



**ÖRNEKLEMEDE AĞIRLIKLANDIRMA PROSEDÜRLERİ VE
KALİBRASYON YAKLAŞIMI**

Cenker Burak METİN

**DOKTORA TEZİ
İSTATİSTİK ANA BİLİM DALI**

**GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

MART 2020

Çenker Burak METİN tarafından hazırlanan "ÖRNEKLEMEDE AĞIRLIKLANDIRMA PROSEDÜRLERİ VE KALİBRASYON YAKLAŞIMI" adlı tez çalışması aşağıdaki jüri tarafından OY BİRLİĞİ ile Gazi Üniversitesi İstatistik Ana Bilim Dalında DOKTORA TEZİ olarak kabul edilmiştir.

Danışman: Prof. Dr. Yaprak Arzu ÖZDEMİR

İstatistik Ana Bilim Dalı, Gazi Üniversitesi

Bu tezin, kapsam ve kalite olarak Doktora Tezi olduğunu onaylıyorum.

.....

Başkan: Prof. Dr. Ahmet Sinan TÜRKİYILMAZ

Sosyal Araştırma Yöntemleri Ana Bilim Dalı, Hacettepe Üniversitesi

Bu tezin, kapsam ve kalite olarak Doktora Tezi olduğunu onaylıyorum.

.....

Üye: Prof. Dr. Fikri GÖKPINAR

İstatistik Ana Bilim Dalı, Gazi Üniversitesi

Bu tezin, kapsam ve kalite olarak Doktora Tezi olduğunu onaylıyorum.

.....

Üye: Prof. Dr. Meral EBEGİL

İstatistik Ana Bilim Dalı, Gazi Üniversitesi

Bu tezin, kapsam ve kalite olarak Doktora Tezi olduğunu onaylıyorum.

.....

Üye: Doç. Dr. Nursel KOYUNCU

İstatistik Ana Bilim Dalı, Hacettepe Üniversitesi

Bu tezin, kapsam ve kalite olarak Doktora Tezi olduğunu onaylıyorum.

.....

Tez Savunma Tarihi: 13 / 03 / 2020

Jüri tarafından kabul edilen bu tezin Doktora Tezi olması için gerekli şartları yerine getirdiğini onaylıyorum.

.....

Prof. Dr. Sena YAŞYERLİ

Fen Bilimleri Enstitüsü Müdürü

ETİK BEYAN

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

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
 - Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
 - Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
 - Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
 - Bu tezde sunduğum çalışmanın özgün olduğunu,
- bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Cenker Burak METİN

13 / 03 / 2020

ÖRNEKLEMEDE AĞIRLIKLANDIRMA PROSEDÜRLERİ VE KALİBRASYON

YAKLAŞIMI

(Doktora Tezi)

Cenker Burak METİN

GAZİ ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

Mart 2020

ÖZET

Örnekleme yöntemleri kullanılarak yapılan araştırmalarda hedef yığın ilgilenilen karakteristikler için en iyi şekilde temsil edilmelidir. Temsil sorunu ile karşılaşmamak ve parametreleri etkin biçimde tahmin etmek için hedef yığını olabildiğince kapsayan bir örnekleme çerçevesi oluşturulmalıdır. Bu çerçeve kullanılarak birimlerin seçim olasılıklarının farklı olduğu durumlarda tasarım ağırlıklarının kullanımını gerektiren örnekleme tasarımları geliştirilir. Cevapsızlık, kapsam dışılık gibi sorunların tasarım ağırlıklarında olumsuz etkisini azaltmak amacıyla bazı düzeltme işlemleri yapılır. Kalibrasyon yaklaşımı, yardımcı bilgi kullanarak bilinen yığın değerlerine uyum sağlayan bir ağırlıklandırma işlemidir. Bu tez çalışmasındaki amaç, aykırı değer, aykırı ağırlık ve farklı korelasyon yapılarının olduğu büyük veri setlerinde kullanılacak ağırlıklandırma ve kalibrasyon işlemlerinin etkinliklerinin araştırılmasıdır. Bu durumlarda genellikle ağırlık budaması kullanılarak sorunlar giderilmektedir. Bu çalışmada, ağırlık budamasına alternatif olarak uygulamada kullanımı daha kolay olan minimum uzaklık yöntemlerinden sınırlandırılmış kalibrasyon tahmin edicileri incelenmiştir. Ayrıca yardımcı değişkenlerin korelasyon yapısının kalibrasyon tahmin edicilerinin etkinliklerini ne düzeyde etkilediği de araştırılmıştır. Simülasyon çalışması yapılarak, ele alınan tahmin edicilerin etkinlikleri farklı korelasyon yapıları ve aykırı değer durumları için elde edilmiştir. Simülasyon çalışması sonucunda, kalibrasyon tahmin edicilerinin Horvitz-Thompson tahmin edicisinden daha etkin olduğu; yardımcı değişkenlerin hedef değişkenle korelasyonu arttığında etkinliğin belirgin biçimde arttığı gözlemlenmiştir. Bunlara ek olarak hedef ve yardımcı değişkenlerde aykırı değerler olduğunda, kalibrasyon tahmin edicilerinin görece etkinliğinin sorunsuz veri setlerine göre çok daha büyük olduğu da belirlenmiştir. Tezin uygulama kısmında ise 2017 Yıllık Sanayi ve Hizmet İstatistikleri verisi kullanılmış ve "Ciro" gibi varyansı yüksek olan değişkenlerin tahmininde sınırlandırılmış kalibrasyon tahmin edicilerinin Genelleştirilmiş regresyon tahmin edicisinden daha etkin oldukları tespit edilmiştir. Özellikle küçük örnekleme oranlarında, kalibrasyon işlemi sonrasında karşılaşılan negatif ve birden küçük ağırlık sorununu çözme konusunda sınırlandırılmış kalibrasyon tahmin edicilerinin, ağırlık budaması ile elde edilen tahmin edicilerden daha etkin sonuçlar verdiği belirlenmiştir.

Bilim Kodu : 20510

Anahtar Kelimeler : Ağırlıklandırma, Kalibrasyon, Ağırlık Budaması, Minimum Uzaklık Yöntemi, Sınırlandırılmış Kalibrasyon Tahmin Edicileri

Sayfa Adedi : 110

Danışman : Prof. Dr. Yaprak Arzu ÖZDEMİR

WEIGHTING PROCEDURES AND CALIBRATION APPROACH IN SAMPLING

(Ph. D. Thesis)

Cenker Burak METİN

GAZİ UNIVERSITY

GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

March 2020

ABSTRACT

Target population should be represented in the best way for the related characteristics in the sample surveys. A sampling frame that covers the target population as much as possible is constructed in order not to encounter the problem of representation and estimate the parameters efficiently. By using this frame, sampling designs in which the probability of selection of units is generally different and therefore require design weights usage are developed. For reducing the negative effects of non-response and out-of-scope problems some adjustments are made in design weights. The calibration approach is a weighting process that agree with the known population values by using auxiliary information. The purpose of this thesis is to analyze the efficiency of calibration and weighting processes that can be used in large data sets with outliers, extreme weights and different correlation structures. In these cases, problems are usually solved by using weight trimming. In this study, restricted calibration estimators, which are easier to apply in practice as an alternative to weight trimming, are examined. It was also investigated that how the correlation structure of the auxiliary variables affects the efficiency of the calibration estimators. As a result of the simulation study, the calibration estimators are more efficient than the Horvitz-Thompson estimator. The efficiency increase explicitly when the correlation of auxiliary variables with target variable increased. Moreover, the relative efficiency of the calibration estimators is much greater when there are outliers in the target and auxiliary variables against smooth data sets. 2017 Annual Industry and Service Statistics data was used in the application and it was determined that restricted calibration estimators are more efficient than Generalized Regression estimator for the estimation of high variance variables such as "Turnover". Especially in small sample fractions, it was recognized that the restricted calibration estimators more efficient than the weight trimming about to solve the negative and less than one weights problem encountered after the calibration process.

Science Code : 20510

Key Words : Weighting, Calibration, Weight Trimming, Minimum Distance Method
Restricted Calibration Estimators

Page Number : 110

Supervisor : Prof. Dr. Yaprak Arzu ÖZDEMİR

TEŞEKKÜR

Örnekleme konusundaki çalışmalarımı destekleyerek doktora yapmamı teşvik eden; tez çalışması süresince de değerli katkılarıyla bana yol göstererek anlayışlı tavrını esirgemeyen hocam ve danışmanım Sayın Prof. Dr. Yaprak Arzu ÖZDEMİR'e (Gazi Üniversitesi İstatistik Ana Bilim Dalı) en içten teşekkür ve şükranlarımı sunarım.

Tez çalışmam süresince, görüş ve önerileri ile bana katkı sağlayan Sayın Dr. Sinem Tuğba ŞAHİN TEKİN'e (Gazi Üniversitesi İstatistik Ana Bilim Dalı), önemli yorum ve katkılarıyla çalışmalarına ışık tutan Sayın Prof. Dr. Ahmet Sinan TÜRKYILMAZ'a (Hacettepe Üniversitesi Sosyal Araştırma Yöntemleri Ana Bilim Dalı) ve Sayın Prof. Dr. Fikri GÖKPINAR'a (Gazi Üniversitesi İstatistik Ana Bilim Dalı) teşekkürü bir borç bilirim.

Doktora eğitimi boyunca sabır göstererek yanımda olan sevgili eşim Gözde METİN'e; bu süreçte zaman zaman ihmal edilse de babasını üzmeyen Beren'e ve tüm öğrenim hayatımda olduğu gibi desteğini esirgemeyen anneme sonsuz teşekkürlerimi sunarım. Örnekleme konusunda akademik çalışmalar yapmamı teşvik eden ve tez çalışması sürecinde kaybettiğimiz Sayın Hasibe DEDEŞ'i saygı ve rahmetle anarken bu çalışmayı kendisine ithaf ediyorum.

İÇİNDEKİLER

	Sayfa
ÖZET	iv
ABSTRACT	v
TEŞEKKÜR	vi
İÇİNDEKİLER	vii
ÇİZELGELERİN LİSTESİ	ix
ŞEKİLLERİN LİSTESİ	xi
SİMGELER VE KISALTMALAR	xii
1. GİRİŞ.....	1
2. AĞIRLIKLANDIRMA VE AĞIRLIK DÜZELTMESİ.....	9
2.1. Örnekleme Tasarımı.....	9
2.2. Örneklemede Ağırlık Kullanımı	12
2.3. Tasarım Ağırlığı ve Ağırlık Düzeltme Aşamaları.....	17
2.3.1. Tasarım ağırlığının belirlenmesi ve Horvitz-Thompson tahmin edicisi....	18
2.3.2. Cevapsızlık düzeltmesi	20
2.3.3. Güvenilir dışsal kaynağa göre düzeltme.....	25
2.3.4. Varyans şişirme faktörü ve budama	28
2.3.5. Ölçeklendirme	31
3. KALİBRASYON TAHMİN EDİCİLERİ	35
3.1. Sonradan-Tabakalama Tahmin Edicisi	38
3.2. Raking Yaklaşımı.....	41
3.3. Genelleştirilmiş Regresyon Tahmin Edicisi (GREG).....	44
3.4. Minimum Uzaklık Yöntemi ile Kalibrasyon.....	49
3.5. Alternatif Kalibrasyon Tahmin Edicileri	55
4. SİMÜLASYON ÇALIŞMASI.....	57

	Sayfa
4.1. Farklı Korelasyon Yapıları İçin Kalibrasyon Tahmin Edicilerinin Etkinliği.....	57
4.2. Aykırı Değerli Hedef Değişkende Kalibrasyon Tahmin Edicilerinin Etkinliği..	60
4.3. Aykırı Değerli Yardımcı Değişkende Kalibrasyon Tahmin Edicilerinin Etkinliği.....	62
5. UYGULAMA.....	69
5.1. Veri Kaynağı ve Değişkenler	69
5.2. Tahmin Edicilerin Etkinliklerinin Karşılaştırılması.....	71
5.2.1. Paketleme faaliyetleri sektöründe ciro ve FMKD tahmini.....	73
5.2.2. Gösteri sanatları sektöründe ciro ve çalışan sayısı tahmini.....	75
5.2.3. İş bulma acentelerinin faaliyetleri sektöründe ciro ve FMKD tahmini	77
5.3. Sınırlandırılmış Kalibrasyonda Alt ve Üst Sınırların Etkisi	78
5.4. Uygulama Sonuçları.....	85
6. SONUÇ VE ÖNERİLER	89
KAYNAKLAR	93
EKLER	101
EK-1. Simülasyon Kodu	102
EK-2. Uygulama Kodu (NACE 7810 için)	105
ÖZGEÇMİŞ	109

ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 2.1. $V(\bar{y})$ ve $V(\bar{y}_d)$ karşılaştırılmasında $V(\bar{y})$ 'nin küçük olması örneği	15
Çizelge 2.2. $V(\bar{y})$ ve $V(\bar{y}_d)$ karşılaştırılmasında $V(\bar{y})$ 'nin büyük olması örneği.....	16
Çizelge 2.3. Farklı cevaplama eğilimlerinde görelî sapma.....	23
Çizelge 2.4. Verma (2014) ağırlık budama prosedürünün örneklendirilmesi	30
Çizelge 3.1. Sonradan-tabakalamanın örneklendirilmesi	40
Çizelge 3.2. Sonradan-tabakalama ağırlık düzeltme katsayıları	41
Çizelge 3.3. Raking işleminin örneklendirilmesi.....	43
Çizelge 3.4. Raking işleminin sonucu ve ağırlık düzeltme katsayıları	44
Çizelge 3.5. Deville ve Särndal (1992) tarafından verilen uzaklık fonksiyonu örnekleri.....	50
Çizelge 4.1. Hedef deęişken Y ve yardımcı deęişkenler X_1 ve X_2 korelasyon deęerleri	58
Çizelge 4.2. Kalibrasyon tahmin edicilerinin farklı durumlardaki görelî etkinlięi.....	59
Çizelge 4.3. Aykırı Y olan veride kalibrasyon tahmin edicilerinin görelî etkinlikleri....	60
Çizelge 4.4. Sorunsuz veri seti ve aykırı hedef deęişken (Y) içeren veri setlerinde GREG'in HT'ye görelî etkinlięi.....	61
Çizelge 4.5. Aykırı Y deęerli veride simülasyon sonucundaki görelî sapmalar	62
Çizelge 4.6. Aykırı X_1 olan veride kalibrasyon tahmin edicilerinin MSE tahminleri (10^{12})	63
Çizelge 4.7. Aykırı X_1 olan veride kalibrasyon tahmin edicilerinin görelî etkinlięi.....	63
Çizelge 4.8. Aykırı X_1 deęerli veride simülasyon sonucundaki görelî sapmalar.....	64
Çizelge 4.9. Aykırı X_2 olan veride kalibrasyon tahmin edicilerinin MSE tahminleri (10^{12})	65
Çizelge 4.10. Aykırı X_2 olan veride kalibrasyon tahmin edicilerinin görelî etkinlięi.....	65
Çizelge 4.11. Aykırı X_2 deęerli veride simülasyon sonucundaki görelî sapmalar	66
Çizelge 4.12. Sorunsuz veri seti ve aykırı deęerli deęişkenler içeren veri setlerinde GREG'in HT'ye görelî etkinlięi.....	66

Çizelge	Sayfa
Çizelge 5.1. 2017 YSHİ veri setinde yer alan değişkenler	70
Çizelge 5.2. 2017 YSHİ veri setinden yardımcı değişken olarak kullanılacak değişkenler.....	71
Çizelge 5.3. Paketleme faaliyetlerinde değişkenler için korelasyon matrisi	73
Çizelge 5.4. Paketleme faaliyetleri için tahmin edicilerin görelî sapma (RB) ve görelî etkinlikleri (RE).....	74
Çizelge 5.5. Gösteri sanatlarında değişkenler için korelasyon matrisi	75
Çizelge 5.6. Gösteri sanatları için tahmin edicilerin görelî sapma ve etkinlikleri.....	76
Çizelge 5.7. İş bulma acentelerinin faaliyetlerinde değişkenler için korelasyon matrisi.....	77
Çizelge 5.8. İş bulma acenteleri için tahmin edicilerin görelî sapma ve etkinlikleri.....	78

ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 2.1. Kapsam ve cevapsızlık probleminin gösterimi.....	20
Şekil 3.1. Kalibrasyon fonksiyonlarının grafiksel gösterimi	52
Şekil 5.1. GREG ve alternatif TRN'ler için kutu grafikleri ($\min(g^{(GREG)}) = -0,8671$).....	79
Şekil 5.2. GREG ve alternatif TRN'ler için histogramlar ($\min(g^{(GREG)}) = -0,8671$).....	80
Şekil 5.3. RAK ve alternatif LOG'lar için kutu grafikleri ($\min(g^{(RAK)}) = 0,0583$)....	81
Şekil 5.4. RAK ve alternatif LOG'lar için histogramlar ($\min(g^{(RAK)}) = 0,0583$)	81
Şekil 5.5. GREG ve alternatif TRN'ler için kutu grafikleri ($\min(g^{(GREG)}) = 0,3988$)..	82
Şekil 5.6. RAK ve alternatif LOG'lar için kutu grafikleri ($\min(g^{(RAK)}) = 0,4610$).....	83
Şekil 5.7. GREG ve alternatif TRN'ler için histogramlar ($\min(g^{(GREG)}) = 0,3988$)	83
Şekil 5.8. RAK ve alternatif LOG'lar için histogramlar ($\min(g^{(RAK)}) = 0,4610$)	84
Şekil 5.9. Ciro değişkeninin tahmini için bulunan görelî etkinlikler	86
Şekil 5.10. Çalışan sayısı ve FMKD değişkenleri tahmini için bulunan görelî etkinlikler	86

SİMGELER VE KISALTMALAR

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

Simgeler	Açıklamalar
$AV(.)$	Asimptotik varyans
$B_{s;dq}$	Örnek regresyon katsayıları
$B_{U;q}$	Yığın regresyon katsayıları
d	Tasarım ağırlığı
$E(.)$	Beklenen değer
H	Tabaka sayısı
I	Örnekte içerilme göstergesi
L	Sınıf veya grup sayısı
L^λ	Lagrange fonksiyonu
$MSE(.)$	Hata kareler ortalaması
$p(.)$	Olasılık fonksiyonu
r^*	Cevaplı birimler kümesi
s	Örnek kümesi
\hat{t}	Toplam tahmin edicisi
\hat{t}_{yHT}	HT toplam tahmin edicisi
\hat{t}_{yCVP}	RHG cevapsızlık düzeltmesi tahmin edicisi
\hat{t}_{yPS}	Sonradan tabakalama tahmin edicisi
\hat{t}_{yRAK}	Raking tahmin edicisi
\hat{t}_{yGREG}	Genelleştirilmiş regresyon tahmin edicisi
\hat{t}_{yCAL}	Kalibrasyon tahmin edicisi
U	Yığın kümesi
$V(.)$	Varyans
$w^{(i)}$	i. ağırlıklandırma süreci
W	Tabaka ağırlığı
x	Yardımcı değişkenler vektörü

Simgeler \bar{y}

Ağırlıklandırılmamış ortalama tahmin edicisi

 \bar{y}_d

Ağırlıklandırılmış ortalama tahmin edicisi

 $\bar{y}^{(h)}$

Sonradan h. tabaka ortalaması

 Λ

Kalibrasyon düzeltmesi için alt sınır

 θ

Cevap verme olasılığı

 ϕ

Cevapsızlık düzeltme katsayısı

 π

Örnekte içerilme olasılığı

 φ

İlk seçimde seçilme olasılığı

 Y

Olası örnekler kümesi

 V

Kalibrasyon düzeltmesi için üst sınır

Kısaltmalar**AB**

Avrupa Birliği

BRÖ

Basit Rastgele Örnekleme

EPSEM

Eşit Olasılıklı Seçim Yaklaşımları

FMKD

Faktör Maliyetiyle Katma Değer

GİB

Gelir İdaresi Başkanlığı

GREG

Genelleştirilmiş Regresyon Tahmin Edicisi

HT

Horvitz-Thompson

IID

Bağımsız Aynı Dağılımlı

ISI

Uluslararası İstatistik Kurumu

MAR

Rastgele Kayıp

MCAR

Tamamen Rastgele Kayıp

NACE

Avrupa Ekonomik Faaliyetler Sınıflaması

NMAR

Rastgele Olmayan Kayıp

RHG

Homojen Cevap Grupları

SGK

Sosyal Güvenlik Kurumu

TÜİK

Türkiye İstatistik Kurumu

VIF

Varyans Şişirme Faktörü

YSHİ

Yıllık Sanayi ve Hizmet İstatistikleri

Açıklamalar

1. GİRİŞ

Günlük hayatımızda gazete, televizyon vb. medya organlarından işsizlik oranı, siyasi partilerin oy oranı, kadınların okur-yazarlık oranı, imalat sanayinin toplam cirosu vb. gibi çeşitli konularda bilgi edinilmektedir. Sanayi, ekonomi, sosyoloji, siyaset bilimleri, sağlık ve eğitim gibi alanlarda elde edilen bu bilgiler ve bundan çok daha fazlasının önemli bir kısmı, istatistiğin bir alanı olan "örnekleme" ile gerçekleştirilmektedir.

Örnekleme, bir yığın toplamının bütünü temsil etmek için belirli bir parçasını seçen yaygın bir uygulamadır. Bir çuval tahıldan bir avuç almak veya büyük bir rulo kumaştan küçük bir parça kesmek bunun basit örnekleridir. Burada seçim sürecine dikkat edilmesi gerekmektedir. Yığının bütünü benzer veya iyi karışmışsa, çok küçük olmadığı sürece bu yığından alınan bir parça bütünü iyi temsil edecektir. Diğer yandan benzer olmayan veya iyi karışmamış bir yapıdan küçük bir örnek seçimi gerçekleştirilirse bütünü temsil etmek mümkün olamayabilir (Yates, 1981:1). Bütünü en iyi şekilde temsil edebilmek için örnekleme teorisinden faydalanılır.

Örnekleme teorisinin amacı örnekleme için en etkin biçimde gerçekleştirilmesidir. Örnekleme teorisi kullanılarak, amacımız doğrultusunda yeterince doğru tahminlerin olası en düşük maliyetle elde edilebildiği örnek seçim ve tahmin yöntemleri oluşturulur (Cochran, 1977:8). Klasik örnekleme teorisi ile araştırma örnekleme teorisi arasında farklılıklar bulunmaktadır.

Klasik teoride, yığındaki örnek birimleri üzerinde yapılan ölçümler, normal dağılım gibi bir dağılım varsayımı ile gerçekleştirilir. Bu dağılımın ortalama ve varyans gibi belirli yığın parametreleri ile bilinen matematiksel bir biçimi vardır. Parametre değerleri örnek verisi kullanılarak tahmin edilir. Diğer yandan, araştırma örnekleme teorisinde ise dağılım hakkında çok kısıtlı bilgi sahibi olunduğu varsayılır. Özellikle, matematiksel biçim bilinmediğinden model-bağımsız veya dağılım bağımsız olarak tanımlanan yaklaşım benimsenir (Cochran, 1977:8). Tez içeriğinde kullanılan örnekleme ifadesi araştırma örneklemesini belirtmekte olup; açıklanan, önerilen ve uygulanan bütün yöntemler de araştırma örnekleme için yapılmıştır.

Örnekleme yönteminin ilk kullanıldığı çalışmalara örnek olarak 19. yüzyılda Fransa nüfusunu tahmin etme üzere küçük idari birimlerin seçilmesi gösterilebilir. Bu çalışmaya benzer bir yöntem çok önceleri İngiltere nüfusunun tahmin edilmesinde Graunt (1662) tarafından kullanılmıştır. Kiaer (1895) Uluslararası İstatistik Kurumu (ISI) toplantısında sosyal ve ekonomik araştırmalar için tamsayım yerine temsili örnekleme yönteminin kullanımını önermiştir. Bu tarih birçok araştırmacı tarafından modern örneklemenin başladığı tarih olarak kabul edilmektedir. Bowley (1906) rastgele örneklerin ortalamasının normal dağıldığını gösterip; 1912'de bir alan uygulaması yaparak araştırmalarda örnek seçiminin uygulanabilirliğini hem teorik olarak ispatlamış hem de pratik olarak göstermiştir. (Bureau of The Census Statistical Research Division, 2000). ISI tarafından 1925 yılında yapılan toplantıda tamsayım araştırmalarına alternatif olarak amaçlı ve rastgele örnekleme yöntemlerinin kullanımı kabul edilmiştir.

Neyman (1934) amaçlı örneklemeyle karşı olasılıklı yöntemlere dayanan örnekleme yöntemlerinin kullanımı fikrini güçlendirmiştir. Takip eden on yılda olasılıklı örnekleme çalışmaları birimlerin eşit olasılıklı seçilmesi esasına dayanırken; Hansen ve Hurwitz (1943) örnek birimlerinin eşit olasılıklı olmayan örnekleme ile seçilebileceği teorisini ortaya koymuşlardır. Çok aşamalı örnekleme teorisini de ortaya attıkları çalışma, araştırmalarda kullanılan örnekleme teorisinin gelişmesinde çok önemli bir adım olmuştur (Bethlehem, 2009). Stephan (1948) tarafından yayınlanan makale ile modern örnekleme prosedürlerinin paylaşıldığı dönemin başladığı kabul edilebilir. Yates (1949), Deming (1950), Cochran (1953), Hansen, Hurwitz ve Madow (1953) gibi örnekleme teorisinin temelini oluşturan birçok klasik kitap da bu dönemde yayınlanmıştır. Sonraki yıllarda Kish (1965) de örnekleme teorisinin tanıtılmasına ve geliştirilmesine katkıda bulunmuştur.

Örneklemenin standart yöntemi yığının tüm birimlerini gösteren bir listeden örnek seçmektir. Bu liste araştırma için "çerçeve" veya "örnek çerçevesi" olarak adlandırılır. Bu çerçevelerin aynı zamanda örnekleme yöntemlerinin uygulanmasını sağlayacak bilgiler içermesi de istenir. Örneğin; tabakalı örnekleme yönteminde çerçeve, birimin hangi tabakaya ait olduğunu belirlemek için yeterli bilgiyi içermelidir. Bu bilgiye yardımcı bilgi adı verilir; genellikle araştırmada ölçülmek istenen değişkenlerle ilişkili olan yığın karakteristiklerini içerir (Bergdahl vd., 1999:7-8).

Olasılıklı örnekleme yöntemi, çerçeveden örneğe birim seçerken rastgeleleştirme aracını kullanan yöntemdir. Bu tip bir yöntemle, çerçevedeki hangi birimlerin örneği oluşturacağını önceden belirlemek mümkün değildir. Sonuç olarak bu tip örnekler, olasılıklı olmayan örnekleme yöntemlerinden farklı olarak sapmalı olmaktan uzaktır. Olasılıklı örneklemede temel varsayım, çerçevede bulunan her birimin sıfırdan farklı bir örneğe seçilme olasılığının olmasıdır. Bu varsayım tasarım-bazlı yaklaşımdan tahmin ve çıkarsama yapmak için gerekliliktir (Bergdahl vd., 1999:8). Literatürde "tasarım-bazlı teori" olarak da adlandırılan bu yaklaşımda parametre tahmini tekrarlanan örnekleme dağılımına göre elde edilir. Bu yaklaşımın etkin sonuçlar verebilmesi için, örnek seçiminde rastgele bir yöntem kullanılmalı ve birimlerin örnekte içerilme olasılıkları (π) bilinmelidir. Tekrarlanan örnekleme dağılımının oluşturulmasında kullanılan örnek içerilme göstergesi (I), iki değer alabilen rastgele bir değişken olup; birim örnekte yer alıyorsa 1 aksi takdirde 0 değerini alır. I 'nin dağılımı örnek seçim sürecine bağlıdır.

Yığın kümesi U ile gösterilmek üzere, yığındaki her birimin örnekte içerilme olasılığının 0'dan farklı olduğu varsayıldığından $\forall j \in U$ için $\pi_j > 0$ olur. I_j 'ler bağımsız rastgele değişkenler olmayıp; bu rastgele değişkenlerin herhangi bir alt kümesinin bileşik dağılımı, uygulanan örnekleme yöntemine bağlı olacaktır.

Olasılıklı örneklemede içerilme olasılıkları yığın toplamı için \hat{t} ve ağırlıklandırılmış ortalama \bar{y}_d gibi nokta tahminlerini hesaplamak için kullanılır. Herhangi bir örnekleme tasarımı için tasarım ağırlığı genellikle içerilme olasılığının tersi olarak $d_j = \frac{1}{\pi_j}$ biçiminde tanımlanır (Lohr, 2010:39).

N birim içeren bir yığından Basit Rastgele Örnekleme (BRÖ) ile n birim seçilmesi durumunda her birimin içerilme olasılığı $\pi_j = n/N$ olup birbirlerine eşittir. Örnekleme ağırlığının, içerilme olasılığının tersi olduğu dikkate alındığında bütün birimler için tasarım ağırlıklarının da birbirine eşit olduğu görülecektir. Yığındaki her bir birimin örnekte içerilme olasılığının eşit olduğu bu tip örnekler "kendinden-ağırlıklı örnekler" olarak adlandırılır. Bu tip örneklerde ağırlık kullanılarak yapılan tahmin ile ağırlık kullanılmadan yapılan tahmin arasında fark yoktur. Diğer yandan, araştırmalarda genellikle eşit olasılıklı seçim yaklaşımlarının kullanılmaması nedeniyle ağırlıklandırma yapılmaktadır. Ağırlıklandırma yapılmasının temel nedeni, örnekleme tasarımı sonucunda oluşan içerilme

olasılıklarını kullanarak sapmasız tahmin ediciler elde etmektir. Birçok durumda yığında ilgilenilen değişkenlerin olabildiğince yakın tahminlerini yapabilmek için, örnek verisi ağırlıklandırılmak zorundadır.

