\beta}^{(0)} = (X'W^{(0)}X)^{-1}X'W^{(0)}Y \text{ başlangıç tahminleri bulunur;}$$

Burada, $W^{(0)} = k\ddot{s}egen(w_1^{(0)}, w_2^{(0)}, \dots, w_n^{(0)})$ dir.

- İkinci ve daha sonraki adımlar için en son regresyondan elde edilen artıklar kullanılarak yeni ağırlıklar hesaplanır işlemler j'inci iterasyon için aşağıdaki gibidir:

$$e^{(j-1)} = y - \hat{y}^{(j-1)} = y - X\hat{\beta}^{(j-1)} \quad (3.15)$$

$$w_i^{(j)} = (1 - h_{ii})^2 / \max\{|e_i^{(j-1)}|, ortc|e_i^{(j-1)}|\} \quad (3.16)$$

Bu işlem istenen yakınsama gerçekleşinceye kadar tekrarlanır. Yakınsama garantisi yoktur.

3.8. TEKRARLI GÖZLEMLER İÇİN ORTALAMA ve VARYANS FONKSİYONLARI

Amaç öngörü (prediction) olduğunda her x_i' bağımsız değişkenler satır vektörü için m_i sayıda y_i değeri elde edilir.

Başka bilgi olmaksızın öngörü değişkenlerinin her bir düzeyindeki örneklem varyanslarının tersi ağırlık alınarak β parametresi ağırlıklı en küçük karelerle tahmin edilir.

i 'inci tekrarın örneklem ortalaması \bar{y}_i iken,

$$\text{örneklem varyansı } s_i^2 = (m_i - 1)^{-1} \sum_{j=1}^{m_i} (y_{i,j} - \bar{y}_i)^2,$$

$$\text{ağırlık tahminleri } \hat{w}_i = 1 / s_i^2,$$

ve $\hat{W} = \text{kösegen}(w_1, w_2, \dots, w_n)$ olmak üzere β vektörü,

$$\hat{\beta}_w = (X' \hat{W} X)^{-1} X' \hat{W} Y \quad (3.17)$$

ile tahmin edilir.

Tekrar sayısı genelde oldukça küçüktür. Tipik olarak 2 ya da 3 olabilir. Yöntemin dezavantajı, tekrar sayısı küçük olduğunda ağırlıkların çok zayıf bir biçimde tahmin edilmesidir (Carroll ve Ruppert, 1988).

3.9. BOOTSTRAP YÖNTEMİ

Regresyon modellerinde eş varyanslı olmayan hatalar durumunda tahmin, yeniden ağırlıklandırılmış en küçük kareler ya da bazı sağlam yöntemler kullanılarak yapılırsa tahmin varyanslarının değerlendirilmesi için standart yöntemler işlemeyebilir. Bootstrap, Efron tarafından bu tip karmaşık durumlarda tahminlerinin kesinliğini sağlamak için geliştirilmiştir. Bootstrap yöntemi, gözlenen örneklemden aynı büyüklükte rastgele iadeli örneklemelerin seçilmesidir. Bu yöntemde aynı gözlemin birkaç kez seçilebilmesi ya da orijinal örneklemde bulunan bazı gözlemlerin seçilmemesi olasıdır.

Basit doğrusal regresyon için orijinal örnekteki (x, y) çiftlerinin bootstrap örnekleme kullanılır. İadeli bootstrap örnekleme ile n tane (x^*, y^*) çifti elde edilir. Bootstrap örnekleme oluşturulduktan sonra regresyon katsayıları standart yöntemler

kullanılarak bulunur. β parametresi için ilk bootstrap tahmini b_1^* bulunduktan, sonra n örneklem büyüklüğü için, yeteri kadar tekrarlanarak bir örnekleme dağılımı oluşturulur.

Kutner ve diğ. (2005), göre regresyon için bootstrap örneklemesinin ikinci bir yolu da vardır: Orijinal verilerden standart yöntemlerle elde edilen e_i artıkları örneklem kümesi kabul edilerek, bu artıkların örneklemeden rasgele iadeli örneklem seçilir. Örneklemeden elde edilen n sayıda $e_1^*, e_2^*, \dots, e_n^*$ bootstrap artığı, orijinal \hat{y}_i 'lere

$$Y_i^* = \hat{y}_i + e_i^* \quad (3.18)$$

şeklinde eklenerek $Y_1^*, Y_2^*, \dots, Y_n^*$ bootstrap değerleri elde edilir. Elde edilen bu değerler yeni bağımlı değişken gibi dikkate alınır ve bağımsız değişkenler ile regresyonu yapılarak b^* bootstrap parametre tahmin edicisi elde edilir. Bu süreç yeteri sayıda tekrarlanarak b^* 'nin örnekleme dağılımı oluşturulur. Örneklem çekme işlemi bazen çok az sayıda örneğin 50 kez yapılır. Genelde 200-500 sayıda yineleme yeterli olur. Bootstrap tahminlerinin doğruluğu, yineleme sayısı artıkça $S^*\{b^*\}$ 'nin kararlı hale gelmesiyle gözlenebilir. $S^*\{b^*\}$, tüm bootstrap tahminlerinin standart sapması aynı zamanda $\hat{\beta}$ 'nin örnekleme dağılımının değişkenliğinin tahmini, yani kesinliğinin ölçüsüdür.

Bootstrap, yaklaşık güven aralıklarının elde edilmesi için de kullanılır. Bootstrap güven aralıklarının oluşturulmasında pek çok yöntem vardır. Basitçe, $\%(1-\alpha)$ 'lık güven aralığı oluşturmak için kullanılan yöntemlerden biri yansıma (reflection) yöntemidir. Yöntemin her zaman olmasa da genelde iyi sonuçlar verdiği belirtilmektedir. β için yansıma güven aralığı, b^* 'in bootstrap dağılımının $(\alpha/2)100$ ve $(1-\alpha/2)100$ yüzdelerine karşılık gelir. Bu yüzdeler,

$$d_1 = b - b^*(\alpha/2)$$

$$d_2 = b^*(1-\alpha/2) - b$$

biçimde hesaplanarak β için $\%(1-\alpha)$ 'lık güven aralığı

$$b - d_2 \leq \beta \leq b + d_1 \quad (3.19)$$

olarak elde edilir.

3.10. JACKKNIFE YÖNTEMİ

Bazı istatistiksel tahmin problemlerinde, teorik karmaşıklık ya da istatistiksel model ile ilgili bilgi eksikliği, tahminin standart hata ve yanlılık (bias) hesaplanmasını engeller. Jackknife yöntemleri, hem yanın hem de standart hatanın sayısal yaklaşımlarla doğrudan elde edilmesini sağlar ve güven sınırları verir. Yinelemeli örnekleme yöntemlerinden biri olan Jackknife istatistiği θ , n olası örneklem büyüklüğü ile her adımda bir gözlem dışarıda bırakılarak (n-1) gözlem için hesaplanır (Hinkly, 2010). Wu (1986), Jackknife yönteminin düzgün (smooth) tahmin ediciler için varyans ve yanlılık tahmininde iyi işlediğini belirtmiştir. Ancak tutarsız varyans tahminleri veren örneklem ortancası gibi düzgün olmayan tahmin ediciler için Jackknife yöntemi iyi sonuçlar vermez. Yöntemin bir diğer dezavantajı ise orijinal $\hat{\theta}$ 'dan i. gözlemin silinmesiyle elde edilen $\{\theta_{(i)}\}_i^n$ 'lerin normalize edilmiş histogramı standart normale yaklaşmaz. Bu nedenle de varyans tahminleri yapılmadan geçerlilik aralıkları oluşturulamaz. Klasik $y_i = x_i'\beta + \varepsilon_i$ doğrusal regresyon modelinde, ε_i hata terimleri sıfır ortalama ve σ_i^2 varyansı ile aralarında ilişkisizdir. Tekil olmayan $(X'X)$ matrisi için β 'nın en küçük kareler tahmin edicisi $\hat{\beta} = (X'X)^{-1}X'Y$ dir. β 'nın tahmin edicisi olan $\hat{\beta}$, (x_i, y_i) çiftinin silindiği örneklemden $\hat{\beta}_{(i)}$ Jackknife tahmin edicisi yeniden hesaplama ile

$$\hat{\beta}_{(i)} = (X'_{(i)}X_{(i)})^{-1}X'_{(i)}y_{(i)} \quad (3.20)$$

formülünden elde edilir. β 'nın doğrusal olmayan $\theta = g(\beta)$ şeklindeki fonksiyonunun tahmini $\hat{\theta} = g(\hat{\beta})$ için, Jackknife tahmin edicisi $\hat{\theta}_{(i)} = g(\hat{\beta}_{(i)})$ ve sözde değerler (pseudo value) $p_i = n\hat{\theta} - (n-1)\hat{\theta}_{(i)}$ dir. θ 'nın Jackknife nokta tahmin edicisi $\tilde{\theta} = n^{-1}\sum_1^n p_i$ ve $\hat{\theta}$ için varyans tahmin edicisi,

$$v_j = \frac{1}{n(n-1)}\sum_1^n (p_i - \tilde{\theta})(p_i - \tilde{\theta})' \quad (3.21)$$

ile elde edilir.

3.11. PARAMETRİK OLMAYAN DÜZLEME

Parametrik yöntemlere bir başka alternatif yaklaşım olarak varyanslar parametrik olmayan regresyon teknikleriyle tahmin edilebilir. Varyansların nasıl belirleneceğinin bilinmediğini ve bunun yerine yalnızca bilinmeyen bir g_0 fonksiyonunun olduğunu ve bu fonksiyon için,

$$st.sapma(y_i) = g_0(x_i) \quad (3.22)$$

ya da

$$st.sapma(y_i) = g_0(\mu_i(\beta)) \quad (3.23)$$

biçiminde bir ilişkinin var olduğu varsayalım. Sorun, (3.22) ya da (3.23) durumuna ek olarak ağırlıklar bilindiğinde bir β tahmin edicisinin hesaplanmasının olası olup olmadığıdır. Her bir x_i tasarım noktasında gözlem tekrarı sayısı m_i olsun. Pratikte yineleme sayısı genelde küçük olur. İlk olarak veriye ağırlıksız en küçük kareler uygulanır ve mutlak sapmalar,

$$d_{ij}(\hat{\beta}_{LS}) = |y_{ij} - f(x_i, \hat{\beta}_{LS})| \quad (3.24)$$

biçiminde hesaplanırsa, x_i noktasındaki varyans tahmini,

$$\hat{\sigma}_i^2 = m_i^{-1} \sum_{j=1}^{m_i} d_{ij}^2(\hat{\beta}_{LS}) \quad (3.25)$$

olur. Tahmini ağırlıklar $w_i = 1.0/\hat{\sigma}_i^2$ biçiminde bulunarak genelleştirilmiş en küçük kareler uygulanır. Bu ağırlıkların çok büyük bir bölümü, ağırlıklar küçük serbestlik derecelerine sahip olduklarından güvenilir değildir. β için asimptotik varyanstaki artış, tutarsız fonksiyon kullanımı nedeniyle önemli olabilir. (3.25)'deki varyans tahminleri yeteri kadar düzgün değildir ve β 'nın genelleştirilmiş en küçük kareler sonuçlarının zayıf olmasına yol açar. Bu durumda x 'e çok "yakın" tasarım noktaları en büyük ağırlığı alır. Varyans fonksiyonu tahmin yöntemlerinden biri,

$$Varyans(y_i) = E(y_i^2 | x_i) - [E(y_i | x_i)]^2$$

dir. Bu yaklaşım, verilen x_i için y_i^2 ve y_i ' nin koşullu beklenen değerinin tahminiyle parametrik regresyon uygulamasını öneren bir yöntemdir. Ortalama fonksiyonunun $f(x_i, \beta)$ olduğuna dair kuşku yoksa o zaman parametrik olmayan bir regresyon uygulaması,

$$\text{Varyans}(y_i) = E(d_i^2(\beta) | x_i) \quad (3.26)$$

ilişkisinin kullanılmasıyla daha etkin olur. x_{ij} , p elemanlı bir vektör iken β 'nin bilindiği, varyansların (3.26) modeline uyduğu ve $d_i^2(\beta)$ terimlerinin ağırlıklı ortalaması olduğu varsayalım. O halde, $g_x(0)$ için $\sum_{i=1}^N c_{i,n}(x) = 1$ olmak üzere varyansların $d_i^2(\beta)$ kullanılarak tahmini,

$$\hat{g}_0^2(x, \beta) = \sum_{i=1}^N c_{i,n}(x) d_i^2(\beta) \quad (3.27)$$

olur.

Burada $c_{i,n}(x)$, $h \rightarrow 0$, yerel (local) ortalama miktarını kontrol eden bant genişliği (düzleme parametresi); $a_{i,n}(x)$, $K(\cdot)$ orijinde tek tepeli ve p boyutlu

$$a_{i,n}(x) = K\left(\frac{x - X_{i1}}{h}, \frac{x - X_{i2}}{h}, \dots, \frac{x - X_{ip}}{h}\right)$$

şeklinde yaygınlık fonksiyonu olmak üzere,

$$c_{i,n}(x) = \left(\frac{a_{i,n}(x)}{\sum_{j=1}^n a_{j,n}(x)} \right) \quad (3.28)$$

dir.

h 'nin büyük değerleri için fonksiyon daha çok düzgünleşir ve yanlılık artar bundan dolayı sabit bir n için $h \rightarrow \infty$ 'a iraksadığında,

$$\hat{g}_0^2(x, \beta) \rightarrow n^{-1} \sum_{i=1}^N d_i^2(\beta)$$

olur.

Varyans fonksiyonunun tutarlı bir tahminini elde etmenin bir yolu çekirdek fonksiyonlarının kullanımudur (Carroll ve Ruppert, 1988). Çekirdek fonksiyonları, simetrik olup olasılık fonksiyonları özelliklerini taşırlar. Çizelge 3.1'de verilen bu

fonksiyonlar, en iyi oldukları için değil kolay anlaşılır ve diğer yöntemlere aracılık yapmaları nedeniyle tercih edilirler (Kıroğlu, 2001).

Çizelge 3.1. Çekirdek Fonksiyonları

Çekirdek	Fonksiyon
<i>Epanechnikov</i>	$K = \frac{3}{4}(1-t^2) (I(t \leq 1))$
<i>İki Ağırlıklı (Biweight)</i>	$K = \frac{15}{16}(1-t^2)^2 (I(t \leq 1))$
<i>Üçgensel (Triangular)</i>	$K = (1- t)(I(t \leq 1))$
<i>Normal (Gaussian)</i>	$K = \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}t^2}$
<i>Uniform (Rectangular)</i>	$K = \frac{1}{2}(I(t \leq 1))$
<i>Üç Ağırlıklı (Triweight)</i>	$K = \frac{35}{32}[1-t^2]^3 (I(t \leq 1))$
<i>Cosinus</i>	$K = \frac{\pi}{4} \cos\left(\frac{\pi}{2}t\right) (I(t \leq 1))$

Çizelge 3.1'deki $I(\cdot)$ gösterge fonksiyon olup, koşul gerçekleştiğinde 1, aksi halde 0'dır (Eviews 4.1 User Guide).

Genel olarak bir $f(x)$ fonksiyonunun çekirdek tahmin edicisi,

$$f(x) = \frac{1}{nh} \sum_{i=1}^n K\left(\frac{x - X_i}{h}\right)$$

şeklinde tanımlanır.

Bu fonksiyon,

$K(u) \geq 0$ pozitif,

$K(u) = K(-u)$ simetrik,

$$\int_{-\infty}^{\infty} K(u)du = 1 \text{ olasılık yoğunluk fonksiyonu,}$$

$$\int_{-\infty}^{\infty} K^2(u)du < \infty \text{ sonlu olma,}$$

$$\int_{-\infty}^{\infty} uK(u)du=0,$$

özelliklerine sahiptir.

Bant genişliğinin seçimi oldukça önemlidir. Bant genişliği, fonksiyonun düzleme miktarını kontrol eder. Küçük bant genişlikleri sivri ve pürüzlü histogramlar verirken, büyük bant genişlikleri daha düzgün histogramlar verir (Kıroğlu, 2001).

$\hat{\beta}$, β 'nin bir tahmin edicisi olsun. Ağırlıksız en küçük karelerin uygulanması olasıdır ama etkili değerlerden etkilendiğinden tercih edilmez. Değişen varyanslılıktan dolayı, ağırlıksız en küçük kareler yüksek kaldıraç noktalarında aykırı değerleri bulmaya yönelir. Bu durumun önüne geçmenin bir yolu, varyansları çekirdek fonksiyonları ile tahmin etmektir. Çekirdek varyans fonksiyonunun biçimi $\hat{g}_0^2(x, \beta)$ ve ağırlık fonksiyonunun biçimi,

$$\hat{w}(x, \hat{\beta}) = \left[\hat{g}_0^2(x, \beta) + \eta_n \right]^{-1} \quad (3.29)$$

dir. Burada η_n , bant genişliğine göre sıfıra daha yavaş yakınsayan ve işlevi, $\left[\hat{g}_0^2(x, \beta) + \eta_n \right]$ ifadesinin sıfır olmasını engelleyerek sonsuz ağırlıkların oluşmamasını sağlayan pozitif sayılar dizisidir (Carroll ve Ruppert, 1988).

3.12. DÖNÜŞÜMLER

Regresyon analizinde bağımlı değişken dönüşümü, çoğunlukla üç farklı amaç için yapılır: Normal dağılan toplamsal hatalar, artık varyanslarını dengeleme ve bağımsız değişkenlerle temsil edilen basit bir doğrusal model elde etme (Hamasaki ve Goto, 2005). En sık başvuru dönüşüm, Box ve Cox (1964) tarafından geliştirilen bağımlı değişken dönüşümlerdir. Varyansın bağımlı değişkenin artan değerlerine paralel olarak arttığı durumlarda kullanılan bu dönüşüm, pozitif değerli değişkenlere uygulanabilmektedir. Bu dönüşümler, Y artarken Y'nin varyansı da artıyorsa varyansı dengelemek için; Y'nin hataları sağa çarpıksa Y'nin dağılımını normalleştirmek ya da bağımlı değişken ile bağımsız değişken arasında sürekli artan bir eğim söz konusu olması durumunda ise modeli doğrusallaştırmak için kullanılmaktadır (Albayrak, 2008).

Tek başına değişen varyanslılık, ağırlıklandırma teknikleriyle düzeltilebilir; ancak yalnızca varyansların tersi, hatalar normal dağılmadığında uygun olmaz (Carroll ve Ruppert, 1988). Çarpık verinin modellenmesi konusunda çok iyi kurgulanmış iki yol vardır: İlkinde hata paylarının yoğunluğuna çarpık parametrik yoğunluk fonksiyonu

(örneğin gamma) ile yaklaşılır (McCullagh ve Nelder, 1983). Bu yaklaşım, Y'nin simetrik bir dağılıma dönüştürülebildiğini varsayar.

$h(y, \lambda)$, λ 'ya bağlı Y rastlantı değişkeni için dönüşümleri gösterebilir. Çoğu kez λ bir skalerdir. Bu aile genelde $h(y, \lambda)$ 'nın Y'de monoton olmasını gerektirir; aksi halde, Y için $h(y, \lambda)$ ile ters dönüşüm olmaz.

En çok kullanılan dönüşüm ailesi, Box ve Cox'un (1964) değiştirilmiş üs (modified power) dönüşümüdür:

$$h(y, \lambda) = \begin{cases} (y^\lambda - 1) / \lambda & \lambda \neq 0 \text{ ise} \\ \log y & \lambda = 0 \text{ ise} \end{cases} \quad (3.30)$$

Bir başka olası üs dönüşümü ise,

$$h(y, \lambda, \mu) = (y - \mu)^{(\lambda)} \quad (3.31)$$

şekindeki dönüşümüdür.

(3.30)'un kullanımı Y değerlerinin pozitif olmasını varsayar. Eğer Y, bir minimum değere sahipse, o zaman $(y - \mu)$ 'nün uygun bir μ seçimiyle pozitif olması sağlanır.

Dönüşüm ailesinin seçiminden sonra hataları, 0 ortalama ve σ^2 varyansla normal dağılım toplamsal $Y = f(x, \beta) + \varepsilon$ modeli,

$$h(y, \lambda) = h(f(x, \beta), \lambda) + \varepsilon \quad (3.32)$$

modeli ile yer değiştirir. Model, Y ve $f(x, \beta)$ 'ye bazı dönüşümler uygulandıktan sonra artıkların eş varyansla normal dağıldığını ifade eder. (3.32) modelinin hareket noktası, $\varepsilon \equiv 0$ olduğunda hiçbir değişim kaynağı yoksa (3.32) modeli $y = f(x, \beta)$ 'e eşitliğine denktir. $h(y, \lambda)$ bazı λ değerleri için y 'de doğrusalsa o zaman (3.32) modeli $y = f(x, \beta)$ modelini özel bir hal olarak kapsar ki veri böyle bir göstergeye sahip olduğunda dönüşüm yapmama seçeneği ortaya çıkar. Örneğin, değiştirilmiş üs dönüşümü ailesi kullanıldığında "dönüşüm ihtiyacı yok" şeklinde ifade edilebilen yokluk hipotezi, $H_0 : \lambda = 1$ ile test edilir.

Regresyon eşitliğini korumak için, eşitliğin her iki tarafına dönüşüm uygulanabilir. Artık değişimi çarpıklık ya da eş varyanslı olmayan bir manzara sergilediğinde Y'ye basitçe $f(x, \beta)$ ile ağırlıksız olarak eğri uydurmak yerine çift yanlı dönüşüm yöntemleri kullanmak için pek çok neden vardır. İlk olarak normalleştirme ve eş

varyansa dönüşüm yapmak, β parametre tahmin edicilerinin daha etkin olmasını sağlar. Herhangi bir dönüşüm olmaksızın β 'nin standart en küçük kareler tahmin edicisi büyük varyansa sahip olur. Dahası çift yanlı dönüşüm modeli, verilen X için Y 'nin tam koşullu bir modeline olanak sağlar. Böylece ortalama için güven aralıkları ya da Y 'nin çeyrekleri kadar Y için öngörü aralıkları ve verilen X için kalibrasyon aralıkları mevcut olur. $\hat{\beta}$, β 'yi çok iyi tahmin etse bile standart en küçük karelere dayalı güven, öngörü ve kalibrasyon aralıkları, artık değişimi normalden uzak ve varyans dengeli değilse çok büyük yanılgılara neden olur.

Dönüşümler normalliği ve eş varyanslılığı sağlayabilse bile verilen herhangi bir veri kümesi için tek bir dönüşüm her ikisini garanti etmez. Çarpıklığı gidermek ve varyansı dengelemek için eş anlı olarak ağırlıklandırma ve dönüşüm gerekebilir. Aykırı değerler, dönüşüm parametreleri tahmini üzerinde çok şiddetli etki yapar; örneğin tek bir aykırı değer normal ve eş varyanslı veri kümesinde çok büyük bir çarpıklığa ve görünür bir değişen varyanslılığa neden olabilir. Karşıt olarak, sağa çarpıklık sol kuyruktaki tek bir aykırı değer tarafından maskelenebilir ve küçük varyansa sahip bir gözlemde aykırı değer ortaya çıkarsa değişen varyanslılık gizlenebilir.

Doğrusallaştırma dönüşümleri en küçük karelerin etkinliğini çok azaltarak asimetriye ya da değişen varyanslılığa neden olur. Kimi zaman doğrusallaştırma şiddetli değişen varyanslılığa ve fiziksel olarak mümkün olmayan bir parametre tahminine neden olur (Carroll ve Ruppert, 1998).

Çift yanlı dönüşümlerin bir örneği, dönüştürülmüş yanıt $y^{(\lambda)}$ 'nin dönüştürülmüş bağımsız değişken $x^{(\lambda)}$ ile

$$y^{(\lambda)} = \alpha_0 + \alpha_1 x^{(\lambda)} + \varepsilon \quad (3.33)$$

biçimindeki doğrusal regresyonudur.

Dönüşümler, yalnızca eş varyanslı ya da normal dağılan hata terimleri elde etmek için yapılmaz. Bazı veri kümelerinde bağımlı ve bağımsız değişkenlerin dönüşümleri, veriye çok iyi uyan bir model sonucu verdiği için yapılabilir (Ryan, 1997).

3.13. AĞIRLIKLANDIRMA ve DÖNÜŞÜMLERİN BİRLEŞTİRİLMESİ

Bazı veri kümeleri için tek bir dönüşümün normalliği sağlayamaması ve varyansı dengeleyememesi çok beklenmedik bir durum değildir. Aslında beklenmedik olan tek bir dönüşümün her iki durumu yerine getirmesidir. Buna rağmen bazı durumlarda eş varyansla normale yakın hatalar elde etmek için hem dönüşüme hem de ağırlıklandırmaya başvurmak gerekebilir. Bu, özellikle varyans bir değişkene bağlı olduğunda doğrudur (Carroll ve Ruppert, 1988).

Bazı veri kümelerinde her ikisi muhtemelen gerekli olmamasına rağmen dönüşüm ya da ağırlıklandırmadan hangisinin tercih edilmesi gerektiği açık değildir. Bu durum varyans ortalamasının monoton bir fonksiyonu olduğunda daha çok geçerlidir. Willet ve Singer (2002) tarafından ifade edildiği üzere ağırlıklandırma için uygun bir yöntem olmadığında ağırlıklandırma stratejisinin uygulanması, ağırlıklı en küçük kareler sonuçlarında çok büyük belirsizliklere neden olur.


3.14. KELEBEK DAĞILAN ARTIKLAR İÇİN DEĞİŞEN VARYANSLILIĞI DENGEMEDE ALTERNATİF YÖNTEMLER

Bu bölümde, kelebek dağılan artıklar için değişen varyanslılığın dengelenmesinde iki yönteme ek olarak bir de araç yöntem önerilmiştir. Önerilen yöntemler ve ayrıntıları aşağıda açıklanmıştır.

3.14.1. Dışsal Değişken ve Merkezileştirme


İstatistik literatüründe var olan değişen varyanslılık kalıpları, genel olarak monoton azalan ya da monoton artan varyanslar şeklindedir. Buna koşul olarak varyans dengeleme teknikleri de monoton artan ya da monoton azalan varyansı dengelemeye yöneliktir. Bu çalışmaya konu olan kelebek dağılan artıklar konveks bir yapıya sahiptir. Konveksliği basitçe şu şekilde tanımlarız: $y = f(x)$ fonksiyonu, $[a, b]$ aralığında 2'nci türe ve sahip ve $\forall x \in [a, b]$ için $f''(x) > 0$ ise $f(x)$ fonksiyonu, bu aralıkta konvekstir; $\forall x \in [a, b]$ için $f''(x) < 0$ ise $f(x)$ fonksiyonu bu aralıkta konkavdır.

Artıklar kelebek şeklinde bir dağılma gösterdiklerinde (Şekil 3.1), artıkların varyans ya da standart sapma fonksiyonları “azalan – artan” şeklinde monoton olmayan bir yapı sergiler.




Şekil 3.1. Aylar - Ham Artıklar

Artıklar kelebek şeklinde bir dağılıma sahip olduğunda, varyansların tahminleri olan artıkların kareleri ve standart sapmaların tahminleri olan mutlak artıklar, kolları yukarı doğru olan 2. dereceden bir karesel forma uygun dağılıma gösterirler (Şekil 3.2 ve 3.3).



Şekil 3.2. Aylar - Karesel Artıklar



Şekil 3.3. Aylar - Mutlak Artıklar

Bu bölümde yukarıda belirtilen bilgiler doğrultusunda, ham, mutlak ve karesel artıkların çizimleri dikkate alınarak alternatif yöntemler önerilmiştir.

Kelebek dağılan artıklar için mutlak ya da karesel artık çizimleri dikkate alındığında artık varyanslarının uçlarda büyüdüğü orta bölümde ise küçüldüğü görülmektedir. Öyle bir değişken tanımlansın ki bu değişken uç kısımlarda, orta kısımlara göre daha

büyük değerler alsın ve ağırlıklar tahmin edilirken monoton olmayan varyanslara duyarlı olsun. Aşağıda algoritması verilen yöntem bu algıya dayanmaktadır.

Algoritma:

1. $Y = f(X, \beta) + \varepsilon$ regresyon fonksiyonu için $Y_{n \times 1}$ bağımlı değişken, $X_{n \times p}$ tasarım matrisi ve $\beta_{(p+1) \times 1}$ boyutlu parametre vektörü olmak üzere, en küçük kareler parametre tahmin edicisi $\hat{\beta} = (X'X)^{-1}(X'Y)$, bağımlı değişkenin tahmin değerleri $\hat{Y} = X\hat{\beta}$ ve artıklar $e_i = y_i - \hat{y}_i$ eşitlikleriyle elde edilir.

2. $d = \{1, 2, \dots, n\}$ şeklinde yeni bir sıra değişkeni tanımlanır. Burada n, veri kümesindeki gözlem (sıra) sayısıdır. Yeni değişkenin kullanıldığı, mutlak artıklar $|e_i|$ için standart sapma fonksiyonu,

$$\hat{s}_i = |e_i| = \alpha_0 + \alpha_1 d_i + \alpha_2 d_i^2 \quad (3.34)$$

ya da karesel artıklar e_i^2 için varyans fonksiyonu

$$\hat{s}_i^2 = e_i^2 = \alpha_0 + \alpha_1 d_i + \alpha_2 d_i^2 \quad (3.35)$$

olarak yazılır.

Bu fonksiyonların dışsal değişken d 'ye göre 1. dereceden türevi

$$\frac{\partial s}{\partial d} = \alpha_1 + 2d\alpha_2$$

dir. Türev fonksiyonunun sıfır olduğu nokta kelebek dağılan artık yüzeyinin en dar noktasına karşılık gelen merkez (boğum noktası) olacaktır. Benzer şekilde galaksi dağılan artıklar söz konusu olduğunda merkez, dağılım yüzeyinin yaygınlığının en fazla olduğu noktaya karşılık gelecektir.

$$m = -0.5 \frac{\hat{\alpha}_1}{\hat{\alpha}_2} \quad (3.36)$$

$\hat{\alpha}_1$ ve $\hat{\alpha}_2$ değerleri (3.34) ya da (3.35) eşitliklerinin en küçük kareler çözümünden elde edildikten sonra (3.36) formülüyle boğum noktası hesaplanır.

3. Boğum noktasına göre dönüştürülmüş yeni merkezi dışsal değişken,

$$o_i = (d_i - m) \quad (3.37)$$

olur.

4. Önceki adımda elde edilen " o_i " merkezi değişkenin bağımsız değişken olduğu ve standart sapma fonksiyonu (Şekil 3.4) için mutlak artıkların bağımlı değişken olduğu,

$$\hat{s}_i = |e_i| = \theta_1 o_i + \theta_2 o_i^2 \quad (3.38)$$

ya da varyans fonksiyonu için karesel artıkların bağımlı değişken olduğu,

$$\hat{s}_i^2 = e_i^2 = \theta_1 o_i + \theta_2 o_i^2 \quad (3.39)$$

şeklinde regresyon modelleri kurulur. Bunların çözümünden, $|\hat{e}|$ 'ya dayalı ağırlık tahminleri,


$$\hat{w}_i = 1/|\hat{e}_i|, \quad |\hat{e}_i| \neq 0 \quad (3.40)$$

ya da \hat{e}^2 'ya dayalı ağırlık tahminleri,

$$\hat{w}_i = 1/\hat{e}_i^2, \quad \hat{e}_i^2 \neq 0 \quad (3.41)$$

ile elde edilerek $\hat{\beta}_w = (X'\hat{W}X)^{-1} X'\hat{W}Y$ ağırlıklı en küçük kareler uygulanır.

Ağırlık tahminleri için karesel ya da mutlak artıklardan hangisinin tercih edileceği kararı, görsel olarak grafiklere bakılarak ve ya belirtme katsayısı dikkate alınarak verilebilir.



Şekil 3.4. Mutlak Artıklardan Merkezi Dışsal Değişken ile Standart Sapma Fonksiyonu

Böylelikle modelde yer almayan bir değişken ağırlık tahmininde kullanılarak modele dâhil edilmiş olur.

3.14.2. Merkezi Dışsal Değişken ile Doğrudan Ağırlık Tahmini

Uygulamada da görüleceği üzere, verinin boğum noktasının asimetric olması durumunda, veriye bağlı olarak karesel artıkların ya da mutlak artıkların dışsal değişkenle ağırlık tahminlerinin elde edilmesinde kullanılması, boğum noktası çevresindeki artıkların sifira çok yakın olması, bu artıklara karşılık gelen gözlemlerin çok aşırı ağırlık almasına neden olabilir. Böyle bir durumda aykırı değerler sorunu ortaya çıkabilir. Bununla birlikte standart sapmalar ya da varyanslar, ortalamanın ya da bir ya da daha çok bağımsız değişkenin fonksiyonu olarak “azalan” ya da “azalan-artan” bir yapı sergileyebilir. Böyle bir durumda yatay ekseninde yer alan değişken artan ölçekte olduğundan söz konusu değişkenin mevcut skalası, varyansları değişkenin tersi ya da tersinin üsleriyle dengelemeye izin vermeyebilir. Böyle bir durum için merkezileştirilmiş dışsal değişkenin mutlak değerlerinin doğrudan ağırlık tahminlerinin elde edilmesinde kullanılması, değişen varyanslılığın dengelenmesi konusunda işe yarayabilir. Bu tip durumlarda kesim 3.14.1’de verilen algoritmanın ilk üç adımında elde edilen $o_i = (d_i - m)$ merkezi dışsal değişkenin mutlak değerleri

$$\hat{w}_i = 1/|o_i|, \quad |o_i| \neq 0 \quad \text{için} \quad (3.42)$$

şeklinde ağırlık tahminlerinin doğrudan elde edilmesinde ikinci bir alternatif olarak kullanılabilir. Buna ilişkin bir uygulama kesim 4.12.6'da verilmiştir.

Verilen iki yönteme ek olarak, merkezi dışsal değişkenin kesim 3.14.1'de verilen algoritmasının ilk iki adımında elde edilen boğum ya da merkez noktası, kesim 4.11'de bir uygulamasına yer verilen veri kümelerinin parçalanmasının gerektiği durumlarda bölme ekseninin elde edilmesinde araç olarak kullanılabilir.

4. UYGULAMA

Bu bölümde, önceki bölümde tanıtılan yöntemlerin kelebek dağılan artıklar için değişen varyanslılığa etkisi, hava kirliliğini etkileyen değişkenler için değerlendirilmiştir. Değerlendirmede artık çizimlerinin yanısıra belirtme katsayısı, denklemin standart hatası, değişim katsayısı gibi model yeterlilik ve karşılaştırma ölçüleri; AIC, BIC, SBC gibi model seçme kriterleri dikkate alınmıştır. Öte yandan önerilen yöntemler hem veri kümesinde hem de farklı örnekleme genişliğinde yapay veri kümeleriyle de sınanmıştır.

4.1. HAVA KALİTESİ İNDEKSİ

Hava kalitesi, belli kirletici konsantrasyonlarını kaydeden ölçüm cihazlarından oluşan bir ağ yardımı ile ölçülür. Bu ham ölçüm değerleri, geliştirilen standart formüller kullanılarak hava kalitesi indeksi (HKİ) değerlerine dönüştürülmektedir. HKİ değeri, bölgedeki her bir kirletici için ayrı ayrı hesaplanır (yer seviyesindeki ozon, partiküller madde, karbon monoksit, kükürt dioksit ve azot dioksit). Her bir kirletici için hesaplanan en yüksek HKİ, o güne ait HKİ değerini oluşturur. Örneğin, belli bir alandaki HKİ değerleri, ozon için 90, kükürt dioksit için 88 ise, o güne ait HKİ değeri ozon için hesaplanan 90 değeri olacaktır.