Ağırlık belirlenmesi ve ağırlık düzeltme işlemleri örnekleme ve araştırma sürecindeki etkenler dikkate alınarak bir aşamalar dizisi ile gerçekleştirilir. Bu etkenler eşit olmayan seçim olasılıkları, cevapsızlık, kapsam dışılık ve bilinen yığın değerlerine uyum sağlanması amacıyla örnek birimlerinin tahmine olan etkisinin değiştirilmesidir (Brick ve Kalton, 1996). Bu tez çalışmasında, bahsi geçen etkenlerle birlikte son aşamada aykırı ağırlıkların ortaya çıkması durumu da dikkate alınarak; ağırlıklandırma süreci aşamalar halinde ele alınacaktır. Bu aşamaların üçüncüsü olan "bilinen yığın değerlerine uyum sağlanması" aşaması, kalibrasyon yaklaşımı ya da kısaca kalibrasyon olarak adlandırılmaktadır. Bilinen yığın değerlerine uyum sağlamak için kullanılan eşitliklere kalibrasyon eşitlikleri; bu aşama sonunda elde edilen ağırlıklar kullanılarak ulaşılan tahmin edicilere ise kalibrasyon tahmin edicileri denilmektedir. Literatürdeki klasik tanımıyla kalibrasyon; belirlenen yardımcı bilgiyi de kapsayarak ve kalibrasyon denklemine bağlı kalarak örnek ağırlıklarının hesaplanması olarak tanımlanır. Kott (2006) kalibrasyon ağırlıklarını, örnekteki birimler için yığın toplamını sağlayan ve tasarım tutarlı tahmin ediciler elde eden ağırlıklar kümesi olarak tanımlar.

Kalibrasyon aşaması öncesindeki ağırlıklar kullanılarak elde edilen sonuçların bir kısmı (cinsiyet, eğitim, yaş vb. karakteristiklerin tahmini) nüfus sayımı, kayıt verileri, daha büyük ölçekli araştırma vb. güvenilir dışsal kaynaklarla karşılaştırılabilir. Karşılaştırma sonrasında elde edilen ortalama, toplam ve oran gibi sayısal sonuçların ya da dağılım yapılarının dışsal kaynaklarla tutarlı olmadığı görülebilir. Bu durum ağırlıklandırma işlemi sonrasında elde ettiğimiz tahminlerin duyarlılığının sorgulanmasına neden olabilmektedir. Kalibrasyon işlemiyle tahminlerin duyarlılığı geliştirilmektedir. 20. yüzyılda yapılan çalışmalar; ilgilenilen değişken ile arasında korelasyon olan yardımcı değişkenler kullanılarak elde edilen tahminlerin, yığın toplam ve ortalama tahmin edicilerinin duyarlılığını arttırdığını göstermiştir. Bu çalışmalar sonucunda elde edilen tahmin edicilerin önemli bir kısmının kalibrasyon tahmin edicisi oldukları söylenebilir. Diğer yandan; Deville ve Särndal (1992) kalibrasyon tahmin edicileri ifadesini ilk kez kullanarak kalibrasyonu bir ağırlık düzeltme aşaması olarak tanımlamışlardır. Başta Genelleştirilmiş Regresyon (GREG) tahmin edicisi olmak üzere birçok kalibrasyon tahmin edicisi

tanımlanabileceğini göstermişlerdir. Deville ve Särndal (1992)'ın bu çalışması, geçmiş yıllarda kalibrasyon konusunda yapılan birçok çalışmanın da temel kaynağı olmuştur.

Deville, Särndal ve Sautory (1993) kalibrasyon yaklaşımından faydalanarak; Deming'in bilinen marjinal toplamları sağlama prosedürü olan "raking ratio" işlemini genelleştirerek örnekleme sürecinde kullanılacak kalibrasyon ağırlıkları elde etmişlerdir. Singh ve Mohl (1996) deneysel olarak tanımladıkları yedi farklı kalibrasyon tahmin edicisinin etkinliklerini farklı açılardan karşılaştırmışlardır. Duchesne (1999) aykırı değer varlığı durumunda kalibrasyon tahmin edicilerini incelemiştir. Kalton ve Flores-Cervantes (2003) farklı kalibrasyon yöntemlerini ağırlıklandırma yöntemleri başlığı altında özetlemiştir. Särndal (2007) araştırma teorisinde kalibrasyon kullanımının son on yıldaki gelişimini ve seçili yaklaşımları ele aldığı bir çalışma yapmıştır. Verma (2007) ağırlıklandırma aşamalarını tanımladığı çalışmada cevapsızlık düzeltmesi sonrası kalibrasyon işlemini de ayrı bir biçimde ele almıştır. Estevao ve Särndal (2009) iki aşamalı örnekleme tasarımları için kalibrasyon ile tahmin konusunu incelemiştir.

Son on yıl içerisinde de ağırlıklandırma ve kalibrasyon konusunda önemli çalışmalar gerçekleştirilmiştir. Henry ve Valliant (2012a, 2012b) alternatif ağırlık düzeltme yöntemlerini ve kalibrasyon konularını kapsamlı biçimde ele almışlardır. Brick (2013) araştırmalardaki birim cevapsızlıkların sapmalı tahminlere neden olduğu üzerinde durarak; sapmanın giderilmesi için kullanılacak yöntemleri özetlediği çalışmada kalibrasyon uygulamalarına da değinmiştir. Kott ve Liao (2015) ile Haziza ve Lesage (2016) cevapsızlık düzeltmesi ve kalibrasyonun bir aşamada mı yoksa iki aşamada mı yapılmasının etkin olacağı konusunu ele almışlardır.

Singh ve Sedory (2016) birçok farklı tahmin edicinin türetilebileceği iki aşamalı yeni bir kalibrasyon yöntemi önermişlerdir. Haziza ve Beaumont (2017) tarafından yayınlanan çalışmada ulusal istatistik ofisleri tarafından yapılan ağırlıklandırma işlemleri gözden geçirilmiştir. Chen vd. (2017) yaptıkları çalışmada ağırlık budaması, ağırlık modellemesi ve ağırlıklarla araştırma değişkenleri için oluşturulan modelleri bağdaştıran yaklaşımları ele almışlardır. Ağırlıkların modifiye edilmesi işlemlerini sınıflandırmış ve nümerik bir çalışmayla yöntemleri karşılaştırmışlardır.

Brion ve Gros (2015) ulusal istatistik ofislerinin veri üretiminde idari kayıt verilerinden faydalanmalarının genel bir trend olduğunu belirtmişlerdir. İdari kayıt verileri ile araştırma verileri bilgilerinin ortak kullanımı için, kalibrasyon yaklaşımını kullanan bazı özel tahmin edicilere ihtiyaç duyulduğunu anlatmışlardır. Çalışmalarında bu tahmin edicileri ve özelliklerini inceleyerek diğer yöntemlerle bunları karşılaştırmışlardır.

Türkiye'de ise ağırlıklandırma ve kalibrasyon konusunda sınırlı sayıda çalışma gerçekleştirilmiştir. Ağırlıklandırma ve kalibrasyon ile ilgili ilk tez çalışmaları Ünüvar (1997), Ünver (1998) ve Toprak (1999) tarafından yapılmıştır. Alkaya ve Esin (2005) kalibrasyon tahmin edicisini inceleyerek hipotetik bir veri ile uygulama yapmışlardır. Borazan Çelikleşik (2006), cevapsızlıktan kaynaklanan hataların azaltılması konulu çalışmasında ağırlıklandırma ve kalibrasyon konularını ele almıştır. Alkaya (2009) kalibrasyon ve ağırlıklandırma konusunda iyi bir literatür taramasıyla konuyu ele alarak; açıkladığı tahmin ediciler için parametre tahminlerinin duyarlılıklarını araştırmıştır. Bu çalışmaların yanı sıra Koyuncu (2012), Koyuncu ve Kadılar (2016) ve Özgül (2018) çalışmalarında kalibrasyon konusunu ağırlıklandırmadan bağımsız olarak tabakalı örnekleme yöntemi özelinde ele almışlardır.

Yapılan çalışmalara bakıldığında Deville ve Särndal (1992) çalışmasını takip eden yıllardan günümüze kadar kalibrasyon konusunda farklı amaçlarla çeşitli çalışmalar gerçekleştirildiği görülmektedir. Son yıllarda idari kayıt verilerinin kullanım imkanlarının artmasıyla birlikte; başta ulusal istatistik ofisleri olmak üzere, örneklem araştırması yapan kuruluşların istatistik üretim sürecinde kalibrasyon kullanımı gelişmektedir. Buna paralel olarak çeşitli araştırmalar için amaca özel kalibrasyon yaklaşımları geliştirilmektedir. Örneğin; Avrupa Birliği (AB) tüm üye ve aday ülkelerde gerçekleştirilen Gelir ve Yaşam Koşulları Araştırması'nın ağırlık hesaplamalarında fert ve hane ağırlıkları arasında tutarlılığı sağlayan bütünleşmiş kalibrasyon yaklaşımının kullanımını önermektedir (EUROSTAT, 2017). Diğer bir örnek ise Brion ve Gros (2015)'un Fransa Yapısal İş İstatistikleri'nin üretimi için ESANE ismi verilen amaca özel kalibrasyon tahmin edicisini kullanmalarıdır.

Kalibrasyon kullanımının artması, amaca özel kalibrasyon yaklaşımlarının yanı sıra farklı kalibrasyon tahmin edicileri ile kalibrasyon süreçlerinin etkinlik karşılaştırması ihtiyacını doğurmaktadır. Bu tez çalışmasında, simülasyon çalışması yapılarak ve gerçek veri

kullanılarak ulusal istatistik ofislerinin iş istatistikleri üretiminde kullanabilecekleri kalibrasyon tahmin edicileri araştırılmıştır. Literatürdeki çalışmalar genellikle belli dağılım yapıları ile tanımlanmış küçük veri setleri için simülasyon çalışması yaparak; kalibrasyon tahmin edicilerini karşılaştırmışlardır. Diğer yandan; Deville ve Särndal (1992) tarafından önerilen kalibrasyon tahmin edicilerinin asimptotik olarak GREG tahmin edicisine eşit olması nedeniyle, aykırı ağırlık yapıları için önerilen sınırlandırılmış kalibrasyon tahmin edicileri çalışmalarda yeterince incelenmemiştir. Bunun yanı sıra yardımcı değişkenlerin korelasyon yapısının kalibrasyon tahmin edicilerinin etkinliklerini ne düzeyde etkilediği de araştırılmamıştır.

İş istatistiklerinde kalibrasyon yaklaşımının etkinliğini tam olarak test edebilmek için büyük veri setinde aykırı değer, aykırı ağırlık ve farklı korelasyon yapıları durumlarının karşılaştırılması gerekmektedir. Bu amaçla; Türkiye İstatistik Kurumu (TÜİK) 2017 Yıllık Sanayi ve Hizmet İstatistikleri (YSHİ) verisi kullanılarak, farklı korelasyon yapılarında olan ve aykırı değerlerin olduğu veri setleri için ağırlık budaması ile elde edilen tahmin edicilerle sınırlandırılmış kalibrasyon tahmin edicileri karşılaştırılmıştır.

Çalışmanın ikinci bölümünde, örnekleme tasarımı ve örneklemede ağırlık kullanımı konuları açıklanmıştır. Aynı bölümde ağırlıklandırma işleminin süreçleri incelenmiştir. Üçüncü bölümde, ağırlıklandırma süreçlerinden biri olan ve tez çalışmasının temelini oluşturan kalibrasyon yaklaşımına yer verilmiştir. Bu bölümde öncelikle en çok kullanılan kalibrasyon tahmin edicileri hakkında genel bilgilendirme yapılmıştır. Daha sonra Deville ve Särndal (1992)'in önerdiği minimum uzaklık yöntemi ile kalibrasyon tahmin edicileri elde etme yaklaşımı detaylı olarak açıklanmıştır. En çok kullanılan kalibrasyon tahmin edicilerinin bu yaklaşımdan türetilmediği ve sınırlandırılmış kalibrasyon tahmin edicilerinin de elde edilebileceği gösterilmiştir. Üçüncü bölümün sonunda minimum uzaklık yaklaşımı dışında literatürde yer alan alternatif kalibrasyon tahmin edicileri tanıtılmıştır.

Dördüncü bölümde, simülasyon çalışması ile hedef değişken ve yardımcı değişkenler arasında farklı korelasyon yapıları olması durumunda kalibrasyon tahmin edicilerinin etkinlikleri incelenmiştir. Bu bölümde ayrıca örnekte aykırı değerli hedef değişken yer alması durumu ile yardımcı değişkenlerde aykırı değerli veriler bulunması durumları da simülasyon çalışması ile ele alınmıştır. Beşinci bölümde, TÜİK 2017 YSHİ verisi

kullanılarak üç farklı sektörün her birinde iki farklı hedef değişkenin yığın toplamının tahmin edilmesi için kalibrasyon tahmin edicilerinden faydalanılmıştır. Tahmin edicilerin etkinlikleri her sektör için kendi başlıkları altında ayrı ayrı karşılaştırılmıştır. Bölümün sonunda, uygulama sonuçları için genel bir değerlendirme de yapılmıştır. Altıncı bölümde, simülasyon ve gerçek veri üzerinde yapılan uygulama sonuçları birlikte değerlendirilerek; tez çalışması sonucunda elde edilen bilgilerden çıkarımlar yapılarak bazı önerilerde bulunulmuştur.



2. AĞIRLIKLANDIRMA VE AĞIRLIK DÜZELTMESİ

Örnekleme teorisinde temel amaç, yığında ilgilenilen değişkenlerin karakteristikleri hakkında bilgi edinebilmek için yığını temsil edebilecek küçük bir örnek seçmektir. Örnek seçimi gerçekleştirilirken olasılıklı ve olasılıklı olmayan örnekleme yöntemleri kullanılabilir. Örnekten elde edilen sonuçların hata payı, güvenilirlik düzeyi ve güven aralığı gibi istatistiksel göstergelerle açıklanabilmesi için olasılıklı örnekleme yöntemlerinin kullanılması gerekmektedir. Olasılıklı örnekleme yöntemlerinde, örnek çerçevesinde yer alan her birimin sıfırdan farklı değeri olan bir örneğe seçilme olasılığı vardır. Bu olasılık, gerçekleştirilen örnekleme tasarımına göre değişiklik gösterecektir.

Örneğin, j biriminin örnekte içerilme olasılığı BRÖ için $j \in U$ olmak üzere $\forall j$ için $\pi_j = n/N$ iken, Tabakalı BRÖ'de birimin bulunduğu tabaka esas olmak üzere $\pi_j = n_h/N_h$ değerini alacaktır. Çok aşamalı örnekleme gibi karmaşık örnekleme tasarımlarında ise her j biriminin örnekte içerilme olasılığı farklı olabilecektir. Bu içerilme olasılıklarında oluşan değişkenliğin tahmine olan olumsuz etkisinin giderilmesi gerekmektedir. Eşit olasılıklı olmayan örneklemede değişkenlik etkisini gidererek araştırma sonuçlarında sapmasız tahminler elde edilebilmesi için ağırlık kullanılmasına ihtiyaç duyulmaktadır. Herhangi bir örnekleme tasarımı için örnekleme ağırlığı ya da tasarım ağırlığı (d_j) içerilme olasılığı π_j 'nin tersidir. Kish (1992) ile Kalton ve Flores-Cervantes (2003) tasarım ağırlıklarını olasılığın tersi ile orantılı olacak şekilde $d_j \propto 1/\pi_j$ biçiminde tanımlamışlardır.

2.1. Örnekleme Tasarımı

N büyüklüğündeki U yığın kümesinden seçilen bir örnek s olmak üzere, bir örnek U yığınının herhangi bir alt kümesi olabilir. Ancak; genellikle belirlenen örneklerin olasılıklı bir seçim şeması üzerinden gerçekleştirildiği düşünülür. Burada seçim şeması olarak adlandırılan kavram, olasılık teorisindeki olasılık uzayı olup seçilebilecek bütün örnekler kümesini açıklamaktadır.

Verilen bir örnek seçim şeması için belirli bir s örneğinin seçim olasılığı $p(s)$ ile ifade edilebilir. Diğer bir ifadeyle; öyle bir $p(.)$ fonksiyonu vardır ki, kullanılan örnek seçim şemasından s örneğinin gelme olasılığı $p(s)$ 'dir. Burada belirtilen $p(.)$ fonksiyonu

örnekleme tasarımı olarak adlandırılır. Örnekleme tasarımı; örnekten hesaplanan ortalama, ortanca, varyans gibi rastgele niceliklerin örnekleme dağılımı, beklenen değer, varyans gibi önemli istatistiksel özelliklerini belirlemesi nedeniyle önemli bir rol oynamaktadır (Särndal, Swensson, Wretman, 1992: 27).

Belirlenen bir $p(\cdot)$ örnekleme tasarımı için s örneği, olasılık dağılımı $p(\cdot)$ ile belirlenen S rastgele değişkeninin bir gerçekleşmesi olsun. Diyelim ki \mathcal{Y} tüm s örneklerinin kümesi olsun (Bu durumda \mathcal{Y} kümesi boş küme ve U 'nun kendisini içeren 2^N tane alt kümeden oluşur). Herhangi bir $s \in \mathcal{Y}$ için Eş. 2.1, $p(s)$ de \mathcal{Y} üzerinde bir olasılık dağılımı olduğu için Eş. 2.2 ve Eş. 2.3 tanımlanabilir.

$$Pr(S = s) = p(s) \quad (2.1)$$

$$p(s) \geq 0, \quad \forall s \in \mathcal{Y} \quad (2.2)$$

$$\sum_{s \in \mathcal{Y}} p(s) = 1 \quad (2.3)$$

Dikkat edilecek olursa \mathcal{Y} kümesinde yer alan 2^N tane s örneğinin çoğunun olasılığı sıfırdır. Yalnızca belirlenen örnekleme tasarımına göre seçilebilecek örnekler sıfırdan büyük olasılığa sahiptir. Modern literatürde olasılık dağılımı $p(\cdot)$ 'nin örnekleme tasarımı olarak belirtilmesi standartlaşmıştır. Bazı istatistikçiler ise örnekleme tasarımı ifadesini farklı anlamda kullanmaktadırlar. Örneğin; Hansen, Hurwitz ve Madow (1953:7) örnekleme tasarımının örnekleme planı ve tahmin yönteminden oluştuğunu belirtmiştir. Burada belirtilen örnekleme planı bizim açıkladığımız örnekleme tasarımı içeriği ile örtüşmektedir. Bu anlamla kullanıldığı takdirde; geniş içeriği ile örnekleme tasarımı örnek seçiminin yapıldığı örnek tasarımı ile birlikte tahmin aşamasını da içermektedir (Särndal vd., 1992: 29).

N birimli sonlu yığın ilginç bir özelliği, birimlerin örnekte yer alması durumu için farklı olasılıklar verilebilmesidir. Örnekleme istatistikçileri bilinçli olarak çeşitli birimlere farklı içerilme olasılıkları atayarak; birimlerin örnekte yer alması konusunda sıklıkla avantaj sağlarlar. Bu yaklaşım daha doğru tahminler elde etmek için kullanılan bir yoldur.

Belirli bir örnekleme tasarımı $p(s)$ 'in belirlendiği varsayalım. Bir j biriminin örnekte yer alması rastgele bir olaydır ve bu olaya karşılık gelen I_j rastgele değişkeni Eş. 2.4'teki gibi tanımlanır.

$$I_j = \begin{cases} 1 & \text{eğer } j \in S \\ 0 & \text{eğer } j \notin S \end{cases} \quad (2.4)$$

Burada $I_j = I_j(S)$, S rastgele değişkeninin bir fonksiyonudur. I_j ; örnekte içerilme göstergesi olarak adlandırılır. j . birimin bir örnekte içerilme olasılığı π_j ile gösterilir ve bu olasılık verilen $p(\cdot)$ örnekleme tasarımından Eş. 2.5'te gösterildiği gibi elde edilir.

$$\pi_j = Pr(j \in S) = Pr(I_j = 1) = \sum_{j \in S} p(s) \quad (2.5)$$

Eş. 2.5'te j . birimin yer aldığı örneklerin tümünün seçilme olasılıkları toplamının j için içerilme olasılığı değerini verdiği belirtilmektedir. j . ve k . birimlerin örnekte birlikte içerilme olasılığı π_{jk} ile gösterilir ve verilen $p(\cdot)$ örnekleme tasarımından Eş. 2.6'da gösterildiği gibi elde edilir.

$$\pi_{jk} = Pr(j \& k \in S) = Pr(I_j I_k = 1) = \sum_{j \& k \in S} p(s) \quad (2.6)$$

Bütün j ve k değerleri için $\pi_{jk} = \pi_{kj}$ eşitliği sağlanmaktadır (Särndal vd., 1992: 31). Örnekleme tasarımı genellikle birinci ve ikinci sıra içerilme olasılıklarını verecek biçimde seçilir. Örnekleme tasarımı $p(\cdot)$ karmaşık olsa da sadece π_j ve π_{jk} bilgileri kullanılarak örnekten hesaplanan istatistiklerin beklenen değer ve varyans değerleri hesaplanabilir.

İstatistikçilerin incelemek istediği nokta, rastgele S değişken kümesinde yer alan farklı s gerçekleştirmeleri sonucu elde edilen belirli bir istatistiğin nasıl değiştiğidir. Rastgele S değişken kümesinin gerçek değerler alan fonksiyonu $Q(S)$ olmak üzere; bu fonksiyon istatistik olarak tanımlanır. S değişken kümesinin bir gerçekleşmesi olan s için hesaplanan istatistiğin değeri ise $Q(s)$ ile gösterilir. $Q(S)$ istatistiği bir rastgele değişken olduğu için beklenen değer, varyans ve kovaryans gibi çeşitli istatistiksel özellikleri vardır. $Q = Q(S)$ istatistiği için beklenen değer, varyans, kovaryans sırasıyla Eş. 2.7, Eş. 2.8 ve Eş. 2.9'da verilmiştir.

$$E(Q) = \sum_{s \in Y} p(s)Q(s) \quad (2.7)$$

$$V(Q) = E\{[Q - E(Q)]^2\} = \sum_{s \in Y} p(s)[Q(s) - E(Q)]^2 \quad (2.8)$$

$$\begin{aligned} C(Q_1, Q_2) &= E\{[Q_1 - E(Q_1)][Q_2 - E(Q_2)]\} \\ &= \sum_{s \in Y} p(s)[Q_1(s) - E(Q_1)][Q_2(s) - E(Q_2)] \end{aligned} \quad (2.9)$$

Dikkat edilirse; Eş. 2.7, Eş. 2.8 ve Eş. 2.9'daki tanımlamalar verilen $p(s)$ örnekleme tasarımı altında elde edilebilecek bütün olası örneklerin değişkenliğini belirtmektedir. Gelişigüzel belirlenmiş bir $p(s)$ örnekleme tasarımı için Eş. 2.4'de verilen I_j rastgele değişkeni de bir istatistik olup; $E(I_j)$, $V(I_j)$ ve $C(I_j, I_k)$ daha önce belirtildiği gibi yalnızca π_j ve π_{jk} örnek içerilme olasılıkları ile Eş. 2.10, Eş. 2.11 ve Eş. 2.12'deki gibi hesaplanabilir.

$$E(I_j) = \pi_j \quad (2.10)$$

$$V(I_j) = \pi_j(1 - \pi_j) \quad (2.11)$$

$$C(I_j, I_k) = \pi_{jk} - \pi_j\pi_k \quad (2.12)$$

Örnekleme tasarımı $p(s)$ ve içerilme olasılıkları π_j ve π_{jk} için farklı uygulamalar Särndal, Swensson, Wretman (1992)'in çalışmasında detaylı olarak verilmiştir. Örnekleme tasarımına bağlı olarak her birim için oluşturulan π_j ve π_{jk} olasılıklarından faydalanılarak tahmin aşamasında kullanılacak olan ağırlık değerleri elde edilmektedir.

2.2. Örneklemede Ağırlık Kullanımı

Araştırma örnekleme (survey sampling) ve örnekleme teorisi arasında bazı farklılıklar bulunmaktadır. Örnekleme teorisi hedef değişkene ilişkin tahmin yaparken matematiksel istatistik kuramlarından faydalanmaktadır. Bilindiği üzere matematiksel istatistiğin en önemli varsayımı rastgele değişkenlerin bağımsız ve aynı dağılımlı (IID) olmasıdır. Öte yandan gerçek dünyada IID değişkenlere her zaman rastlanamaz; ayrıca matematiksel istatistiğin temel varsayımlarını sağlayan BRÖ kullanımı araştırmalar için nadiren uygun

olmaktadır. Kish (1995) matematiksel istatistiği ve araştırma örneklemesini teorik çerçevede karşılaştırırken, matematiksel istatistiğin bahsi geçen olumsuzluklarını vurgulamıştır. Araştırma örneklemesinde eşit olasılıklı seçim yaklaşımlarının (EPSEM) genellikle kullanılmaması nedeniyle ağırlıklandırma yapıldığını belirtmiştir.

Yığındaki her bir birimin örnekte içerilme olasılığının eşit olduğu kendinden-ağırlıklı örneklerde ağırlık kullanılmasına ihtiyaç yoktur. Bu özellikteki örnek, eşit olasılıklı seçimle ya da çok aşamalı seçimlerin çeşitli aşamalarında, farklı seçim olasılıklarının birbirlerini dengelemesi ile ortaya çıkmaktadır (Kish, 1965:21). Araştırmacıların genellikle kendinden-ağırlıklı tasarımları tercih etmesinde bir takım nedenler vardır. Bu nedenler Verma'nın (2014:16) çalışmasında detaylı olarak açıklanmıştır. Kish (1990), bu tercih nedenini kısaca işlem kolaylığı, varyansın azaltılması ve sağlamlık konusundaki avantajlara bağlamıştır. Diğer yandan, kendinden-ağırlıklı tasarımı terk ederek eşit olmayan olasılıklı seçim ile ağırlık kullanmanın da bazı haklı nedenleri vardır. Verma (2014:17) bu nedenleri üç başlık altında toplamıştır:

1. Gerekli terk edişler: Araştırma amacı doğrultusunda; yığın alt grupları için özel raporlama ihtiyaçlarını karşılamak üzere, farklı örnek oranlarının kullanılmasıyla farklı seçim olasılıkları dolayısıyla ağırlıklar oluşmaktadır.
2. Gerekli olmayan terk edişler: Örnek çerçevesi veya araştırmadaki diğer kısıtlamalar (örnekleme dışı hata kaynakları vb.) nedeniyle ağırlıklandırmaya gidilebilir. Araştırma amacında ağırlıklandırma ihtiyacı olmaması nedeniyle Verma (2014:17) "gerekli olmayan" ifadesini kullanmıştır.
3. Sapma ve varyansın azaltılması için planlanmış ağırlıklandırma: Örnek seçim olasılıklarında yapılan bazı varyasyonlar örnekleme tasarımını daha etkin yapmaktadır. Bu şekilde tahminlerin varyansı ve/veya araştırma maliyeti azaltılabilir.

N büyüklüğündeki yığından seçilen n birim kullanılarak tahmin edilecek hedef değişken Y olmak üzere, farklı seçim olasılıklarına sahip örnekler için bu değişkene ilişkin ağırlıklandırılmamış ortalama tahmin edicisi \bar{y} ve ağırlıklandırılmış ortalama tahmin edicisi \bar{y}_d olsun. \bar{y} ve \bar{y}_d sırasıyla Eş. 2.13 ve Eş. 2.14'teki gibi tanımlanır.

$$\bar{y} = \frac{\sum_{j=1}^n y_j}{n} \quad (2.13)$$

$$\bar{y}_d = \frac{\sum_{j=1}^n d_j y_j}{\sum_{j=1}^n d_j} \quad (2.14)$$

Eşit olmayan olasılıklı örneklerde yığın ortalamasının \bar{y} tahmin edicisi genellikle \bar{y}_d tahmin edicisinden daha küçük varyansa sahip olacaktır. Ancak; tasarım ağırlıkları ile ilgilenilen karakteristikler arasındaki ilişkiyle orantılı olarak ağırlıklandırılmamış tahmin edici sapmalı olacaktır. Birçok örnekleme stratejisi için \bar{y} ve \bar{y}_d tahmin edicilerinin varyansları, örnek çapı büyüdükçe 0'a yaklaşmaktadır; ancak \bar{y}_d 'nin sapması 0'a yaklaşırsa dahi \bar{y} tahmin edicisi için bu geçerli değildir (Kish, 1992).

Kish (1992) \bar{y} tahmin edicisinin \bar{y}_d 'den genellikle daha küçük varyansa sahip olduğunu belirtirken, Verma (2014:17) \bar{y}_d tahmin edicisinin varyansın azaltılması için de kullanıldığını belirtmiştir. İlk bakışta iki çalışmanın birbiriyle çeliştiği düşünülebilir. Ancak, kullanılan örnekleme tasarımına göre iki durum da söz konusu olabilecektir. Çizelge 2.1 ve Çizelge 2.2'de her iki durumun uygulamalı örnekleri gösterilmiştir.

İlk örnekleme tasarımında, 8 birimden oluşan bir yığının 4'er birimden oluşan iki tabakaya ayrıldığını varsayalım. Y değişkeninin 1-8 değerleri arasında olduğu bu yığının birinci tabakası 1-4 arası değerlerden, ikinci tabakası ise 5-8 arası değerlerden oluşsun. Birinci tabakadan 3, ikinci tabakadan 1 olmak üzere toplam 4 birim örneğe çekilsin. Bu örnek seçim işleminde $\binom{4}{3} * \binom{4}{1} = 16$ olası durum ile karşılaşılacaktır. Burada, birinci tabakadaki herhangi bir birimin örnekte olma oranının $(12/16)$ ikinci tabakadaki herhangi bir birimin örnekte olma oranından $(4/16)$ fazla olduğu açıktır. Bu durum Çizelge 2.1'deki d_j tasarım ağırlıklarına yansıtılarak ($d_j = 1$ ve $d_j = 3$); bütün olası durumlar için \bar{y} ve \bar{y}_d tahminleri ile bu iki tahmin edici için beklenen değer $E(.)$, varyans $V(.)$ ve hata kareler ortalaması $MSE(.)$ göstergeleri hesaplanmıştır.