Partiküller madde (PM) terimi, havada bulunan katı partiküller ve sıvı damlacıkları ifade eder. PM, insan faaliyetleri sonucu ve doğal kaynaklardan, doğrudan atmosfere karışır. Atmosferde diğer kirleticiler ile reaksiyona girerek PM oluşturur ve atmosfere verilirler. Katı ve sıvı partiküllerin boyutları geniş bir aralığa yayılır. 2,5 µm den daha küçük partiküller, ince partiküller olarak adlandırılır. İnce partikül kaynakları, tüm yanma prosesleri ve bazı endüstriyel prosesleri içerir. 2,5-10 µm. aralığındaki partiküller, kaba partiküller olarak adlandırılır. Kaba partikül kaynakları ise kırma, öğütme işlemleri ile ortaya çıkan, yollardan kalkan tozlardır (www.rshm.saglik.gov.tr/hki/hkindex/index5.htm).

Uygulama için Sivas iline ilişkin Ocak 1990-Aralık 2010 dönemleri arasında aylık ortalama partiküller madde, kükürt ve sıcaklık ölçüm değerleri kullanılmıştır.

Analizlerde kullanılan SAS 9.2, SPSS 15.0, Eviews 4.1 demo ve S-Plus 8.0 demo programların çıktılarında başvurulan terimlerin açıklamaları aşağıdadır:

Analiz Çizelgelerinde Kullanılan İstatistik ve Kriterler:

Düzeltilmiş çoklu belirtme katsayısı: $\bar{R}^2 = 1 - \frac{n-1}{n-p} R^2$

AIC: Akaike Bilgi Kriteri (Akaike's Information Criterion)

SBC: Schwarz'ın Bayes Kriteri (Schwarz's Bayesian Criterion)

BIC: Bayes Bilgi Kriteri (Bayes Information Criterion)

AIC, SBC ve BIC model değerlendirme kriterleridir. Özellikle değişken seçimi yapılırken başvurulan ölçüleridir. Modele eklenen her bir değişken için ceza ölçüsüdür. Eklenen her parametre bu kriterleri büyütür. Kriter değeri en küçük olan model tercih edilir.

$$AIC = n \ln(AKT / n) + 2p$$

$$SBC = n \ln(AKT / n) + 2p \ln(n)$$

$$BIC = n \ln(AKT / n) + 2n(p+2) \frac{\sigma^2}{AKT} - 2 \left(\frac{n\sigma^2}{AKT} \right)^2$$

Collinearity Diagnostics (Çoklubağlantı Tanıları):

Bağımsız değişkenler arasındaki ilişkinin olup olmadığı $(X'X)$ matrisinin öz değerleriyle değerlendirilir. λ_i öz değerleri, X uzayı temel bileşenlerinin yayılma miktarının ölçüleridir. Koşul indeksi (Condition Index) ve Koşul Sayısı (Condition Number) ölçüleri öz değerlere dayalı ilişki ölçüleridir. Koşul sayısı, X uzayındaki her bir temel bileşene ilişkin bir ölçü; koşul indeksi ise i'inci temel bileşene ilişkin bir ölçüdür. Söz konusu ölçüler aşağıdaki gibi ifade edilirler.

$$\text{Koşul Sayısı, } CN = [\lambda_{\max} / \lambda_{\min}]^{1/2} \text{ ve Koşul İndeksi } CI_i = [\lambda_{\max} / \lambda_i]^{1/2}.$$

Koşul indeksinin 10 dolaylarında olması zayıf ilişki, 30 ila 100 arasında olması kuvvetli ilişkiyi ve 100'ün üzerinde olması çok ciddi bir ilişkiyi ifade eder.

Bir diğer ölçü ise varyans büyüme faktörüdür (variance inflation factor -V.I.F). İlişki matrisi tersinin köşegen öğeleri olan bu kriterin, $V.I.F_j > 10$ olması bağımsız değişkenler arasında çoklubağlantıyı ifade eder.

Test of First and Second Moment Specification: Bu test, kesim 2.2.2.3'de verilen, değişen varyanslılığın saptanmasında kullanılan White testine karşılık gelmektedir.

Durbin Watson D İstatistiği: Ardışık artıklar arasındaki otokorelasyonun testidir.

D test istatistiği ile otokorelasyonun olup olmadığı test edilir. Burada $\hat{\rho}$, $e_i - e_{i-1}$ 'ler arasındaki örneklem korelasyonudur. Artıklar arasındaki otokorelasyon artıka Durbin Watson-D istatistiği küçülür. D, istatistiğinin 1'den küçük olması otokorelasyonun varlığına; 2'ye yakın olması yokluğuna işaret eder.

4.2. MODEL SEÇİMİ ve ARTIKLAR

Başlangıçta partiküller madde miktarı bağımlı değişken; taşıt sayısı, sıcaklık, doğal gaz kullanımı ve kükürt miktarı bağımsız değişken alınarak modellenme yapıldı. Sıcaklığa ilişkin ortalama aylık veriler Devlet Meteoroloji Müdürlüğü'nden, kükürt miktarı, taşıt sayısı ve partiküller maddeye ilişkin aylık ortalama veriler ise TÜİK kayıtlarından elde edilmiştir (www.tuik.gov.tr/cevredagitimapp/hava.zul). Taşıt sayısına ilişkin TÜİK kayıtlarının başlangıç yılı 1994 Temmuz; diğer değişkenlere ilişkin kayıtların başlangıcı ise Ocak 1990 ayıdır. Doğalgaz değişkeni, doğalgazın bu ilde kullanılmaya başlandığı yıl olan 2004 Nisan ayından öncesi için 0, sonrası için 1 şeklinde kodlanarak modele dâhil edildi. Kükürt ve partiküller madde ölçümlerinde eksik olan gözlemler doğrusal interpolasyonla bulunmuştur.

Alınan başlangıç modeli ve model tahminleri aşağıdadır:

$$\text{Partiküller_Madde} = \beta_0 + \beta_1 * \text{Sıcaklık} + \beta_2 * \text{Kükürt} + \beta_3 * \text{Tasit_sa} + \beta_4 * \text{dgaz} + \varepsilon$$


Çizelge 4.1. Tam Küme Parametre Tahmin Edicileri ve Model Seçimi

Number of Observations Read						253
Number of Observations Used						199
Number of Observations with Missing Values						54
R-Square	0.6400					
Variable	DF	Estimate	S.E	t Value	Pr > t 	
Intercept	1	66.26640	8.83994	7.50	<.0001	
sıcaklık	1	-2.71338	0.30537	-8.89	<.0001	
Kükürt	1	0.29889	0.05462	5.47	<.0001	
Taşıt Sayısı	1	0.00020002	0.00012476	1.60	0.1105	
Dgaz	1	0.41247	4.58087	0.09	0.9283	
Model	R-Square	AIC	BIC	SBC	Variables in Model	
1	0.5682	1341.5573	1342.9369	1348.14396	sıcaklık	
2	0.4649	1384.2607	1384.8293	1390.84730	Kükürt	
3	0.0114	1506.4059	1505.1154	1512.99253	dgaz	
4	0.0040	1507.9049	1506.5962	1514.49155	tasit_sa	
5	0.6351	1310.0485	1312.1215	1319.92843	Kükürt Sıcaklık	
6	0.5813	1337.4362	1338.7008	1347.31614	Sıcaklık dgaz	
7	0.5703	1342.6133	1343.7302	1352.49318	Sıcaklık tasit_sa	
8	0.4852	1378.5538	1378.6985	1388.43374	Kükürt dgaz	
9	0.4751	1382.4287	1382.4744	1392.30864	Kükürt tasit_sa	
10	0.0167	1507.3407	1504.8144	1517.22062	dgaz tasit_sa	
11	0.6400	1309.4071	1311.6116	1322.58035	Kükürt Sıcaklık tasit_sa	
12	0.6352	1312.0182	1314.1168	1325.19141	Kükürt Sıcaklık dgaz	
13	0.5844	1337.9638	1339.0479	1351.13704	Sıcaklık dgaz tasit_sa	
14	0.4934	1377.3467	1377.0323	1390.51991	Kükürt dgaz tasit_sa	
15	0.6400	1311.3988	1313.6552	1327.86533	Kükürt Sıcaklık dgaz tasit_sa	

Çizelge 4.1 incelendiğinde, seçilen başlangıç modelinde taşıt sayısı ve doğalgaz kullanımı istatistiksel olarak anlamlı çıkmamıştır. Diğer yandan ileriye doğru seçim (forward) tekniği ile AIC, BIC ve SBC kriterleri açısından modeller değerlendirildiğinde model 5 ile model 11’in değerleri bir birine çok yakındır. AIC ve BIC kriterleri açısından “Sıcaklık Kükürt ve Taşıt Sayısı” değişkenlerinin yer aldığı model 11; SBC kriteri açısından model 5 daha uygundur. Öte yandan taşıt sayısına ilişkin kayıtlar 1994 Temmuzundan itibaren mevcuttur. Dolayısıyla taşıt sayısı değişkenini içeren model 11 seçilirse 54 tane gözlemin vereceği bilgiden yoksun kalınacaktır. Bu nedenlerle uygulamanın bundan sonraki sürecinde, taşıt sayısı ve doğalgaz kullanımı değişkenleri analiz dışı bırakılarak,

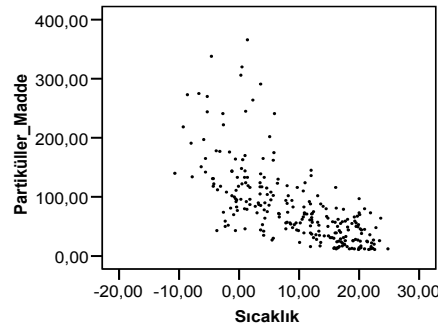
$$Partiküller_Madde = \beta_0 + \beta_1 * Sıcaklık + \beta_2 * Kükürt + \varepsilon$$

modeli ile çalışılmıştır. Partiküller maddenin, sıcaklık ve kükürtle değişim grafikleri (Şekil 4.1) incelendiğinde sıcaklık artışının partiküller madde miktarını azalttığı; kükürt miktarı artışının arttırdığı görülmektedir.

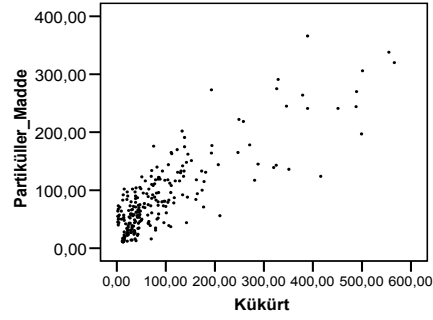


Şekil 4.1. Partiküller Maddenin Kükürt ve Sıcaklıkla Değişimi

Bu durum partiküller maddenin sıcaklık (Şekil 4.2) ve kükürtle değişimi (Şekil 4.3) incelendiğinde daha açık olarak görülmektedir.



Şekil 4.2. Sıcaklık- Partiküller Madde Değişimi



Şekil 4.3. Kükürt - Partiküller Madde Değişimi

Partiküller maddenin bağımlı, sıcaklık ve kükürt ölçümlerinin bağımsız değişken olduğu en küçük kareler analiz sonuçları Çizelge 4.2’de verilmiştir.

Çizelge 4.2. En Küçük Kareler Sonuçları

Dependent Variable: partikul						
Number of Observations Read	253					
Number of Observations Used	253					
Analysis of Variance						
Source	DF	Sum of Squares	Mean Square	F Value	Pr > F	
Model	2	831850	415925	418.40	<.0001	
Error	250	248518	994.07317			
Corrected Total	252	1080369				
Dependent Mean	83.43083	Adj R-Sq	0.7681			
Coeff Var	37.79050					
Parameter Estimates						
Variable	DF	Estimate	S.E	t Value	Pr > t	95% Conf.Limits V.I.F
Intercept	1	70.12801	4.44628	15.77	<.0001	61.37 78.88
Sıcaklık	1	-2.40700	0.27389	-8.79	<.0001	-2.95 -1.87 1.43
kukurt	1	0.40456	0.02218	18.24	<.0001	0.361 0.448 1.43
R-Square	AIC	BIC	RMSE	SBC	Variables in Model	
0.7700	1749.1402	1751.2119	31.52893	1759.74038	sıcaklık Kükürt	
Collinearity Diagnostics						
Condition	-----Proportion of Variation-----					
Number	Eigenvalue	Index	Intercept	Sıcaklık	Kükürt	
1	2.06480	1.00000	0.04371	0.04705	0.04950	
2	0.82188	1.58502	0.00018456	0.16749	0.29037	
Test of First and Second Moment Specification						
DF	Chi-Square	Pr > ChiSq				
5	14.33	0.0136				
Durbin-Watson D			1.249			
1st Order Autocorrelation			0.359			
<div style="display: flex; justify-content: space-around;"> <div style="text-align: center;"> <p>Studentized Residual</p> <p>Aylar</p> </div> <div style="text-align: center;"> <p>Studentized Residual</p> <p>Frequency</p> <p>Mean =8,47E-5 Std. Dev.=1,00549</p> </div> </div>						

Çizelge 4.2 incelendiğinde kelebek dağılan artıklar dolayısıyla değişen varyanslılık ve aykırı değerler sorunu dışında herhangi bir varsayım bozulmasının olmadığı görülür.

4.3. YENİDEN AĞIRLIKLANDIRILMIŞ İTERATİF EN KÜÇÜK KARELER

Burada, Meloun ve diğ. (2002) tarafından önerilen ve kesim 3.6'da detayları verilen YAIEKK yöntemi için SAS 9.2 programında yazılan kodlar ile elde edilen ağırlıklar kullanılarak ağırlıklı en küçük kareler uygulanmıştır. Analiz sonuçları Çizelge 4.3'de verilmiştir.

Çizelge 4.3. Yeniden Ağırlıklandırılmış İteratif En Küçük Kareler Sonuçları

Number of Observations Read	253					
Number of Observations Used	253					
Weight: SONAGIRLIK						
Analysis of Variance						
Source	DF	Sum of Squares	Mean Square	F Value	Pr > F	
Model	2	2.57687E16	1.288435E16	1.45E13	<.0001	
Error	250	221905	887.62096			
Corrected Total	252	2.57687E16				
Dependent Mean	184.80360	Adj R-Sq	1.0000			
Coeff Var	16.12142					
R-Square	AIC	BIC	RMSE	SBC	Variables in Model	
1.0000	1720.4783	1722.5500	29.79264	1731.07843	sıcaklık Kükürt	
Parameter Estimates						
Variable	DF	Estimate	S.E	t Value	Pr > t 	V.I.F
Intercept	1	74.58443	0.00006454	1155717	<.0001	0
sıcaklık	1	-2.90632	0.00010482	-27728	<.0001	191.42976
Kükürt	1	0.36812	0.00000102	361768	<.0001	191.42976
Collinearity Diagnostics						
Condition	-----Proportion of Variation-----					
Number	Eigenvalue	Index	Intercept	Sıcaklık	Kükürt	
1	2.75532	1.00000	0.00640	0.00019529	0.00024336	
2	0.24383	3.36155	0.16415	0.00054762	0.00181	
3	0.00084491	57.10589	0.82945	0.99926	0.99794	
Test of First and Second Moment Specification						
DF	Chi-Square	Pr > ChiSq				
3	3.04	0.3851				
Durbin-Watson D	1.023					
1st Order Autocorrelation	0.483					

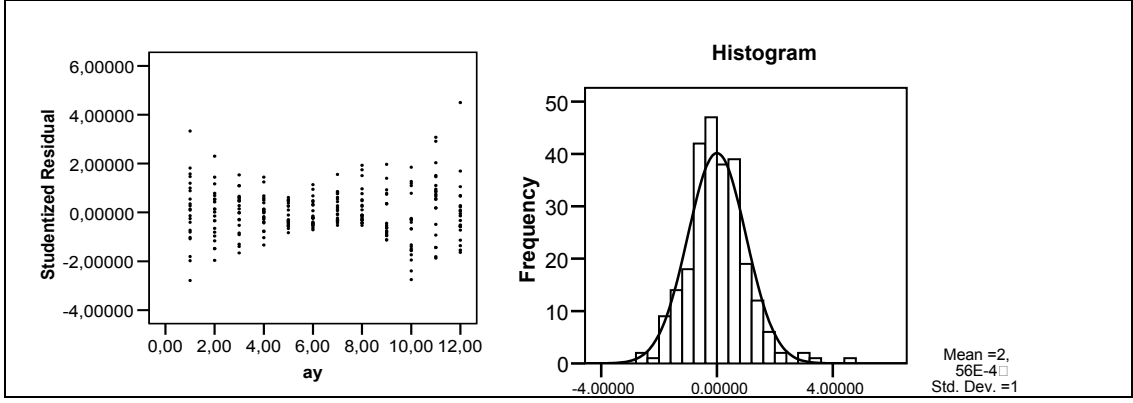
38 İterasyon sonucunda elde edilen sonuç ağırlıklar kullanılarak elde edilen regresyon analizi sonuçları (Çizelge 4.3) incelendiğinde, çok yüksek bir çoklu belirtme katsayısı ($R^2 = 1$) elde edilmesine rağmen değişen varyanslılığın dengelenemediği görülmektedir. Diğer yandan, söz konusu yöntemin uygulanması sonucunda, hem çoklubağlantı hem de normal dağılımdan sapma durumunun ortaya çıktığı görülebilir.

4.4. CHATTERJEE ve MACHLER TARAFINDAN ÖNERİLEN İTERATİF YÖNTEMİN SONUÇLARI

Chatterjee ve Mahler (1997) tarafından önerilen yöntem için SAS programında yazılan kodlarla elde edilen son ağırlıklarla ağırlıklı en küçük kareler uygulanmış ve Çizelge 4.4’de verilen sonuçlara ulaşılmıştır.

Çizelge 4.4. Chatterjee ve Machler İteratif Yöntemi Sonuçları

Dependent Variable: partikul						
Number of Observations Read		253				
Number of Observations Used		253				
Weight: SON_AGIRLIK						
Analysis of Variance						
Source	DF	Sum of Squares	Mean Square	F Value	Pr > F	
Model	2	5452.73794	2726.36897	403.66	<.0001	
Error	250	1688.51001	6.75404			
Corrected Total	252	7141.24794				
Dependent Mean	82.40007	Adj R-Sq	0.7617			
Coeff Var	3.15395					
R-Square	AIC	BIC	RMSE	SBC	Variables in Model	
0.7636	486.2477	488.3194	2.59885	496.84788	Sıcaklık Kükürt	
Parameter Estimates						
Variable	DF	Estimate	S.E	t Value	Pr > t 	V.I.F
Intercept	1	70.03857	4.45928	15.71	<.0001	0
Sıcaklıkk	1	-2.40097	0.27359	-8.78	<.0001	1.43066
Kükürt	1	0.40482	0.02277	17.78	<.0001	1.43066
Collinearity Diagnostics						
Condition	-----Proportion of Variation-----					
Number	Eigenvalue	Index	Intercept	Sıcaklık	Kükürt	
1	2.07422	1.00000	0.04253	0.04625	0.04905	
2	0.81441	1.59591	0.00020067	0.16617	0.29102	
3	0.11137	4.31555	0.95727	0.78757	0.65992	
Test of First and Second Moment Specification						
DF	Chi-Square	Pr > ChiSq				
6	17.22	0.0085				
Durbin-Watson D			1.242			
1st Order Autocorrelation			0.364			



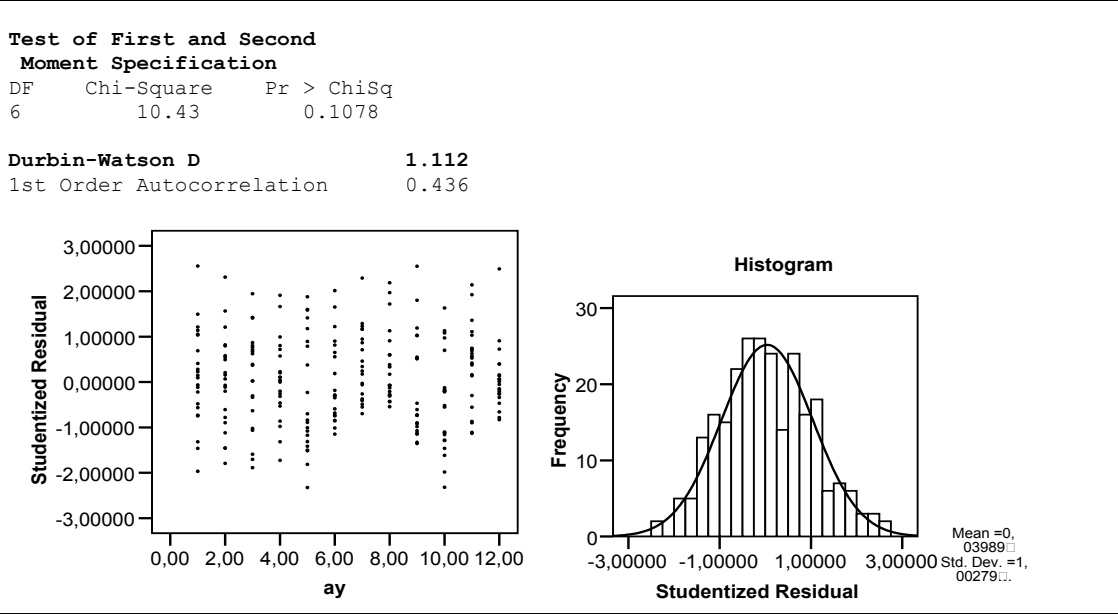
Yakınsama 3 iterasyon sonucunda gerçekleşmiş, ancak değişen varyanslılığın düzelmediği son iterasyondan elde edilen artıkların aylara karşı çiziminden anlaşılmaktadır. Yöntem, diğer kriterler açısından incelendiğinde birkaç aykırı değer dışında herhangi bir sorun göze çarpmamaktadır.

4.5. DEĞİŞTİRİLMİŞ ARDIŞIK ARTIKLAR YÖNTEMİ SONUÇLARI

Bischoff ve diğ. (2006) tarafından önerilen ve işleyişi kesim 3.5’de verilen algoritmaya paralel olarak elde edilen değiştirilmiş ardışık artıklar, ağırlık tahminlerinin belirlenmesinde edilmesinde kullanılmıştır. Elde edilen ağırlıklar ile ağırlıklı en küçük kareler regresyonu gerçekleştirilmiş ve Çizelge 4.5’de özetlenen sonuçlara ulaşılmıştır.

Çizelge 4.5. Değiştirilmiş Ardışık Artıklar ile Ağırlıklı En Küçük Kareler Sonuçları

Dependent Variable: partikull						
Number of Observations Read	253					
Number of Observations Used	250					
Number of Observations with Missing Values	3					
Weight:	weight					
Analysis of Variance						
Source	DF	Sum of Squares	Mean Square	F Value	Pr > F	
Model	2	557.39853	278.69926	343.98	<.0001	
Error	247	202.55270	0.81021			
Corrected Total	249	759.95122				
Dependent Mean	57.62722	Adj R-Sq	0.7313			
Coeff Var	1.56197					
R-Square	AIC	BIC	RMSE	SBC	Variables in Model	
0.7335	-50.2645	-48.1928	0.90012	39.66435	sıcaklık kükürt	
Parameter Estimates						
Variable	DF	Estimate	S.E	t Value	Pr > t	V.I.F
Intercept	1	70.35585	4.50072	15.63	<.0001	0
sıcaklık	1	-2.46777	0.26653	-9.26	<.0001	1.47551
kükürt	1	0.38588	0.02582	14.95	<.0001	1.47551
Collinearity Diagnostics						
Condition	-----Proportion of Variation-----					
Number	Eigenvalue	Index	Intercept	Sıcaklık	kükürt	
1	2.21932	1.00000	0.02008	0.02270	0.04337	
2	0.72218	1.75302	0.00250	0.05214	0.44425	
3	0.05851	6.15904	0.97741	0.92516	0.51238	



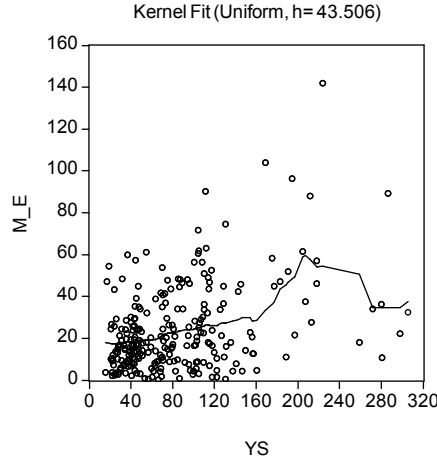
Çizelge 4.5 incelendiğinde, değiştirilmiş ardışık artıklar yöntemiyle değişen varyanslılık sorununun kısmen düzeldiği ve diğer analiz kriterleri açısından herhangi bir sorun olmadığı görülebilir.

4.6. PARAMETRİK OLMAYAN DÜZLEME

Bu kesimde, varyans ve standart sapma fonksiyonlarının tahmini için parametrik olmayan regresyon yöntemleri kullanılmıştır.

4.6.1. Mutlak Artıklarla Parametrik Olmayan Düzleme

Burada, standart sapma fonksiyonu düzlemesinde, mutlak artıklar bağımlı değişken ve \hat{y}_i değerleri, bağımsız değişken alınarak uniform çekirdek fonksiyonu için yerel doğrusal regresyon (local linear regresyon) uygulanmıştır. Genel olarak, yerel polinomiyel çekirdek regresyonları kullanılarak her x değerinde, artık kareleri toplamlarını minimize eden $\hat{\beta}$ 'ların seçimiyle \hat{y} tahmin edilir (Eviews 4.1 User Guide).



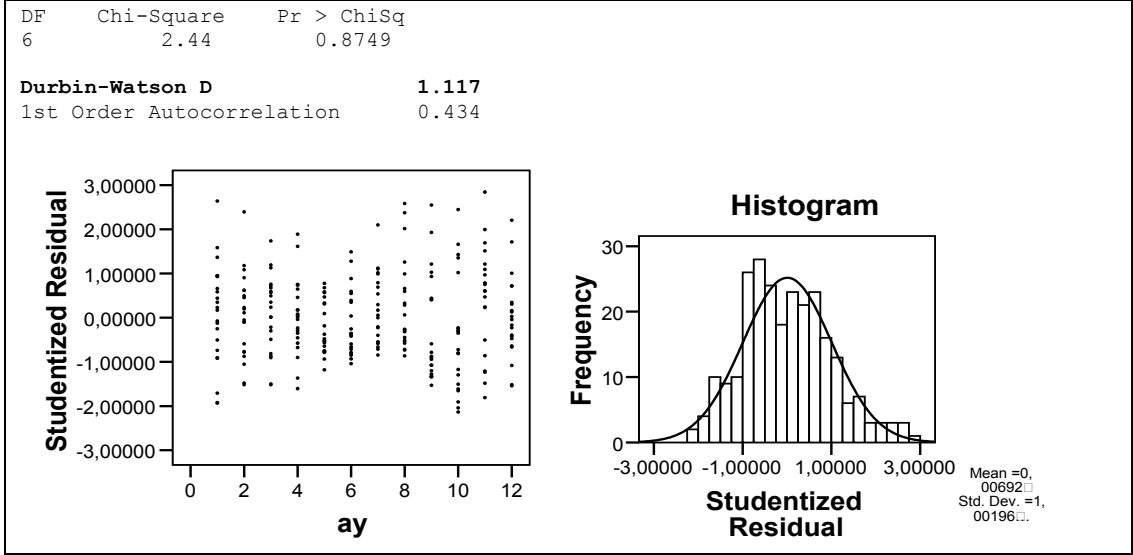
Şekil 4.4. Mutlak Artıkların Bağımlının Tahmin Değerleriyle Çekirdek Düzlemesi¹

Mutlak artıkların, bağımlı değişkenin en küçük kareler tahmin değerleriyle yerel doğrusal regresyonundan elde edilen tahmin değerleri (Şekil 4.4'deki kırık çizgi) standart sapma tahminleridir. Bu standart sapma tahmin değerleri, ağırlık tahminleri için kullanılarak, ağırlıklı en küçük kareler uygulanmıştır. Analiz sonuçları Çizelge 4.6'da verilmiştir.

Çizelge 4.6. Mutlak Artıklar İçin Parametrik Olmayan Regresyon ile Ağırlık Tahminleri ve Ağırlıklı En Küçük Kareler Sonuçları

Dependent Variable: partikül						
Number of Observations Read 253						
Number of Observations Used 253						
Weight: $\hat{w}_i = 1/ \hat{e}_i $						
Analysis of Variance						
Source	DF	Sum of Squares	Mean Square	F Value	Pr > F	
Model	2	876.43324	438.21662	283.16	<.0001	
Error	250	386.90253	1.54761			
Corrected Total	252	1263.33576				
Root MSE	1.24403	R-Square	0.6937			
Dependent Mean	63.17089	Adj R-Sq	0.6913			
Coeff Var	1.96931					
R-Square	AIC	BIC	RMSE	SBC	Variables in Model	
0.6913	113.4702	115.5419	1.24403	124.07034	Kükürt sıcaklık	
Parameter Estimates						
Variable	DF	Estimate	S.E	t Value	Pr > t 	V.I.F
Intercept	1	69.03554	4.54418	15.19	<.0001	0
Kükürt	1	0.39100	0.02944	13.28	<.0001	1.46382
Sıcaklık	1	-2.24265	0.25352	-8.85	<.0001	1.46382
Collinearity Diagnostics						
Condition -----Proportion of Variation-----						
Number	Eigenvalue	Index	Intercept	Kükürt	Sıcaklık	
1	2.19479	1.00000	0.02656	0.04415	0.03088	
2	0.72787	1.73648	0.00146	0.37528	0.09329	
3	0.07734	5.32702	0.97198	0.58058	0.87583	
Test of First and Second Moment Specification						

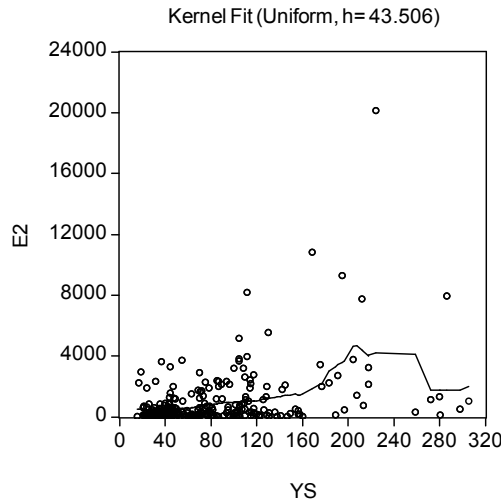
¹ Grafikte M_E, mutlak artıklar ve YS da \hat{y} 'dir.



Mutlak artıkların, bağımlı değişkenin en küçük kareler tahminleriyle düzlemesinden elde edilen mutlak artık tahmin değerlerinin tersinin ağırlık olduğu regresyon sonuçları incelendiğinde skor testinin sonucuna rağmen değişen varyanslılık sorunun ortadan kalkmadığı görülmektedir. Bunun dışında herhangi bir istatistiksel varsayım bozulması gözlenmemektedir.

4.6.2. Karesel Artıklarla Parametrik Olmayan Düzleme

Burada, karesel artıklar bağımlı değişken ve \hat{y}_i değerleri bağımsız değişken alınarak uniform çekirdek fonksiyonu için yerel doğrusal regresyon uygulanmıştır (Şekil 4.5).

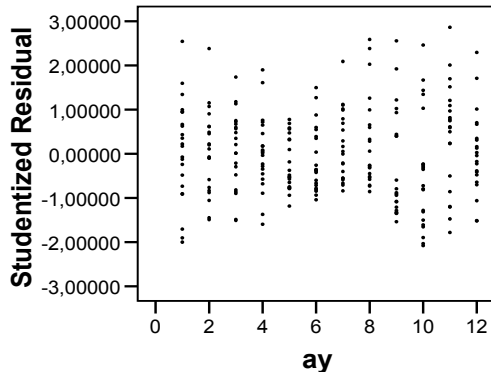
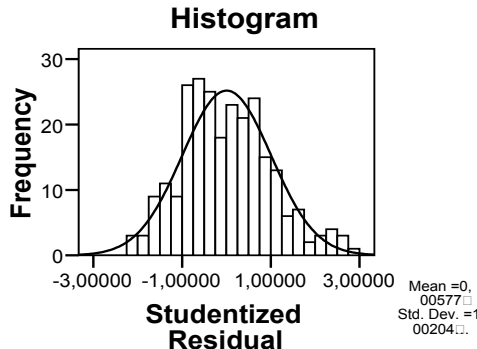


Şekil 4.5. Karesel Artıkların Bağımlı Tahminleri ile Çekirdek Düzlemesi²

²Grafikte, E2 Karesel artıklar, YS de \hat{y} 'dir.

Karesel artıkların, uniform çekirdek fonksiyonu için, bağımlı değişkenin EKK tahmin değerleriyle yerel doğrusal regresyonundan elde edilen \hat{e}_i^2 değerleri (Şekil 4.5'deki kırık çizgi \hat{e}_i^2 değerlerine karşılık gelmektedir.), ağırlık tahmininde kullanılmıştır. Elde edilen ağırlıklar ile ağırlıklı en küçük kareler uygulanmıştır. Analiz sonuçları Çizelge 4.7'de verilmiştir.

Çizelge 4.7. Karesel Artıklar İçin Parametrik Olmayan Regresyon ile Ağırlık Tahminleri ve Ağırlıklı En Küçük Kareler Sonuçları

Dependent Variable: partikul						
Number of Observations Read	253					
Number of Observations Used	253					
Weight $\hat{w}_i = 1/\hat{e}_i^2$						
Analysis of Variance						
Source	DF	Sum of Squares	Mean Square	F Value	Pr > F	
Model	2	571.29498	285.64749	285.86	<.0001	
Error	250	249.81587	0.99926			
Corrected Total	252	821.11084				
Root MSE	0.99963	R-Square	0.6958			
Dependent Mean	63.06634	Adj R-Sq	0.6933			
Coeff Var	1.58505					
R-Square	AIC	BIC	MSE	RMSE	SBC	Variables in Model
0.6958	2.7957	4.8674	0.99926	0.99963	13.39583	Kükürt Sıcaklık
Parameter Estimates						
	DF	Estimate	S.E	t Value	Pr > t	V.I.F
Intercept	1	68.87696	4.55123	15.13	<.0001	0
Kükürt	1	0.39316	0.02917	13.48	<.0001	1.45991
Sıcaklık	1	-2.23429	0.25452	-8.78	<.0001	1.45991
Collinearity Diagnostics						
Condition	-----Proportion of Variation-----					
Number	Eigenvalue	Index	Intercept	Kükürt	Sıcaklık	
1	2.19208	1.00000	0.02663	0.04438	0.03081	
2	0.73064	1.73211	0.00153	0.38109	0.09086	
3	0.07728	5.32594	0.97184	0.57453	0.87833	
Test of First and Second Moment Specification						
DF	Chi-Square	Pr > ChiSq				
6	2.11	0.9089				
Durbin-Watson D 1.117						
Number of Observations 253						
1st Order Autocorrelation 0.434						
						
						

Karesel artıklardan, düzleme ile elde edilen tahminlerin ağırlık olarak kullanılması ile gerçekleştirilen ağırlıklı en küçük kareler sonuçları incelendiğinde skor testinin sonucuna rağmen değişen varyanslılık sorunun ortadan kalkmadığı ve ek olarak artık dağılımında küçük çaplı bir bozulma dışında herhangi bir istatistiksel varsayım bozulması gözlenmemektedir.