Çizelge 2.1 incelendiğinde yığın ortalaması \bar{Y} tahmini için \bar{y} 'nin varyansının $V(\bar{y}) = 0,16$ \bar{y}_d 'nin varyansı $V(\bar{y}_d) = 0,35$ 'den küçük olduğu görülmektedir. Diğer yandan, bu tip bir örnekleme tasarımında \bar{y} 'nin \bar{Y} için sapmalı bir tahmin edici olduğu ve hata kareler ortalamaları incelendiğinde \bar{Y} 'nin tahmin edilmesi için \bar{y}_d tahmin edicisinin kullanılmasının daha etkin olacağı gözlemlenmektedir.

Çizelge 2.1. $V(\bar{y})$ ve $V(\bar{y}_d)$ karşılaştırılmasında $V(\bar{y})$ 'nin küçük olması örneği

Tabaka 1 ($d_j = 1$)			Tabaka 2 ($d_i = 3$)					
Örnekler	$\sum_{j:1}^n y_j$	$\sum_{j:1}^n d_j y_j$	Örnekler	$\sum_{j:1}^n y_j$	$\sum_{j:1}^n d_j y_j$			
1;2;3	6	6	5	5	15			
1;2;4	7	7	6	6	18			
1;3;4	8	8	7	7	21			
2;3;4	9	9	8	8	24			
16 olası örnek için ortalamalar \bar{y}								
2,75	3,00	3,00	3,25	3,25	3,25	3,50	3,50	
3,50	3,50	3,75	3,75	3,75	4,00	4,00	4,25	
16 olası örnek için ağırlıklı ortalamalar \bar{y}_d								
3,50	3,67	3,83	4,00	4,00	4,17	4,33	4,50	
4,50	4,67	4,83	5,00	5,00	5,17	5,33	5,50	
\bar{Y}	=	4,50						
$E(\bar{y})$	=	3,50	$V(\bar{y})$	=	0,16	$MSE(\bar{y})$	=	1,16
$E(\bar{y}_d)$	=	4,50	$V(\bar{y}_d)$	=	0,35	$MSE(\bar{y}_d)$	=	0,35

İkinci örnekleme tasarımında ise 4 birimden oluşan bir yığında X yardımcı değişken bilgisi büyüklük ölçüsü olarak kullanılmıştır. Örnek olarak 2 birimin yerine koyulmadan seçildiği varsayalım. j . birimin ilk seçimde seçilme olasılığı Eş. 2.15'deki gibi tanımlanır.

$$Pr(j \text{ ilk seçimde örnekte}) = \varphi_j \quad (2.15)$$

Yardımcı değişken X 'e orantılı olarak belirlenen φ_j olasılığı bilinirken k biriminin ikinci seçimde örnekte yer alma olasılığı ise Eş. 2.16'da gösterilmiştir.

$$Pr(k \text{ ikinci seçimde örnekte} / j \text{ ilk seçimde örnekte}) = \frac{\varphi_k}{1-\varphi_j} \quad (2.16)$$

İki birimin aynı örnekte olma olasılıkları olan π_{jk} Eş. 2.6'dan yola çıkılarak ve Eş. 2.15 ile Eş. 2.16 kullanılarak Eş. 2.17'de gösterildiği gibi hesaplanmaktadır.

$$\pi_{jk} = \varphi_j \frac{\varphi_k}{1-\varphi_j} + \varphi_k \frac{\varphi_j}{1-\varphi_k} \quad (2.17)$$

j . birimin örnekte içerilme olasılığını gösteren π_j , Eş. 2.5 kullanılarak hesaplanabilir. Tasarım ağırlığı d_j ise π_j 'nin tersi alınarak hesaplanmaktadır.

Çizelge 2.2. $V(\bar{y})$ ve $V(\bar{y}_d)$ karşılaştırılmasında $V(\bar{y})$ 'nin büyük olması örneği

x	φ_j	y	d_j	Örnekler				
				$\sum_{j:1}^n y_j$	$\sum_{j:1}^n d_j y_j$	π_{jk}		
1	1/16	5	5,26	5;9	14	152	0,0173	
2	2/16	9	2,70	5;12	17	144	0,0269	
3	3/16	12	1,85	5;100	105	240	0,1458	
10	10/16	100	1,11	9;12	21	136	0,0556	
				9;100	109	232	0,2976	
				12;100	112	224	0,4567	
6 olası örnek için ortalamalar \bar{y}								
7,00	8,50	10,5	52,50	54,50	56,00			
6 olası örnek için ağırlıklı ortalamalar \bar{y}_d								
6,36	6,82	10,22	21,56	35,54	44,97			
\bar{Y}	=	31,5						
$E(\bar{y})$	=	31,5	$V(\bar{y})$	=	523,42	$MSE(\bar{y})$	=	523,42
$E(\bar{y}_d)$	=	20,9	$V(\bar{y}_d)$	=	219,59	$MSE(\bar{y}_d)$	=	331,73

Çizelge 2.2'deki sonuçlar incelendiğinde yığın ortalaması \bar{Y} tahmini için \bar{y} 'nin varyansının \bar{y}_d 'den büyük olduğu görülmektedir. Ancak \bar{y}_d tahmin edicisinin de sapmalı bir tahmin edici olduğu tespit edilmektedir. Bu iki tahmin edicinin MSE değerleri karşılaştırıldığında ise \bar{y}_d tahmin edicisinin daha etkin olduğu anlaşılmaktadır. Çizelge 2.1 ve Çizelge 2.2'de verilen örneklerde ağırlıklandırılmış tahmin edicilerin daha etkin olduğu açıkça görülmektedir. Bu iki örnekte gösterildiği gibi seçim olasılıklarının farklı olduğu örnek tasarımları için tasarım ağırlıklarının kullanımı gerekmektedir. Araştırmalarda etkin sonuçlar elde edebilmek için, genellikle seçim olasılıklarının farklı olduğu örnekleme tasarımları oluşturulduğundan; tahmin aşamasında ağırlık kullanımı zorunlu bir tercihe dönüşmektedir.

Örnek verisinin ağırlıklandırılmasına karar verilirken; ağırlıklandırmanın maliyetleri ve faydaları arasında bir dengeye ihtiyaç duyulmaktadır. Maliyetler; artan karmaşıklık, işin zorlaşması, programlama ve analiz çalışması ile maliyeti, veri ile ilgili hata yapma veya yanlış kullanım olasılığı, dağınık ağırlıklar sonucu artan varyans ve ağırlık düzeltmesinin uygun olmayan standartlarda kullanılması ile artan varyanstır. Potansiyel faydaları ise sapmanın azaltılması ve özenli hazırlanmış bir tahmin prosedürü ile başarılabilir olacak olası bir varyans azaltılmasıdır (Verma, 2014:18).

Verma (2014:18); seçim olasılıklarındaki farklılık, çerçeve hataları, cevapsızlık sorunları ile diğer örnekleme ve örnekleme dışı hata kaynaklarının birleşik etkisinin kendinden-

ağırlıklı yapıdan +/- %20 farklılık göstermesi durumunda ağırlık kullanımının düşünülmesi gerektiğini belirtmiştir.

2.3. Tasarım Ağırlığı ve Ağırlık Düzeltme Aşamaları

Bölüm 2.1'de belirtildiği gibi araştırmalarda etkin sonuçlar elde edebilmek için farklı seçim olasılıklarının etkisini tahmin aşamasına yansıtarak sapmasız ve/veya küçük varyanslı tahminler elde edebilmek için ağırlıklandırma yapılmaktadır. Örnekleme tasarımının oluşturulma aşamasında elde edilen ağırlıklar için; temel ağırlık, başlangıç ağırlığı ifadeleri de kullanılmakla birlikte; bu ağırlıklar genellikle tasarım ağırlığı (d_j) olarak adlandırılmaktadırlar.

Araştırma sonucunda elde edilen tahminlerin etkinliğini sağlamak için doğrudan tasarım ağırlığını kullanmak her zaman yeterli olmamaktadır. Örnek birimlerinin seçildiği çerçevenin hedef yığını tam kapsamaması (eksik veya fazla kapsam sorunu), örnek birimlerinin hepsinden cevap alınamaması gibi sorunlar olması durumunda tasarım ağırlıkları kullanılarak yapılan tahminlerin etkinliği azalacaktır. Bunun yanı sıra tasarım ağırlıkları kullanılarak yapılan tahminlerin güvenilir dışsal kaynaklardaki bilgilerle tutarsız olma durumu da ortaya çıkabilecektir. Belirtilen problemlerin üstesinden gelebilmek için tasarım ağırlıkları üzerinde bazı düzeltme işlemleri yapılmaktadır.

Araştırmalarda ağırlık düzeltmesi, genellikle cevapsız ve kapsamdışı birimleri telafi etmek ve ağırlıklı örnek tahminlerini dışsal kaynaktaki parametre değerleri ile uyumlu hale getirmek için uygulanmaktadır (Kalton ve Cervantes, 2003). Tasarım ağırlığı genellikle araştırma verisindeki cevaplayıcı birimlere atanır. Tasarım ağırlığının belirlenmesi ve ağırlık düzeltme işlemleri sıklıkla bir aşamalar dizisi ile gerçekleştirilerek tahmin aşamasında kullanılacak nihai ağırlıklar elde edilir. Verma (2014:85-93), tasarım ağırlığı ve ağırlık düzeltme işlemlerini 5 aşama ile tanımlamıştır:

1. Tasarım ağırlıklarının belirlenmesi
2. Cevapsızlık düzeltmesi
3. Güvenilir dışsal kaynağa göre düzeltme
4. Budama
5. Ölçekleme

Ağırlıklandırılmış tahmin yapabilmek için tasarım ağırlıklarının belirlenmesi zorunludur. Diğer aşamalar ise, ihtiyaç halinde ve/veya imkan dahilinde gerçekleştirilir.

2.3.1. Tasarım ağırlığının belirlenmesi ve Horvitz-Thompson tahmin edicisi

Tasarım ağırlıkları, eşit olmayan seçim olasılıklarının gerçekleştiği durumlarda farklılığın etkisini gidermek için kullanılan ağırlıklardır. Bir başka ifadeyle; örnekleme tasarımı $p(s)$ altında oluşan π_j içerilme olasılıklarının farklılıklarını tahmin aşamasına yansıtan ağırlıklardır. Tasarım ağırlıklarının kullanılması ile örnekteki birimlerin temsiliyetleri dengelenerek daha etkin tahminler yapılması amaçlanmaktadır. Tasarım ağırlığı (d_j), Eş. 2.18'de gösterildiği gibi genellikle yığındaki j biriminin örnekte içerilme olasılığı π_j 'nin tersi ($1/\pi_j$) ile veya bu tersin bir oranı olarak tanımlanır.

$$d_j = w_j^{(1)} = \frac{1}{\pi_j} \quad (2.18)$$

Burada $w_j^{(k)}$; j . birimin k . aşamadaki ağırlıklandırma sürecini temsil etmektedir. Buna göre $w_j^{(1)}$, j . birimin 1. ağırlıklandırma süreci olan tasarım ağırlığını ifade eder. Tasarım ağırlığı, örnekte içerilme olasılığı π_j 'nin tersi olmak üzere; Horvitz ve Thompson (1952) hedef değişken Y için toplam tahmininin Eş. 2.19'daki gibi yapılabileceğini belirtmişlerdir.

$$\hat{t}_{yHT} = \sum_{j \in S} \pi_j^{-1} y_j = \sum_{j \in S} d_j y_j \quad (2.19)$$

Bütün j 'ler için $\pi_j > 0$ koşulunun sağlandığı herhangi bir örnekleme tasarımı için \hat{t}_{yHT} tahmin edicisi hedef değişken Y 'nin yığın toplamı t_y için sapmasızdır. Bu sapmasızlık Eş. 2.10 kullanılarak Eş. 2.20'deki gibi gösterilebilir.

$$E(\hat{t}_{yHT}) = E\left(\sum_{j \in U} I_j \frac{y_j}{\pi_j}\right) = \sum_{j \in U} \pi_j \frac{y_j}{\pi_j} = \sum_{j \in U} y_j = t_y \quad (2.20)$$

Horvitz ve Thompson (1952) önerdikleri sapmasız toplam tahmin edicisinin varyansını, Eş. 2.21'de verildiği biçimde ifade etmişlerdir.

$$V(\hat{t}_{yHT}) = \sum_{j \in U} \frac{1-\pi_j}{\pi_j} y_j^2 + \sum_{j \in U} \sum_{\substack{k \in U \\ j \neq k}} \frac{\pi_{jk} - \pi_j \pi_k}{\pi_j \pi_k} y_j y_k \quad (2.21)$$

Varyansın sapmasız bir tahmin edicisi ise,

$$\hat{V}(\hat{t}_{yHT}) = \sum_{j \in S} \frac{1-\pi_j}{\pi_j} y_j^2 + \sum_{j \in S} \sum_{\substack{k \in S \\ j \neq k}} \frac{\pi_{jk} - \pi_j \pi_k}{\pi_j \pi_k} y_j y_k \quad (2.22)$$

biçiminde tanımlanmıştır. Särndal vd. (1992:44) HT tahmin edicisi için varyans ve varyans tahmin edicisini sırasıyla Eş. 2.23 ve Eş. 2.24'teki gibi göstermişlerdir.

$$V(\hat{t}_{yHT}) = \sum_{j \in U} \sum_{\substack{k \in U \\ j \neq k}} (\pi_{jk} - \pi_j \pi_k) \frac{y_j y_k}{\pi_j \pi_k} \quad (2.23)$$


$$\hat{V}(\hat{t}_{yHT}) = \sum_{j \in S} \sum_{\substack{k \in S \\ j \neq k}} \left(\frac{\pi_{jk} - \pi_j \pi_k}{\pi_j \pi_k} \right) \frac{y_j y_k}{\pi_j \pi_k} \quad (2.24)$$

Başta Sen (1953) ile Yates ve Grundy (1953) olmak üzere araştırmacılar tarafından HT tahmin edicilerinin varyansı ve varyans tahmin edicileri için farklı yaklaşımlar da önerilmiştir. HT tahmin edicisi literatürde ters-olasılık ağırlıklandırması (inverse-probability weighting) veya π -ters ağırlıklandırması (π -inverse weighting) adlarıyla da kullanılmaktadır (Alkaya, 2009:16).

HT tahmin edicisi sapmasız bir tahmin edici olmakla birlikte; hedef değişken değerleri y_j ile π_j olasılıklarının yakın ilişkili olmaması durumunda, seçim olasılıklarında görülen değişkenliğe bağlı olarak etkin olmayabilir. Tek bir örnekten elde edilen HT'ye dayalı tahminler, özellikle ilgilenilen karakteristikle seçim olasılıklarının ilişkisi negatif olduğunda; gerçek toplam değerden uzak olabilir (Henry ve Valliant, 2012a). Teoride örnekleme tasarımına bağlı olarak elde edilen HT tahmin edicisi sıklıkla kullanılırken, pratikte yalnızca tasarım ağırlığını kullanan bu tahmin edici çok kullanılmamaktadır. Bunun nedeni; araştırma sürecinde karşılaşılan sorunların tahmine olan etkisini gidermek için tasarım ağırlıkları üzerinde birtakım düzeltme işlemleri uygulanmasıdır. Bir sonraki bölümde, bu ağırlık düzeltme işlemlerinden biri olan cevapsızlık düzeltmesi ele alınacaktır.

2.3.2. Cevapsızlık düzeltmesi

Hedef yığından örnek seçebilmek için öncelikle bir örnekleme çerçevesi oluşturmak gereklidir. Hedef yığındaki bütün birimleri içerdiği düşünülen bu çerçeve Şekil 2.1'de gösterildiği gibi hedef yığınla tam örtüşmeyebilir ya da örneğe seçilen birimlerin hepsinden cevap alınamayabilir. Bu problemler sonucunda ortaya çıkan hatalara örnekleme dışı hatalar denilmektedir.



Şekil 2.1. Kapsam ve cevapsızlık probleminin gösterimi

Örnekleme dışı hatalardan biri olan cevapsızlık hemen her araştırmada karşılaşılan bir durumdur. Cevapsızlık genel olarak birim ve madde cevapsızlık olmak üzere ikiye ayrılır. Örneğe alınan birim hiçbir bilgi vermez, yani soru formundaki maddelerin hiçbiri cevaplanmazsa birim cevapsızlığı, soru formunda yer alan bazı maddelere cevap verirken, bazılarında cevap vermezse madde cevapsızlığı ortaya çıkar. Her iki cevapsızlık durumunda da tahminlerin sapması artabilir. Madde cevapsızlığın neden olduğu sapmayı azaltmak için genellikle yerine değer atama (imputasyon) işleminden faydalanılır. Diğer yandan birim cevapsızlığın sapmasını azaltmak için ağırlıklandırma işleminden faydalanılmaktadır. Birim cevapsızlığın tahminlerde sapmaya neden olması için yığında yer alan ve ilgilenilen değişken bakımından ortak özelliğe sahip bazı gruplarda cevapsızlık olması gerekmektedir.

Bu durumda yığındaki bazı gruplar örnekte daha az veya daha fazla temsil edilecektir. Buna seçici cevapsızlık adı verilir (Bethlehem, Cobben, Schouten, 2011:3). Bu tür bir cevapsızlık sonucunda yığın parametrelerinin tahminleri sapmalı olacaktır.

Cevapsızlığın tahmin edici üzerindeki etkisini belirleyebilmek için sabit cevap modeli ile rastgele cevap modeli olmak üzere iki ayrı cevap modeli kullanılmaktadır (Lindstrom (1979), Cassel vd. (1983)). Bu modellerden yararlanılarak hangi koşullar altında cevapsızlık sapmasının ortaya çıktığı daha açık biçimde belirlenebilir. Sabit cevap modeli için yığın cevaplı ve cevapsızlar şeklinde iki tabaka olarak düşünülür. Cevaplı tabakasından bir birim örneğe çıktığında cevap alınırken, cevapsız tabakasından örneğe gelen herhangi bir birim ise cevap vermeyecektir. Buna bağlı olarak yığın ortalamasının tahmin edicisi sapmalıdır. Cevaplı ve cevapsız tabaka yığın ortalamaları arasındaki fark arttıkça ve cevapsızlık oranı yükseldikçe sapma miktarı artmaktadır (Metin ve Özdemir, 2014).

Rastgele cevap modelinde yığındaki her birimin bir θ_j cevaplama eğilimine sahip olduğu varsayılır. Cevaplama eğilimine göre birimlerin cevapsızlık durumu hakkında bir sonuca varılabilir. Cevaplama eğilimi hedef değişken Y ve yardımcı değişkenler vektörü \mathbf{X} 'e göre değişir. Cevaplama gösterge değişkeni R^* olmak üzere, birim cevap vermesi durumunda $R^*=1$, aksi takdirde $R^*=0$ olacaktır. Böylece j . birimin hedef değişken ve yardımcı değişken bilgilerine bağlı olarak cevaplama eğilimi $\theta_{x,y} = Pr[R_j^* = 1 | \mathbf{X}_j = \mathbf{x}, Y_j = y]$ olarak tanımlanır. \mathbf{x} ve y değerleri biliniyorsa $\theta_{x,y}$ değerine cevaplama olasılığı da denir. (Schouten, 2007). Cevaplama eğilimini bir model yardımıyla tanımlayabilmek için cevapsızlık mekanizması kullanılır. Cevapsızlık mekanizmasını belirlemek için üç önemli varsayım önerilmiştir (Little ve Rubin, 2002:16-19).

1. Tamamen Rastgele Kayıp (MCAR): $\theta_{x,y}$, \mathbf{X} ve Y değişkenlerinden yani araştırmadan tamamen bağımsız ise cevapsızlık sonucunda oluşan kayıplar Tamamen Rastgele Kayıp olarak adlandırılır. Bu kayıp varsayımında $\theta_{x,y}$ deterministik olup; seçici cevapsızlık durumu ortaya çıkmadığından tahminler sapmasızdır. Tüm \mathbf{x} ve y değerleri için $\theta_{x,y} = \theta_{R^*}$ olup sabittir.
2. Rastgele Kayıp (MAR): $\theta_{x,y}$, yardımcı değişkenlere yani \mathbf{X} 'e bağlı olup; hedef değişken Y 'ye bağlı değilse Rastgele Kayıp durumu ortaya çıkmaktadır. MAR, MCAR varsayımından daha zayıf olup; seçici cevapsızlık görülmektedir. Dolayısıyla; bu tür bir

cevapsızlık olduğunda elde edilen tahminler sapmalı olacaktır. Bununla birlikte; yardımcı değişken bilgilerinden faydalanılarak sapmasız tahminler elde etmek mümkündür. Belirli x değerleri için $\theta_{x,y} = \theta_x$ olup sabittir.

3. Rastgele Olmayan Kayıp (NMAR): Bazı durumlarda $\theta_{x,y}$, bütünüyle hedef değişken Y 'ye bağlı olmaktadır. Cevaplama eğilimi ile hedef değişken arasındaki bu ilişkinin yardımcı değişkenler tarafından açıklanamaması durumunda oluşan kayıplar Rastgele Olmayan Kayıp şeklinde değerlendirilmektedir. Bu tür kayıpların olduğu durumlarda elde edilen tahminler sapmalıdır.

Bu aşamada, cevapsızlığın sapma üzerindeki etkisini görmek için rastgele kayıp durumunu gösteren bir simülasyon çalışması yapılmıştır. Cevaplama eğiliminin (θ) sapma üzerindeki etkisini göstermek için yığının hedef değişken bakımından iki gruba (Erkek-Kadın vb.) ayrıldığı varsayalım. Hedef değişken (Y), iki değer alan bir yardımcı değişken (X) ile ilişkili olacaktır ve j . birim için cevap verme eğilimi θ_{jx} , θ_1 veya θ_2 olmak üzere iki değerden oluşabilecektir. Yığın çapları $N_1=5000$ ve $N_2=5000$ olmak üzere yığındaki hedef değişkenimizi Normal dağılımlı $Y_1 \sim N(2500,600)$ ve $Y_2 \sim N(2000,600)$ olmak üzere eşit varyanslı iki gruptan oluşturalım.

Cevaplama oranları $\bar{\theta} = \%70, \%80, \%90$ ve $\%100$ olmak üzere, bu değerleri sağlayan farklı cevaplama eğilimleri ($\theta_1 = \theta_2$ ve $\theta_1 \neq \theta_2$) kullanılmış; $n=500$ birimlik örnekler BRÖ ile $R=1\ 000\ 000$ tekrarlarla örneğe seçilerek cevaplama eğilimine göre cevapsızlık durumundaki \bar{y}_c ile tam cevaplı durumdaki \bar{y} hesaplanmıştır. Monte-Carlo simülasyon yaklaşımından faydalanarak; göreceli sapma $RB(\bar{y}_c) = \frac{1}{R} \sum_{i=1}^R (\bar{y}_c)_i / \bar{Y}_c$ hesaplanarak sonuçlar Çizelge 2.3'te verilmiştir.

Çizelge 2.3 incelendiğinde tam cevaplılık durumunda olduğu gibi cevapsızlık olsa dahi cevaplama eğilimlerinin iki grup için eşit olduğu durumda ortalama tahmin edicisi sapmasızdır. Diğer yandan cevaplama eğiliminin farklı olduğu durumlarda tahmin edicide sapma ortaya çıkarken; eğilimdeki fark arttıkça sapma da artmaktadır. Ayrıca cevaplama eğilimlerinin farklı olduğu $\theta_1 = 0,5$ $\theta_2 = 0,9$ durumunda MSE en yüksek değeri olan $MSE(\bar{y}_c) = 6275,99$ olmaktadır. Metin ve Özdemir (2014) Çizelge 2.3'teki örnek dışında farklı cevaplama eğilimleri ve farklı veri yapıları için de cevapsızlığın olumsuz etkilerini inceleyerek; cevaplama eğiliminin farklı olduğu durumlarda sapmalı tahminler elde

edildiğini göstermişlerdir. Aynı çalışmada seçici cevapsızlık ve cevapsızlık mekanizması hakkında daha detaylı bilgi yer almaktadır.

Çizelge 2.3. Farklı cevaplama eğilimlerinde görel sapma

$\bar{\theta} = 1$		n=500			
		$MSE(\bar{y}_c)$	$B(\bar{y}_c)$	$V(\bar{y}_c)$	$RB(\bar{y}_c)$
	$\theta_1 = \theta_2 = 1$	819,57	-0,01	819,57	1,00
$\bar{\theta} = 0.7$		n=500			
		$MSE(\bar{y}_c)$	$B(\bar{y}_c)$	$V(\bar{y}_c)$	$RB(\bar{y}_c)$
	$\theta_1 = 0.5$ $\theta_2 = 0.9$	6275,99	-73,71	842,98	0,97
	$\theta_1 = 0.6$ $\theta_2 = 0.8$	2169,78	-36,76	818,71	0,98
$\theta_1 = 0.7$ $\theta_2 = 0.7$	1189,08	0,00	1189,08	1,00	

Cevapsızlık düzeltmesi, örneğin farklı bölümlerinde görülen cevaplama oranlarındaki farklılıkların (seçici cevapsızlığın) etkisini azaltmak için kullanılır. Bu düzeltme katsayıları sadece cevaplayan ve cevaplamayan birimlerin bilinen ortak bir karakteristiğine bağlı olarak tahmin edilebilir. Cevapsızlık olduğu durumda kullanılan bu düzeltme katsayıları; özellikle cevapsızlık oranının yüksek ve örneğin bir bölümünden diğerine değiştiği zamanlarda önemlidir (Verma, 2014:86).

Genel strateji cevaplı ve cevapsız birimlerin hepsi için kullanılabilen bir yardımcı bilgiye göre cevaplı birimlerle benzer olan cevapsız birimleri belirlemek; daha sonra cevaplı birimlerin tasarım ağırlıklarını cevapsız benzerlerini temsil edecek şekilde arttırmaktır. Birçok durumda cevapsız birimler hakkında çok az şey bilinmektedir. Bu durumda basit hücre cevapsızlık düzeltmesi kullanılabilir. Ancak yeterli büyüklükte yardımcı bilgi kullanılabilir durumdaysa ve araştırmacı bu bilgilerle uyumlu bir ağırlık düzeltmesi yapmak isterse alternatif cevapsızlık düzeltmelerinden faydalanılabilir (Kalton ve Flores-Cervantes, 2003).

Cevapsızlık düzeltmesi başlığı altında ele alınacak ağırlık düzeltmesi işlemi basit hücre cevapsızlık düzeltmesidir. Ağırlıklandırma sürecinin sıralı biçimde ele alındığı

yaklaşımlarda genellikle cevapsızlık düzeltmesi işlemi yapıldıktan sonra ağırlık düzeltmesinin sonraki aşaması olan kalibrasyon işlemine geçilmektedir. Diğer yandan birçok kaynakta cevapsızlık düzeltmesi işlemi için sonradan-tabakalama, GREG vb. gibi çeşitli kalibrasyon yaklaşımlarının kullanımı da önerilmiştir. Cevapsızlık düzeltmesinin yanı sıra, dışsal kaynaklarla tutarlılığı da sağlayan bu yöntemler kalibrasyon başlığı altında ele alınmıştır.

Cevapsızlık düzeltmesi için katsayılar elde edilirken genellikle homojen cevap grupları modelinden (Response Homogeneity Grup - RHG) faydalanılır. Hücre veya sınıf ağırlık düzeltmesi olarak da adlandırılan bu işlemde, örnek bir yardımcı bilgiye göre $l=1,2,\dots,L$ sınıfa bölünür. Her l sınıfı içinde cevap verme olasılığının aynı ve θ_l olduğu varsayalım. l sınıfın örnek çapı n_l , cevaplayıcılar kümesi c_l , cevaplayıcıların sayısı da m_l ile gösterilsin. Cevap verme olasılığının tahmin edicisi olarak cevaplama oranı $\hat{\theta}_{j(l)} = m_l/n_l$ kullanılır. Bu tahmin edicinin tersi Eş. 2.25'deki gibi gösterilir.

$$\phi_{j(l)} = w_j^{(2)} = \frac{1}{\hat{\theta}_{j(l)}} \quad l=1,2,\dots,L \quad \text{ve} \quad j=1,2,\dots,c_l \quad (2.25)$$

Burada $w_j^{(2)}$; j . birimin 2. ağırlıklandırma süreci olan cevapsızlık düzeltme katsayısı olup; her sınıf için farklı, sınıf içerisinde ise tek bir değer almaktadır. Cevapsızlık düzeltme katsayısı kullanılarak elde edilen toplam tahmini Eş. 2.26'daki gibi yazılabilir.

$$\hat{t}_{y_{CVP}} = \sum_l \sum_{j \in c_l} d_j \phi_{j(l)} y_j = \sum_l \sum_{j \in c_l} \frac{1}{\pi_j} \frac{1}{\hat{\theta}_{j(l)}} y_j = \sum_l \sum_{j \in c_l} d_j \frac{n_l}{m_l} y_j \quad (2.26)$$

Verma (2014:88), cevapsızlık düzeltme katsayıları için örnekteki ortalamalarının 1 olacağı bir ölçeklendirilmiş yaklaşımın daha uygun olduğunu belirtmiştir. Buna göre, $\bar{\phi}$ cevapsızlık düzeltme katsayılarının ortalaması olmak üzere ölçeklendirilmiş cevapsızlık düzeltme katsayıları Eş. 2.27 biçiminde tanımlanacaktır.

$$\phi_{j(l)}' = \frac{\phi_{j(l)}}{\bar{\phi}} \quad (2.27)$$

Homojen gruplarda yer alan birimlerin farklı tasarım ağırlıkları olduğunda; cevapsızlığın gerçek etkisi, cevaplı ve örnek birimlerin tasarım ağırlıkları kullanılarak daha iyi

yakalanacaktır. Bu durumda $m_l^{(d)} = \sum_{j=1}^{m_l} d_j$ ve $n_l^{(d)} = \sum_{j=1}^{n_l} d_j$ olmak üzere cevap verme olasılığının tahmini;

$$\hat{\theta}'_{j^{(l)}} = \frac{m_l^{(d)}}{n_l^{(d)}} \quad (2.28)$$

biçiminde elde edilecektir. RHG'de, grupların oluşturulması için kullanılan yardımcı bilginin cevaplama eğilimi ve ilgilenilen değişkenler ile yüksek korelasyonda olduğu düşünülür. Cevapsızlığın her hücrede tamamen rastgele olduğu varsayılarak cevapsızlık düzeltme katsayısı hesaplanır.