4.7. TEKRARLI GÖZLEMLER İÇİN ORTALAMA ve VARYANS FONKSİYONLARI

Bu bölümde, önce bağımlı değişkenin standart sapmaları; sonra da karesel artıkların standart sapmaları ağırlık elde etmede kullanılarak ağırlıklı en küçük kareler uygulanmıştır.

4.7.1. Alt Gruplara Karşılık Gelen Bağımlı Değişken Değerlerinin Standart Sapmaları

Çalışmada öncelikle veri kümesi aylara göre gruplara bölünerek her bir gruba karşılık gelen bağımlı değişken standart sapmaları hesaplanmıştır. Hesaplanan standart sapmalar yeni bir değişken olarak atanarak, bağımlı değişken alt gruplarının standart sapmaları ağırlık değişkeni, partiküller madde miktarı bağımlı değişken; sıcaklık ve kükürt bağımsız değişken olmak üzere $\hat{w}_i = s_{y_{ij}}^{\lambda_i}$, $\lambda_i \in [-2, 2]$ için log olabilirlik (log likelihood) değeri en büyük olan λ_i 'ye karşılık gelen üs kullanılarak ağırlıklar elde edilmiştir. Burada, log olabilirlik fonksiyonu


$$l = -\frac{n}{2}(1 + \log(2\pi) + \log(AKT / n)) \text{ 'dir.}$$

Bu işlem SPSS 15.0 paket programı ağırlık tahmin modülü (weight estimation prosedürü) otomatik olarak yapılmaktadır. En büyük log olabilirlik değeri (-3/2) için

$\hat{w}_{ij} = s_{y_{ij}}^{-3/2}$ $j=1, \dots, 12; i=1, \dots, n$ eşitliğinden elde edilen ağırlıklar ile gerçekleştirilen ağırlıklı en küçük kareler analiz sonuçları Çizelge 4.8'de verilmiştir.

Çizelge 4.8. Bağımlı Değişken Standart Sapmaları için AEKK Sonuçları

Dependent Variable: Partikuller_madde					
Number of Observations Read 253					
Number of Observations Used 253					
Analysis of Variance					
Source	DF	Sum of Squares	Mean Square	F Value	Pr > F



Skor testi ve Student-türü artık çizimlerine bakıldığında varyansın kısmen dengelendiği görülmektedir. Diğer sonuçlar incelendiğinde herhangi bir varsayım bozulması sorunun olmadığı görülmektedir.

4.7.2. Karesel Artıklar

Ağırlıksız en küçük karelerden elde edilen artıkların kareleri, bağımsız bir değişken gibi düşünülerek her bir alt gruba karşılık gelen standart sapmaları hesaplanmıştır. Kesim 4.7.1’de bağımlı değişken için yapılan işlemler burada artıkların kareleri için tekrarlanarak ağırlıklar elde edilmiştir. En büyük log olabilirlik değerine karşılık gelen $(-1/2)$ için $\hat{w}_j = 1 / s_{e_j}^2$ $j=1, \dots, 12$; $i=1, \dots, n$; eşitliğinden elde edilen ağırlıklar ile gerçekleştirilen ağırlıklı en küçük kareler regresyonunun sonuçları Çizelge 4.9’da verilmiştir.

Çizelge 4.9. Karesel Artık Standart Sapmaları için AEKK Sonuçları

Dependent Variable: Partikuller_madde						
Number of Observations Read		253				
Number of Observations Used		253				
Analysis of Variance						
Source	DF	Sum of Squares	Mean square	F Value	Pr > F	
Model	2	759.24439	379.62219	370.61	<.0001	
Error	250	256.08096	1.02432			
Corrected Total	252	1015.32534				
Dependent Mean	58.16094	Adj R-Sq	0.7458			
Coeff Var	1.74015					
R-Square	AIC	BIC	RMSE	SBC	Variables in Model	
0.7478	9.0623	11.1341	1.01209	19.66252	Sıcaklık Kükürt	
Parameter Estimates						
Variable	DF	Estimate	S.E	t Value	Pr > t	V.I.F
Intercept	1	67.32753	4.55037	14.80	<.0001	0
Sıcaklık	1	-2.21379	0.25606	-8.65	<.0001	1.51868
Kükürt	1	0.40890	0.02572	15.90	<.0001	1.51868
Collinearity Diagnostics						
Condition -----Proportion of Variation-----						
Number	Eigenvalue	Index	Intercept	Sıcaklık	Kükürt	
1	2.19002	1.00000	0.02142	0.02390	0.04218	
2	0.74957	1.70930	0.00207	0.05257	0.42422	
3	0.06041	6.02103	0.97651	0.92353	0.53361	
Test of First and Second Moment Specification						
DF	Chi-Square	Pr > ChiSq				
6	4.52	0.6060				
Durbin-Watson D		1.166				
1st Order Autocorrelation		0.409				

Skor testi ve Student-türü artıkların grafiği incelendiğinde değişen varyanslılığın dengelendiği görülmektedir.

4.8. JACKKNİFE YÖNTEMİ SONUÇLARI

S Plus 8.0 Demo programı kullanılarak elde edilen parametre tahmin edicilerinin ortalamasına karşılık gelen değerler regresyon eşitliğinde yerine yazılarak artıklar elde edilmiştir. Bu artıkların normal dağılım için histogramları, değişen varyanslılık için artık grafikleri ve parametre tahmin edicilerinin örnekleme dağılımları Çizelge 4.10'da verilmiştir.

Çizelge 4.10. Jackknife Parametre Tahmin Edicileri ve Artık Çizimleri

```
jackknife(data = siv, statistic = coef(lm(Partikul ~ Sıcaklık + Kükürt,
siv)),
assign.frame1 = T)
Number of Replications: 253
```

Summary Statistics:

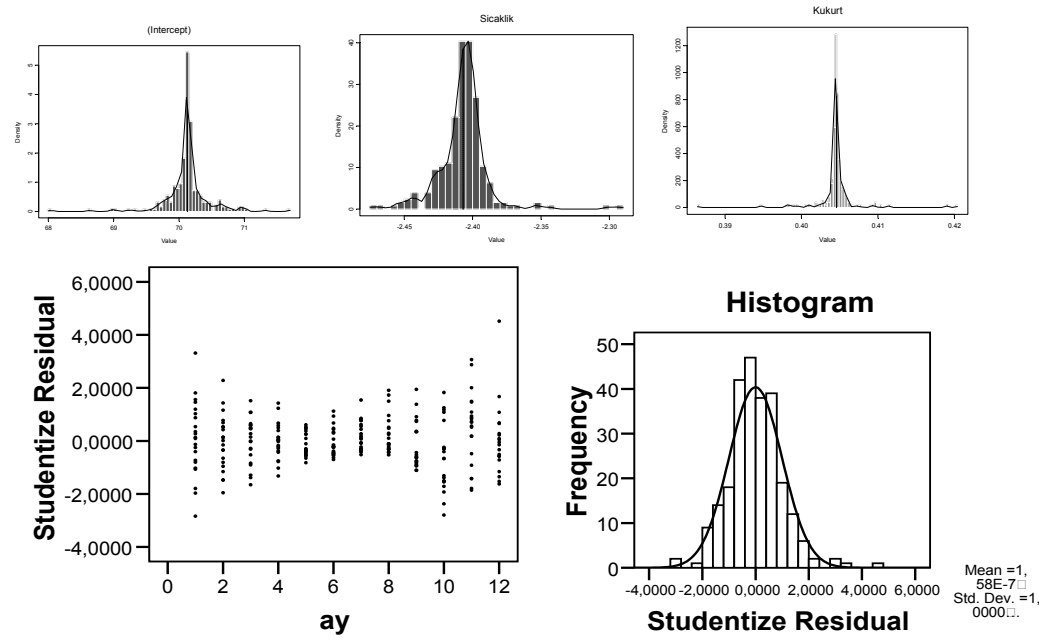
	Observed	Bias	Mean	S.E
(Intercept)	70.1280	-0.0448217	70.1278	5.30786
Sıcaklık	-2.4070	0.0030980	-2.4070	0.29637
Kükürt	0.4046	0.0001199	0.4046	0.03697

Empirical Percentiles:

	2.5%	5%	95%	97.5%
(Intercept)	69.5195681	69.7074327	70.6555462	70.8988473
Sıcaklık	-2.4456687	-2.4355400	-2.3874572	-2.3734147
Kükürt	0.4006256	0.4024015	0.4061704	0.4092484

Correlation of Replicates:

	(Intercept)	Sıcaklık	Kükürt
(Intercept)	1.0000000	-0.9030347	-0.7814282
Sıcaklık	-0.9030347	1.0000000	0.6162596
Kükürt	-0.7814282	0.6162596	1.0000000

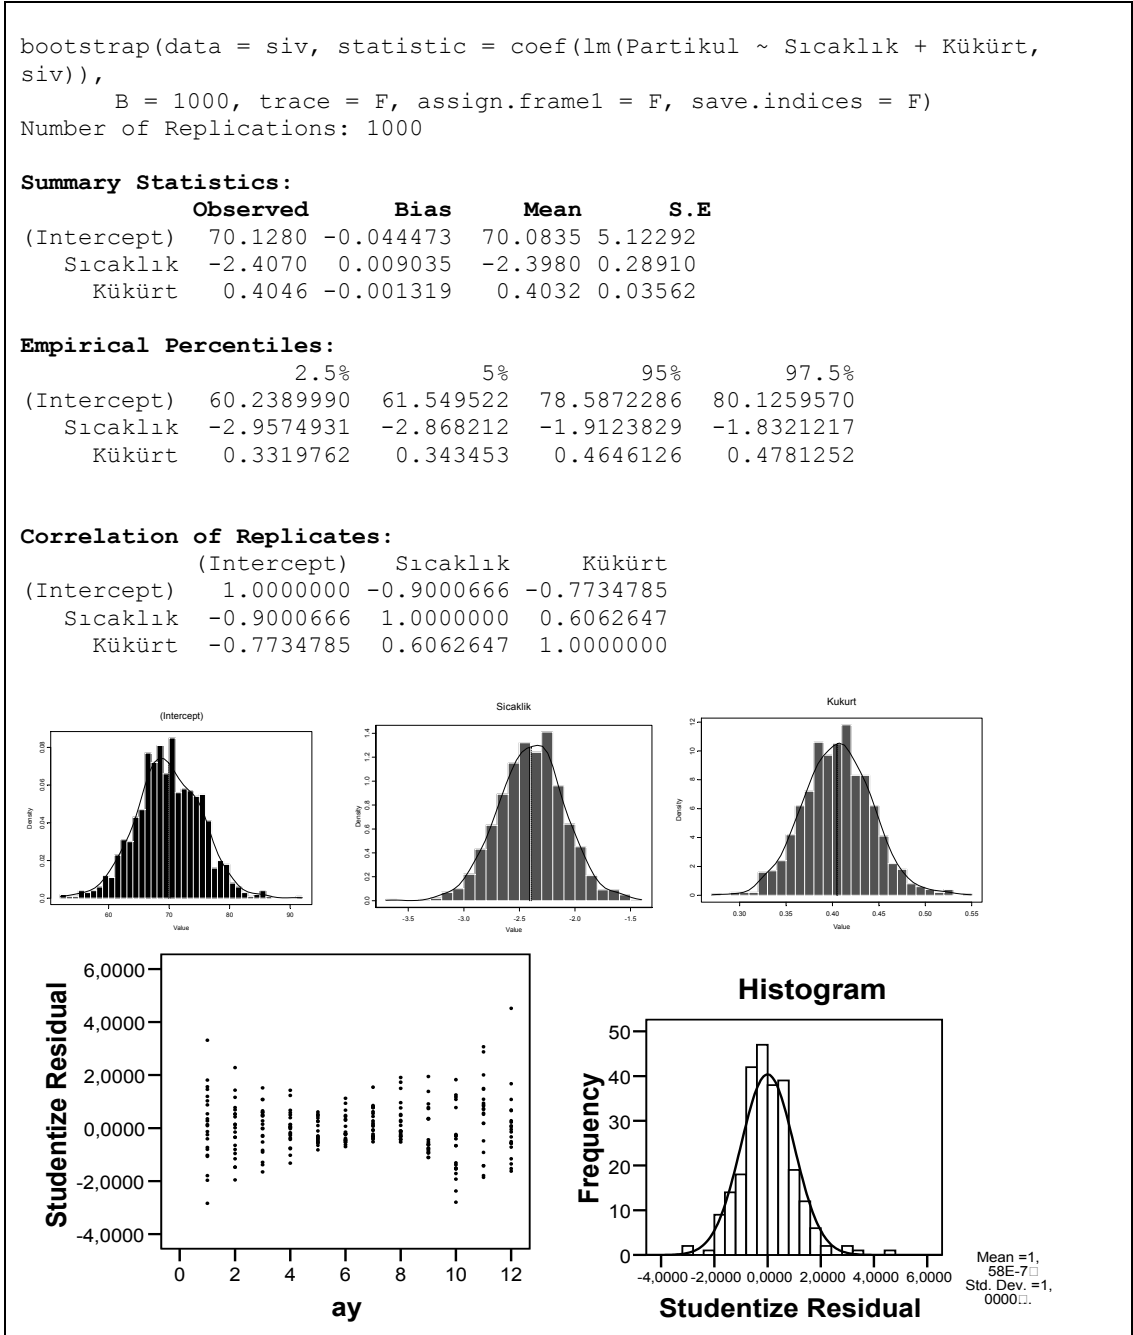


253 yineleme sonucunda gerçekleşen Jackknife parametre tahminleri için elde edilen artık çizimleri incelendiğinde kelebek dağılan artıklar dolayısıyla değişen varyanslılık sorununun devam ettiği gözlenmektedir. Öte yandan tek tek parametre tahmin edicilerinin örnekleme dağılımı için Jackknife yöntemi sonuçlarına bakıldığında parametre tahmin edicilerinin örnekleme dağılımının normal dağılıma uymadığı görülmektedir.

4.9. BOOTSTRAP YÖNTEMİ SONUÇLARI

S Plus 8.0 Demo programı kullanılarak elde edilen bootstrap parametre tahmin edicilerinin ortalamalarına karşılık gelen değerler regresyon eşitliğinde yerine yazılarak artıklar elde edilmiştir. Elde edilen artıkların normal dağılım için histogramları, değişen varyanslılık için artık grafikleri ve bootstrap parametre tahmin edicilerinin örnekleme dağılımları Çizelge 4.11’de verilmiştir.

Çizelge 4.11. Bootstrap Yöntemi için Parametre Tahmin Edicileri ve Artık Çizimleri



1000 tekrar sonucu elde edilen bootstrap için ortalama parametre tahminlerinden elde edilen artık çizimleri incelendiğinde kelebek dağılan artıklar dolayısıyla değişen varyanslılık sorununun devam ettiği gözlenmektedir. Parametre tahmin edicilerinin örnekleme dağılımı incelendiğinde ise Jackknife yöntemine göre sonuçların daha iyi olduğu görülmektedir. Parametre tahmin edicilerin örnekleme dağılımı normal dağılıma uymaktadır.

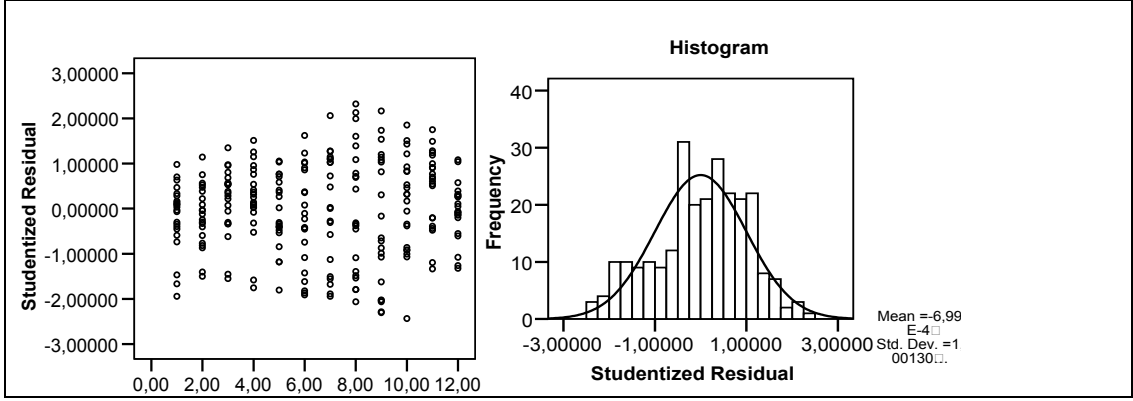
4.10. BOX-COX DÖNÜŞÜMLERİ

Uygulamanın bu bölümünde, en çok başvurulan bağımlı değişken dönüşümü olan Box-Cox dönüşümleri veri kümesine uygulanmıştır. λ parametresi için $[-2,2]$ aralığında -2'den başlanarak 0.5 artışlarla elde edilen değerleri için bağımlı değişkene dönüşüm uygulanmıştır. Burada, yalnızca $\lambda = 0,5$ ve $\lambda = 0 \rightarrow$ logaritmik dönüşüm değerleri için tam analiz sonuçları verilmiştir.

Bağımlı değişken değerlerinin logaritması alınarak uygulanan regresyon analizi sonuçları Çizelge 4.12'de verilmiştir.

Çizelge 4.12. Box-Cox $\lambda = 0 \rightarrow$ Logaritma Dönüşümü Sonuçları

Dependent Variable: log partikül						
Number of Observations Read			253			
Number of Observations Used			253			
Analysis of Variance						
Source	DF	Sum of Squares	MS	F Value	Pr > F	
Model	2	19.99065	9.99533	225.85	<.0001	
Error	250	11.06436	0.04426			
Corrected Total	252	31.05502				
Dependent Mean	1.79225	Adj R-Sq	0.6409			
Coeff Var	11.73799					
R-Square	AIC	BIC	SBC	Variables in Model		
0.5400	-723.1765	-722.1345	-716.10972	Sıcaklık		
Parameter Estimates						
Variable	DF	Estimate	SE	t Value	Pr > t 	V.I.F
Intercept	1	70.35585	4.50072	15.63	<.0001	0
Sıcaklık	1	-2.46777	0.26653	-9.26	<.0001	1.47551
kükürt	1	0.38588	0.02582	14.95	<.0001	1.47551
Collinearity Diagnostics						
Condition -----Proportion of Variation-----						
Number	Eigenvalue	Index	Intercept	Sıcaklık	Kükürt	
1	2.06480	1.00000	0.04371	0.04705	0.04950	
2	0.82188	1.58502	0.00018456	0.16749	0.29037	
3	0.11332	4.26856	0.95611	0.78546	0.66013	
Test of First and Second Moment Specification						
DF	Chi-Square	Pr > ChiSq				
5	37.21	<.0001				
Durbin-Watson D			0.794			
1st Order Autocorrelation			0.597			

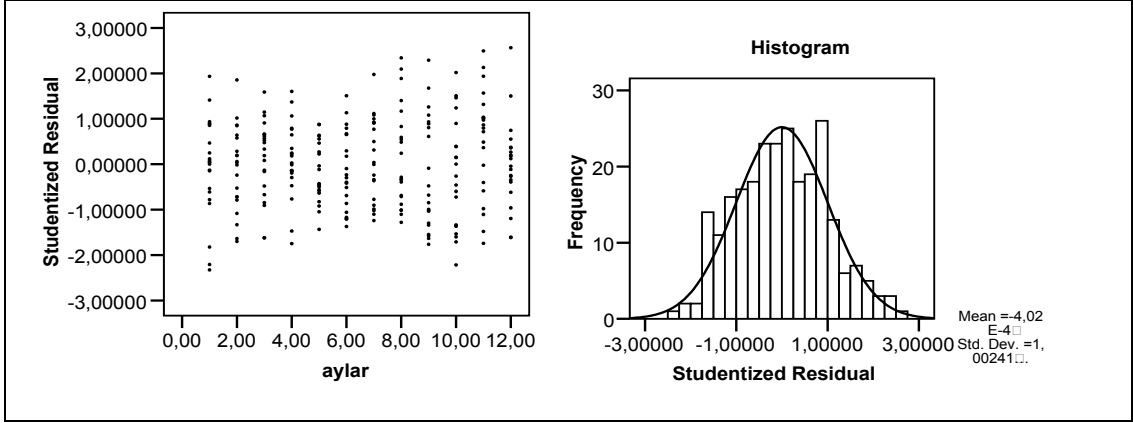


Skor testi sonucuna bakıldığında istatistiksel olarak logaritma dönüşümünün varyansı dengeleyemediği sonucu ortaya çıkmaktadır. Artık grafikleri incelendiğinde ise kelebek dağılan artıkların yerine, Weisbeg'in (2005), "double outward box" olarak adlandırdığı artık kalıbı ortaya çıkmıştır. Öte yandan dönüşüm ardışık artıklar arasında otokorelasyona neden olmuştur.

Box-Cox'un burada yer verilen , $\lambda = 0.5$ için bağımlı değişkenin dönüşümü sonucu elde edilen analiz sonuçları Çizelge 4.13'de verilmiştir.

Çizelge 4.13. Box-Cox $\lambda = 0.5$ için Dönüşüm Sonuçları

Number of Observations Read	253					
Number of Observations Used	253					
Analysis of Variance						
Source	DF	Sum of Squares	Mean Square	F Value	Pr > F	
Model	2	8164.21811	4082.10906	350.07	<.0001	
Error	250	2915.23105	11.66092			
Corrected Total	252	11079				
Root MSE	3.41481	R-Square	0.7369			
Dependent Mean	15.02736	Adj R-Sq	0.7348			
Coeff Var	22.72395					
AIC	BIC	SBC	Variables			
624.4117	626.4834	635.01183	Kükürt Sıcaklık			
Parameter Estimates						
Variable	DF	Estimate	S.E	t Value	Pr > t 	V.I.F
Intercept	1	15.21774	0.48156	31.60	<.0001	0
KÜKÜRT	1	0.03321	0.00240	13.83	<.0001	1.42876
SICAKLIK	1	-0.33516	0.02966	-11.30	<.0001	1.42876
Collinearity Diagnostics						
Condition	-----Proportion of Variation-----					
Number	Eigenvalue	Index	Intercept	KÜKÜRT	SICAKLIK	
1	2.06480	1.00000	0.04371	0.04950	0.04705	
2	0.82188	1.58502	0.00018456	0.29037	0.16749	
3	0.11332	4.26856	0.95611	0.66013	0.78546	
Test of First and Second Moment Specification						
DF	Chi-Square	Pr > ChiSq				
5	1.69	0.8896				
Durbin-Watson D		1.022				
Number of Observations		253				
1st Order Autocorrelation		0.479				



$\lambda = 0.5$ değeri için değişen varyanslılığın dengelenmediği aylara karşı çizilen Student-türü artıkların çizimlerinden görülmektedir.

Burada yer verilmeyen diğer dönüşüm değerleri için varyansın dengelenmesi bir yana artıkların dağılımında çarpıklık ve sivrileşme gözlenmiştir.

4.11. DEĞİŞEN VARYANSLILIĞIN İKİ PARÇALI AĞIRLIKLANDIRMA İLE DENGELENMESİ


Kesim 3.14.1’de verilen algoritmanın ilk üç adımı doğrultusunda veriye en küçük kareler uygulanmıştır. En küçük karelerden elde edilen artıklarının kareleri alınarak dışsal değişken ile regresyonu gerçekleştirilmiştir. Buradan boğum noktası m ,

$$\hat{e}_i^2 = 1860.4478 - 25.65692d_i + 0.110901d_i^2, \quad m = -0.5 * \left(\frac{-25.65692}{0.110901} \right) \cong 116$$

olarak hesaplanmıştır. Boğum noktasına göre partiküller madde bağımlı, sıcaklık ve kükürtün bağımsız değişkenler olduğu ilk 116 gözlem için ayrı bir regresyon ve kalan 137 gözlem için ayrı bir regresyon uygulanmıştır. Her bir regresyondan elde edilen artıkların kareleri alınmış ve alt gruplar bazında standart sapmaları hesaplanmıştır. Elde edilen standart sapmaların tersi ağırlık tahmini olarak kullanılmıştır. Ağırlıklar birleştirilerek 253 gözlem için ağırlıklı en küçük kareler gerçekleştirilmiştir. Analiz sonuçları Çizelge 4.14’de verilmiştir.

Çizelge 4.14. İkiye Parçalamadan Elde Edilen Ağırlıklar ile AEKK Sonuçları

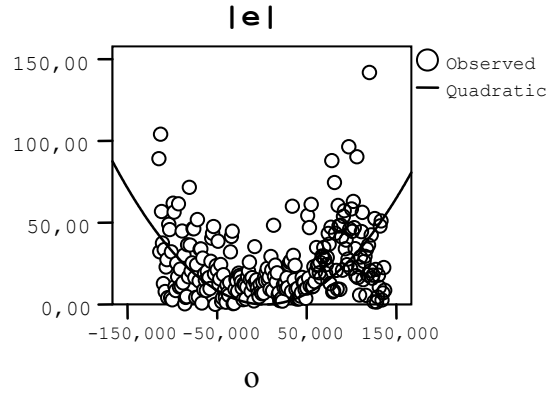
Dependent Variable: Partiküller Madde					
Weight: W					
Number of Observations Read 253					
Number of Observations Used 253					
Analysis of Variance					
Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	2	570.26678	285.13339	345.79	<.0001
Error	250	206.14509	0.82458		



Her bir parça için elde edilen ağırlıkların birleştirilmesi sonucunda elde edilen ağırlıklı en küçük karelerin sonuçları incelendiğinde kelebek dağılan artıklardan kaynaklanan değişen varyanslılık sorununun başarılı bir şekilde ortadan kalktığı, diğer kriterler incelendiğinde ise herhangi ciddi bir varsayım bozulmasının olmadığı görülmektedir.

4.12. DIŞSAL DEĞİŞKEN ve MERKEZİLEŞTİRME SONUÇLARI

Kesim 3.14.1’de algoritması verilen yöntem doğrultusunda merkezileştirilmiş dışsal değişken ile en küçük kareler mutlak artıklarından standart sapma fonksiyonu (Şekil 4.6) tahmin edildikten sonra bu fonksiyondan elde edilen tahmin değerleri ağırlık elde etmekte kullanılarak ağırlıklı en küçük kareler gerçekleştirilmiştir.



Şekil 4.6. Merkezi dışsal değişken ile mutlak artıkların dağılımı

Çizelge 4.15. Merkezi Dışsal Değişken ile Tahmin Edilen Standart Sapma Fonksiyonu için Model Özeti ve Parametre Tahminleri

Dependent Variable: |e|

Equation	Model Summary					Parameter Estimates	
	R Square	F	df1	df2	Sig.	b1	b2
Quadratic	,495	122,798	2	251	,000	-,021	,003

The independent variable is o.

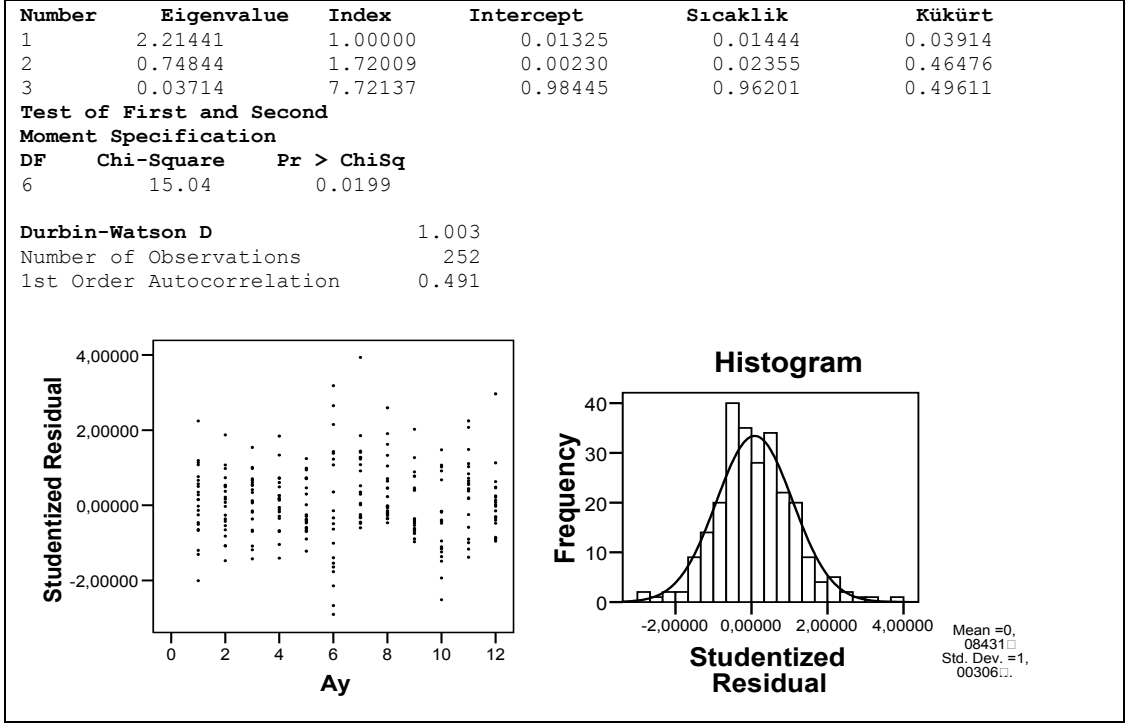
Standart sapma fonksiyonu,

$$|\widehat{e}_i| = 0.21o_i + 0.003o_i^2$$

olarak elde edildikten sonra fonksiyonun tahmin değerleri tahmini ağırlıkların elde edilmesinde kullanılmıştır. $\widehat{w}_i = 1/|\widehat{e}_i|$ fonksiyonundan elde edilen ağırlıklar ile ağırlıklı en küçük kareler analizi uygulanmıştır. Sonuçlar Çizelge 4.16'de verilmiştir

Çizelge 4.16. Merkezi Dışsal Değişken ile Ağırlık Tahmini ve AEKK Sonuçları

Dependent Variable: Partiküller_madde							
Number of Observations Read		253					
Number of Observations Used		253					
Weight: \widehat{w}_i							
Analysis of Variance							
Source	DF	Squares	Square	F Value	Pr > F		
Model	2	254192	127096	360.89	<.0001		
Error	249	87691	352.17226				
Corrected Total	251	341883					
Root MSE	18.76625	R-Square	0.7435				
Dependent Mean	45.18898	Adj R-Sq	0.7414				
Coeff Var	41.52838						
R-Square	R-Square	AIC	BIC	SBC	Variables		
0.7435	0.7414	1480.7404	1482.8123	1491.32864	Sıcaklık Kükürt		
Parameter Estimates							
Variable	DF	Estimate	S.E	t Value	Pr > t	95% Conf. Lim	VIF
Intercept	1	65.06665	5.24196	12.41	<.0001	54.74 75.39	0
Sıcaklık	1	-2.32991	0.28001	-8.32	<.0001	-2.88 -1.778	1.59
Kükürt	1	0.42510	0.02803	15.17	<.0001	0.36989 0.4803	1.59
Collinearity Diagnostics							
Condition	-----Proportion of Variation-----						



Merkezi dışsal değişkenle elde edilen standart sapma fonksiyonunun tahmin değerlerinin ağırlık olarak kullanılması sonucu elde edilen ağırlıklı en küçük kareler analizi sonuçları incelendiğinde artık çizimlerindeki kelebek dağılıma sorununun ortadan kalktığı ve artıkların normal dağıldığı görülmektedir. Buna karşılık az sayıda da olsa yöntemin aykırı değer ürettiği göze çarpmaktadır.

4.13. YAPAY VERİLER ile ÖNERİLEN YÖNTEMLERİN SINANMASI

Önerilen yöntemlerin geçerliliklerinin sınanması için kelebek dağılan artıkları olan bir regresyon fonksiyonu yaratma gereksinimi ortaya çıktı. PBC Eletronics Designing'de (2009) yer verilen bir trigonometrik fonksiyon, amaca uygun biçimde geliştirilerek kullanılmıştır.

Bu bölümde temel olarak kullanılan başlangıç algoritması aşağıda verilmiştir:

```

j=0;
do i = (n/5) to (n-n/5);
    j = j + 1;
    y[j] = 800 + i + 25 * sin2(2 * i * 3.14 / n) * RAND('NORMAL');
    x[j] = i;
    d[j] = j;
end;

```

(4.1)


Burada, $y[j]$ bağımlı değişkeni, $x[j]$ bağımsız değişkeni ve $d[j]$ dışsal değişkeni temsil etmektedir.

Bu kısıtlar altında, SAS 9.2 programında yazılan kodlar yardımıyla farklı örneklem büyüklükleri için kelebek dağılan artıkları veren yapay veri kümeleri oluşturularak, kesim 3.14'te önerilen “merkezileştirme ve dışsal değişken” yönteminin geçerliliği sınanmıştır. Kelebek dağılan artıkları elde etmek için fonksiyon, sağdan ve soldan $n/5$, merkez çevresinde $n/10$ oranında kırılmıştır. İzleyen analizlerde belirtilen veri büyüklükleri kırılma işlemi yapıldıktan sonra kalan net veri sayılarıdır. Elde edilen veriler,

$$Y = \beta_0 + \beta_1 X + \varepsilon$$

şeklindeki basit doğrusal regresyon ile önerilen “merkezileştirme ve dışsal değişken” yöntemleri; yaklaşık simetrik, sağa asimetric ve sola asimetric kelebek dağılan artıklar için incelenmiştir.

Aynı büyüklükteki veri için en küçük karelerden elde edilen artıkların mutlak değerleri, kareleri, karelerinin küp kökleri ve mutlak artıkların logaritmalarının çizimleri incelenmiş (Şekil 4.7); kelebek dağılan artıklar için mutlak artıklar ile çalışmanın daha iyi standart sapma, dolayısıyla varyans fonksiyonları vereceği sonucuna varılmıştır. Bundan sonraki analizler için standart sapma fonksiyonunun tahmini için mutlak artıkların kullanılması uygun görülmüştür.




Şekil 4.7. Artık Dönüşümlerinin Merkezi Dışsal Değişken ile Fonksiyonları

Burada normal dağılım gereği sıfır çevresinde yer alması gereken artıkların sayısı fazla olduğundan mutlak artıklar için varyans fonksiyonu tahmin edilirken, merkezi dışsal değişkenin de sıfırı içermesi nedeni ile fonksiyonun orijinden geçmesine olanak tanınarak daha iyi sonuçlara ulaşılması sağlanmıştır. Örneğin, aynı koşullarda orijinden geçmeyen standart sapma fonksiyonu için belirtme katsayısı %20-30 dolaylarında iken orijinden geçen standart sapma fonksiyonu için belirtme katsayısının %50-60 dolayında olduğu gözlenmiştir. Pardoe ve Cook (2007)'da belirtildiği üzere, varyans ya da standart sapma fonksiyonu tahmininin negatif olmaması gerekse bile düzleme sonucunda negatif varyans fonksiyonu tahminleriyle karşılaşılabilir. Bu çalışmada fonksiyonun orijinden geçirilmesi sonucu çok az sayıda da olsa negatif standart sapma tahminleri elde edilmiştir. Bu negatif tahminlerin mutlak değerleri alındıktan sonra ağırlık tahmininde kullanılmıştır.