Genellikle örnek birimleri için tasarım ağırlıkları toplamının $\sum_{j \in S} d_j = N$ biçiminde yığın toplamına eşit olması beklenir. Örnek birimlerden gelen cevapsızlık durumunda $\sum_{j \in C_l} d_j$ için bu eşitlik sağlanamayacaktır. Bu sebeple tasarım ağırlıkları genellikle cevap oranının tersiyle çarpılarak düzeltilir. Böylece cevap verenlerin cevap vermeyenleri temsil etmesi sağlanır. Bu düzeltme işlemi sonucunda cevaplı birimlerin ağırlıklarının toplamı yığın toplamını verecektir. Ancak; cevaplayanlarla cevaplamayanlar arasındaki sistematik farklılıklardan kaynaklanan sapma sorunu ortaya çıkacaktır. Bu sapmanın azaltılabilmesi için RHG yöntemi gibi cevap verme olasılıklarını kullanan yaklaşımlar kullanılmalıdır. Cevap verme olasılığının tahmin edilmesinde eğilim modelleri de kullanılabilir. Brick ve Montaquila (2009) diğer cevapsızlık düzeltme yaklaşımlarını göstermiştir.

2.3.3. Güvenilir dışsal kaynağa göre düzeltme

Örnek verileri farklı örnekleme olasılıkları ve cevaplama oranları için düzeltildikten sonra, birimlerin karakteristikleri ve sayıları açısından örneğin dağılımı; genellikle nüfus sayımı, projeksiyonlar, kayıtlar veya diğer büyük ölçekli araştırmalar gibi daha güvenilir olan dışsal kaynaklardaki dağılımdan hala farklılık gösterebilir. Bu durumda, örnek verisine dışsal bilgi ile örnek dağılımının uyumlu olmasını sağlayan bir düzeltme işlemi daha yapılarak tahminlerin doğruluğu geliştirilir. Bu aşamanın uygulanması sırasında, dışsal kaynak ile örnek birimlerinin birebir eşleştirilmesine ihtiyaç yoktur. Ağırlık düzeltmesi örnek ve dışsal kaynağın toplamları düzeyinde yapılır (Verma, 2014:89). Bu aşamada yapılan, örnekte ve dışsal kaynakta yer alan ortak değişkenlerin dağılımlarının birbirleriyle

uyumlu hale getirilmesidir. Bu uyumluluk sürecinde yeni bir ağırlık düzeltme katsayısı elde edilmektedir.

Örnekleme arařtırmalarından yapılan tahminlerde dıřsal kaynaktan yani yardımcı bilgi veya yardımcı deęiřkenden faydalanma düşüncesi çok eskilere dayanmaktadır. Matematikte "Rule of Three" olarak bilinen, D biliniyorsa ve $AB=CD$ ise $D=AB/C$ eřitlięinden faydalanan Graunt (1662) için örneklemede ilk yardımcı deęiřken kullanan istatistikçi denilebilir. Yıęın parametresinin tahmininde yardımcı deęiřken kullanımının dięer erken örneęi Laplace (1786) tarafından önerilen oran tahmin edicisidir.

Tabakalı rastgele örneklemede oran tahmin edicisinin kullanımı ise ilk olarak Hansen, Hurwitz ve Gurney (1946) tarafından önerilmiřtir. Sonraki yıllarda, oran tahmin edicisine alternatif olarak çeřitli oran tahmin edicileri önerilmiřtir. Quenouille (1956), Beale (1962), Tin (1965), Srivastava (1965) BRÖ yönteminde klasik oran tahmin edicisine alternatif oran tahmin edicileri öneren ilk arařtırmacılarıdır. Daha sonraki yıllarda Chakrabarty (1979), Ray ve Singh (1981), Sisodia ve Dwivedi (1981), Singh ve Kakran (1993), Upadhyaya ve Singh (1999), Singh ve Tailor (2003) BRÖ yönteminde alternatif oran tahmin edicileri önermiřlerdir. Sisodia ve Dwivedi (1981), Singh ve Kakran (1993), Upadhyaya ve Singh (1999) tarafından BRÖ için önerilen oran tahmin edicileri Kadılar ve Çıngı (2003) tarafından tabakalı rastgele örnekleme uyarlanmıřtır.

Örnekleme arařtırmalarının tahmin ařamasında, yardımcı deęiřken bilgisi regresyon denklemleri ile de kullanılmaktadır. Örnekleme arařtırmalarında regresyonun kullanımı ile ilgili ilk referanslar Cochran (1942) ve Jessen (1942)'dir. Cochran (1942) örnekleme arařtırmasında regresyon için doęrusal model teorisine dayanan temel teoriyi vermiřtir. Fuller (1973,1975) örnekleme arařtırmasından elde edilen regresyon katsayıları vektörünün büyük çaplı örnekler için özelliklerini vermiřtir. Royall ve Cumberland (1981) regresyon tahmin edicilerinin kořullu özelliklerini çalıřmıřlardır.

Önerilen oran ve regresyon tahmin edicileri yardımcı deęiřken bilgilerinden faydalanmakla birlikte tasarım ağırlıkları üzerinde bir düzeltme iřlemi yapmak yerine sadece tek bir hedef deęiřken için tahmini iyileřtirmektedir. Cassel, Särndal ve Wretman (1976) tahmin edici oluşturulmasında hem model hem de tasarım prensiplerini düşünerek, tasarım tutarlı tahmin ediciler için GREG tahmin edicisini önermiřlerdir. Bu tahmin edicinin

hesaplanması aşamasında tasarım ağırlığı üzerinde bir düzeltme işlemi gerçekleştirilmektedir. Bu nedenle; düzeltilmiş tasarım ağırlıkları kullanılarak birden fazla değişkenin tahminleri iyileştirilebilir. GREG tahmin edicisi üçüncü bölümde detaylı biçimde ele alınacaktır.

Bu aşamada; örnek dağılımının güvenilir dışsal kaynaktaki yığın dağılımı ile tutarlı hale getirilmesinin iki amacı vardır:

- Araştırmadaki kapsam dışılığı telafi etmek.
- Araştırma tahminlerinin doğruluğunu geliştirmek.

Bu yöntem aynı zamanda cevapsızlıktan kaynaklanan sapmayı düzeltmek için de kullanılmaktadır. Bazı araştırmacılar cevapsızlık düzeltmesi aşamasını atlayarak sadece bu ağırlık düzeltme işlemini yapmaktadır. Burada yapılan düzeltme işlemi özellikle cevapsız ve kapsam dışı birimlerin çok fazla olduğu durumlarda kullanışlı olabilir. Verma (2014:89) bu aşamada yapılan düzeltme işlemi için Eş. 2.29'daki gibi basit bir uygulama örneği vermiştir. Buna göre; örneğin L tane gruba ayrıldığı varsayalım. Belirli bir karakteristiğe (cinsiyet, yaş, eğitim vb.) göre, l . grupta $l=1,2,...L$ gerçekleşme oranı γ_l olsun. Bu oran hesaplanırken tasarım ve cevapsızlık ağırlıkları kullanılır. Aynı oran güvenilir dışsal kaynaktaki Γ_l olsun. Bu iki oranın birbirine oranlanması ile örnek dağılımının yığın dağılımına uydurulmasını sağlayacak düzeltme katsayısı elde edilebilir. Cevapsızlık düzeltmesinde kullanılan sınıflar olabildiğince detay düzeyde belirlenirken, bu aşamada kullanılan gruplar daha genel düzeyde oluşturulmaktadır. Dolayısıyla cevapsızlıkta belirtilen L sınıf sayısı ile burada belirtilen L grup sayısı genellikle farklılık göstermektedir.

$$g_{j(l)} = w_j^{(3)} = \frac{\Gamma_l}{\gamma_l}, \quad l=1,2,...L \quad (2.29)$$

Burada $w_j^{(3)}$, j . birimin 3. ağırlıklandırma süreci olan güvenilir dışsal kaynağa göre düzeltme katsayısı olup; Eş. 2.29'da gösterilen eşitlik dışında 3. bölümde ele alınacak olan yaklaşımlarla da elde edilebilir. Bu düzeltme sonucunda ağırlıklandırılmış tahminler bazı anahtar değişkenler için bilinen yığın toplamları ile uyumlu hale getirilir. Bu tip düzeltmelerin sıkça rastlanan bir formu belirli değişkenlerin örnekteki birleşik dağılımının

yığında bilinen birleşik dağılıma uygun hale getirilmesidir. Bu tip düzeltmeler genellikle sonradan-tabakalama olarak adlandırılır. Sonradan-tabakalama oran tahmin edicisinin bir formudur. Örnekleme ile ilgili metinlerde sonradan tabakalama teorisi ile ilgili olarak tam cevaplılık ve mükemmel kapsam varsayımı yapıldığı da not edilmelidir. Bu durumda, sonradan oluşturulan tabakaların örnek çapının yeterince büyük olması durumunda düzeltmeler genellikle küçüktür. Standart bir sonradan tabakalama işleminin araştırma tahminlerinin doğruluğunda kazanç sağlaması beklenebilir. Bununla birlikte, araştırma önemli miktarda kapsamdışı ve/veya cevapsızlık içeriyorsa azımsanamayacak düzeltmeler olabilir; bu durumda düzeltmeler araştırma tahminlerinin sapmasını azaltmada kullanılır. Ancak, düzeltmede kullanılan değişkenlerle ilişkili olmayan değişkenlerin parametre tahminlerinin standart hatası artabilir.

Daha önce belirtildiği gibi tahmin sürecinde yardımcı değişken kullanımı ilk olarak oran ve regresyon tahmin edicileri ile ele alınmıştır. Hücre bazlı cevapsızlık düzeltmesi ve sonradan tabakalama düzeltmesi yıllardır geniş biçimde kullanılmaktadır. Yakın zamandaki gelişmelerle daha karmaşık düzeltme yöntemlerinin kullanımı artmıştır. Bu yöntemler hücre bazlı düzeltme yöntemlerine göre yardımcı bilgiden daha fazla faydalanmaktadır. Bu yeni düzeltme yöntemleri, hem cevapsızlığın telafi edilmesinde hem de sonradan tabakalamada olduğu gibi örnek dağılımlarının bilinen yığın dağılımlarına uyumlu hale getirilmesinde kullanılabilir. Bu yöntemler, raking, GREG, lojistik regresyon modellemesi ve bu yöntemlerle hücre ağırlıklandırması yöntemlerinin kombinasyonlarını içerir (Kalton ve Flores-Cervantes, 2003). Örnek dağılımlarının bilinen yığın dağılımlarına uyumlu hale getirildiği gelişmiş yöntemler kalibrasyon başlığı altında üçüncü bölümde detaylı biçimde ele alınacaktır.

2.3.4. Varyans şişirme faktörü ve budama

Örnekteki herhangi bir birime aşırı büyüklükte ağırlık ataması yapılmasından kaçınmak istenir. Aşırı büyük ve değişken ağırlıkların kullanımı, örneğin çok küçük bir kısmını etkilese de varyans da önemli bir miktarda artışa sebep olabilir. Bu nedenle; aşırı büyük ağırlıkların bazı maksimum ve minimum değerler arasında kalacak biçimde budanması, varyanstaki ilgili artışın sınırlandırılması için yaygın bir uygulamadır (Verma, 2014:92). Tasarım ağırlığı (d), cevapsızlık düzeltmesi (ϕ) ve kalibrasyon düzeltmesi (g) elde edildikten sonra birbirleriyle çarpılması sonucunda her örnek birimi için araştırma ağırlığı

yani nihai ağırlıklar (w) elde edilir. Toplama ilişkin tahmin ise Eş. 2.30'da gösterildiği gibi olacaktır.

$$\hat{t}_{yCAL} = \sum_{j \in S} d_j \phi_j g_j y_j = \sum_{j \in S} w_j y_j \quad (2.30)$$

Gerçekleştirilen üç aşama sonrasında elde edilen araştırma ağırlıklarında değişkenlik oluşmaktadır. Araştırma ağırlıklarında büyük değişkenlikler olduğunda ise yığın toplamı ve ortalaması için nokta tahminlerinin duyarlılığı potansiyel olarak azalır (Valliant, 2004). Duyarlılıktaki bu azalış için kullanışlı bir ölçüm,

$$VIF = n \frac{\sum_{j \in S} w_j^2}{(\sum_{j \in S} w_j)^2} = 1 + CV^2(w_j) \quad (2.31)$$

şeklinde tanımlanan varyans şişirme faktörüdür. Burada $CV(w_j)$; ağırlıkların değişim katsayısını ifade eder. Farklı ağırlık düzeltme yöntemlerini karşılaştırmak için VIF'tan faydalanılabilmektedir.

Tahmin edici sapmasız olsa da aşırı büyük ağırlıklar etkin olmayan tahminler üretebilir. Büyük ağırlıkları budamak mantıksızca ortaya çıkan büyük tahminleri düşürerek ağırlıklara bağlı olan değişkenliği azaltır. Bu işlem sonucunda varyans azaltılırken sapmaya neden olunmaktadır. Dolayısıyla MSE'de azalma gerçekleştiği varsayımı ile budama işlemi yapılmalıdır.

Verma (2014:92), cevapsızlık ve kalibrasyon düzeltmelerinin her birinin hesaplanması sonrasında ağırlıklarda aşırı büyük değerlerin ve büyük değişkenliklerin kontrol altında tutulması gerektiğini belirtmiştir. Ağırlık budama işleminde yapılan genel uygulama ağırlıkları bazı alt ve üst sınırlar içerisinde tutmaktır. Ağırlıkların sınırlarının belirlenmesi için etkili genel bir uygulama olduğu söylenemez. Ağırlık budaması ile ilgili farklı yaklaşımlar Henry ve Valliant (2012b) çalışmasında incelenebilir. Tasarım-bazlı ağırlık budama yöntemlerine ilişkin sınırlı literatür ve teori olup; bunlar da genellikle belirli bir araştırma ve tahmin edici içindir. En çok alıntı yapılan çalışma Potter (1988,1990) olup; bu çalışmada alternatif prosedürler gözden geçirilip simülasyon çalışması yapılmıştır. Diğer çalışmalar ise Griffin (1995), Pedlow ve Porras (2003), Battaglia vd. (2004), Liu vd.

(2004), Chowdhury vd. (2007), Reynolds ve Curtin (2009) tarafından yapılmış olup; bu çalışmalar belirli bir araştırma için önerilmiş amaca özgü yaklaşımlardır.

İlgili çalışmalarda ağırlık budaması için gelişmiş bazı yaklaşımlar anlatılmış olup araştırmacılar genellikle basit ve pratik yaklaşımları tercih etmektedir. Verma (2014:92) ağırlıklarla ilgili ana problemin yalnızca sınırlı sayıdaki büyük ağırlık değerlerinin olduğu durumlar için basit bir prosedür önermiştir. Buna göre cevapsızlık düzeltmesi hesaplandıktan sonra;

- Cevapsızlık düzeltmesi ile düzeltilmiş ağırlıkların ($d_j\phi_j$) ortalamalarının 1 olacak biçimde ölçeklendirilmesi,
- Daha sonra ölçeklendirilmiş ağırlıkların $1/T$ ve T sınırları dışında kalanlarının bu sınırlara getirilmesi

işlemleri uygulanır. Genel kabul görmüş kural olarak, T sabitine 2-3 arasında bir değer verilmektedir. Kalibrasyon işleminden sonra da aynı süreç takip edilebilir. Bu yaklaşımın bir uygulama örneği virgülden sonra iki basamak gösterimiyle Çizelge 2.4'te verilmiştir.

Çizelge 2.4. Verma (2014) ağırlık budama prosedürünün örneklendirilmesi

Birim	w_j	Ölçek (1)	Düzeltilme (1)	Ölçek (2)	Düzeltilme (2)	Aynı adımların tekrarı	Ölçek (Son)	$w_j^{(T)}$	$w_j^{(S)}$
1	3	0,03	0,30	0,42	0,42	...	0,50	53,52	52,87
2	12	0,11	0,30	0,42	0,42	...	0,50	53,52	52,87
3	15	0,14	0,30	0,42	0,42	...	0,50	53,52	52,87
4	20	0,19	0,30	0,42	0,42	...	0,50	53,52	52,87
5	25	0,23	0,30	0,42	0,42	...	0,50	53,52	52,87
6	30	0,28	0,30	0,42	0,42	...	0,50	53,52	52,87
7	50	0,47	0,47	0,53	0,53	...	0,64	67,84	67,01
8	60	0,56	0,56	0,79	0,79	...	0,96	101,76	100,51
9	150	1,41	1,41	1,99	1,99	...	2,39	254,39	251,29
10	700	6,57	3,00	4,18	3,00	...	3,00	319,87	315,96
Toplam	1065	10,00	7,24	10,00	8,82	...	10,00	1065,00	1052,00

Örnek uygulamasında $1/T=0,3$; $T=3$ alınarak ölçeklendirilmiş ağırlıkların en büyüğünün, ölçeklendirilmiş ağırlıkların en küçüğünün maksimum 10 katı kadar büyük olmasına izin verilmiştir. $N=1052$ birimlik yığından $n=10$ birimlik örnek seçildiği varsayılınsın. Yapılan

kalibrasyon işlemi sonrası elde edilen ağırlıklar w_j ile gösterilsin. Ağırlıkların en küçüğünün 3, en büyüğünün ise 700 olduğu Çizelge 2.4'te görülmektedir. Ağırlıkların ortalaması $\bar{w} = \sum_{i:1}^n w_j/10 = 106,5$ olarak elde edilir. Her bir w_j değeri bu ortalama değerine bölünerek 1 ortalamalı ölçeklendirilmiş değerler elde edilir. Örneğin birinci birim için $w_1/\bar{w} = 3/106,5 = 0,03$ sonucu ortaya çıkmaktadır. Bu değer belirlediğimiz 0,3 alt sınırının altında kaldığından düzeltme aşamasında bu değer yerine alt sınır olan 0,3 değeri atanır. Benzer şekilde ilk altı ölçeklendirilmiş değer de 0,3 değerinin altında kaldığından düzeltilir. Diğer yandan, 10 numaralı birim için ölçeklendirilmiş değer $w_{10}/\bar{w} = 700/106,5 = 6,57$ olup üst sınırı geçmektedir. Bu nedenle; ilgili ölçeklendirilmiş değer yerine düzeltme aşamasında üst sınır olan 3 değeri atanır. Düzeltme işlemi sonrasında elde edilen ölçeklendirilmiş ağırlıklar, ortalamaları 1 toplamları 10 olacak şekilde yeniden ölçeklendirilir. Örneğin; ilk birim için ikinci ölçeklendirilmiş ağırlık $0,3 * (10/7,24) = 0,42$ olur. Bu işlemler tüm birimler için ölçeklendirilmiş ağırlıklar $1/T=0,3$ ve $T=3$ arasında kalana kadar devam eder. Son ölçek değerleri ile ortalama ağırlık çarpılarak; $w_1^{son} * \bar{w} = 0,5 * 106,5 \approx 53,52$, budanmış ağırlık elde edilir.

Bazen cevapsızlık düzeltmesi ve/veya kalibrasyon düzeltmesi yapılmadan önce tasarım ağırlıklarına budama işlemi yapılmasına ihtiyaç duyulabilir. Örneğin bir örnek birimi yanlış tabakada sınıflandırılabilir; bu nedenle olması gerekenden daha düşük bir olasılık değeri alabilir. Bu birim örneğe seçildiği takdirde olması gerekenden daha büyük bir ağırlık alarak araştırma tahminleri için doğruluk kaybına neden olacaktır. Doğruluk kaybını azaltmak için bu tip birimlerin tasarım ağırlıklarında budama işlemi gerçekleştirilebilir (Kalton ve Flores-Cervantes, 2003). Diğer yandan; yapılan kalibrasyon işleminde tanımlanacak kısıtlar ile, yani sınırlandırılmış kalibrasyon yaklaşımı ile de ağırlıklarla ilgili büyük değer ve değişkenlik sorunu giderilebilir. Bu konu da üçüncü bölümde ele alınacaktır.

2.3.5. Ölçeklendirme

Yapılan ağırlıklandırma işlemleri sonrasında örnek sonuçlarının bilinen yığın toplamlarını tutması beklenir. Örneğin, örnek birimlerinin nihai ağırlıklarının toplamının yığındaki birim sayısı ile eşit olması beklenir. Daha önce yapılan işlemler sonucunda bu eşitlik

bozulabilir. Bu durumda bir şişirme faktörü ile bu eşitlik sağlanacaktır. Nihai ağırlıklar için yapılan ölçeklendirme araştırmadaki oran ve ortalama tahminleri ile diğer rasyoları etkilemez. Çizelge 2.4.'te tekrarlamalı işlemler sonucunda elde edilen tüm budanmış ağırlıklar $w_j^{(T)}$ sütununda gösterilmiştir. Son olarak ağırlıklar toplamının yığındaki birim sayısını vermesi için $w_1^{(S)} = w_1^{(T)} * \left(N / \sum_{i:1}^n w_j^{(T)} \right) = 53,52 * (1052/1065) = 52,87$ şeklinde son bir ölçeklendirme yapılarak $w_j^{(S)}$ ağırlıkları elde edilir.

Verma (2014:85-93) tarafından beş aşama biçiminde açıklanan ağırlıklandırma süreçleri; başta ulusal istatistik ofisleri olmak üzere büyük örnek çaplı araştırmalar ile çalışan örneklem araştırmacıları tarafından genellikle tercih edilmektedir. Diğer yandan; çoğunlukla cevapsızlık düzeltmesi ve kalibrasyon aşaması ile ilgili olmak üzere son yıllarda ağırlık düzeltmeleri ile ilgili birçok çalışma yapılmıştır. Ağırlık düzeltmesiyle ilgili yapılan en kapsamlı çalışmalardan biri Henry ve Valliant (2012b) tarafından gerçekleştirilmiştir. Bu çalışma literatürde önerilen ağırlık düzeltme alternatiflerinin büyük çoğunluğunu özetlemiş; ayrıca güçlü ve zayıf yönlerini de tartışmıştır. Tasarım-bazlı ağırlıkların yanında model-bazlı ağırlıklar hakkında da bilgi verilen çalışmada, aslında model-bazlı bir yaklaşım olan ve Beaumont (2008) tarafından önerilen "Genelleştirilmiş Tasarım Bazlı Yöntem" üzerinde durulmuştur. Bu yaklaşımda ağırlık budaması işlemi yapılırken ağırlıklar hedef değişken Y 'nin bir fonksiyonu olarak modellenmektedir. Bu yöntem genel tasarım-bazlı yaklaşımların aksine tüm araştırma ağırlıklarını modifiye etmektedir. Genel tasarım-bazlı düzeltme işlemleri az sayıda birimin ağırlığını modifiye ederek; genel tahminin etkinliğini artırırken bazı alt tahmin gruplarını olumsuz etkileyebilir.

Henry ve Valliant (2012a) alternatif ağırlık düzeltme yöntemlerini tasarım-bazlı, model-bazlı ve model-yardımcı yaklaşımlar başlıkları altında 3 farklı değişkenin etkinlikleri için karşılaştırdıkları çalışmada aynı zamanda kalibrasyon tahmin edicisi de olan GREG ve Sağlam-GREG model-yardımcı yaklaşımlarının en etkin yöntemler olduklarını göstermişlerdir. Haziza ve Lesage (2016) cevapsızlık nedeniyle oluşan sapma için ağırlık düzeltmesinin, tek aşamalı kalibrasyon ile mi yoksa cevap eğilimine göre yapılan cevapsızlık düzeltmesinin kullanıldığı iki aşamalı yaklaşımla mı yapılması gerektiğini ele almışlardır. Tek aşamalı yaklaşımın belli koşullar altında iyi sonuçlar verdiğini; ancak genel olarak iki aşamalı yaklaşımın daha avantajlı olduğunu belirtmişlerdir. Kott ve Liao

(2015) da benzer şekilde bir ve iki aşamalı ağırlık düzeltme konusunu ele almışlar ve iki aşamalı yaklaşımın daha etkin tahmin edici elde ettiğini belirtmişlerdir.

Cervantes ve Brick (2016) farklı tabakalı tasarımlar için yanlış belirlenmiş modeller üzerinden yapılan cevapsızlık düzeltmelerinin etkilerini incelemişlerdir. Ağırlıklandırılmış düzeltmelerin ağırlıklandırılmamış düzeltmelerden önemli derecede avantajlı olduğunu; ayrıca ağırlıklandırılmış tahminlerde örneğin tabakalara nasıl dağıtıldığının önemi olmadığını göstermişlerdir. Chen vd. (2017) ağırlıklandırma ile yapılan tahminlerde olası etkin olmayan durumları incelemişlerdir. Ayrıca tahminlerden yapılan çıkarımları geliştirmek için ağırlık budaması, ağırlık modellemesi ve araştırma değişkenleri ile ağırlıkların birlikte olduğu model tekniklerinden faydalanmışlardır.



3. KALİBRASYON TAHMİN EDİCİLERİ

Kalibrasyon, örnekleme arařtırmalarından elde edilen tahminleri geliřtirmek için kullanılan bir yöntemdir. Bařta ulusal istatistik ofisleri olmak üzere, büyük çaplı çalıřmalar yürüten arařtırmacılar tarafından kullanılmaktadır. İkinci bölümde Eř. 2.29'da verilen tek yardımcı deęiřken için örnek ve yığın daęılımının tutturulması iřlemi ile yardımcı deęiřkenler için belirlenen kısıtlara göre bilinen yığın toplamlarını tutturan ve bu bölümde inceleyeceęimiz kompleks aęırlık düzeltme yöntemlerinin hepsine genel olarak kalibrasyon iřlemi denilmektedir. Kalibrasyon iřlemi sonrası elde edilen tahmin ediciler ise genel olarak kalibrasyon tahmin edicileri olarak adlandırılmaktadır. Bu bölümde kalibrasyon teorisinin yanı sıra en çok kullanılan kalibrasyon tahmin edicileri incelenecektir. Kalibrasyon yaklařımı ortaya atılmadan önce de örneklemede yardımcı bilgi kullanılmakla beraber, kalibrasyon yardımcı bilgi kullanımına sistematik bir bakıř açısı kazandırmıřtır. Zira, yardımcı deęiřken kullanarak elde edilen tahmin edicilerin (sonradan-tabakalama, GREG vb. gibi) büyük bir kısmı kalibrasyon tahmin edicileri sınıfında yer almaktadır.

Kalibrasyon olarak sayılabilecek aęırlık düzeltme iřlemleri daha önceki yıllarda yapılmakla beraber, Deville ve Särndal'ın (1992) çalıřması bir terim olarak "kalibrasyon" ifadesini kullanması ve kalibrasyon tahmin edicilerinin teorik çerçevesini oluřturması nedeniyle bu konuda kilometre tařı olarak kabul görmektedir. Särndal (2007), kalibrasyonun tam tanımını řu řekilde yapmıřtır. Sonlu yığınlar için kalibrasyon yaklařımı,

- a. Kalibrasyon eřitlik(ler)i ile sınırlandırılmıř ve belirlenen yardımcı bilgiyi de kapsayacak řekilde aęırlıkların hesaplanması;
- b. Toplamların ve dięer sonlu yığın parametrelerinin doęrusal aęırlıklandırılmıř tahminlerini hesaplamak için bu aęırlıkların kullanılması; (Aęırlık ve deęiřken deęeri çarpılarak gözlemlenen deęerler kümesinde toplanır.)
- c. Cevapsızlık ve dięer örnekleme-dıřı hataların olmadıęı bilindięinde; yaklařık olarak tasarım sapmasız tahminler elde etme hedefinin saęlanması;

adımlarından oluřmaktadır. Särndal (2007) kalibrasyon denildięinde literatürde genellikle yalnızca (a) maddesinin kastedildięini ancak (c) maddesinin de tanımlamalarda kullanılması gerektięini belirtmiřtir.