Bundan sonraki analizlerin tümünde, veriye önce klasik en küçük kareler uygulandıktan sonra önerilen yöntemler uygulanarak sonuçları klasik doğrusal regresyon varsayımları açısından değerlendirilmiştir.

4.13.1. Yaklaşık Simetrik Veri $n = 270$


Kesim 4.12'de verilen algoritma kullanılarak ve $n = 270$ örneklem büyüklüğü için Şekil 4.8'de grafiği verilen veri kümesi elde edilmiştir.



Şekil 4.8. $n = 270$ için Yapay Veri Grafiği


Elde edilen veri kümesine uygulanan en küçük kareler sonuçları Çizelge 4.17'de verilmiştir.

Çizelge 4.17. n = 270 için En Küçük Kareler Sonuçları



En küçük kareler sonuçları incelendiğinde kelebek dağılan artıklar nedeni ile değişen varyanslılık ve normal dağılımdan sapma göze çarpmaktadır.

En küçük karelerden elde edilen artıkların mutlak değerleri alınarak merkezi dışsal değişken 'o' ile $|e| = \theta_1 o + \theta_2 o^2$ şeklinde standart sapma fonksiyonunun (Şekil 4.9) elde edilmesinde kullanılmıştır.



Şekil 4.9. Standart Sapma Fonksiyonu

Elde edilen standart sapma fonksiyonuna ilişkin özet bilgiler Çizelge 4.18’de verilmiştir.

Çizelge 4.18. Standart Sapma Fonksiyonu için Model Özeti ve Parametre Tahminleri

Dependent Variable: |e|

Equation	Model Summary					Parameter Estimates	
	R Square	F	df1	df2	Sig.	b1	b2
Quadratic	.568	176.276	2	268	.000	.010	.002

The independent variable is O.


Standart sapma fonksiyonu tahmini,

$$|\widehat{e}_i| = 0.010o_i + 0.002o_i^2$$

olarak elde edildikten sonra bu fonksiyonun tahmin değerleri ağırlıkların elde edilmesinde kullanılarak ağırlıklı en küçük kareler analizi uygulanmış ve Çizelge 4.19’da verilen sonuçlara ulaşılmıştır.

Çizelge 4.19. n = 270 Merkezi Dışsal Değişken ile Standart Sapma Fonksiyonu Tahmini ve AEKK Sonuçları


Dependent Variable: Y						
Number of Observations Read		270				
Number of Observations Used		270				
Weight: $\widehat{w}_i = 1/ \widehat{e}_i $, $ \widehat{e}_i \neq 0$						
Analysis of Variance						
Source	DF	Sum of Squares	Mean Square	F Value	Pr > F	
Model	1	184591	184591	4403.52	<.0001	
Error	268	11234	41.91892			
Corrected Total	269	195825				
Root MSE	6.47448	R-Square	0.9426			
Dependent Mean	1033.46319	Adj R-Sq	0.9424			
Coeff Var	0.62648					
Model	R-Square	AIC	BIC	SBC	Variables in Model	
1	0.9426	1010.6416	1012.6714	1017.83848	X	
Parameter Estimates						



Mutlak artıklar için elde edilen standart sapma fonksiyonu tahmin değerlerin ağırlık olarak kullanımı sonucunda elde edilen regresyon analizi sonuçları incelendiğinde temel olarak odaklandığımız değişen varyanslılık sorununun ortadan kalktığı, artıkların dağılımının normal dağılıma uyduğu, 2 tane aykırı değer dışında herhangi bir varsayım bozulmasının olmadığı ve tüm karşılaştırma kriterlerinde olumlu yönde artışlar olduğu görülmektedir.

4.13.2. Yaklaşık Simetrik Veri n = 1339

Yapay veri üretme süreci örneklem büyüklüğü artırılarak n = 1339 örneklem büyüklüğünde, Şekil 4.10'da grafiği verilen veri kümesi elde edilmiştir.




Şekil 4.10. n = 1339 için Yapay Veri Grafiği


Elde edilen veri kümesine en küçük kareler uygulanarak Çizelge 4.20’de verilen sonuçlara ulaşılmıştır.

Çizelge 4.20. n = 1339 için En Küçük Kareler Sonuçları

Dependent Variable: Y						
Number of Observations Read 1339						
Number of Observations Used 1339						
Analysis of Variance						
Source	DF	Sum Squares	Mean Square	F Value	Pr > F	
Model	1	204708062	204708062	649592	<.0001	
Error	1337	421333	315.13324			
Corrected Total	1338	205129396				
Root MSE	17.75199	R-Square	0.9979			
Dependent Mean	1974.75437	Adj R-Sq	0.9979			
Coeff Var	0.89895					
Model	R-Square	AIC	BIC	SBC	Variables in Model	
1	0.9979	7705.2595	7707.2655	7715.65890	X	
Parameter Estimates						
Variable	DF	Estimate	S.E	t Value	Pr > t 	VIF
Intercept	1	800.96967	1.53503	521.79	<.0001	0
X	1	0.99923	0.00124	805.97	<.0001	1.00000
Collinearity Diagnostics						
Condition	--Proportion of Variation--					
Number	Eigenvalue	Index	Intercept	X		
1	1.94875	1.00000	0.02563	0.02563		
2	0.05125	6.16618	0.97437	0.97437		
Test of First and Second Moment Specification						
DF	Chi-Square	Pr > ChiSq				
2	123.92	<.0001				
Durbin-Watson D						
1.924						
Number of Observations 1339						
1st Order Autocorrelation 0.037						



n = 1339 örneklem büyüklüğü için en küçük kareler sonuçları incelendiğinde artıklarda kelebek dağılıma ve sivrileşme sorunları gözlenmektedir. n = 1339 için merkezi dışsal değişken ile en küçük kareler mutlak artıklarından standart sapma fonksiyonu (Şekil 4.11) tahmin edilmiştir.



Şekil 4.11. n = 1339 için Standart Sapma Fonksiyonu

Tahmin edilen standart sapma fonksiyona ilişkin özet istatistikler Çizelge 4.21’de verilmiştir.

Çizelge 4.21. Standart Sapma Fonksiyonu İçin Model Özeti ve Parametre Tahminleri


Dependent Variable: |e|

Equation	Model Summary					Parameter Estimates	
	R Square	F	df1	df2	Sig.	b1	b2
Quadratic	.518	718.229	2	1337	.000	-.001	6.21E-005

The independent variable is o.

$|\widehat{e}_i| = -0.001o_i + 6.2 * 10^{-5} o_i^2$, standart sapma fonksiyonundan elde edilen mutlak artuk tahminleri ile ağırlık tahminleri elde edilerek ağırlıklı en küçük kareler uygulanmıştır. Elde edilen sonuçlar Çizelge 4.22’de verilmiştir.


Çizelge 4.22. n = 1339 için Standart Sapma Fonksiyonu ile Ağırlık Tahmini ve AEKK Sonuçları



Önerilen yönteminin $n = 1339$ örneklem büyüklüğü için kelebek dağılan artık sorununu ortadan kaldırdığı ve en küçük kareler artıklarının dağılımındaki sivriliği çok büyük ölçüde düzelttiği görülmektedir. Diğer kriterler incelendiğinde az sayıdaki aykırı değer dışında herhangi bir sorun olmadığı görülmektedir.

4.13.3. Yaklaşık Simetrik Veri $n = 8057$

Burada, aynı fonksiyon ile veri sayısı bir önceki uygulamaya göre yaklaşık 7 kat büyütülerek önerilen yöntem tekrar sınanmıştır. Veri kümesinin bağımsız değişkeni X ile bağımlı değişkeni Y arasındaki ilişki Şekil 4.12’de verilmiştir.




Şekil 4.12. $n = 8057$ için Yapay Veri Grafiği

Veri kümesine ağırlıksız en küçük kareler uygulanmış ve Çizelge 4.23’de verilen analiz sonuçları elde edilmiştir.

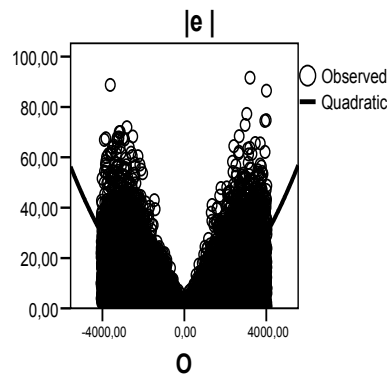
Çizelge 4.23. $n = 8057$ için En Küçük Kareler Sonuçları

Dependent Variable: Y							
Number of Observations Read		8057					
Number of Observations Used		8057					
Analysis of Variance							
Source	DF	Sum of Squares	Mean Square	F Value	Pr > F		
Model	1	44276210162	44276210162	1.361E8	<.0001		
Error	8055	2619856	325.24597				
Corrected Total	8056	44278830018					
Root MSE	18.03458	R-Square	0.9999				
Dependent Mean	7849.66697	Adj R-Sq	0.9999				
Coeff Var	0.22975						
Model	R-Square	AIC	BIC	SBC	Variables in Model		
1	0.9999	46608.3748	46610.3758	46622	X		
Parameter Estimates							
Variable	DF	Estimate	SE	t Value	Pr > t 	VIF	
Intercept	1	801.03934	0.63666	1258.20	<.0001		0
X	1	0.99988	0.00008570	11667.5	<.0001		1.00000



$n = 8057$ için en küçük kareler sonuçları incelendiğinde kelebek dağılan artıklar dolayısıyla bir değişen varyanslılık sorunu ile birlikte normal dağılımdan sapma da göze çarpmaktadır.

Önerilen yöntem uygulaması için ağırlıksız en küçük kareler artıklarınının mutlak değerleri ile merkezi dışsal değişken, standart sapma fonksiyonunun (Şekil 4.13) elde edilmesinde kullanılmıştır.



Şekil 4.13. $n = 8057$ için Standart Sapma Fonksiyonu

Elde edilen standart sapma fonksiyonuna ilişkin istatistikler Çizelge 4.24'de verilmiştir.

Çizelge 4.24. Standart Sapma Fonksiyonu için Model Özeti ve Parametre Tahminleri

Dependent Variable: |e|

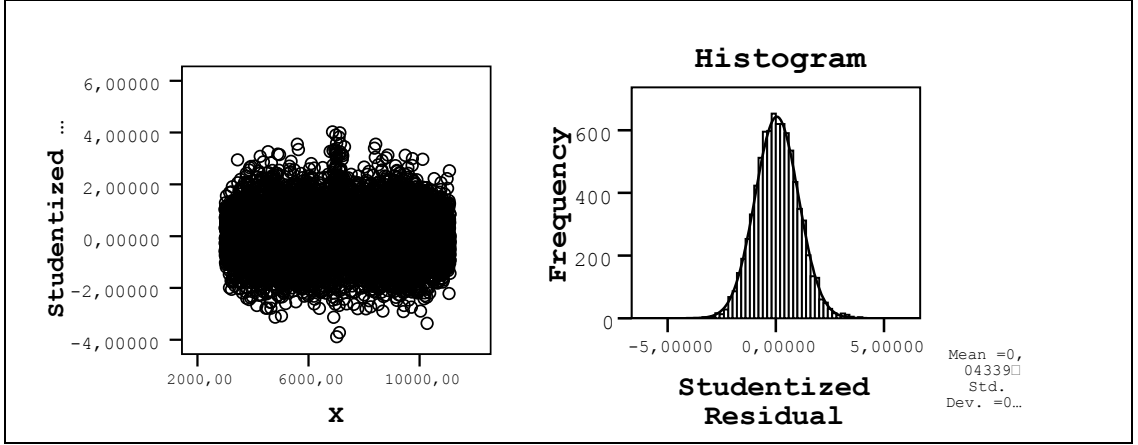
Equation	Model Summary					Parameter Estimates	
	R Square	F	df1	df2	Sig.	b1	b2
Quadratic	.558	5081.557	2	8055	.000	4.42E-005	1.83E-006

The independent variable is O.

$|\widehat{e}_i| = -4.42 * 10^{-5} o_i + 1.83 * 10^{-6} o_i^2$, standart sapma fonksiyonundan elde edilen mutlak artık tahminleri ağırlık elde etmede kullanılarak ağırlıklı en küçük kareler gerçekleştirilmiştir. Analiz sonuçları Çizelge 4.25'te verilmiştir.

Çizelge 4.25. n = 8057 için Merkezi Dışsal Değişken ile Standart Sapma Fonksiyonu Tahmini ve AEKK Sonuçları


Dependent Variable: Y						
$\widehat{w}_i = 1/ \widehat{e}_i , \widehat{e}_i \neq 0$						
Number of Observations Read		8057				
Number of Observations Used		8057				
Analysis of Variance						
Source	DF	Sum of Squares	Mean Square	F Value	Pr > F	
Model	1	4404754406	4404754406	1.124E8	<.0001	
Error	8055	315585	39.17880			
Corrected Total	8056	4405069992				
Root MSE	6.25930	R-Square	0.9999			
Dependent Mean	7850.51094	Adj R-Sq	0.9999			
Coeff Var	0.07973					
Model	R-Square	AIC	BIC	SBC	Variables in Model	
1	0.9999	29556.1688	29558.1698	29570	X	
Parameter Estimates						
Variable	DF	Estimate	SE	t Value	Pr > t	VIF
Intercept	1	799.16852	0.66524	1201.33	<.0001	0
X	1	1.00009	0.00009432	10603.2	<.0001	1.00000
Collinearity Diagnostics						
Condition --Proportion of Variation--						
Number	Eigenvalue	Index	Intercept	X		
1	1.99968	1.00000	0.00016062	0.00016062		
2	0.00032124	78.89803	0.99984	0.99984		
Test of First and Second Moment Specification						
DF	Chi-Square	Pr > ChiSq				
3	10.63	0.0139				
Durbin-Watson D		1.972				
Number of Observations		8057				
1st Order Autocorrelation		0.014				



Önerilen yönteminin $n = 8057$ örneklem büyüklüğü için kelebek dağılan artıklar sorununu ortadan kaldırdığı görülmektedir. Buna ek olarak önerilen yöntem, en küçük kareler artık dağılımındaki normal dağılıma uymama sorununu da çözmüştür. Diğer kriterler incelendiğinde ise merkez çevresinde göze çarpan aykırı değerler dışında herhangi bir sorun olmadığı görülmektedir.

4.13.4. Sağa Asimetrik Veri $n = 203$


Önerilen yöntem, yaklaşık simetrik farklı örneklem büyüklüğüne sahip veri kümelerindeki kelebek dağılan artıklar sorununu başarılı biçimde çözmüştür. Yöntemin simetrik olmayan kelebek dağılan artıklara etkisi, önce sağa asimetrik (Şekil 4.14) sonrasında ise sola asimetrik (Şekil 4.16) veri kümelerinde de sınanmıştır.



Şekil 4.14. $n = 203$ için Yapay Veri Grafığı

Bağımsız değişkeni ile bağımlı değişkeninin ilişkisi, Şekil 4.14'te verilen veri kümesine ağırlıksız en küçük kareler uygulanmıştır. Ağırlıksız en küçük kareler analizi sonuçları Çizelge 4.26'da verilmiştir.


Çizelge 4.26. Sağa Asimetrik Veri için En Küçük Kareler Sonuçları



Sağa asimetrik veri için uygulanan en küçük kareler çıktıları incelendiğinde kelebek dağılan artıklar için değişen varyanslılık ve normal dağılımdan sapma gibi sorunların olduğu gözlenmektedir. Diğer kriterler incelendiğinde ise model ve parametrelerin

istatistiksel olarak anlamlı olduğu, ardışık artıklar arasında herhangi bir ilişki olmadığı anlaşılmaktadır.

Sorunun çözümü için ağırlıksız en küçük karelerin mutlak artıkları, merkezi dışsal değişken ile standart sapma fonksiyonunun tahmininde (Şekil 4.15) kullanılmıştır.



Şekil 4.15. Sağa Asimetrik Veri için Standart Sapma Fonksiyonu

Elde edilen standart sapma fonksiyonu özeti Çizelge 4.27’de verilmiştir.

Çizelge 4.27. Standart Sapma Fonksiyonu için Model Özeti ve Parametre Tahminleri

Dependent Variable |e|


Equation	Model Summary					Parameter Estimates	
	R Square	F	df1	df2	Sig.	b1	b2
Quadratic	.564	130.173	2	201	.000	-.020	.002

The independent variable is O.

Bu standart sapma fonksiyonu tahmininden elde edilen tahmin değerlerinin tersi ağırlık tahminlerinin elde edilmesinde kullanılarak ağırlıklı en küçük kareler analiz gerçekleştirilmiştir. Söz konusu analizin sonuçları Çizelge 4.28’de verilmiştir.

Çizelge 4.28. Sağa Asimetrik Veride Merkezi Dışsal Değişken ile Standart Sapma Fonksiyonu Tahmini ve AEKK Sonuçları


Dependent Variable Y						
Number of Observations Read		203				
Number of Observations Used		203				
$\widehat{ e_i } = -0.020o_i + 0.002o_i^2$						
$\widehat{w}_i = 1/\widehat{ e_i }, \quad \widehat{ e_i } \neq 0$						
Analysis of Variance						
Source	DF	Sum of Squares	Mean Square	F Value	Pr > F	
Model	1	135450	135450	3580.83	<.0001	
Error	201	7603.12846	37.82651			
Corrected Total	202	143053				
Root MSE	6.15033	R-Square	0.9469			
Dependent Mean	1040.59765	Adj R-Sq	0.9466			
Coeff Var	0.59104					



Önerilen yöntemin sağa asimetric olan verideki deęişen varyanslılık ve normal daęılımdan sapma sorunlarını başarılı bir biçimde ortadan kaldırdığı görülmektedir.

4.13.5. Sola Asimetric Veri n = 223

Önerilen yöntem son olarak 223 örneklem büyüklüğünde sola asimetric veri için sınanmıştır. Yapay veri üretme fonksiyonu ile elde edilen bağımsız ve bağımlı deęişkenin grafięi Şekil 4.16'de verilmiştir.



Şekil 4.16. n = 223 Sola Asimetrik Veri Grafiği

Veriye ağırlıksız en küçük kareler uygulanarak Çizelge 4.29’da verilen sonuçlar elde edilmiştir.

Çizelge 4.29. Sola Asimetrik Veri için EKK Sonuçları

```

The REG Procedure
Dependent Variable: Y
Number of Observations Read      223
Number of Observations Used      223

Analysis of Variance
Source          DF          Sum of Squares    Mean Square    F Value    Pr > F
Model           1           875363           875363        3572.83    <.0001
Error          221           54146           245.00571
Corrected Total 222           929509
Root MSE       15.65266    R-Square         0.9417
Dependent Mean 1013.15760    Adj R-Sq         0.9415
Coeff Var      1.54494

Model          R-Square    AIC          BIC          SBC          Variables in Model
1              0.9417     1228.7768   1230.8128   1235.59110   X

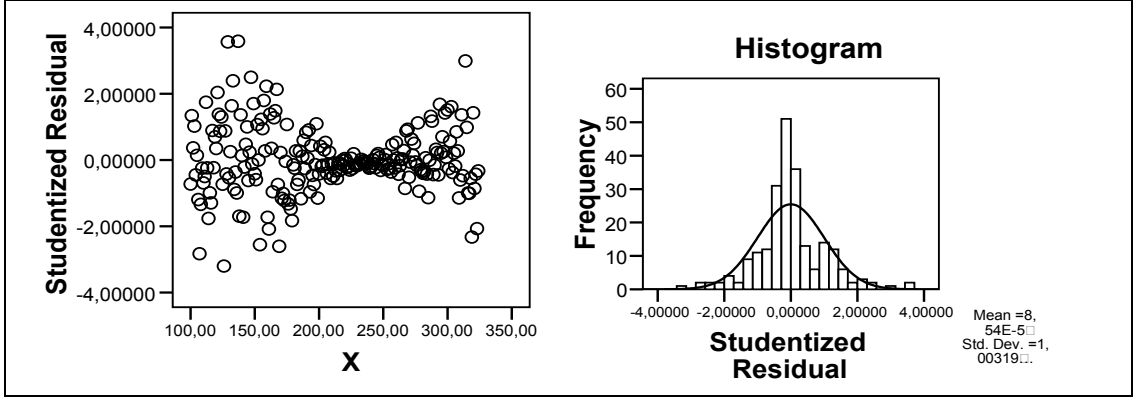
Parameter Estimates
Variable      DF          Estimate          S.E          t Value    Pr > |t|    V.I.F
Intercept    1           807.46421        3.59733     224.46     <.0001      0
X            1           0.97021          0.01623     59.77     <.0001      1.00000

Collinearity Diagnostics
Condition      --Proportion of Variation--
Number        Eigenvalue    Index          Intercept    X
1             1.95661      1.00000        0.02170     0.02170
2             0.04339      6.71504        0.97830     0.97830

Test of First and Second
Moment Specification
DF          Chi-Square    Pr > ChiSq
2           31.39        <.0001


Durbin-Watson D          1.798
Number of Observations   223
1st Order Autocorrelation 0.096

```



Sola asimetric veri için en küçük kareler, sola asimetric kelebek dağılan artıklar ve normal dağılımdan sapmalara neden olmuştur.

Önerilen yöntem ile en küçük kareler mutlak artıklarından standart sapma fonksiyonu (Şekil 4.17) tahmin edilmiştir. Tahmin edilen standart sapma fonksiyonuna ilişkin özet istatistikler Çizelge 4.30’da verilmiştir.



Şekil 4.17. Sola Asimetric Veri için Standart Sapma Fonksiyonu

Çizelge 4.30. Standart Sapma Fonksiyonu için Model Özeti ve Parametre Tahminleri

Dependent Variable: |e|


Equation	Model Summary					Parameter Estimates	
	R Square	F	df1	df2	Sig.	b1	b2
Quadratic	.510	115.669	2	221	.000	.017	.002

The independent variable is O.

$|\widehat{e}_i| = 0.017o_i + 0.002o_i^2$ standart sapma fonksiyonundan elde tahmin değerlerinin

tersleriyle $\widehat{w}_i = 1/|\widehat{e}_i|$, $|\widehat{e}_i| \neq 0$ şeklinde ağırlıklar elde edilerek ağırlıklı en küçük kareler uygulanmıştır. Analizin sonuçları Çizelge 4.31’de verilmiştir.

Çizelge 4.31. Sola Asimetrik Veri için Merkezi Dışsal Değişken ile Standart Sapma Fonksiyonu Tahmini ve AEKK Sonuçları




Önerilen yöntemin sola asimetrik olan verideki artıkların normal dağılımdan sapma ve kelebek dağılan artıklar için değişen varyanslılığı ortadan kaldırdığı gözlenmektedir. Bununla birlikte az sayıda da aykırı değer ortaya çıkmıştır.

4.13.6. Merkezi Dışsal Değişkenle Doğrudan Ağırlık Tahmini ve Ağırlıklı En Küçük Kareler

Kesim 3.14.2’de belirtildiği üzere merkezileştirilmiş dışsal değişkenin mutlak değerlerinin tersi doğrudan ağırlık tahminlerini elde etmekte kullanılabilir. Yöntem,

kesim 4.12.5’de verilen sola asimetrik veri kümesine uygulanmış ve Çizelge 4.32’de verilen analiz sonuçları elde edilmiştir.

Çizelge 4.32. Mutlak Merkezi Dışsal Değişken ile AEKK Sonuçları



Mutlak merkezi dışsal değişkenin doğrudan ağırlık tahmininde kullanılması sonucu kelebek dağılan artıklar için değişen varyanslılığın başarılı bir şekilde dengelendiği görülmektedir. Buna ek olarak yöntemin, Çizelge 4.29’da verilen en küçük kareler artık dağılımındaki bozulmayı giderdiği ve artıkları normal dağılıma uydurduğu görülmektedir. Aynı veri kümesi için değişim katsayıları incelendiğinde ise bu veri

kümesi için en homojen dağılımın merkezileştirilmiş değişkenin ağırlıklandırmada kullanılması sonucunda elde edildiği gözlenmektedir.

5. SONUÇ ve ÖNERİLER

Bu çalışmada, kelebek dağılan artıkların varlığı durumunda, monoton olmayan değişen varyanslılığın düzeltilmesi için aynı veri kümesine, önerilen yöntemler dışında, 11 başlık altında 8 yöntem uygulanmıştır.

Kelebek dağılan artıklar dolayısıyla değişen varyanslılık sorununu düzeltmek üzere uygulanan, iteratif algoritmalara dayanan Meloun ve diğ., (2002) tarafından önerilen yeniden ağırlıklandırılmış iteratif en küçük kareler, Chatterjee ve Machler (1997) tarafından önerilen iteratif yöntem, bağımlı değişken dönüşümlerine dayanan Box - Cox (1964) dönüşümleri, yeniden örnekleme dayanan Jackknife, Bootstrap yöntemleri, karesel ve mutlak artıkların parametrik olmayan düzlemesi istenen sonucu vermemiştir. Adı geçen yöntemlerden Meloun ve diğ. (2002) tarafından önerilen yöntem, iki tepeli bir dağılım sonucuna neden olduğu için normal dağılımı bozmuş ve çoklubağlantı sorunu yaratmıştır.

Dönüşüm ve iteratif algoritmalara dayanan Bischoff ve diğ. (2006) tarafından önerilen değiştirilmiş ardışık artıklar yönteminin yanı sıra, veri kümesinin tekrarlı gözlemler için, karesel ve mutlak artıkların standart sapmalarıyla ağırlıklandırılması, değişen varyanslılık sorununu kısmen ortadan kaldırmıştır. Ancak karesel artıkların standart sapmalarının ağırlık tahmininde kullanılması, bağımlı değişken standart sapmalarının ağırlık tahmininde kullanılmasına göre varyansı dengeleme açısından daha iyi sonuç vermiştir.

Yukarıda sözü edilen yöntemler mevcut pek çok istatistik paket programında yer almamaktadır. Özellikle iteratif olan yöntemler için program kodu yazmak dışında neredeyse seçenek yoktur. Bu bakımdan yöntemlerin kullanımı oldukça zor ve karmaşıktır.

Bu çalışmada önerilen üç yöntemden ilki, ağırlıkların, merkezi dışsal değişken ile karesel ya da mutlak artıklardan varyans ya da standart sapma fonksiyonlarından elde edilmesidir. Bu yöntem, hem uygulama verisi hem de farklı örneklem büyüklüklerinde; yaklaşık simetrik yapay veri kümeleri için kelebek dağılan artıklar

sorununu giderme ve normal dağılıma yaklaştırma konusunda başarılı sonuçlar vermiştir. Söz konusu yöntem, sağa asimetric ve sola asimetric yapay veri kümelerine uygulandığında da kelebek dağılan artıklar sorununu giderme ve normal dağılıma yaklaştırma konusunda başarılı sonuçlar vermiştir. Yukarıda sayılan avantajlarına karşılık, merkezi dışsal değişken ile artık dönüşümlerinden, varyans ya da standart sapma fonksiyonları aracılığıyla, ağırlık tahmini elde edilmesinin, görünen tek dezavantajı, boğum noktası çevresinde çok küçük artıklara karşılık gelen gözlemlerin aşırı ağırlık alması dolayısıyla aykırı değerlere neden olabilmesidir.

Önerilen ikinci yöntem olan, merkezi dışsal değişkenin mutlak değerlerinin doğrudan ağırlık tahmini elde etme sürecinde kullanılması, kelebek dağılan artık sorununu giderme konusunda iyi sonuç vermiştir.

Önerilen yöntemlerin bir parçası olan artıklar için merkez ya da boğum noktası elde edilmesi, kelebek ya da galaksi dağılan artıklarla çalışılırken verinin doğru bir biçimde parçalanmasına ve farklı analiz senaryolarına da olanak sağlamıştır.

Bu konuda, merkezi dışsal değişken ile varyans ya da standart sapma fonksiyonları aracılığıyla ağırlık tahminleri elde edilirken, aykırı değerlerin önlenmesi üzerinde çalışılabilir.

KAYNAKLAR

- Aitkin, M.**, 1987. Modelling Variance Heterogeneity in Normal Regression Using GLIM, *Applied Statistics*, 36, 332-339.
- Albayrak, A. S.**, 2008. Değişen Varyans Durumunda En Küçük Kareler Tekniğinin Alternatifi Ağırlıklı Regresyon Analizi ve Bir Uygulama, *Afyon Kocatepe Üniversitesi, İ.İ.B.F. Dergisi*.
- Bagnall, A., Whittle, I., Studley, M., Pettipher, M., Tekiner, F., Bull, L.**, 2006. Variance Stabilizing Regression Ensembles for Environmental Models, *International Joint Conference on Neural Networks*, Sheraton Vancouver BC, Canada July 16-21.
- Basu, A.**, 2005. Extended generalized linear models: Simultaneous estimation of flexible link and variance functions. *The Stata Journal*, N 4, pp. 501-516.
- Bischoff, W., Heck, B., Howind, J., Teusch, A.**, 2006. A procedure for estimating the variance function of linear models and for checking the appropriateness of estimated variances a case study of GPS carrier-phase observations, *J Geod.* 79, 694-704.
- Box, G. E. P. and Cox, D. R.**, 1964. An analysis of transformations (with discussion), *Journal of the Royal Statistical Society*, series B, 26, 211-246.
- Box, G. E. P. and Hill, W.J.**, 1974. Correcting inhomogeneity of variance with power transformation weighting, *Technometrics*, 16, 385-389.
- Carroll, R.J. and Davidian, M.**, 1987. Variance Function Estimation, *Journal of the American Statistical Association*, 82, 1079-1091.
- Carroll, R. J.**, 1982. Adapting for Heteroscedasticity in Linear Models, *The Annals of Statistics*, 10, 1224-1233.
- Carroll, R.J. and Ruppert, D.**, 1982. Robust Estimation in Heteroscedastic Linear Models, *The Annals of Statistics*, 10, 429-44.
- Carroll, R.J. and Ruppert, D.**, 1988. Transformation and Weighting in Regression, Chapman and Hall.
- Chatterjee, S. and Machler, M.**, 1997. Robust Regression: A Weighted Least Squares Approach, *Commun. Statist.-Theory*, 26(6), 1381-1394.
- Cook, R. D. and Weisberg, S.**, 1982. Residuals and Influence in Regression, Chapman and Hall.
- Darlington, R. B.**, 1997. Correcting the Standard Errors of Regression Slopes for Heteroscedasticity, <http://www.psych.cornell.edu/darlington/heterosc.htm>.
- Draper, N.R. and H. Smith**, 1998. Applied Regression Analysis, 3rd ed. Wiley.

- Eviews 4.1 User Guide**, 2002. Quantitative Micro Software, LLC.
- Friel, C. M.**, 2009. Weighted Least-squares Regression, Sam Houston State University.
- Genceli, M.**, 2001. Ekonometri ve İstatistik İlkeleri, Filiz Kitapevi.
- Gujaratti, D.**, 2001. Basic Econometrics.
- Güriş, S. ve Çağlayan, E.**, 2001. Ekonometri, Der Yayınları.
- Hadi, A. S. and Chatterjee, S.**, 2006. Regression Analysis by Example, Wiley.
- Hamasaki, T. and Goto, M.**, 2005. Power-Transformation Model to Additivity in Regression, *Behaviormetrika*, Vol.32, No.2, 111–125.
- Harvey, A.C.**, 1976. Estimating Regression Models with Multiplicative Heteroskedasticity, *Ekonometrica*, 44, 461-465.
- Hinkley, D.**, 2010, Jackknife Methods, *International Statistical Review to Line Intersect. Sampling*, Encyclopedia of Statistical Science Vol.6, Wiley.
- Kianifrad, F. and Swallow, W. H.**, 1996. A Review of the Development and Application of Recursive Residuals in Linear Models, *Journal of the American Statistical Association*, 91, 391-400.
- Kıroğlu, G.**, 2001. Uygulamalı Parametrik Olmayan İstatistiksel Yöntemler, İstanbul.
- Kuk, A. Y. C.**, 1999. Nonparametrically Weighted Least Squares Estimation in Heteroscedastic Linear Regression, *Biometrical Journal* 41, 4: 401-410.
- Kutner, M.H., Nachtsheim, C.J., Neter, J. and Li, W.**, 2005. Applied Linear Statistical Models, McGraw-Hill.
- McCullagh, P. and Nelder, J.A.**, 1983. Generalized Linear Models, Chapman and Hall.
- Meloun, M., Militky, J., Kupka, K., Brereton, R.G.**, 2002. The effect of influential data, model and method on the precision of univariate calibration, *Talanta* 57, 721-740.
- Oberg, A. and Davidian, M.**, 2000. Estimating Data Transformations in Nonlinear Mixed Effects Models, *Biometrics* 56, 65-72.
- Pardoe, I. and Cook, D.**, 2007. A Graphical Diagnostic For Variance Functions, *Aust. & N. Z. J. Stat.* 49(3), 241–250.
- Paulson, D. S.**, 2006. Handbook of Regression and Modelling, CRC.
- PBC Electronics Designing**, 2009. The fixed geometry structure's FFT algorithm and FPGA realize-www.51rd.net
- Rawlings, O. R., Pantula, S. G. and Dickey, D. A.**, 1998. Applied Regression Analysis, 2nd ed.
- Ryan, T. P.**, 1997. Modern Regression Methods, Wiley.
- SAS/IML 9.2 User's Guide**, 2008. SAS Institute Inc., Cary, NC, USA.

- Shick, A.**, 1999. Improving weighted least squares estimates in heteroscedastic linear regression when the variance is a function of the mean response, *Journal of Statistical Planning and Inference*, 76 127-144.
- Silverman, E. and Kot, M.**, 2000. Rate Estimation for a Simple Movement Model, *Bulletin of Mathematical Biology*, 58, 351-375.
- SPSS Trends 10.0**, 1999. SPSS Inc.
- Verbyla, A.P.**,1993. Modelling Variance Heterogeneity Residual Maximum Likelihood and Diagnostics, *Journal of the Royal Statistical Society*, 55, 493-508.
- Weisberg, S.**, 2005. Applied Linear Regression, 3rd ed., Willy.
- Willet, J. B. and Singer, J. D.**, 2002. Caveats for the Statistical Consumer: A Cautionary Note on Case Weighting as a Method of Implementing Weighted Least-Squares Regression, *Journal of Experimental Educations*, 286-293.
- Wu, J.**, 1986. Jackknife, Bootstrap and Other Resampling Methods in Regresyon Analysis, *The Annals of Statistics*, Vol. 14, No 4.
- url_1 <http://www.tuik.gov.tr/cevredagitimapp/hava.zul>**
- url_2 <http://www.rshm.saglik.gov.tr/hki/hkindex/index5.htm>**

ÖZGEÇMİŞ

Adı Soyadı : Reşit ÇELİK
Doğum Yeri : Sivas
Doğum Tarihi : 29.12.1970
Medeni Hali : Evli ve 1 çocuk sahibi

Eğitim Durumu

İlkokul : Gedikçayır İlkokulu Sivas-Atatürk Çiftliği İlkokulu İstanbul (1981)
Ortaokul : Gazi İlköğretim Okulu İstanbul (1986)
Lise : Pertevniyal Lisesi (1989)
Lisans : Yıldız Teknik Üniversitesi, Fen Edebiyat Fakültesi, İstatistik Bölümü (1994)
Yüksek Lisans : Marmara Üniversitesi, Sosyal Bilimleri Enstitüsü, İstatistik A.B.D. (2003)
Yabancı Dil : İngilizce

İş Tecrübesi

1997-1999- : Milli Eğitim Bakanlığı (Öğretmen)
1999- : İstatistik Bölümü Araştırma Görevlisi (Yıldız Teknik Üniversitesi)