Kanada İstatistik Ofisi Kalite Yönergesi tanımına göre: "Kalibrasyon, yardımcı verinin kapsanabilmesi için kullanılabilen bir prosedürdür. Bu prosedür, kalibrasyon faktörleri olarak bilinen ve tahminleri, bilinen toplamlarla uyumlu hale getiren çarpanlarla örnekleme ağırlıklarını düzeltir. Sonuçta elde edilen ağırlıklar kalibrasyon ağırlıkları veya nihai tahmin ağırlıkları olarak adlandırılır. Bu kalibrasyon ağırlıkları genellikle tasarım tutarlı tahminlerle sonuçlanır ve Horvitz-Thompson tahmin edicisinden daha küçük varyansa sahiptir."(Särndal, 2007). Birçok uygulamada kalibrasyon, tüm araştırma değişkenleri için kullanılabilen tek bir ağırlık kümesi verir. Bunun arkasındaki fikir, kalibre edilmiş ağırlıkların yığın kontrol toplamlarına iyileştirme yaptığına göre; diğer araştırma değişkenleri için de "iyi" olabileceği düşüncesidir. Bu ana fikir ile birlikte Särndal (2007) kalibrasyon kullanımının gerekçelerini altı başlık altında incelemiştir. Bu gerekçeler aşağıda özet olarak açıklanmıştır:

1. Kalibrasyon bir doğrusal ağırlıklandırma yöntemidir. Örnek olarak seçilen birimlere ağırlık verilerek toplam, ortalama vb. gibi yığın parametrelerinin tahmininin gerçekleştirilmesi ulusal istatistik ofislerinin sıkça kullandığı bir yöntemdir. Kalibrasyon işlemi sonucunda tahmin, doğrusal bir fonksiyonla elde edilebilir ve paydaşlara kolayca açıklanabilir.
2. Kalibrasyon yardımcı bilginin kullanımında sistematik bir yoldur. Kalibrasyon kavramı kullanılmadan çok önceleri de araştırma tahminlerinin doğruluğunu geliştirmek için yardımcı bilgi kullanılmaktaydı. Ancak; Rueda vd. (2007) çalışmasında belirtildiği gibi kalibrasyon yardımcı bilgiyi tahmin sürecinin bir parçası yapan basit ve pratik bir yoldur.
3. Kalibrasyon tutarlılığı sağlar. Burada bahsedilen tutarlılık istatistik özelliği anlamında olmayıp bilinen toplam değerleriyle tutarlı olmasıdır. Kalibrasyon eşitlikleri, kısıtlar yardımıyla ağırlıklandırma sistemine tutarlı olmayı empoze eder.
4. Kalibrasyon uygunluk ve şeffaflık için de kullanışlıdır. Tasarım ağırlığı kavramını bilen kullanıcılar için kalibrasyon ağırlıkları sonucu elde edilen tahminleri açıklamak da kolay ve uygundur. Basit formdaki kalibrasyonlar doğal kısıtlar dışında herhangi bir varsayım gerektirmez. Elde edilen kalibrasyon ağırlıkları araştırmanın bütün değişkenleri için kullanılabilir.
5. Kalibrasyon diğer terimlerle kombinasyonlu biçimde kullanılabilir. Bazı yazarlar "kalibrasyon" kelimesini çeşitli düşünce biçimlerini tanımlamak için kullanmaktadır. Model-kalibrasyonu (Wu ve Sitter, 2001), g-kalibrasyonu (Vanderhoeft vd., 2001),

Harmonize kalibrasyon (Webber vd., 2000), Doğrusal olmayan kalibrasyon (Plikusas, 2006) vb. gibi diğer çalışmalar örnek olarak verilebilir.

6. Kalibrasyon, çalışılması düşünülen konular için yeni bakış açıları sunabilir. Burada; Särndal (2007) bazı istatistiki uygulamalar için kalibrasyon yaklaşımının yeni ufuklar açabileceğini belirtmek istemiştir. Küçük alanların (domain) tahmini için kalibrasyon yaklaşımından faydalanılabileceği fikrini örnek olarak göstermiştir.

Kalibrasyon teknikleri $j \in s$ olmak üzere d_j tasarım ağırlıklarını düzeltirken aşağıdaki koşulları sağlar:

- x_j değişkenler vektörü olmak üzere kantitatif değişkenler için toplamların tahmin edicileri yığın toplamına eşittir. ($\hat{t}_{xcal} = t_x$)
- Kalitatif değişkenlerin her bir kategorisi ($k=1,2,\dots$) için tahmin edilen frekanslar gerçek frekanslara eşittir. ($\hat{N}_{kcal} = N_k$)

Kalibrasyon tahmin edicilerinin arkasındaki fikir; aşağıdaki özellikleri sağlayan tahmin ediciler ailesini aramaktır. Buna göre bir kalibrasyon tahmin edicisi;

1. Hedef değişken ve kalibrasyon sonrası ağırlıkların doğrusal bir kombinasyonu biçiminde yazılabilmelidir: $\hat{t}_{yCAL} = \sum_{j \in s} w_j y_j$
2. Temel kalibrasyon özelliğini sağlamalıdır: $\hat{t}_{xCAL} = \sum_{j \in s} w_j x_j = t_x$
3. Kalibrasyon ağırlıkları kümesini gösteren $\{w_j(s) : j \in s\}$ değerleri tasarım ağırlıkları kümesini gösteren $\{d_j = 1/\pi_j : j \in s\}$ değerlerine yakındır.

Särndal ve Lundström (1999) kalibrasyon yaklaşımının cevapsızlıktan kaynaklanan sapmayı düzeltmek için kullanılabileceğini ortaya koymuşlardır. Sonraki yıllarda bu fikri takip eden bazı araştırmacılar da cevapsızlık düzeltmesi aşamasını uygulamadan, yalnızca kalibrasyon işlemini uygulamışlardır.

Särndal ve Lundström (1999) yaklaşımı ile cevaplı birimler kümesi $r^* \subseteq s$ ve $j \in r^*$ olmak üzere cevapsızlık düzeltmesi için kalibrasyon yaklaşımı uygulamak mümkündür. Ancak; iki aşamalı yaklaşımın daha etkin sonuçlar verdiği varsayımı dikkate alınarak, bu bölümde anlatılacak olan kalibrasyon tahmin edicilerinin gösterimleri $j \in s$ olmak üzere tam

cevaplılık varsayımı veya cevapsızlık düzeltilmesinin yapıldığı varsayımı üzerinden yapılacaktır. Öncelikle; araştırma istatistikçileri tarafından en sık kullanılan kalibrasyon tahmin edicileri olan sonradan-tabakalama tahmin edicisi ve GREG tahmin edicisi ile "raking" (tekrarlamalı orantılı uyum) yaklaşımı ele alınacaktır. Deville ve Särndal (1992) kalibrasyon teorisini önermeden önce de yardımcı bilgiyi sistematik olarak kullanan bu yöntemlerin kalibrasyon tahmin edicileri ailesinin üyeleri olduğu farklı çalışmalarda gösterilmiştir. Son olarak; minimum uzaklık yöntemi ile kalibrasyon tahmin edicisi elde etme konusu ele alınacaktır.

3.1. Sonradan-Tabakalama Tahmin Edicisi

Bölüm 2.3.3'de belirtildiği gibi tahmin aşamasında yardımcı değişken kullanımının ilk örnekleri oran ve regresyon tahmin edicileridir. Her iki tahmin edici de kantitatif yardımcı değişkenler kullanmaktadır. Yaş, cinsiyet, eğitim, meslek vb. gibi kalitatif yardımcı değişkenler de tahmin aşamasında kullanılabilir. Bunun iyi bilinen ve sıklıkla kullanılan örneklerinden biri sonradan-tabakalama tahmin edicisidir. Yardımcı değişken bilgisinin Tabakalı Örnekleme yönteminde olduğu gibi örnek seçimi öncesinde birim bazında bilinmeyip; bir birimin hangi tabakada olduğu örnek araştırmasında belirleniyorsa bu tabakalar sonradan tabakalardır.

Sonradan tabakalamanın ana fikri, örnekten gelen bilgilere göre yığılı homojen tabakalara ayırmaktır. Buradaki homojenlik ilgilenilen değişkenlere ve/veya cevap verme eğilimine göre benzerliğin sağlanmasıdır. Homojenlik ne kadar çok sağlanabilirse; tahminin sapması da o derece azalarak doğrulukta artış sağlanacaktır. Sonradan tabakalamada, BRÖ yöntemi ile seçilmiş olmasına rağmen bir örneğin birimlerinin tabakalara sınıflandırılması ve tabakalı tahmin kullanılması söz konusudur. Aşağıdaki durumlarda sonradan tabakalama uygulanmaktadır:

1. Her birimi sınıflandırabilmek ve sıralayabilmek için gerekli tabakalama değişkeninin mevcut olmaması durumunda;
2. Tabakalama değişkeninin mevcut olmasına rağmen kullanılmaması durumunda;
3. Sonradan tabakalama, örnek yığılıdan orantılı olarak çekilmiş olsa da, alt sınıflarda kullanılabilir.

Küçük çaplı alt sınıflarda orantılı dağıtımın etkisi azalmaktadır; örnek çapları tabakalarda değişmektedir ve ortalamanın varyansı, BRÖ varyansına yaklaşmaktadır. Ancak özel ağırlıklar geliştirilerek, her tabakada alt sınıf elemanlarının sayısı, orantılı örnekleme büyük kazançlar sağlamaktadır (Kish, 1965:90). Böylelikle sonradan tabakalama, yığın ortalaması tahmininin bir "düzeltmesi" olarak kabul edilmektedir ve bu düzeltmenin yapılabilmesi için şu koşulların sağlanması gereklidir:

- a) Farklı tabakalardaki $W_h = N_h/N$ yığın oranları ile ilgili bilginin olması
- b) Seçilen örnek biriminin hangi tabakaya ait olduğuna dair sınıflandırma bilgisinin olması

Bu iki koşulun sağlanması durumunda sonradan tabakalama yöntemi, orantılı paylaşırma ile yapılan tabakalı rastgele örnekleme yöntemi ile aynı doğruluk derecesine sahip olmaktadır (Thompson, 1992:109).

Diyelim ki yardımcı değişken bilgisi hedef yığın U 'yu U_1, U_2, \dots, U_H biçiminde H tane alt-yığına (tabakaya) N_1, N_2, \dots, N_H büyüklükleri ile bölmüş olsun. BRÖ ile örnek seçimi yapıldıktan sonra her sonradan-tabaka için örnek ortalaması hesaplanarak toplam için sonradan-tabakalama tahmin edicisi Eş. 3.1'deki gibi hesaplanabilir.

$$\hat{t}_{y_{PS}} = \sum_{h=1}^H N_h \bar{y}_{HT}^{(h)} \quad (3.1)$$

Burada $\bar{y}_{HT}^{(h)}$, h . sonradan tabaka için HT ortalama tahmin edicisini ifade etmektedir. Dikkat edilecek olursa bu toplam tahmin edicisi gösterim olarak tabakalı örneklemenin toplam tahmin edicisi ile aynıdır. Ancak; kullanılan tabaka örnek çapları tabakalı örneklemeden farklı olarak önceden belirlenmiş sabit değerler olmayıp birer rastgele değişkendir. Diğer bir ifadeyle, seçim mekanizması farklıdır ve bu yüzden bu tahmin edici tabakalı örneklemeden farklı istatistiksel özellikler taşımaktadır. Sonradan-tabakalama tahmin edicisi yaklaşık olarak sapmasız olup; varyansı Eş. 3.2'deki gibi hesaplanır.

$$V(\hat{t}_{y_{PS}}) = \frac{1-f}{n} \sum_{h=1}^H W_h S_h^2 + \frac{1}{n^2} \sum_{h=1}^H (1 - W_h) S_h^2 \quad (3.2)$$

Burada $W_h = N_h/N$ ve S_h^2 , h . tabaka için sırasıyla tabaka ağırlığı ve hedef değişkenin yığın varyansıdır. Hedef değişken değerlerine göre tabakalar homojen ise bu varyans küçük

olacaktır. Sonradan- tabakalama tahmin edicisinin varyansı ile ilgili daha detaylı bilgi için Ünver (1998), Şahin (2004) ve Alkaya (2009) çalışmalarına bakılabilir. Holt ve Smith (1979), sonradan tabakalamanın klasik tabakalama yönteminden daha etkin olduğunu belirtmiştir. Uygulama kolaylığı nedeniyle en çok tercih edilen kalibrasyon yaklaşımlarından biridir. Sonradan tabakalarda ilgili kalitatif değişkenler için yığındaki toplam birim sayısının bilinmesine ihtiyaç duyulması yöntemin kullanılabilirliğini kısıtlamaktadır. Ayrıca; kantitatif değişkenlerde direkt kullanılmayıp gruplama ile kalitatif değişken biçiminde kullanım imkanı bilgi kaybına da yol açmaktadır.

Sonradan-tabakalama durumunda ağırlık düzeltme işleminin nasıl yapıldığını bir örnek ile gösterelim. Büyüklüğü 1000 olan bir yığından BRÖ ile 100 birimlik örnek seçildiği varsayalım. Yaş grubu ve cinsiyet olmak üzere iki tane yardımcı değişkenin yığın ve örnek dağılımı Çizelge 3.1'de verilmiştir.

Çizelge 3.1. Sonradan-tabakalamanın örneklendirilmesi

Yığın				Örnekleme			
	Erkek	Kadın	Toplam		Erkek	Kadın	Toplam
Genç	245	215	460	Genç	24	16	40
Orta Yaş	140	140	280	Orta Yaş	15	19	34
Yaşlı	110	150	260	Yaşlı	12	14	26
Toplam	495	505	1000	Toplam	51	49	100

Çizelge 3.1'den görüldüğü gibi örnek dağılımının yığın için tam temsiliyeti sağlamadığı gözlenmektedir. Örneğin; genç kadınların yığındaki oranı $215/1000 = 21,5\%$ iken örnekteki oranının $16/100 = 16\%$ 'dır. Yaş grubu ve cinsiyet için örnek dağılımının yığın dağılımı ile tutarlı olması için Eş. 3.3 kullanılarak Çizelge 3.2'deki ağırlık düzeltme katsayıları elde edilmektedir.

$$g_j^{(PS)} = \frac{N_h/n_h}{N/n} \quad (3.3)$$

Örneğin, genç kadınlar için düzeltme katsayısı $(215/1000) / (16/100) = 1,344$ olarak hesaplanır. Genç kadınlar düşük temsiliyetli olduğundan düzeltme katsayısı 1'den büyük

olup; orta yaş ve yaşlı erkekler ile orta yaş kadınlarda temsiliyet yüksek olduğundan bu gruplar için katsayı 1'den küçüktür.

Çizelge 3.2. Sonradan-tabakalama ağırlık düzeltme katsayıları

Ağırlık Düzeltme Katsayıları		
	Erkek	Kadın
Genç	1,021	1,344
Orta Yaş	0,933	0,737
Yaşlı	0,917	1,071

Lohr (2010:342) bir oransal düzeltme biçimi olan sonradan-tabakalamanın hem eksik kapsam hem de cevapsızlığın düzeltilmesi için kullanılabileceğini belirtmiştir. Ayrıca sonradan-tabakalama konusunu oran ve regresyon tahmin edicileri, cevapsızlık düzeltmesi ve GREG başlığı altında da incelemiştir.

3.2. Raking Yaklaşımı

Raking, sonradan tabakalarda birden fazla yardımcı değişken bilgisinin kullanılabilirdiği; ancak yalnızca marjinal toplamalarının bilindiği bir sonradan-tabakalama yöntemidir. İlk olarak Deming ve Stephan (1940) tarafından 1940 A.B.D nüfus sayımında örnek ve tam sayım arasında tutarlı sonuçlar olduğundan emin olmak için kullanılmıştır. Brackstone ve Rao (1979) daha sonra teoriyi geliştirmişlerdir (Lohr, 2010:344).

Tekrarlamalı orantılı uyum yaklaşımı olarak da bilinen Raking yöntemi kısaca, örnek verisinden gelen yığın büyüklüğü tahminini bilinen marjinal yığın çaplarına tekrarlamalı olarak orantılayarak yığın ile örnek verisini uyumlaştırma işlemidir. Literatürde genellikle "raking" ve "raking ratio" olarak adlandırılmakla beraber; kenar ağırlıklandırma (rim weighting) ve marjinal kalibrasyon olarak da isimlendirilmektedir. Yöntemin uygulanmasında ilk olarak örnek satır toplamaları ile yığın satır toplamalarının tutarlılığı sağlanır. Sonra düzeltilen örnek sütun toplamaları ile yığın sütun toplamalarının tutarlılığı sağlanır. Daha sonra bozulan örnek satır toplamaları için ilk işlem tekrarlanır. Sonrasında da bozulan örnek sütun toplamaları için ikinci işlem tekrarlanır. Yığın toplamalarına yakınsama olana kadar işlemler tekrarlanır.

N birimli bir yığın ve n birimli bir örnek için oluşturulan çapraz tablolarda $r = 1, 2, \dots, R$ satır ve $c = 1, 2, \dots, C$ sütun indisi olmak üzere yığın büyüklüğü \hat{N}_{rc} ile tahmin edilir. Yığında bilinen gerçek marjinal toplamları ise N_r ve N_c olsun. Algoritma aşağıdaki gibi olacaktır. Öncelikle;

$$N_{rc}^{(0)} = \hat{N}_{rc}, \quad \text{tüm } r = 1, 2, \dots, R, c = 1, 2, \dots, C \text{ için}$$

adımıyla başlanır. Her işlem $t = 1, 2, 3, \dots$ ile gösterilmek üzere satır ve sütunlar sırasıyla Eş. 3.4 ve Eş. 3.5'teki tekrarlamalı işlemlerle yığın toplamlarına uyumlu hale getirilir.

$$N_{rc}^{(2t-1)} = N_{rc}^{(2t-2)} \frac{N_r}{\sum_c N_{rc}^{(2t-2)}} \quad \text{tüm } r = 1, 2, \dots, R, c = 1, 2, \dots, C \text{ için} \quad (3.4)$$

$$N_{rc}^{(2t)} = N_{rc}^{(2t-1)} \frac{N_c}{\sum_r N_{rc}^{(2t-1)}} \quad \text{tüm } r = 1, 2, \dots, R, c = 1, 2, \dots, C \text{ için} \quad (3.5)$$

\hat{N}_{rc} tahmini için oluşturulan tabloda boş değerler yoksa algoritma hızlı bir biçimde yakınsayacaktır (Ardilly ve Tille, 2006:264). Burada \hat{N}_{rc} tahmini için uygulamada genellikle tasarım ağırlıklarının toplamı kullanılmaktadır. Yakınsamanın sağlandığı son aşamadaki yığın tahminleri $N_{rc}^{(F)} = \tilde{N}_{rc}$ olmak üzere hedef değişken için toplam tahmin edicisi Eş. 3.6'da verilmiştir.

$$\hat{t}_{yRAK} = \sum_{r=1}^R \sum_{c=1}^C \frac{\tilde{N}_{rc}}{n_{rc}} \sum_{j=1}^{n_{rc}} y_{rcj} \quad (3.6)$$

\tilde{N}_{rc} tahmin edicisinin asimptotik olarak sapmasız, normal dağılımlı ve minimum varyanslı olduğu belirlenmiştir. Dolayısıyla, \tilde{N}_{rc} için en iyi asimptotik sapmasız normal tahmin edici denilebilir (Oh ve Scheuren, 1983).

Çizelge 3.1'de verilen örnek ve yığın dağılımları kullanılarak yöntem örneklendirilebilir. Örneklerin BRÖ ile seçildiğini dikkate alarak tasarım ağırlığının bütün birimler için $d = N/n = 10$ alındığı düşünülürse; genç erkeklerin yığın toplamının tahmini $N_{11}^{(0)} = \hat{N}_{11} = 24 * 10 = 240$ olacaktır. Gençlerin bilinen yığın toplamı ise $N_1 = 460$ 'dır.

Gençlerin örnekten gelen toplam tahmini ise $\sum_c N_1^{(0)} = 400$ 'dür. Bu bilgiler yerine konulduğunda

$$N_{11}^{(1)} = N_{11}^{(0)} \frac{N_{1.}}{\sum_c N_{1.}^{(0)}} = 240 \frac{460}{400} = 276$$

elde edilir. Benzer şekilde $N_{12}^{(1)}, N_{21}^{(1)}$... hesaplanabilir. Daha sonra $N_{11}^{(1)}$ kullanılarak

$$N_{11}^{(2)} = N_{11}^{(1)} \frac{N_{1.}}{\sum_r N_{r.}^{(1)}} = 276 \frac{495}{519,53} = 262,97$$

elde edilir. Çizelge 3.3'te 1. ve 2. tekrarlar işlemalarının sonuçları gösterilmiştir.

Çizelge 3.3. Raking işleminin örneklendirilmesi

	1.tekararlama			2.tekararlama		
	Erkek	Kadın	Toplam	Erkek	Kadın	Toplam
Genç	276	184	460	262,97	193,39	456,36
Orta Yaş	123,53	156,47	280,00	117,70	164,46	282,16
Yaşlı	120	140	260	114,33	147,15	261,48
Toplam	519,53	480,47	1000	495	505	1000

Tekrarlar işlemine devam edildiğinde yığın satır ve sütun toplamalarına yaklaşıldığı yani marjinal dağılımlara yakınsandığı görülmektedir. Çizelge 3.4'te verilen sonuçta 4. tekrarlamada gerekli uyumun sağlandığı varsayılarak işlem kesilmiştir. Aynı çizelgede $N_{rc}^{(F)}$ son işlem sonucunu göstermek üzere raking işlemi sonrasında elde edilen

$$g_j^{(RAK)} = N_{rc}^{(F)} / N_{rc}^{(0)} \quad (3.7)$$

ağırlık düzeltme katsayıları da verilmiştir. Çizelge 3.4 ve Çizelge 3.2 karşılaştırıldığında aynı örnek verisi için sonradan tabakalama ve raking işlemlerinin farklı ağırlık düzeltme katsayıları verdiği görülmektedir.

Bölüm 2.3'te belirtilen varyans şişirme faktörü (VIF) ile bu katsayıların duyarlılığa olan etkisi karşılaştırılabilir. Sonradan-tabakalama sonucu elde edilen $VIF(PS) = 1,034$ iken raking işleminde $VIF(RAK) = 1,022$ olarak hesaplanmaktadır. Verilen örnekte görüldüğü gibi sonradan-tabakalama daha alt düzeyde (sonradan tabaka hücrelerinde) dışsal bilgi

tutarlılığını sağlarken ağırlık düzeltme katsayılarının varyansı daha büyük olmaktadır. Dolayısıyla raking yönteminin bu örnekte daha duyarlı bir tahmin yaptığı söylenebilir. Bu durum, çok sayıda yardımcı değişken kullanıldığında ve hücre sayısının çok olması durumlarında genellikle geçerlidir.

Çizelge 3.4. Raking işleminin sonucu ve ağırlık düzeltme katsayıları

4.tekrarlama			Ağırlık Düzeltme Katsayıları		
	Erkek	Kadın	Toplam	Erkek	Kadın
Genç	264,77	195,15	459,92	1,103	1,220
Orta Yaş	116,67	163,38	280,05	0,778	0,860
Yaşlı	113,56	146,47	260,03	0,946	1,046
Toplam	495,00	505,00	1000		

Oh ve Scheuren (1987) tekraralama tekniklerini kullanarak verilen örnek büyüklüğü n altında \hat{t}_{yRAK} tahmin edicisinin koşullu varyansını Eş. 3.8'deki gibi tanımlamıştır.

$$V(\hat{t}_{yRAK} \setminus n) = \sum_{r=1}^R \sum_{c=1}^C n_{rc} \left(\frac{\tilde{N}_{rc}}{n_{rc}} \right)^2 \left(1 - \frac{n_{rc}}{N_{rc}} \right) S_{rc}^2 \quad (3.8)$$

\tilde{N}_{rc} , çapraz tabloda r satırında ve c sütunu için yığında yer alan birim sayısını; S_{rc}^2 , çapraz tabloda r satırında ve c sütununda yer alan birimlerin Y değişkeni için yığın varyansını göstermektedir. Raking işleminde bazı hücre tahminlerinin sıfır olması durumunda tekrarlamalı algoritma yakınsamayabilir. Diğer bir tehlike ise işlemde kullanılan değişkenlerin yığın dağılımı ile örnek dağılımının az ilişkili olması durumunda varyansın azalması yerine artabilmesi durumudur.

3.3. Genelleştirilmiş Regresyon Tahmin Edicisi (GREG)

Regresyon tahmin edicileri doğrusal tahmin ediciler sınıfında yer aldığından; hesaplanan ağırlıklar herhangi bir araştırma değişkeni için kullanılabilir. Bu nedenle de araştırma örnekleme için önemli bir avantaja sahiptirler. Cassel vd. (1976) tahmin edici oluşturulmasında model ve tasarım prensiplerini birlikte düşünerek toplam tahmini için tasarım tutarlı "Genelleştirilmiş Regresyon (GREG) Tahmin Edicisi" terimini önermişlerdir.

GREG yardımcı bilgiyi kullanarak tahminlerin doğruluğunu geliştirmek için tasarlanan model-yardımcı bir tahmin edicidir. GREG tahmin edicisi yardımcı değişkenler için örnek tahminleri ile bilinen yığın toplamlarının tutarlılığının sağlanmasını garanti etmektedir. Yardımcı bilgi birim veya alan(domain) düzeyinde uygun olduğunda; GREG tahmin edicisi hedef değişken ve yardımcı değişken arasındaki ilişkiden faydalanarak, tahminlerin varyansını azaltmak için kullanılabilir.

Ana fikir $\hat{\mathbf{B}} = \left(\sum_{j \in S} \frac{\mathbf{x}_j \mathbf{x}_j'}{\sigma_j^2 \pi_j} \right)^{-1} \sum_{j \in S} \frac{\mathbf{x}_j y_j}{\sigma_j^2 \pi_j}$ olmak üzere bilinen yardımcı değişken değerleri vektörüyle (\mathbf{x}_j) , $\hat{y}_j = \mathbf{x}_j' \hat{\mathbf{B}}$ yardımcı modelini oluşturarak; $j \in U$ için hedef değişken Y tahmininin bütün N yığın elemanları için üretilebilmesidir. Tahmin edilen \hat{y}_j değerleri kullanılarak elde edilen Eş. 3.9, yığın toplamı t_y 'nin tasarım sapmasız bir tahmin edicisidir.

$$\begin{aligned} \hat{t}_{yGREG} &= \sum_{j \in U} \hat{y}_j + \sum_{j \in S} d_j (y_j - \hat{y}_j) \\ &= \sum_{j \in S} d_j y_j + \left(\sum_{j \in U} \hat{y}_j - \sum_{j \in S} d_j \hat{y}_j \right) \end{aligned} \quad (3.9)$$

Toplamı bu şekilde tahmin etmenin arkasındaki temel fikir, uyumlu bir model yardımıyla $y_j - \hat{y}_j$ artıklarının çok küçük olmasını sağlayarak; doğru tahminler elde etmektir. Modelleme GREG yaklaşımının esasını oluşturmaktadır. Doğrusal, doğrusal olmayan, genelleştirilmiş doğrusal, sabit ve rastgele etkilerin olduğu karma modeller gibi çok çeşitli modeller oluşturmak mümkün olduğundan; geniş bir GREG tahmin edicileri ailesinden söz edilebilir. Burada aynı zamanda bir kalibrasyon tahmin edicisi de olan doğrusal GREG ele alınacaktır.

Doğrusal GREG model-yardımcı bir yaklaşım olup; sabit etkili doğrusal bir model yardımıyla hedef değişkene ilişkin toplam tahmini Eş. 3.10'daki gibi tanımlanır.

$$\hat{t}_{yGREG} = \left(\sum_{j \in U} \mathbf{x}_j \right)' \mathbf{B}_{S,dq} + \sum_{j \in S} d_j (y_j - \mathbf{x}_j' \mathbf{B}_{S,dq}) \quad (3.10)$$

Burada \mathbf{x}_j yardımcı değişkenler vektörü olmak üzere $\mathbf{B}_{S,dq}$ regresyon denklemindeki katsayılar vektörü olup; GREG'de Eş. 3.11'deki gibi hesaplanmaktadır.

$$\mathbf{B}_{S,dq} = \left(\sum_{j \in S} d_j q_j \mathbf{x}_j \mathbf{x}_j' \right)^{-1} \left(\sum_{j \in S} d_j q_j \mathbf{x}_j y_j \right) \quad (3.11)$$

q_j istatistikçiler tarafından belirlenen ölçek faktörleridir. Standart olarak bütün birimler için $q_j = 1$ olarak seçilir. \hat{t}_{yGREG} tahmininin doğruluğu üzerinde q_j seçiminin genellikle sınırlı bir etkisi vardır. Yaklaşık-sapmasızlık q_j 'nin herhangi bir değeri (aşırı büyük/küçük değerler dışında) için gerçekleşmektedir. Doğrusal GREG modeli basit olmakla birlikte, kullanılabilir yardımcı değişkenler vektörü \mathbf{x}_j' nin ve q_j değerlerinin alternatif seçimlerine bağlı olarak birçok tahmin edici elde edilebilir. Genel koşullar altında,

$$(\hat{t}_{yGREG} - t)/N = (\sum_{j \in S} d_j \varepsilon_j - \sum_{j \in U} \varepsilon_j) / N + O_p(n^{-1}) \quad (3.12)$$

$\mathbf{B}_{U;q} = (\sum_U q_j \mathbf{x}_j \mathbf{x}_j')^{-1} (\sum_U q_j \mathbf{x}_j y_j)$ olup; $\varepsilon_j = y_j - \mathbf{x}_j' \mathbf{B}_{U;q}$ artıkları kullanılarak $\sum_S d_j \varepsilon_j$ Horvitz-Thompson tahmin edicisini vermek üzere Eş. 3.12 sağlanmaktadır. Bu sayede GREG tahmin edicisinin Eş. 3.13'de verilen tasarım bazlı özelliklerinden bahsetmek mümkün olacaktır.

$$E(\hat{t}_{yGREG}) \approx t \text{ ve } V(\hat{t}_{yGREG}) \approx V(\sum_S d_j \varepsilon_j) \quad (3.13)$$

GREG tahmin edicisinin varyansının küçük olması için y_j 'nin \mathbf{x}_j üzerinden oluşturulmuş doğrusal regresyon denkleminin çok uyumlu olması gerekmektedir (Särndal, 2007). Herhangi bir örnekleme tasarımı için Eş. 3.11'de verilen $\mathbf{B}_{S;dq}$ tahmin edicisi $\mathbf{B}_{U;q}$ için asimptotik sapmasız tahmin edicidir.

GREG tahmin edicisinin karmaşık yapısı nedeni ile tasarım-bazlı olarak elde edilen klasik varyans belirleme yaklaşımları burada uygulanamamaktadır. Bu nedenle varyans hesaplamalarında yaklaşık teknikler kullanılması önerilmiştir. GREG sapmasız olmamakla birlikte, büyük örnekler için yaklaşık olarak sapmasızdır. Särndal vd. (1992:235) bu durumun Taylor doğrusallaştırması ile desteklendiğini açıklayarak; yaklaşık varyans ve varyans tahmin edicisinin hesaplanmasında ilgili yöntemin kullanılabilirliğini belirtmişlerdir. Buna göre GREG tahmin edicisi için asimptotik varyans ve varyans tahmin edicisi sırasıyla Eş. 3.14 ve Eş. 3.15'te verilmiştir.

$$AV(\hat{t}_{yGREG}) = \sum_{j \in U} \sum_{k \in U} (\pi_{jk} - \pi_j \pi_k) \check{\varepsilon}_j \check{\varepsilon}_k \quad (3.14)$$

$$\hat{V}(\hat{t}_{yGREG}) = \sum_{j \in S} \sum_{k \in S} \left(\frac{\pi_{jk} - \pi_j \pi_k}{\pi_{jk}} \right) (g_j \check{e}_j)(g_k \check{e}_k) \quad (3.15)$$

Bu eşitliklerde $\check{e}_j = \varepsilon_j / \pi_j$ yığın regresyon hatalarının, $\check{e}_j = e_j / \pi_j$ ise örnek regresyon artıklarının ağırlıklandırılmış gösterimleridir. Kalibrasyon ağırlık düzeltme katsayısı olarak daha önce tanımlamış olduğumuz g_j , GREG yaklaşımında Eş. 3.16'daki gibi elde edilmektedir.

$$g_j^{(GREG)} = 1 + (\mathbf{t}_x - \hat{\mathbf{t}}_{xHT})' \hat{\mathbf{T}}^{-1} \mathbf{x}_j / \sigma_j^2 \quad (3.16)$$

Burada $\hat{\mathbf{T}} = \sum_s \mathbf{x}_j \mathbf{x}_j' / \sigma_j^2 \pi_j$ eşitliği ile elde edilmektedir. Dikkat edilecek olursa Y bağımlı değişkeni için bir regresyon modeli yardımıyla GREG tahmini yapılırken; GREG ağırlıkları y_j değerlerinden bağımsızdır. Bu özelliği nedeniyle GREG ağırlıkları araştırmadaki tüm veriler için kullanılabilir. GREG tahmin edicisinin farklı elde edilişleri ve varyans hesaplamalarının detayları için Särndal vd. (1992) incelenebilir.

GREG, hedef değişkenin yığın ortalaması için asimptotik tasarım sapmasız bir tahmin edicidir. \mathbf{I} vektörü 1'lerden oluşan bir vektör olmak üzere $\mathbf{x}\mathbf{c} = \mathbf{I}$ eşitliğini sağlayan p boyutlu bir \mathbf{c} sabit sayılar vektörü varsa ortalama için GREG tahmin edicisi

$$\bar{y}_{GREG} = \bar{\mathbf{x}}' \mathbf{B}_{s,dq} \quad (3.17)$$

biçiminde yazılabilir. BRÖ'de yalnızca tek bir kantitatif yardımcı değişken kullanıldığında, GREG klasik regresyon tahmin edicisine dönüşecektir. Tek bir yardımcı değişken elde edilebilir ve bir modelle desteklenebilir olduğunda ve hedef değişkenin varyansının yardımcı değişkenin doğrusal bir fonksiyonu $V(y) = \sigma^2 x$ olduğu varsayıldığında benzer şekilde oran tahmin edicisi de GREG'in özel bir durumudur (Deville ve Särndal, 1992).

Kategori sayısı p tane olan bir x^* kalitatif yardımcı değişkeni olduğu düşünülün. Bu değişken p tane kukla değişken ile gösterilebilir. Her j birimi için kukla değişkenlerin değerleri $\mathbf{x}_j^* = (x_{j1}^*, x_{j2}^*, \dots, x_{jp}^*)'$ vektörü ile gösterilsin. h . kukla değişkenin x_{jh}^* değeri j . birim tabaka h 'de ise 1, değilse 0 olacaktır. Bu durumda $\mathbf{B}_{U,q}$ Eş.3.18'deki gibi ve tahmin edicisi $\mathbf{B}_{s,dq}$ ise Eş. 3.19'daki gibi yazılabilir.

$$\mathbf{B}_{U;q} = (\bar{Y}^{(1)}, \bar{Y}^{(2)}, \dots, \bar{Y}^{(H)})' \quad (3.18)$$

$$\mathbf{B}_{S;dq} = (\bar{y}_{HT}^{(1)}, \bar{y}_{HT}^{(2)}, \dots, \bar{y}_{HT}^{(H)})' \quad (3.19)$$

x^* yardımcı değişkeninin yığın ortalamaları vektörü ise Eş. 3.20'deki gibi olacaktır.

$$\bar{\mathbf{X}}^* = (W_1, W_2, \dots, W_H)' \quad (3.20)$$

\bar{x} yardımcı değişkenler vektörü yerine $\bar{\mathbf{X}}^*$ kullanılarak; Eş. 3.19 ve Eş. 3.20 denklemleri Eş. 3.17'de yerine yazılırsa;

$$\bar{y}_{PS} = \sum_{h=1}^H N_h \bar{y}_{HT}^{(h)} \quad (3.21)$$

ortalama için sonradan tabakalama tahmin edicisi elde edilecektir. Böylece sonradan tabakalama tahmin edicisinin aslında Eş. 3.17'de tanımlanan GREG tahmin edicisinin özel bir durumu olduğu gösterilmektedir.

GREG tahmin edicisinin hedef değişken Y ve yardımcı değişkenler \mathbf{X} arasında doğrusal ilişki olduğunda kullanılması önerilmektedir. GREG tahmin edicisini kullanırken karşılaşılabilecek olası dezavantajları ise aşağıdaki gibi özetleyebiliriz:

1. Ağırlıklarda büyük varyasyona neden olup varyansı arttırabilir.
2. Düzeltme katsayısının 1'den çok büyük veya çok küçük olduğu durumlar ile negatif değerler aldığı durumlar ortaya çıkabilir.
3. Asimptotik olarak sapmasız olmasına karşın küçük örnek çaplarında sapmalı olabilir.
4. GREG tahmin edicisi aykırı değerler olduğu durumlarda çok hassas olabilir. Bu durum normal dağılımlı olmayan, çarpıklığı büyük hedef değişkenler için sorun teşkil etmektedir.

Doğrusal olmayan GREG tahmin edicilerinde her hedef değişken için ayrı bir model kurulmasına ihtiyaç duyulmaktadır. Bu nedenle; örnek birimleri için kullanılabilir tek bir ağırlık elde edilememektedir. Diğer yandan birim düzeyinde tam bir yardımcı bilginin

varlığında daha iyileştirilmiş bir model elde etmesi nedeniyle doğrusal olmayan GREG tahmininde varyansta ciddi boyutta düşüş olabilir.

3.4. Minimum Uzaklık Yöntemi ile Kalibrasyon

Önceki bölümde anlatılan GREG yöntemi, tahmin aşamasında regresyon denklemi olan bir yardımcı modelden faydalanmaktaydı. Kalibrasyon yaklaşımı ise konu başlığında da vurguladığımız gibi tahmin aşamasında ayarlama yaparken yardımcı bilgidен faydalanmaktadır. Burada açıkça bir modelden faydalanma gereksinimi yoktur; vurgulanmak istenen herhangi bir yardımcı bilgidir. Kalibrasyon düşüncesinin arkasındaki ana fikir, elde edilen y -değerlerini doğrusal ağırlıklandırmış biçimde göstererek; yardımcı değişkenler için hesaplanabilir tutarlı toplamların elde edilmesidir. Bu amaca farklı yollarla ulaşabilmek mümkündür. Bu bölümde, en popüler yaklaşımlardan biri olan minimum uzaklık yöntemi ele alınacaktır.

Bu yöntemde, başlangıçta elde edilen d_j tasarım ağırlıkları "olabilecek en yakın" biçimde yeni w_j ağırlığına modifiye edilir. Buna ulaşabilmek için her $w > 0$ olmak üzere tanımlanan bir $G_j(w, d)$ uzaklık fonksiyonu düşünülür; öyle ki $G_j(w, d) \geq 0$, $G_j(d, d) = 0$ ve w 'ya göre türevlenebilirdir. Aynı zamanda tam konveks olan bu uzaklık fonksiyonu için sürekli türevler $g_j(w, d) = \partial G_j(w, d) / \partial w$ ve $g_j(d, d) = 0$ 'dır. Genellikle uzaklık fonksiyonu belirlenirken $g_j(w, d) = g_j(w/d) / q_j$ eşitliğinden faydalanılır. Burada q_j uygun biçimde seçilen pozitif bir ölçek faktörüdür. $g(\cdot)$ sürekli tam artan ve $g(1) = 0$, $g'(1) = 1$ eşitliklerinin sağlandığı tek bir argümanın fonksiyonudur. Diyelim ki $g(\cdot)$ 'nin ters fonksiyonu $F(u) = g^{-1}(u)$ olsun. $\sum_s w_j x_j = \sum_U x_j$ kalibrasyon eşitliğine bağlı olarak $\sum_s G_j(w_j, d_j)$ toplam uzaklığını minimize edip $w_j = d_j F(q_j x_j' \lambda)$ nihai ağırlıkları elde edilir. Kalibrasyon ağırlık düzeltme katsayısı;

$$g_j^{(CAL)} = F(q_j x_j' \lambda) \quad (3.22)$$

ile elde edilir. Burada gösterilen λ Lagrange çarpanı olup Eş. 3.23'ün çözülmesi sonucunda elde edilmektedir.

$$\sum_s d_j \mathbf{x}_j F(q_j \mathbf{x}'_j \lambda) = \sum_U \mathbf{x}_j \quad (3.23)$$

λ değeri elde edildikten sonra bu değeri kullanarak ulaşılan kalibrasyon tahmin edicisi

$$\hat{t}_{yCAL} = \sum_s w_j y_j = \sum_s d_j F(q_j \mathbf{x}'_j \lambda) y_j \quad (3.24)$$

biçiminde gösterilebilir. Bu tahmin edici, Y ve X arasında güçlü bir ilişki varsa $t = \sum_U y_j$ için yakın tahminler verecektir.

w_j ağırlıklarının en uygun olma özelliği vardır; çünkü gerekli kısıtları sağlayan amaç fonksiyonu minimize edilmiştir. Ancak; olası birçok uzaklık fonksiyonu ve q_j ölçekleri olduğu için bu bir "zayıf en uygunluk" olarak adlandırılır (Särndal; 2007).

Deville ve Särndal (1992) bilinen çeşitli uzaklık fonksiyonlarını ele alarak kalibrasyon tahmin edicileri türetmişlerdir. $F_j(u) = F_j(\mathbf{x}'_j \lambda)$ olmak üzere ele aldıkları uzaklık fonksiyonları Çizelge 3.5'te gösterilmiştir. Durum 1 ve 2 her zaman bir çözüm üretirken; Durum 3, 4 ve 5'te bir çözüm garanti edilememektedir. Durum 1 daha önce anlattığımız GREG tahmin edicisine dönüşebilmektedir; buradaki ağırlıklar negatif veya pozitif olabilmektedir. Diğer durumlar ise pozitif ağırlıkları garanti etmektedir. Tüm durumlarda nadir veya sıkıntılı örnekler için çok büyük ağırlıklar ortaya çıkabilmektedir.

Çizelge 3.5. Deville ve Särndal (1992) tarafından verilen uzaklık fonksiyonu örnekleri

DURUM	$q_j G_j(w_j, d_j)$	$g(w_j/d_j) = q_j g_j(w_j, d_j)$	$F_j(u) = F(q_j u)$
1	$(w_j - d_j)^2 / 2 d_j$	$w_j/d_j - 1$	$1 + q_j u$
2	$w_j \log(w_j/d_j) - w_j + d_j$	$\log(w_j/d_j)$	$\exp(q_j u)$
3	$2 \left(\sqrt{w_j} - \sqrt{d_j} \right)^2$	$2 \left\{ 1 - (w_j/d_j)^{-1/2} \right\}$	$(1 - q_j u/2)^{-2}$
4	$-d_j \log(w_j/d_j) + w_j - d_j$	$1 - (w_j/d_j)^{-1}$	$(1 - q_j u)^{-1}$
5	$(w_j - d_j)^2 / 2 w_j$	$\left\{ 1 - (w_j/d_j)^{-2} \right\} / 2$	$(1 - 2q_j u)^{-1/2}$

Durum 1 uygulanarak elde edilen nihai ağırlıklar kimi zaman negatif ağırlık içerebildiği gibi bazı durumlarda tasarım ağırlıklarından çok uzaklaşabilen ağırlıklar da ortaya çıkabilir. Durum 2 uygulanarak elde edilen ağırlıklarda da tasarım ağırlığına kıyasla çok büyük nihai ağırlıklar elde edilebilir. Ağırlıklarda ortaya çıkabilecek bu tip sorunlar tahmini etkileyeceğinden genellikle istatistikçiler tarafından olumsuz karşılanmaktadır. Bu sorunları dikkate alan Deville ve Särndal (1992), ağırlıkların istatistikçilerin belirlediği sınırlar arasında kalabildiği bazı fonksiyonlar önererek iki yeni durum ortaya koymuşlardır. Böylece; aşırı büyük ağırlıklar elimine edilirken, tahmin edicilerin iyi özellikleri korunmaktadır.

Durum 2'de $F_j(u) = \exp(q_j u)$ 'nin tanım aralığı $(0, \infty)$ 'dur. Ağırlıkları sınırlandırmak ve özellikle aşırı büyük ağırlıkları önlemek için Λ ve V sabitleri tanımlanmaktadır; öyle ki $\Lambda < 1 < V$ olmak üzere $A = (V - \Lambda) / \{(1 - \Lambda)(V - 1)\}$ kümesi kullanılarak Eş. 3.25 elde edilir.

$$F_j(u) = \frac{\Lambda(V-1) + V(1-\Lambda)\exp(Aq_j u)}{(V-1) + (1-\Lambda)\exp(Aq_j u)} \quad (3.25)$$

Eş. 3.25'e göre $F_j(-\infty) = \Lambda$, $F_j(\infty) = V$, $F_j(0) = 1$ ve $F_j'(0) = q_j$ olmaktadır. Bunun sonucunda $w_j = d_j F(q_j x'_j \lambda)$ ağırlıkları da $\Lambda d_j < w_j < V d_j$ arasında sınırlandırılır. Bu sonuçları elde edebilmek için kullanılması gereken uzaklık fonksiyonu ise q_j çarpım sabiti ile birlikte Eş. 3.26'da verilmiştir.

$$q_j G_j(w_j, d_j) = (z_j - \Lambda) \log \frac{z_j - \Lambda}{1 - \Lambda} + (V - z_j) \log \frac{V - z_j}{V - 1} \quad (3.26)$$

Burada $z_j = w_j / d_j$ olup; Λ büyük negatif ve V büyük pozitif bir değer alırsa Durum 1'e yakınsanır. Eğer $\Lambda = 0$ ve V büyük ise Durum 2'ye yakınsanır. Durum 2'yi sınırlandıran bu yaklaşım Deville ve Särndal (1992) tarafından Durum 6 olarak adlandırılmıştır.

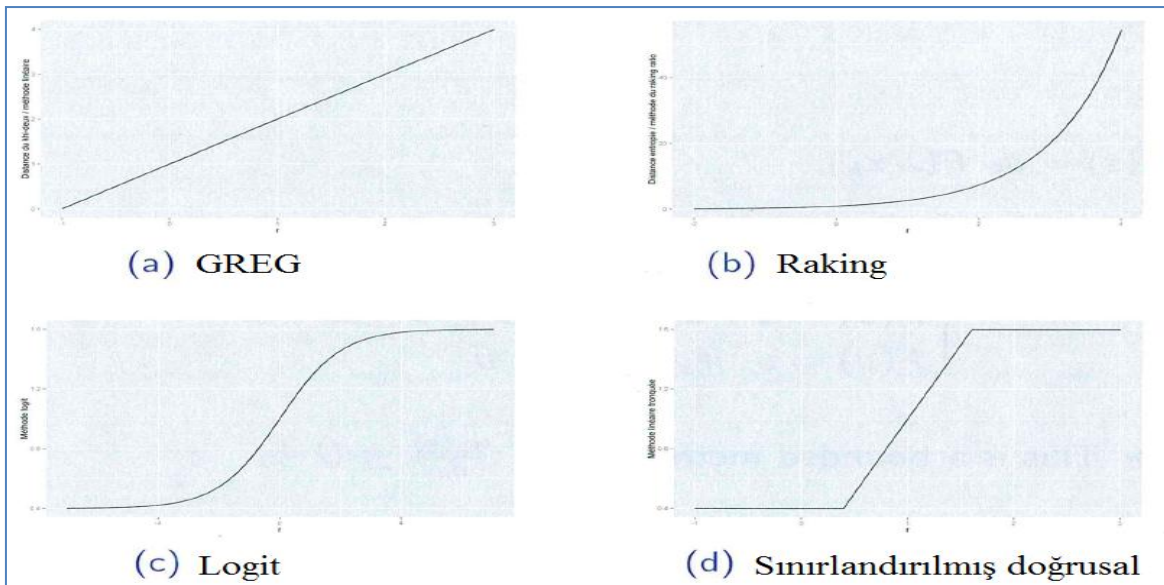
Durum 7'de ise Durum 1'de oluşan negatif ağırlık sorununu çözmek için bir öneri sunmuşlardır. Λ ve V sabitleri yine $\Lambda < 1 < V$ olmak üzere $F_j(u)$ fonksiyonu Eş. 3.27'deki gibi tanımlansın.

$$F_j(u) = \begin{cases} 1 + q_j u & \text{eğer } (\Lambda - 1)/q_j \leq u \leq (V - 1)/q_j \\ \Lambda & \text{eğer } u < (\Lambda - 1)/q_j \\ V & \text{eğer } u > (V - 1)/q_j \end{cases} \quad (3.27)$$

Bu eşitlik sonrasında w_j ağırlıkları $\Lambda d_j < w_j < V d_j$ arasında sınırlandırılır. Uzaklık fonksiyonu $\Lambda d_j < w_j < V d_j$ için Durum 1'in aynısıdır; aksi takdirde sonsuzdur. Λ pozitif seçildiği takdirde negatif ağırlıklarla hiçbir zaman karşılaşılmaz. Burada ele alınan 4 durum kalibrasyon çalışmalarında sıklıkla kullanılan yaklaşımlardır.

Durum 1, doğrusal kalibrasyon yaklaşımı olup $q_j = 1$ için GREG tahmin edicisi elde edilmektedir. Durum 2'de $q_j = 1$ alındığında raking yaklaşımı ortaya çıkmaktadır. Aşırı büyük ağırlıkların gelmesini engelleyen Durum 6 ve 7 ise sırasıyla logit ve sınırlandırılmış doğrusal kalibrasyon yaklaşımları olarak adlandırılmaktadır. Bu yaklaşımlar kullanılarak elde edilen toplam tahmin edicileri de sırasıyla \hat{t}_{yLOG} ve \hat{t}_{yTRN} ile gösterilecektir.

Şekil 3.1'de, doğrusal kalibrasyon olan GREG'in sınırlandırılarak nasıl sınırlandırılmış doğrusal kalibrasyon yaklaşımına dönüştüğü görülmektedir. Aynı şekle bakıldığında logit yaklaşımının da raking yaklaşımı için bir sınırlandırma getirdiği görülmektedir.



Şekil 3.1. Kalibrasyon fonksiyonlarının grafiksel gösterimi

Minimum uzaklık ile kalibrasyon işlemi özünde, $\sum_s w_j \mathbf{x}_j = \sum_U \mathbf{x}_j$ kısıtı altında $\min_{j \in S} \sum_s G_j(w, d)$ amaç fonksiyonunu çözen bir optimizasyon problemidir. Bu optimizasyon probleminde farklı uzaklık fonksiyonları kullanılarak ve/veya ekstra kısıtlar eklenerek değişik kalibrasyon tahmin edicileri elde edilebilir. Araştırmaların tahmin sürecinde sıklıkla kullanılan oran, regresyon, GREG vb. tahmin ediciler de minimum uzaklık yaklaşımı ile türetilir.

Örnek olarak GREG tahmin edicisinin minimum uzaklık yaklaşımı ile nasıl elde edildiği incelenecektir. Toplam uzaklığı minimize etmek için Lagrange eşitliği kullanılmaktadır.

$$L^\lambda = \sum_s G_j(w, d) - \lambda (\sum_s w_j \mathbf{x}_j - \sum_U \mathbf{x}_j) \quad (3.28)$$

$G_j(w, d)$ uzaklık ölçüsü olarak ki-kare uzaklık ölçüsüne dayanan ve Durum 1'de gösterilen $(w_j - d_j)^2 / 2 d_j$ fonksiyonu ile $q_j = 1$ değeri kullanıldığında Lagrange eşitliği,

$$L^\lambda = \frac{1}{2} \sum_s (w_j - d_j)^2 / d_j - \lambda (\sum_s w_j \mathbf{x}_j - \sum_U \mathbf{x}_j) \quad (3.29)$$

biçimine dönüşür. w_j 'ye göre türev alınarak çözüm yapıldıktan sonra $\lambda \sum_s \mathbf{x}_j = \mathbf{x}'_j \lambda$ şeklinde ifade edilebilir. Bu ifade kullanılarak w_j nihai ağırlıkları Eş. 3.31'deki gibi yazılabilir.

$$\frac{\partial L^\lambda}{\partial w} = \left[\frac{w_j}{d_j} - 1 \right] - \lambda \sum_s \mathbf{x}_j = 0 \quad (3.30)$$

$$w_j = d_j(1 + \mathbf{x}'_j \lambda) \quad (3.31)$$

$T_s = \sum_s d_j q_j \mathbf{x}_j \mathbf{x}'_j$ olmak üzere Lagrange çarpanı $\lambda = T_s^{-1}(\mathbf{t}_x - \hat{\mathbf{t}}_{xHT})$ olarak belirlendiğinde, elde edilen tahmin edici Eş. 3.32'de gösterilmiştir. Bu tahmin edici Eş. 3.10 ve Eş. 3.11'in birlikte kullanılmasıyla elde edilecek olan GREG tahmin edicisine eşittir.

$$\hat{\mathbf{t}}_{yGREG} = \sum_s w_j y_j = \hat{\mathbf{t}}_{yHT} + (\mathbf{t}_x - \hat{\mathbf{t}}_{xHT})' T_s^{-1} d_j q_j \mathbf{x}_j \quad (3.32)$$

Eş. 3.32'de yardımcı değişkenler vektörü $x_j = x_j$ biçiminde tek değişkenli olduğu durumda $q_j = 1/x_j$ alınır. Lagrange çarpanı $\lambda = (t_x/\hat{t}_{xHT}) - 1$ olacaktır. Bu λ eşitliği için ise nihai ağırlık $w_j = d_j(1 + \lambda) = d_j(t_x/\hat{t}_{xHT})$ olacaktır. Bu değer Eş. 3.32'de yerine konulduğunda ise

$$\hat{t}_{yR} = \sum_s w_j y_j = \hat{t}_{yHT} (t_x/\hat{t}_{xHT}) \quad (3.33)$$

oran tahmin edicisi elde edilmektedir. Minimum uzaklık yaklaşımı kullanılarak sonradan-tabakalama tahmin edicisi ve genelleştirilmiş raking yaklaşımlarının elde edilişleri de Deville, Särndal ve Sautory (1993) çalışmasında detaylı biçimde gösterilmiştir.

Genellikle farklı $F_j(u)$ fonksiyonları farklı tahmin ediciler türetir. Ancak; orta ve büyük çaplı örneklerde bu tahmin edicilerin ürettiği tahminlerin küçük farklılıklar göstermesi beklenir. Bu durumun sebebi herhangi bir \hat{t}_{yCAL} tahmin edicisinin asimptotik olarak GREG tahmin edicisine denk olmasıdır. Bu durumun sonucu olarak \hat{t}_{yCAL} tahmin edicisinin asimptotik varyansı ve varyans tahmin edicisi GREG ile aynı olup; sırasıyla Eş. 3.14 ve Eş. 3.15'te verilmiştir. Burada farklı kalibrasyon tahmin edicileri için elde edilecek farklı g_j ağırlık düzeltme katsayıları, tahmin edicilerin varyans tahminlerini farklılaştıracaktır. Uygulama aşamasında elde edilen sonuçlarda farklı kalibrasyon tahmin edicileri için tahmin edilen varyansların belirgin biçimde farklı olduğu görülmektedir.

Minimum uzaklık yaklaşımı ile elde edilen kalibrasyon tahmin edicilerinde, GREG tahmin edicisinde belirtilen 4 dezavantaj ortaya çıkabilmektedir. Bunlara ek olarak; ağırlıkları sınırlandıran uzaklık fonksiyonları kullanıldığında, kısıtların sağlanmaması yüzünden çözüm bulunamayabilir. Böyle bir durumla karşılaşıldığında alt ve üst sınırlar gözden geçirilerek, $\Lambda < 1 < V$ koşulu bozulmadan alt ve üst sınırlarda güncellemeye gidilmelidir. Bu güncelleme yapılırken; GREG ve raking yaklaşımlarında elde edilen minimum ve maksimum kalibrasyon katsayılarına küçük arttırma ve azaltmalarla yakınsanmalıdır. Bu şekilde sınırlandırılmış yaklaşımlardan optimum sonuç alınabilecektir.

3.5. Alternatif Kalibrasyon Tahmin Edicileri

Deville ve Särndal (1992) tarafından önerilen minimum uzaklık yöntemi ile kalibrasyon yaklaşımı konusunda takip eden yıllarda birçok çalışma gerçekleştirilmiştir. Deville, Särndal ve Sautory (1993), Singh ve Mohl (1996) ile Stukel, Hidiroglou ve Särndal (1996) alternatif uzaklık fonksiyonlarını karşılaştırmışlardır. Bazı uzaklık fonksiyonları ağırlıkların belirlenen sınırlar içerisinde kalmasını garanti ederek çok büyük ve çok küçük ağırlıklar gelmesini engellemektedir. Uzaklık fonksiyonundaki değişimlerin, örnek çapı küçük olsa bile genellikle kalibrasyon tahmin edicisi \hat{t}_{yCAL} varyansı üzerinde çok küçük etkisi vardır (Särndal, 2007).

Yardımcı değişkenlerdeki aykırı değerler çok büyük ağırlıklara neden olabilir. Aykırı değer olması durumunda kalibrasyon konusu Duchesne (1999) tarafından ele alınmıştır. Duchesne tarafından önerilen "Sağlam kalibrasyon" tekniği tahminlerde açık sapmalar ortaya koyabilir; ancak varyanstaki düşüşle bunu dengeleyebilir. Théberge (2000), ağırlıkların belirli sınırlar içerisinde kalmasını sağlayan kısıtların optimizasyon probleminin çözümünü garanti etmediği durumları incelemiştir. Aynı çalışmada aykırı değerlerle mücadele etmek için de bir yöntem önermiştir. Estevao ve Särndal (2000), uzaklık fonksiyonu yaklaşımının kalibrasyon için tek başlangıç noktası olmayacağını ileri sürerek fonksiyonel biçim yaklaşımını ortaya koymuşlardır. Kalibre edilmiş ağırlıklar iki parametreye bağlı basit fonksiyonel bir biçimde gösterilmiştir.

Isaki, Tsay ve Fuller (2004), hanehalkı araştırmalarında hane ve fert ağırlıklarının her ikisini de belirlenen sınırlar arasında elde etmek için bir kuadratik programlama düşünmüşlerdir. Birçok çalışma geleneksel ağırlık yaklaşımının aksine cevapsızlık düzeltilmesi için kalibrasyon üzerinde durmuştur. Konu hakkında Deville (1998, 2002), Skinner (1998), Lundström ve Särndal (1999), Folsom ve Singh (2000), Fuller (2002), Särndal ve Lundström (2005), Ardilly (2006), Kott (2006), Brick ve Montaquila (2009), Brick (2013)'in çalışmaları öne çıkmaktadır. Bu çalışmalar sonrasında cevapsızlık düzeltilmesi ve kalibrasyonun tek aşamalı kalibrasyonla mı, yoksa iki aşamalı biçimde mi ele alınması gerektiği Estevao ve Särndal (2009), Kott ve Liao (2015), Haziza ve Lesage (2016) tarafından incelenmiştir. Cevapsızlık düzeltilmesi için kalibrasyon yaklaşımından faydalanan araştırmacılar da genellikle minimum uzaklık yönteminden faydalanmışlardır.

Uzaklık minimizasyonu yaklaşımına alternatif bir yöntem olarak enstrüman vektör yöntemi Deville (1998), Estevao ve Särndal (2000, 2006) ve Kott(2006) çalışmalarında önerilmiştir. Bu yöntemde minimum uzaklık yaklaşımı için kullanılan aynı bilgiler kullanılarak birçok ağırlıklar kümesi alternatifleri türetilmektedir.

Diğer bir alternatif yaklaşım ise model-kalibrasyon yaklaşımıdır. Wu ve Sitter (2001) tarafından önerilen yöntem Wu (2003), Montanari, Ranalli (2003, 2005) çalışmalarıyla sürdürülmüştür. Yöntemdeki motive edici faktör, modelden bağımsız kalibrasyon yaklaşımında $\sum_U x_j$ bilinmesi yeterliyken burada her $j \in U$ olmak üzere tam yardımcı bilgi x_j 'nin bilinmesine bağlı olarak yardımcı bilginin daha etkin kullanılabilmesidir. Diğer yandan model-kalibrasyonunda ağırlıklar y değerlerine bağlı olduğundan gerçekten bir kalibrasyon tahmin edicisi olduğu da tartışmalıdır.

Minimum uzaklık yöntemi dışında önerilen alternatif kalibrasyon tahmin edicileri model-kalibrasyon yaklaşımı gibi detaylı bilgiye veya Isaki, Tsay ve Fuller (2004) çalışmasındaki gibi özel programlama çözümlerine ihtiyaç duymaktadır. Bu alternatifler literatüre katkı sağlamakla birlikte iş istatistikleri gibi süreli (aylık, dönemlik, yıllık vb.) üretilmesi gereken istatistiklerde uygulanabilir değildir. Diğer yandan, minimum uzaklık yöntemine dayalı olarak üretilen kalibrasyon yöntemleri bu konuda önemli bir avantaja sahiptir. Başta ulusal istatistik ofisleri olmak üzere istatistik çevreleri tarafından kullanılan SAS yazılımında minimum uzaklık yöntemlerinin kullanılabilirdiği CALMAR isimli bir makro hazırlanmıştır. Ayrıca, minimum uzaklık yöntemlerinin uygulanabilmesi için diğer bir yaygın istatistik yazılımı olan R yazılımında da birçok paket yer almaktadır.

Bu tez çalışmasının simülasyon ve gerçek veri uygulama aşamalarında bahsi geçen nedenlerden ötürü minimum uzaklık yaklaşımlarından elde edilen kalibrasyon tahmin edicileri karşılaştırılmıştır. Bu yaklaşımla elde edilen tüm kalibrasyon tahmin edicilerinin asimptotik olarak GREG tahmin edicisine gittiği önceki makale çalışmalarında teorik olarak gösterilmiştir. Ancak uygulamada, asimptotik yaklaşımı sağlayacak koşullar her zaman sağlanmadığından; bu durumlar için tahmin ediciler arasındaki farklılıklar incelenmiştir.

4. SİMÜLASYON ÇALIŞMASI

Başta ulusal istatistik ofisleri olmak üzere büyük çaplı araştırmalar gerçekleştiren kurum/kuruluşlar elde ettikleri değişkenlere ilişkin birçok istatistik üretmektedirler. İdari kayıt verileri, büyük ölçekli araştırma bilgileri vb. dışsal veri kaynaklarının kullanım imkanlarının artmasıyla, istatistiklerin yardımcı bilgilerden faydalanarak üretilmesi daha yaygın hale gelmektedir. Çok fazla değişken için tahminler üreten istatistikçiler yardımcı bilgi kullanımında tasarım-bazlı yaklaşıma bağlı kalmayı tercih etmektedirler. Bu amaçla; genellikle 3. Bölüm'de açıklanan kalibrasyon tahmin edicilerinden birini kullanmaktadırlar. Minimum uzaklık yaklaşımına göre üretilen kalibrasyon tahmin edicilerinin asimptotik olarak GREG tahmin edicisine denk olduğu Deville ve Särndal (1992) çalışmasında belirtilmiştir. Diğer yandan, Duchesne (1999) yardımcı değişkende aykırı değer olması durumunda geleneksel kalibrasyon tahmin edicilerinin etkilendiğini öne sürerek farklı bir kalibrasyon tahmin edicisi önermiştir.

Minimum uzaklık yaklaşımına göre türetilmiş olan kalibrasyon tahmin edicilerinin asimptotik eşitliği bilinmekle birlikte, uygulamada çıkabilecek sorunları görmek için bir simülasyon çalışması gerçekleştirilmiştir. Buradaki amaç, hedef değişken ile yardımcı değişkenlerde aykırı değerler olması ve yardımcı değişkenlerin hedef değişkenle farklı korelasyonlarda olması durumunda kalibrasyon tahmin edicilerinin etkinliklerinin karşılaştırılmasıdır. Bu amaçla, 3. Bölümde açıklanan kalibrasyon tahmin edicileri Durum 1 (\hat{t}_{yGREG}), Durum 2 (\hat{t}_{yRAK}), Durum 6 (\hat{t}_{yLOG}), Durum 7 (\hat{t}_{yTRN}) ile HT tahmin edicisinin etkinlikleri çeşitli durumlar için karşılaştırılmıştır.

4.1. Farklı Korelasyon Yapıları İçin Kalibrasyon Tahmin Edicilerinin Etkinliği

Bu uygulamada kalibrasyon tahmin edicileri karşılaştırılırken yardımcı değişken ve hedef değişken arasında oluşabilecek korelasyonlara göre 5 farklı alternatif durum türetilmiştir. Buna göre, hedef değişken Y ve yardımcı değişkenler X_1 ve X_2 arasındaki korelasyon ilişkileri Çizelge 4.1'de gösterilmiştir.

Çizelge 4.1'de verilen alternatif durumlar için $N=10\ 000$ büyüklüğünde Üstel Dağılımlı yığınlar ($Y \sim Exp[\theta = 10^{-6}]$) oluşturulmuş; $n=500$ büyüklüğünde örnekler BRÖ yöntemi kullanılarak $R=50\ 000$ tekrarla seçilmiştir. Burada Üstel Dağılım kullanılmasının nedeni;

arařtırmalarda tahmin edilmek istenen ciro, yatırım, gelir vb. hedef deęişkenlerin Üstel Daęılım gibi saęa çarpık yapıda olmasıdır. Elde edilen örnek birimler kullanılarak 4 kalibrasyon tahmin edicisinin etkinlikleri karşılaştırılmıştır.

Çizelge 4.1. Hedef deęişken Y ve yardımcı deęişkenler X_1 ve X_2 korelasyon deęerleri

ALTERNATİF	ρ_{YX_1}	ρ_{YX_2}	$\rho_{X_1X_2}$
1	0,90	0,45	0,10
2	0,70	0,65	0,10
3	0,90	0,80	0,50
4	0,50	0,35	0,05
5	0,50	0,35	0,50

Simülasyon çalışması sonucunda Deville ve Särndal (1992) çalışmasında belirtilen asimptotik tasarım sapmasızlık özellięi belirgin biçimde görülmüştür. Simülasyon sonucu elde edilen sapma deęerleri çok küçük olup ihmal edilebilir. Hedef deęişkeni yardımcı bilgi kullanmadan tahmin eden HT tahmin edicisi için varyans $V(\hat{t}_{yHT}) = 194\,048 * 10^{12}$ olup; Çizelge 4.2'de ilgili tahmin edicilerin simülasyon sonucu varyans tahminleri elde edilerek görel etkinlikleri karşılaştırılmıştır. Varyans tahminlerinde tekrar sayısı $R=50\,000$ olmak üzere Monte Carlo Simülasyon yaklaşımından faydalanılmıştır. Buna göre; \hat{t}_{ym} genel kalibrasyon tahmin edicisini tanımlamak üzere 5 tahmin edicinin her biri ile 5 alternatif için beklenen deęer ve varyans sırasıyla Eş. 4.1 ve Eş. 4.2'deki gibi hesaplanmıştır. Eş. 4.3'te ise tahmin edicilerin simülasyon sonucunda elde edilen varyansları ile bilinen HT varyansı kullanılarak görel etkinliklerin (RE) hesaplanması gösterilmiştir. Simülasyon çalışmasına ilişkin R kodları Ek 1'de verilmiştir.

$$E(\hat{t}_{ym}) = \frac{\sum_{i=1}^R (\hat{t}_{ym})_i}{R} \quad m = 1, \dots, 5 \quad (4.1)$$

$$\hat{V}(\hat{t}_{ym}) = \frac{1}{R} \sum_{i=1}^R \left[(\hat{t}_{ym})_i - E(\hat{t}_{ym}) \right]^2 \quad m = 1, \dots, 5 \quad (4.2)$$

$$RE(\hat{t}_{yHT}, \hat{t}_{ym}) = \frac{V(\hat{t}_{yHT})}{\hat{V}(\hat{t}_{ym})} \quad m = 1, \dots, 5 \quad (4.3)$$

Çizelge 4.2'de verilen sonuçları incelediğimizde 4 farklı kalibrasyon yaklaşımının aynı alternatif durum için önemli farklılık göstermediği görülmektedir. Deville ve Särndal (1992), farklı $F_j(u)$ için elde edilen alternatif tahmin edicilerin ılımlı koşullar altında ve/veya örnek çapları büyüdükçe birbirlerinden ufak farklılıklar göstereceğini ispatlamıştır.

Çizelge 4.2. Kalibrasyon tahmin edicilerinin farklı durumlardaki görelî etkinliđi

ALTERNATİF	$RE(\hat{t}_{yHT})$	$RE(\hat{t}_{yGREG})$	$RE(\hat{t}_{yRAK})$	$RE(\hat{t}_{yTRN})$	$RE(\hat{t}_{yLOG})$
1	0,99	13,47	13,50	13,47	13,49
2	1,00	5,27	5,27	5,27	5,27
3	0,99	30,37	30,34	30,37	30,34
4	1,00	1,54	1,54	1,54	1,54
5	0,99	1,34	1,34	1,34	1,34

Bu uygulamada verimizin türetilmiş bir veri olması nedeniyle dağılımı bozuk bir yapı veya aykırı değer sorunu gibi sorunlar içermemesi ılımlı koşulları sağlamış; ayrıca $n=500$ örnek çapının yeterince büyük olması da asimptotik özelliklerin çalışmasına yardımcı olmuştur. Çizelge 4.2'deki alternatif durumlar incelendiğinde; bu tip bir veri yapısında hedef değişkene ilişkin düşük varyanslı bir tahmin elde edebilmek için hangi tahmin edicinin seçildiđi değil hedef değişkenle ilişkisi yüksek yardımcı değişkenler bulunması gerektiđi anlaşılmaktadır. En büyük görelî etkinliđin ortaya çıktığı "Alternatif 3"de X_1 ve X_2 yardımcı değişkenlerinin Y ile korelasyonu sırasıyla 0,90 ve 0,80'dir. Yardımcı değişkenler X_1 ve X_2 arasındaki 0,50 büyüklüğündeki korelasyon, HT tahmin edicisine göre çok daha küçük varyanslı kalibrasyon tahmin edicileri elde edilmesini engellememiştir. Yardımcı değişkenlerin Y ile korelasyonunun sırasıyla 0,90 ve 0,45; X_1 ve X_2 arasındaki korelasyonun 0,10 olduđu "Alternatif 1" için en iyi ikinci görelî etkinlik ortaya çıkmaktadır. Yardımcı değişkenlerin aralarındaki korelasyonun "Alternatif 1" ile aynı (0,10) olduđu; ancak Y ile korelasyonların sırasıyla 0,70 ve 0,65 olduđu "Alternatif 2" daha büyük bir varyans ile sonuçlanmaktadır. Buradan hedef değişken ile korelasyonu fazla iki yardımcı değişken kullanmaktansa; hedef değişkenle korelasyonu çok fazla olan bir yardımcı değişken ve hedef değişkenle orta düzeyde korelasyonlu ikinci bir yardımcı değişken kullanmanın daha etkin olduđu ortaya çıkmaktadır.

4.2. Aykırı Değerli Hedef Değişkende Kalibrasyon Tahmin Edicilerinin Etkinliği

Bu bölümde tahmin edilecek hedef değişkenin aykırı değer sorunu içerdiği durum ele alınmıştır. Burada daha önce türetilmiş olan $N=10\ 000$ büyüklüğündeki Üstel Dağılımlı yığınlardan faydalanılmıştır. Önceki çalışmadan farklı olarak $n=500$ büyüklüğündeki örneklerin aykırı değer içermesi için Y değişkeninin en büyük 25 değer aldığı birimlerin örnekte yer aldığı varsayılarak $N'=9975$ birimden $n'=475$ örnek seçilmiştir. Ancak hesaplamalarda tasarım ağırlığı (d) 10 000'den 500 birim seçilmiş gibi hesaplanmıştır. Bu yaklaşımdan dolayı HT tahmin edicimiz teoride olması gereken sapmasız tahmin edici özelliğini yitirmiştir. Diğer yandan bu uygulama çeşitli nedenlerden dolayı aykırı değer içeren örneklerin tahmin üzerindeki etkilerini ve kalibrasyon tahmin edicilerinin bu durumdaki etkinliklerini görmek için gerçekleştirilmiştir. Başta HT tahmin edicisinin sapmalı olması nedeni ile bu bölümde yapılan karşılaştırmalar varyans yerine MSE üzerinden gerçekleştirilmiştir. MSE değerleri Eş. 4.4 kullanılarak elde edilmiştir. Göreliliklerin hesaplanması için de Eş. 4.5 kullanılmıştır.

$$\widehat{MSE}(\hat{t}_{ym}) = \frac{1}{R} \sum_{i=1}^R \left[(\hat{t}_{ym})_i - t_y \right]^2 \quad m = 1, \dots, 5 \quad (4.4)$$

$$RE(\hat{t}_{yHT}, \hat{t}_{ym}) = \frac{\widehat{MSE}(\hat{t}_{yHT})}{\widehat{MSE}(\hat{t}_{ym})} \quad m = 2, \dots, 5 \quad (4.5)$$

Çizelge 4.3. Aykırı Y olan veride kalibrasyon tahmin edicilerinin görelilikleri

ALTERNATİF	$RE(\hat{t}_{yGREG})$	$RE(\hat{t}_{yRAK})$	$RE(\hat{t}_{yTRN})$	$RE(\hat{t}_{yLOG})$
1	85,72	77,36	85,20	77,94
2	27,76	25,77	27,70	25,91
3	303,18	264,83	300,61	267,37
4	3,33	3,31	3,33	3,31
5	2,78	2,79	2,78	2,79

Çizelge 4.3 incelendiğinde aşağıdaki sonuçları elde etmek mümkündür:

- ✓ Yardımcı değişkenlerin hedef değişkenle en yüksek korelasyona sahip olduğu durum olan Alternatif 3'te en yüksek etkinlik görülmektedir.

- ✓ X değişkenlerinin korelasyonunun Y değişkeni ile yüksek olduğu Alternatif 1, 2 ve 3'te GREG ve onun sınırlandırılmış biçimi olan TRN kalibrasyonlarının raking (RAK) ve logit (LOG) kalibrasyonlara göre daha etkin olduğu net biçimde gözlenmektedir. X değişkenleri ile Y arasındaki korelasyonun az olduğu Alternatif 4'te etkinlik farkı çok azdır. Benzer şekilde korelasyonun az olduğu; ancak buna ek olarak X değişkenlerinin arasında çoklu bağlantı olan Alternatif 5'te ise 4 tahmin edicinin etkinlikleri arasında neredeyse fark yoktur.
- ✓ Teorik olarak TRN kalibrasyonu GREG kalibrasyonunda oluşan aykırı ağırlıkları, LOG kalibrasyonu da RAK kalibrasyonunda oluşan aykırı ağırlıkları sınırlandırmaktadır. Dolayısıyla ağırlıklara bağlı olarak oluşan varyans da TRN ve LOG kalibrasyonlarıyla azaltılacaktır. Burada hedef değişken olan Y değerlerinin aykırı değer içermesi kalibrasyon tahmin edicisini direkt olarak etkilememektedir. Zira tüm kalibrasyon ağırlıkları hesaplanırken Y değerlerinden etkilenmeyen bir formül olan $w_j = d_j F(q_j x'_j \lambda)$ formülünden faydalanılmaktadır.

Burada dikkat çekici nokta, örnekte hedef değişken aykırı değer içeriyorsa kalibrasyon tahmin edicilerinin hedef değişkenin tahminindeki görece etkinliğinin sorunsuz veri setlerine göre çok daha fazla olmasıdır. Bölüm 4.1'de üretilen ve aykırı değer içermeyen veri seti sorunsuz veri seti olarak değerlendirilmiştir. Çizelge 4.4'te, Bölüm 4.1'de elde edilen GREG'in HT'ye görece etkinliği ile bu bölümde elde edilen GREG'in HT'ye görece etkinliği karşılaştırılmıştır. GREG tahmin edicisinin sorunsuz veri setindeki görece etkinliği 1,34 ile 30,37 aralığındayken; aykırı değer olduğu durumda görece etkinlik 2,78 ile 303,18 aralığında gerçekleşmiştir. Özellikle hedef değişkenle korelasyonu yüksek yardımcı değişken kullanıldığı Alternatif 3 durumunda görece etkinlik 300 kata kadar çıkmaktadır.

Çizelge 4.4. Sorunsuz veri seti ve aykırı hedef değişken (Y) içeren veri setlerinde GREG'in HT'ye görece etkinliği

ALTERNATİF	1	2	3	4	5
Sorunsuz veri seti	13,47	5,27	30,37	1,54	1,34
Aykırı Y değerli veri seti	85,72	27,76	303,18	3,33	2,78

Hedef değişkenle yardımcı değişkenler arasındaki ilişkinin zayıf olduğu ve çoklu doğrusal bağlantı olan Alternatif 5 için dahi aykırı değerli veri setindeki görece etkinlik (2,78)

sorunsuz veri setindeki göreceli etkinliğin (1,34) yaklaşık iki katıdır. Hedef değışkende aykırı değerler olması durumunda klasik tahmin edici olan HT tahmin edicisinin etkinliğinin ciddi anlamda bozulduğu görülmektedir. Bozulmanın kaynağı varyanstan ziyade büyük bir sapmanın oluşmasıdır. Kalibrasyon tahmin edicileri oluşan bu sapmayı ciddi anlamda azaltırken tamamen sapmasız bir tahmin edici elde edememektedir. Çizelge 4.5'te $t_y = 9,85 * 10^9$ olan yığın parametresinin simülasyon çalışması sonucunda elde edilen göreceli sapma değerleri verilmiştir. Göreceli sapma Eş. 4.6'da gösterilen biçimde hesaplanmıştır.

$$RB(\hat{t}_{ym}) = \frac{E(\hat{t}_{ym})}{t_y} \quad m = 1, \dots, 5 \quad (4.6)$$

Çizelge 4.5. Aykırı Y değerli veride simülasyon sonucundaki göreceli sapmalar

ALTERNATİF	$RB(\hat{t}_{yHT})$	$RB(\hat{t}_{yGREG})$	$RB(\hat{t}_{yRAK})$	$RB(\hat{t}_{yTRN})$	$RB(\hat{t}_{yLOG})$
1	1,30	1,03	1,03	1,03	1,03
2	1,30	1,06	1,06	1,06	1,06
3	1,30	1,02	1,02	1,02	1,02
4	1,30	1,16	1,17	1,16	1,17
5	1,30	1,18	1,18	1,18	1,18

Çizelge 4.5'te elde edilen değerlere bakıldığında kalibrasyon tahmin edicilerinin özellikle aykırı değer içeren veri setlerinde kullanımının önemi görülmektedir. Kalibrasyon tahmin edicilerinin birbirlerinden büyük farklılık göstermediği durumların nedeni olarak örnek çapının büyük olması ve daha önce bahsettiğimiz ılımlı koşulların fazla bozulmaması düşünülebilir. Daha küçük örnek çaplarında dört kalibrasyon tahmin edicisinin sonuçlarında belirgin farklılıklar oluşması beklenebilir. Ayrıca, TRN ve LOG yöntemleri her örnek için ayrı olarak tasarlandığında, yani her örnek verisi için sınırlar özel olarak belirlendiğinde daha etkin sonuç verebilecektir. Bu bir simülasyon çalışması olduğundan sistematik bir şekilde sınırlar belirlenmiştir.

4.3. Aykırı Değerli Yardımcı Değişkende Kalibrasyon Tahmin Edicilerinin Etkinliği

Tahmin edilecek hedef değışkenin yanı sıra kalibrasyon aşamasında kullanılan yardımcı değışkenler için de aykırı değer sorunu ortaya çıkabilir. Yardımcı değışkenlerde görülen

aykırı değerler kalibrasyon tahmin edicilerini hedef değişken Y 'de görülen aykırı değerlerden daha çok etkileyebilecektir. Bunun nedeni, Bölüm 4.2'de belirtildiği gibi kalibrasyon ağırlıkları $w_j = d_j F(q_j x'_j \lambda)$ değerlerinin yardımcı değişkenlerden etkilenmesidir.

Yardımcı değişkenlerde görülebilecek aykırı değerlerin kalibrasyon tahmin edicilerinin etkinliğine olan etkisini araştırmak için Bölüm 4.2'de Y için kullanılan yaklaşım benimsenmiştir. Buna göre; daha önce türetilmiş olan $N=10\ 000$ büyüklüğündeki Üstel Dağılımlı yığınlardan faydalanılmıştır. Yardımcı değişken X_1 için en büyük 25 değer alan birimlerin örnekte yer aldığı varsayılmıştır. Veri setinde geriye kalan $N'=9975$ birimden $n'=475$ örnek seçilerek; bu işlem $R=50\ 000$ kez tekrar edilmiştir. Tahmin ediciler hesaplanırken tasarım ağırlığı (d) $10\ 000$ 'den 500 birim seçilmiş gibi hesaplanmıştır. Bu uygulama yardımcı değişken X_2 için de aynı şekilde tekrar edilmiştir. Yardımcı değişken X_1 'in aykırı değer içerdiği durumda HT tahmin edicisi ve kalibrasyon tahmin edicilerinin etkinlikleri Çizelge 4.6'da gösterilmiştir. MSE değerleri Eş. 4.4 kullanılarak elde edilmiştir. Ayrıca Eş. 4.5 yardımıyla her alternatif için göreceli etkinlik değerleri hesaplanarak Çizelge 4.7'de verilmiştir.

Çizelge 4.6. Aykırı X_1 olan veride kalibrasyon tahmin edicilerinin MSE tahminleri (10^{12})

ALTERNATİF	$\widehat{MSE}(\hat{t}_{yHT})$	$\widehat{MSE}(\hat{t}_{yGREG})$	$\widehat{MSE}(\hat{t}_{yRAK})$	$\widehat{MSE}(\hat{t}_{yTRN})$	$\widehat{MSE}(\hat{t}_{yLOG})$
1	7 594 894	77 185	87 322	77 312	86 500
2	3 668 619	114 273	113 649	116 059	113 802
3	7 594 780	28 435	32 579	28 572	32 247
4	827 918	134 186	151 914	133 802	149 726
5	822 816	250 836	282 302	250 117	279 241

Çizelge 4.7. Aykırı X_1 olan veride kalibrasyon tahmin edicilerinin göreceli etkinliği

ALTERNATİF	$RE(\hat{t}_{yGREG})$	$RE(\hat{t}_{yRAK})$	$RE(\hat{t}_{yTRN})$	$RE(\hat{t}_{yLOG})$
1	98,40	86,98	98,24	87,80
2	32,10	32,28	31,61	32,24
3	267,09	233,12	265,81	235,52
4	6,17	5,45	6,19	5,53
5	3,28	2,91	3,29	2,95

Çizelge 4.6 ve Çizelge 4.7 incelendiğinde aşağıdaki sonuçları elde etmek mümkündür:

- ✓ GREG tahmin edicisi ile sınırlandırılmış biçimi olan TRN'nin MSE değerleri birbirine yakındır. Aynı şekilde RAK tahmin edicisi ile sınırlandırılmış biçimi olan LOG tahmin edicilerinin etkinlikleri incelendiğinde aralarında belirgin bir farklılık yoktur. Bu sonuca bakarak; yardımcı değişkenin aykırı değer içermesinin aykırı kalibrasyon ağırlıkları yaratmadığı söylenebilir.
- ✓ Alternatif 1 ve Alternatif 3 için HT tahmin edicisinin MSE değerleri sırasıyla $7\,594\,894 \cdot 10^{12}$ ve $7\,594\,780 \cdot 10^{12}$ olarak bulunmuştur. Bu değerler Çizelge 4.3'te verilen ve Y 'nin aykırı değer içerdiği MSE değerine yakındır. Bunun nedeni X_1 'in hedef değişken Y ile 0,90 gibi yüksek bir korelasyona sahip olmasıdır. Diğer yandan Alternatif 3'ün kalibrasyon tahmin edicilerinin Alternatif 1'den daha etkin olmasının nedeni X_2 'nin Alternatif 3'te Y ile daha büyük korelasyona sahip olmasıdır.
- ✓ Alternatif 2, 4 ve 5 için HT tahmin edicilerinin MSE değerleri Çizelge 4.3'te yer alan karşılıklarına göre çok daha düşüktür. Bunun nedeni; bu alternatiflerde Y ile X_1 arasında düşük korelasyon olmasından dolayı X_1 'de görülen aykırı değerlerin t_y tahminini sınırlı biçimde etkilemesidir.

Yardımcı değişken X_1 'de görülen aykırı değerler hedef değişken Y 'de görülen aykırı değerlerde olduğu gibi HT tahmin edicisinin sapmasızlık özelliğini bozarak etkinliğini azaltmaktadır. HT ve kalibrasyon tahmin edicilerindeki görel sapmayı değerlendirmek için $t_y = 9,85 \cdot 10^9$ parametre değeri için Eş. 4.6 kullanılarak görel sapmalar Çizelge 4.8'deki gibi hesaplanmıştır. Kalibrasyon tahmin edicilerinin X_1 'de görülen aykırı değerlerin yarattığı sapmayı başarılı bir biçimde azalttığı görülmektedir. Çizelge 4.8'e bakıldığında kalibrasyon tahmin edicilerinin hedef değişkenin yanı sıra yardımcı değişkende aykırı değer olması durumunda da kullanımının ne kadar önemli olduğu görülmektedir.

Çizelge 4.8. Aykırı X_1 değerli veride simülasyon sonucundaki görel sapmalar

ALTERNATİF	$RB(\hat{t}_{yHT})$	$RB(\hat{t}_{yGREG})$	$RB(\hat{t}_{yRAK})$	$RB(\hat{t}_{yTRN})$	$RB(\hat{t}_{yLOG})$
1	1,28	1,03	1,03	1,03	1,03
2	1,19	1,03	1,03	1,03	1,03
3	1,28	1,02	1,02	1,02	1,02
4	1,08	0,98	0,98	0,99	0,98
5	1,08	0,96	0,96	0,96	0,96

Yardımcı değişken X_2 için de aykırı değer yer alması durumunun incelenmesi için aynı işlemler gerçekleştirilerek Çizelge 4.9, Çizelge 4.10 ve Çizelge 4.11 elde edilmiştir. Çizelge 4.9 incelendiğinde; Çizelge 4.6'da elde edilen sonuçlarla temel olarak benzerlik göstermektedir. X_2 'nin X_1 'e göre Y ile daha düşük korelasyonlu olduğu Alternatif 1 için, Y ile yüksek korelasyonlu X_1 'in kalibrasyonda yer almasıyla X_2 'de görülen aykırı değerlerin etkisi giderilmiştir. Böylece; Alternatif 1'in kalibrasyon tahmin edicilerinde Çizelge 4.9'da görüldüğü gibi MSE değerlerinde önemli bir düşüş olmuştur. Bu düşüşün nedeni, Çizelge 4.11'de görüldüğü gibi Alternatif 1 için kalibrasyon tahmin edicilerinin sapmasız olmasıdır.

Alternatif 2 için HT tahmin edicisinin yüksek olan MSE değeri kalibrasyon tahmin edicileriyle ciddi biçimde azaltılmıştır. Alternatif 3 için ise X_1 'in aykırı değer içerdiği durum ile benzer sonuçlar ortaya çıkmıştır. X_1 ve X_2 'nin Y ile 0,90 ve 0,80 gibi yakın korelasyona sahip olması bu durumun nedenidir. Alternatif 4 ve 5 için X_2 'nin Y ile korelasyonun düşük olması nedeni ile HT tahmin edicisinin MSE değeri ile kalibrasyon tahmin edicilerinin MSE değerleri arasında belirgin farklılık yoktur.

Çizelge 4.9. Aykırı X_2 olan veride kalibrasyon tahmin edicilerinin MSE tahminleri (10^{12})

ALTERNATİF	$\overline{MSE}(\hat{t}_{yHT})$	$\overline{MSE}(\hat{t}_{yGREG})$	$\overline{MSE}(\hat{t}_{yRAK})$	$\overline{MSE}(\hat{t}_{yTRN})$	$\overline{MSE}(\hat{t}_{yLOG})$
1	3 042 010	11 127	10 621	11 236	10 620
2	6 392 462	111 636	114 247	112 022	114 146
3	8 665 200	23 490	26 990	23 696	26 734
4	245 496	203 203	243 971	202 559	239 161
5	284 198	216 876	232 935	215 776	231 277

Çizelge 4.10. Aykırı X_2 olan veride kalibrasyon tahmin edicilerinin görel etkinliği

ALTERNATİF	$RE(\hat{t}_{yGREG})$	$RE(\hat{t}_{yRAK})$	$RE(\hat{t}_{yTRN})$	$RE(\hat{t}_{yLOG})$
1	273,39	286,41	270,74	286,44
2	57,26	55,95	57,06	56,00
3	368,89	321,05	365,68	324,13
4	1,21	1,01	1,21	1,03
5	1,31	1,22	1,32	1,23

Dikkat edilecek olursa; hedef değişken Y 'de aykırı değer olması durumunda görüldüğü gibi yardımcı değişkenlerde aykırı değer olması durumunda da kalibrasyon tahmin edicilerinin HT tahmin edicisine görel etkinliği sorunsuz veri setlerine göre çok daha fazladır. Bu tespit Çizelge 4.12'ye bakıldığında net bir şekilde görülecektir.

Çizelge 4.11. Aykırı X_2 değerli veride simülasyon sonucundaki görelî sapmalar

ALTERNATİF	$RB(\hat{t}_{yHT})$	$RB(\hat{t}_{yGREG})$	$RB(\hat{t}_{yRAK})$	$RB(\hat{t}_{yTRN})$	$RB(\hat{t}_{yLOG})$
1	1,17	1,00	1,00	1,00	1,00
2	1,25	1,03	1,03	1,03	1,03
3	1,30	1,01	1,02	1,01	1,02
4	1,03	0,97	0,96	0,97	0,97
5	1,03	0,97	0,97	0,97	0,97

Çizelge 4.12'de görelî etkinlikteki en dikkat çekici artışın Alternatif 1 için X_2 'de aykırı değer olması durumu olduğu görülmektedir. Tahmin edilen t_y değeri için, X_2 'de görülen aykırı değerlere bağılı olarak 0,45 korelasyonlu Y değerleri de etkilenerek HT tahmin edicisinin etkinliğini olumsuz etkilemiştir. Diğer yandan Alternatif 1'deki kalibrasyon aşamasında X_2 'nin yanı sıra Y değerleri ile 0,90 korelasyonlu X_1 değişkeninin kullanımı etkinliği yaklaşık 273 kat gibi ciddi bir orana taşımıştır. Çizelge 4.12'de dikkat çekici diğer bir nokta ise Alternatif 4 ve Alternatif 5 için X_2 'de görülen aykırı değerler durumunda uygulanan kalibrasyon işlemi sonucunda görelî etkinliğin sorunsuz veri setlerindeki görelî etkinlikten daha düşük olmasıdır. Bu alternatiflerde X_2 'nin Y değerleri ile 0,35 gibi düşük bir korelasyonu olduğu hatırlanacak olursa, düşük korelasyonlu yardımcı değişkenlerde görülen aykırı değer durumunda kalibrasyon işleminin etkinliğinin az olduğu söylenebilir. Yine de birden büyük olan görelî etkinlikler HT yerine kalibrasyon tahmin edicilerinin tercih edilebileceğini göstermektedir.

Çizelge 4.12. Sorunsuz veri seti ve aykırı değerli değişkenler içeren veri setlerinde GREG'in HT'ye görelî etkinliği

ALTERNATİF	1	2	3	4	5
Sorunsuz veri seti	13,47	5,27	30,37	1,54	1,34
Aykırı değerli veri seti (Y)	85,72	27,76	303,18	3,33	2,78
Aykırı değerli veri seti (X_1)	98,40	32,10	267,09	6,17	3,28
Aykırı değerli veri seti (X_2)	273,39	57,26	368,89	1,21	1,31

Hedef değişken Y ve yardımcı değişkenler X_1 ile X_2 'de görülen aykırı değer durumları için yapılan üç farklı simülasyon çalışması sonucunda elde edilen sonuçları aşağıdaki 4 madde ile özetlemek mümkündür:

1. Büyük örnek çapları için kalibrasyon tahmin edicileri birbirlerinden belirgin farklılıklar göstermemektedir. Bu tespit sorunsuz veri seti için tam olarak geçerliyken; aykırı değerlerin olduğu veri setlerinde Alternatif 3 için GREG tahmin edicisinin RAK tahmin edicisinden %10 ve üzerinde daha etkin olduğu gözlenebilir.
2. Sınırlandırılmış kalibrasyon tahmin edicileri TRN ve LOG sınırlandırılmamış alternatifleri olan GREG ve RAK'tan büyük farklılık göstermemektedir. Bunun temel nedeni GREG ve RAK ile elde edilen kalibrasyon katsayılarının çok büyük aykırı değerler üretmemesidir. Ayrıca simülasyon çalışmasında tüm örnekler için standart sınır uygulaması da bu sonuca neden olmaktadır. Her örnek için belirlenecek özel sınırlar ile etkinliklerde farklılaşma beklenebilir.
3. Kalibrasyon tahmin edicilerinin etkinlikleri üzerindeki en önemli unsur hedef değişkenle ilişkisi yüksek olan yardımcı değişken bilgisinin kalibrasyon aşamasında kullanılmasıdır. Hedef değişkenle yüksek korelasyonlu iki yardımcı değişkenin kullanıldığı Alternatif 3 için elde edilen göreceli etkinlikler oldukça yüksektir.
4. Hedef değişken ve yardımcı değişkenlerde aykırı değer olması durumunda, kalibrasyon tahmin edicilerinin Horvitz-Thompson tahmin edicisine göre göreceli etkinliği sorunsuz veri seti olması durumundaki göreceli etkinliğe göre çok daha fazladır. Bu tespit istisnası X_2 'nin Y değerleri ile 0,35 gibi düşük bir korelasyonu olduğu Alternatif 4 ve 5 durumlarıdır.



5. UYGULAMA

Minimum uzaklık yöntemi ile elde edilen GREG tahmin edicisi için nihai ağırlıkların negatif ve/veya 1'den küçük, RAK tahmin edicisi için ise nihai ağırlıkların 1'den küçük olma durumu ortaya çıkabilmektedir. Bölüm 2'de açıklanan ağırlıklandırma süreçlerini takip eden istatistikçiler bu sorunu ortadan kaldırmak; ayrıca nihai ağırlıklardaki aykırı değerleri yok etmek için ağırlık budaması işlemi gerçekleştirmektedirler. Budama işlemi bahsi geçen sorunları ortadan kaldırırken kalibrasyon işleminin sağlanmasını istediği kısıtları ise bozmaktadır. Bu durum da ağırlıklandırma sürecinde "undo effect" yani optimizasyon işleminin boşa gitmesi gibi bir durum ortaya çıkarabilmektedir. Bu olumsuz etkiyi gidermek için ağırlık budaması kullanmak yerine; GREG tahmin edicisine alternatif olarak TRN, RAK tahmin edicisine alternatif olarak ise LOG tahmin edicisinin kullanımı ağırlıkların sınırlandırılmasını sağlayacaktır.

Uygulama aşamasında; ağırlıklandırma süreçlerinde geleneksel olarak yapılan kalibrasyon sonrası budama işlemi yerine sınırlandırılmış kalibrasyon yöntemlerinin kullanımının etkinliği incelenmiştir. Bu amaçla; TRN ve LOG sınırlandırılmış kalibrasyon tahmin edicileri, GREG ve RAK tahmin edicilerinin ağırlık budaması sonucunda elde edilen tahmin edicilerle (GREG_TRIM, RAK_TRIM) karşılaştırılmıştır.

5.1. Veri Kaynağı ve Değişkenler

Ulusal istatistik ofislerinin istatistik üretiminde idari kayıt verilerini kullanma yüzdesi her geçen gün artmaktadır. Güvenilir dışsal kaynak olarak değerlendirilen idari kayıtlar kalibrasyon aşamasında yardımcı bilgi temini konusunda sıklıkla kullanılmaktadır. Bu düşünceden yola çıkarak uygulama aşamasında idari kayıt verilerinin kullanılması düşünülmüştür. Sosyal Güvenlik Kurumu (SGK) Aylık Prim ve Hizmet Bildirgesi ile Gelir İdaresi Başkanlığı (GİB) Yıllık Beyanname Kayıtları'nı kullanarak oluşturulan, 2017 Yıllık Sanayi ve Hizmet İstatistikleri (YSHİ) verisinin kullanımı için TÜİK ile protokol gerçekleştirilmiştir.

Belli kurallara dayanan bu protokol nedeniyle ilgili veri seti üzerindeki çalışmalar TÜİK Veri Araştırma Merkezi'nde gerçekleştirilmiştir. Ayrıca; çalışmalardan elde edilen bulgular da kurumun ilgili kuralları nedeniyle detaylandırılmamaktadır.

YSHİ veri setinde 2017 yılındaki $N = 3\ 100\ 412$ girişim için, yaptıkları faaliyeti belirten NACE 2 faaliyet sınıflaması kodlarının yanı sıra Çizelge 5.1'de verilen değişken bilgileri mevcuttur.

Çizelge 5.1. 2017 YSHİ veri setinde yer alan değişkenler

Değişken	Değişkenin Adı	Değişken	Değişkenin Adı
D ₁	Çalışan Sayısı	D ₆	Ciro
D ₂	Ücretli Çalışan Sayısı	D ₇	Üretim Değeri
D ₃	Personel Maliyeti	D ₈	Faktör Maliyetiyle Katma Değer
D ₄	Toplam Mal ve Hizmetlerin Satın Alışları	D ₉	Ticari Mal Satın Alışları
D ₅	Mal ve Hizmet Stokundaki Değişim		

Yapılan uygulamada daha önce simülasyon verisi için ele alınan korelasyon yapılarının benzeri durumlar 2017 YSHİ verisinde bulunarak, altı tahmin edicinin etkinlikleri karşılaştırılmıştır. Öncelikle çalışmada hedef değişken (Y_1) olarak "Ciro" belirlenmiştir. Diğer yandan kalibrasyon sürecinin önemli bir avantajı, istediğimiz kısıtları sağlayan tasarım ağırlıklarına en yakın kalibrasyon ağırlıklarını elde etmesidir. Bu ağırlıklar araştırmadaki herhangi bir değişken parametresinin tahmin edilmesinde de kullanılabilir. Bu nedenle; kalibrasyon yaklaşımının hedef değişken dışındaki değişkenlerin tahmin edilmesindeki etkinlikleri de incelenecektir. Bu değişkenler tahmin sürecinde Y_2 olarak ele alınacaktır.

"Ciro" hedef değişken olarak belirlendikten sonra, kalibrasyon yaklaşımı için veri setinde yardımcı değişken olarak kullanılacak değişkenler incelenmiştir. "Personel Maliyeti" (D₃) değişkeni birçok girişim için kayıp veri içerdiğinden, "Ticari Mal Satın Alışları" (D₉) ise çok fazla 0 verisi içerdiğinden uygun yardımcı değişken olarak değerlendirilmemiştir. "Ücretli Çalışan Sayısı" (D₂) ise "Çalışan Sayısı" (D₁) ile çoğunlukla aynı bilgileri içermekte olup; bazı girişimler için kayıp değerleri olduğundan yardımcı değişken olarak kullanılmamıştır. Bu değişkenler çıkarıldığında elimizde kalan yardımcı değişkenler listesi Çizelge 5.2'de verilmiştir. Bu değişkenler yardımcı değişken olarak kullanılmadığı durumlarda Y_2 olarak değerlendirilmiştir.

Veri setinde yer alan 527 NACE 2 dördü faaliyet sınıflaması bazında ciro sonuçları kamuoyuna açıklanmaktadır. Bu 527 faaliyet grubu için SAS programında korelasyon

matrisi oluşturularak; Çizelge 4.1'de gösterilen ve simülasyon çalışmasında belirlediğimiz 5 olası durumla benzer faaliyet grupları incelenmiştir. Alternatif 4 ve 5'e benzer yapılar gözlemlenmemiştir. Diğer yandan Alternatif 1 için "8292" NACE 2 dörtlü faaliyet sınıflaması kodunu alan "Paketleme Faaliyetleri" sektörü, Alternatif 2 için "9001" NACE 2 dörtlü faaliyet sınıflaması kodunu alan "Gösteri Sanatları" sektörü, Alternatif 3 için "7810" NACE 2 dörtlü faaliyet sınıflaması kodunu alan "İş Bulma Acentelerinin Faaliyetleri" sektörü tespit edilmiştir. Bu sektörlerde "Ciro" (Y_1) tahmini için yapılan çalışmalar detaylı olarak açıklanmıştır.

Çizelge 5.2. 2017 YSHİ veri setinden yardımcı değişken olarak kullanılacak değişkenler

Değişken	Değişkenin Adı
X_1	Çalışan Sayısı
X_2	Toplam Mal ve Hizmetlerin Satın Alışları
X_3	Mal ve Hizmet Stokundaki Değişim
X_4	Üretim Değeri
X_5	Faktör Maliyetiyle Katma Değer (FMKD)

5.2. Tahmin Edicilerin Etkinliklerinin Karşılaştırılması

R-Studio programında yapılan uygulamada, üç sektör verisinden örnekler çekilerek cevapsızlık düzeltmesi dışında Bölüm 2'de anlatılan ağırlıklandırma ve ağırlık düzeltme işlemlerinin hepsi gerçekleştirilmiştir. Tahmin ediciler için sonuçlar $n=50,100,250$ büyüklüğündeki örneklerden $R=5000$ tekrar ile elde edilmiştir. Seçilen her n büyüklüğündeki örnekte Y_1 ve Y_2 değişkeninin toplam tahminleri için yapılan işlemler aşağıda özetlenmiştir:

1. Tasarım ağırlığı kullanılarak Y_1 ve Y_2 için HT tahminleri hesaplanır. $(\sum_S d_j y_j)$
2. İlgili sektör için belirlenen yardımcı değişkenler kullanılarak GREG kalibrasyon ağırlıkları hesaplanır. $F(q_j u) = 1 + q_j u$ için $w_j = d_j F(q_j u)$
3. İlgili sektör için belirlenen yardımcı değişkenler kullanılarak RAK kalibrasyon ağırlıkları hesaplanır. $F(q_j u) = \exp(q_j u)$ için $w_j = d_j F(q_j u)$

4. GREG ve RAK kalibrasyon tahmin edicilerine dayalı toplam tahminleri yapılır. Bunun dışında ağırlık budaması yapıp elde edilen nihai ağırlıklar kullanılarak GREG_TRIM ve RAK_TRIM adı verilen iki farklı tahmin edici daha elde edilmiştir.
5. İlgili sektör için belirlenen yardımcı değişkenler kullanılarak TRN kalibrasyon ağırlıkları hesaplanır.

$$F(q_j u) = \begin{cases} 1 + q_j u & \text{eğer } (\Lambda - 1)/q_j \leq u \leq (V - 1)/q_j \\ \Lambda & \text{eğer } u < (\Lambda - 1)/q_j \\ V & \text{eğer } u > (V - 1)/q_j \end{cases}$$

$$\text{için } w_j = d_j F(q_j u)$$

6. İlgili sektör için belirlenen yardımcı değişkenler kullanılarak LOG kalibrasyon ağırlıkları hesaplanır.

$$F(q_j u) = \frac{\Lambda(V-1) + V(1-\Lambda)\exp(Aq_j u)}{(V-1) + (1-\Lambda)\exp(Aq_j u)} \quad \text{için } w_j = d_j F(q_j u)$$

7. TRN ve LOG kalibrasyonlarına dayalı toplam tahminleri yapılır. TRN ve LOG kalibrasyonlarının yapılması için Λ ve V alt ve üst sınırları belirlenirken en büyük ağırlığın en küçük ağırlığın 10 katından fazla olmaması koşulu sağlanmaya çalışılır. 10 kat kuralı ağırlık budaması işleminde de uygulanarak yöntemlerin karşılaştırılabilir olması sağlanmıştır.
8. Bütün tahmin edicilerin son aşamasında yığın toplamını sağlamak için ağırlık ölçeklendirmesi yapılır. $w_{son} = \frac{w_j}{\bar{w}}$

Burada yapılan ağırlık budama işlemi Verma'nın (2014:92) önerdiği yaklaşımdır. Buna göre kalibrasyon ağırlıkları hesaplandıktan sonra;

- Kalibrasyon ağırlıkları ile düzeltilmiş ağırlıkların ($d_j w_j$) ortalamalarının 1 olacak biçimde ölçeklendirilmesi,
- Daha sonra ölçeklendirilmiş ağırlıkların $1/T$ ve T sınırları dışında kalanlarının bu sınırlara getirilmesi

işlemleri uygulanmıştır. Uygulamada $1/T=0,3$ ve $T=3$ kullanılarak sınırlandırılmış kalibrasyonlardaki 10 kat kuralıyla uyum sağlanmıştır. Tahmin edicilerin karşılaştırılması aşamasında Eş. 5.3'deki görelî etkinlik formülünden faydalanılmıştır. Ayrıca, tüm tahmin ediciler için Eş. 5.1'deki deneysel görelî sapma değerleri de hesaplanmıştır.

$$RB(\hat{t}_{ym}) = \frac{\frac{1}{R} \sum_{i=1}^R (\hat{t}_{ym})_i}{t_y} \quad m = 1, \dots, 6 \quad (5.1)$$

$$MSE(\hat{t}_{ym}) = \frac{1}{R} \sum_{i=1}^R [(\hat{t}_{ym})_i - t_y]^2 \quad m = 1, \dots, 6 \quad (5.2)$$

$$RE(\hat{t}_{yHT}, \hat{t}_{ym}) = \frac{MSE(\hat{t}_{yHT})}{MSE(\hat{t}_{ym})} \quad m = 1, \dots, 6 \quad (5.3)$$

5.2.1. Paketleme faaliyetleri sektöründe ciro ve FMKD tahmini

Bu sektörde "Ciro" (Y_1) değişkeni tahmin edilirken yardımcı değişken olarak "Çalışan Sayısı" (X_1) ve "Toplam Mal ve Hizmetlerin Satın Alışları" (X_2) kullanılmıştır. Değişkenler için korelasyon matrisi Çizelge 5.3'de verilmektedir. $N=1126$ girişimin bulunduğu sektörde Y_1 ve X_1 arasındaki korelasyon 0,47; Y_1 ve X_2 arasındaki korelasyon ise 0,95'tir. X_1 ve X_2 arasındaki korelasyon ise 0,21 olup; bu yapı simülasyon aşamasında türetilmiş olan Alternatif 1'e benzemektedir. "FMKD" değişkeninin (Y_2) ise yine araştırmadan tahmin edilen diğer hedef değişken olduğu varsayılmıştır. Y_2 ve X_1 arasındaki korelasyon 0,89; Y_2 ve X_2 arasındaki korelasyon ise 0,43'tür.

Çizelge 5.3. Paketleme faaliyetlerinde değişkenler için korelasyon matrisi

	Y_1	Y_2	X_1	X_2
Y_1	1,00	0,68	0,47	0,95
Y_2		1,00	0,89	0,43
X_1			1,00	0,21
X_2				1,00

Çizelge 5.4'de "Ciro" ve "FMKD" değişkenlerinin tahminleri için görel sapma ve görel etkinlik değerleri verilmiştir. Çizelge incelendiğinde önümüze birçok sonuç çıkmaktadır.

1. Öncelikle, simülasyon çalışması sonucunda $n=50,100,250$ örnek çaplarının hepsi ve her iki hedef değişken için en etkin tahmin ediciler **kırmızı** renkle işaretlenen raking ratio (RAK) tahmin edicileridir. Burada bir noktaya dikkat edilmesi gerekmektedir. RAK tahmin edicisinin sınırlandırılmış versiyonu olan LOG tahmin edicileri RAK tahmin edicileri ile yaklaşık olarak aynı etkinliğe sahiptir. Simülasyon çalışmasında 5000

örneğin hepsi için standart bir yaklaşım kullanıldığından LOG tahmin edicilerinin etkinliği aslında ortalama bir sonuçtur. Her örnek için özel olarak belirlenecek alt ve üst sınırlarla LOG tahmin edicisinin Çizelge 5.4'de gözükten etkinlik performansı biraz daha arttırılabilir. (Benzer durum TRN için de geçerlidir) Ayrıca RAK kalibrasyonunun 1'den küçük ağırlıklar verebilmesi dikkate alındığında LOG tahmin edicilerinin bu sektörün tahmininde kullanılabilecek en iyi kalibrasyon yaklaşımı olduğu söylenebilir.

Çizelge 5.4. Paketleme faaliyetleri için tahmin edicilerin görel sapma (RB) ve görel etkinlikleri (RE)

		CİRO		FMKD	
Örnek Çapı	Tahmin Edici	$RB(\hat{t}_{ym})$	$RE(\hat{t}_{yHT}, \hat{t}_{ym})$	$RB(\hat{t}_{ym})$	$RE(\hat{t}_{yHT}, \hat{t}_{ym})$
n=50	GREG	0,89	7,80	0,88	3,61
	RAK	0,91	9,38	0,89	3,91
	TRN	0,89	7,46	0,88	3,83
	LOG	0,90	8,74	0,89	3,85
	GREG_TRIM	0,93	5,98	0,91	3,47
	RAK_TRIM	0,92	7,27	0,90	3,77
n=100	GREG	0,95	10,57	0,94	3,98
	RAK	0,96	12,59	0,95	4,24
	TRN	0,94	9,97	0,93	3,96
	LOG	0,95	12,13	0,94	4,21
	GREG_TRIM	0,97	7,65	0,95	3,81
	RAK_TRIM	0,96	9,43	0,95	3,98
n=250	GREG	0,98	15,30	0,98	4,27
	RAK	0,99	17,22	0,99	4,32
	TRN	0,98	15,22	0,98	4,28
	LOG	0,99	16,84	0,98	4,32
	GREG_TRIM	0,99	12,80	0,98	4,22
	RAK_TRIM	0,99	14,57	0,98	4,22

2. Çalışmanın temel amacı; GREG ve RAK kalibrasyonu sonrasında oluşabilen negatif ve 1'den küçük ağırlıkların düzeltilmesi sürecinde kullanılan budama işlemlerine alternatif olarak sınırlandırılmış yaklaşımların irdelenmesidir. Bu hususu dikkate aldığımızda; **mavi** renkli sonuçlar birbirleriyle karşılaştırılması gereken GREG_TRIM ve TRN yöntemlerini göstermektedir. Burada incelenen tüm örnek çapları ve her iki hedef değişken için de TRN yönteminin GREG_TRIM'den daha etkin olduğu görülmektedir. Aynı şekilde; **yeşil** renkli sonuçları incelediğimizde de incelenen tüm örnek çapları ve

her iki hedef deęişken için de LOG yönteminin RAK_TRIM'den daha etkin olduęu gözlenmektedir.

3. Örnek çapı arttıkça tüm tahmin edicilerin görelî sapması 1'e yaklaşmaktadır. Bu durum da kalibrasyon tahmin edicilerinin asimptotik sapmasızlık özelliğini doğrulamaktadır.
4. Yardımcı deęişkenlerin korelasyonun yüksek olduęu "Ciro" deęişkeninde tahmin edicilerin etkinlik sonuçları arasında daha belirgin farklar vardır. Yardımcı deęişkenlerle korelasyonun daha düşük olduęu "FMKD" deęişkeninde örnek çapı büyük olduęunda; 6 tahmin edici de neredeyse aynı sonuçları vermektedir. Bu durumda dięer tahmin edicilerden farklı olarak; kalibrasyon kısıtlarının bozulmadığı, negatif ve 1'den küçük ağırlıklarla karşılaşılmayan TRN ve LOG tahmin edicilerinin kullanımı daha doğru olacaktır.

5.2.2. Gösteri sanatları sektöründe ciro ve çalışan sayısı tahmini

Bu sektörde "Ciro" (Y_1) deęişkeni tahmin edilirken yardımcı deęişken olarak "Toplam Mal ve Hizmetlerin Satın Alışları" (X_2) ve "FMKD" (X_5) kullanılmıştır. $N=3666$ girişimin bulunduğu sektörde Y_1 ve X_2 arasındaki korelasyon 0,75; Y_1 ve X_5 arasındaki korelasyon ise 0,77'dir. X_2 ve X_5 arasındaki korelasyon ise 0,15 olup; bu yapı simülasyon aşamasında türetilmiş olan Alternatif 2'ye benzemektedir.

Çizelge 5.5. Gösteri sanatlarında deęişkenler için korelasyon matrisi

	Y_1	Y_2	X_2	X_5
Y_1	1,00	0,41	0,75	0,77
Y_2		1,00	0,50	0,13
X_2			1,00	0,15
X_5				1,00

"Çalışan Sayısı" deęişkeninin (Y_2) ise yine araştırmadan tahmin edilen dięer hedef deęişken olduęu varsayılmıştır. Y_2 ve X_2 arasındaki korelasyon 0,50; Y_2 ve X_5 arasındaki korelasyon ise 0,13'tür. Çizelge 5.6'da "Ciro" ve "Çalışan Sayısı" deęişkenlerinin tahminleri için görelî sapma ve görelî etkinlik deęerleri verilmiştir. Çizelge 5.6 incelendiğinde Çizelge 5.4'e göre bazı farklı sonuçlar elde edilmektedir.

Çizelge 5.6. Gösteri sanatları için tahmin edicilerin görelî sapma ve etkinlikleri

		CİRO		CAL_SAY	
Örnek Çapı	Tahmin Edici	$RB(\hat{t}_{ym})$	$RE(\hat{t}_{yHT}, \hat{t}_{ym})$	$RB(\hat{t}_{ym})$	$RE(\hat{t}_{yHT}, \hat{t}_{ym})$
n=50	GREG	0,86	7,04	1,01	1,05
	RAK	0,88	8,78	1,01	1,10
	TRN	0,86	5,92	0,99	1,25
	LOG	0,87	7,91	1,00	1,11
	GREG_TRIM	0,93	5,70	1,01	1,04
	RAK_TRIM	0,90	6,73	1,00	1,15
n=100	GREG	0,93	10,24	1,03	0,86
	RAK	0,94	14,32	1,03	0,89
	TRN	0,92	7,05	1,02	0,99
	LOG	0,94	12,74	1,03	0,91
	GREG_TRIM	0,97	7,01	1,04	0,86
	RAK_TRIM	0,95	8,80	1,03	0,96
n=250	GREG	0,97	20,72	1,03	0,84
	RAK	0,98	30,35	1,03	0,82
	TRN	0,97	18,52	1,03	0,89
	LOG	0,98	28,01	1,03	0,83
	GREG_TRIM	0,99	12,21	1,03	0,86
	RAK_TRIM	0,98	15,78	1,02	0,90

1. "Ciro" değişkeninin tahmininde Çizelge 5.4'deki sonuçlarla aynı doğrultuda sonuçlar elde edilmiştir. RAK en etkin tahmin edici olurken; sınırlandırılmış TRN ve LOG kalibrasyonları budama yaklaşımları GREG_TRIM ve RAK_TRIM'den daha etkin sonuçlar vermiştir.
2. Burada ilgi çekici olan önceki sonuçlardan farklı olarak "Çalışan Sayısı" değişkeninin toplam tahmininde, kalibrasyon tahmin edicilerinin \hat{t}_{yHT} tahminine karşı çok da başarılı olmamasıdır. Bu durumun iki nedeni vardır; birincisi yardımcı değişkenlerin "Çalışan sayısı" değişkeni ile korelasyonlarının düşük olmasından dolayı kalibrasyonun faydasının azalması, ikincisi ise "Çalışan sayısı" değişkeninin daha önceki sektörde tahmin edilen "FMKD" değişkenine göre çok daha küçük değişkenliğe sahip olması nedeni ile HT tahmin edicisinin $n=50,100,250$ örnek çaplarında yeterince etkin sonuç vermesidir.

5.2.3. İş bulma acentelerinin faaliyetleri sektöründe ciro ve FMKD tahmini

Bu sektörde "Ciro" (Y_1) değişkeni tahmin edilirken yardımcı değişken olarak "Çalışan Sayısı" (X_1) ve "Toplam Mal ve Hizmetlerin Satın Alışları" (X_2) kullanılmıştır. $N=1542$ girişimin bulunduğu sektörde Y_1 ve X_1 arasındaki korelasyon 0,89; Y_1 ve X_2 arasındaki korelasyon ise 0,70'tir. X_1 ve X_2 arasındaki korelasyon ise 0,49 olup; bu yapı simülasyon aşamasında türetilmiş olan Alternatif 3'e benzemektedir. "FMKD" değişkeninin (Y_2) ise yine araştırmadan tahmin edilen diğer hedef değişken olduğu varsayılmıştır. Y_2 ve X_1 arasındaki korelasyon 0,91; Y_2 ve X_2 arasındaki korelasyon ise 0,47'dir.

Çizelge 5.7. İş bulma acentelerinin faaliyetlerinde değişkenler için korelasyon matrisi

	Y_1	Y_2	X_1	X_2
Y_1	1,00	0,96	0,89	0,70
Y_2		1,00	0,91	0,47
X_1			1,00	0,49
X_2				1,00

Çizelge 5.8'de "Ciro" ve "FMKD" değişkenlerinin tahminleri için görel sapma ve görel etkinlik değerleri verilmiştir. Çizelge 5.8 incelendiğinde daha önceki sonuçlardan farklı olarak aşağıdaki tespitleri yapmak mümkündür:

1. LOG tahmin edicisinin, $n=100$ ve $n=250$ örnek çaplarında her iki değişken için de RAK tahmin edicisinden daha etkin sonuçlar verdiği görülmektedir. Bu "Paketleme faaliyetleri" sektöründe LOG tahmin edicisinin belirlenecek sınırlara göre RAK'tan daha etkin sonuçlar verebileceğini doğrulamaktadır.
2. Burada diğer iki analizden farklı olarak örnek çapı arttıkça "Ciro" değişkeninin görel etkinliğinin artmadığı görülmektedir. Bu duruma, yardımcı değişkenler arasındaki korelasyonun büyük olmasının sebep olduğu düşünülmektedir. Örnek çapı arttıkça HT tahmin edicisinin etkinliği ise artmaktadır; görel etkinliğin artması için kalibrasyon tahmin edicilerinin etkinliğinin HT tahmin edicisinden daha hızlı artması beklenir. Yardımcı değişkenler arasındaki korelasyonun yüksek olduğu Alternatif 3'te; yardımcı değişkenler arasındaki korelasyonun küçük olduğu Alternatif 1 ve 2'de olduğu gibi etkinlik artışı HT tahmin edicisini geçememiştir.


Çizelge 5.8. İş bulma acenteleri için tahmin edicilerin göreceli sapma ve etkinlikleri

		CİRO		FMKD	
Örnek Çapı	Tahmin Edici	$RB(\hat{t}_{ym})$	$RE(\hat{t}_{yHT}, \hat{t}_{ym})$	$RB(\hat{t}_{ym})$	$RE(\hat{t}_{yHT}, \hat{t}_{ym})$
n=50	GREG	0,89	6,47	0,88	5,88
	RAK	0,89	8,42	0,88	8,06
	TRN	0,89	7,35	0,87	7,42
	LOG	0,89	8,09	0,88	7,88
	GREG_TRIM	0,93	5,09	0,93	4,62
	RAK_TRIM	0,91	6,29	0,90	6,17
n=100	GREG	0,94	7,43	0,93	6,16
	RAK	0,95	8,46	0,94	7,00
	TRN	0,94	7,61	0,93	6,66
	LOG	0,94	8,47	0,93	7,09
	GREG_TRIM	0,97	5,93	0,96	5,01
	RAK_TRIM	0,95	6,93	0,95	6,01
n=250	GREG	0,97	7,10	0,96	5,29
	RAK	0,97	7,23	0,97	5,30
	TRN	0,97	7,16	0,96	5,37
	LOG	0,97	7,30	0,96	5,37
	GREG_TRIM	0,98	6,46	0,97	4,93
	RAK_TRIM	0,98	6,70	0,97	5,06

5.3. Sınırlandırılmış Kalibrasyonda Alt ve Üst Sınırların Etkisi

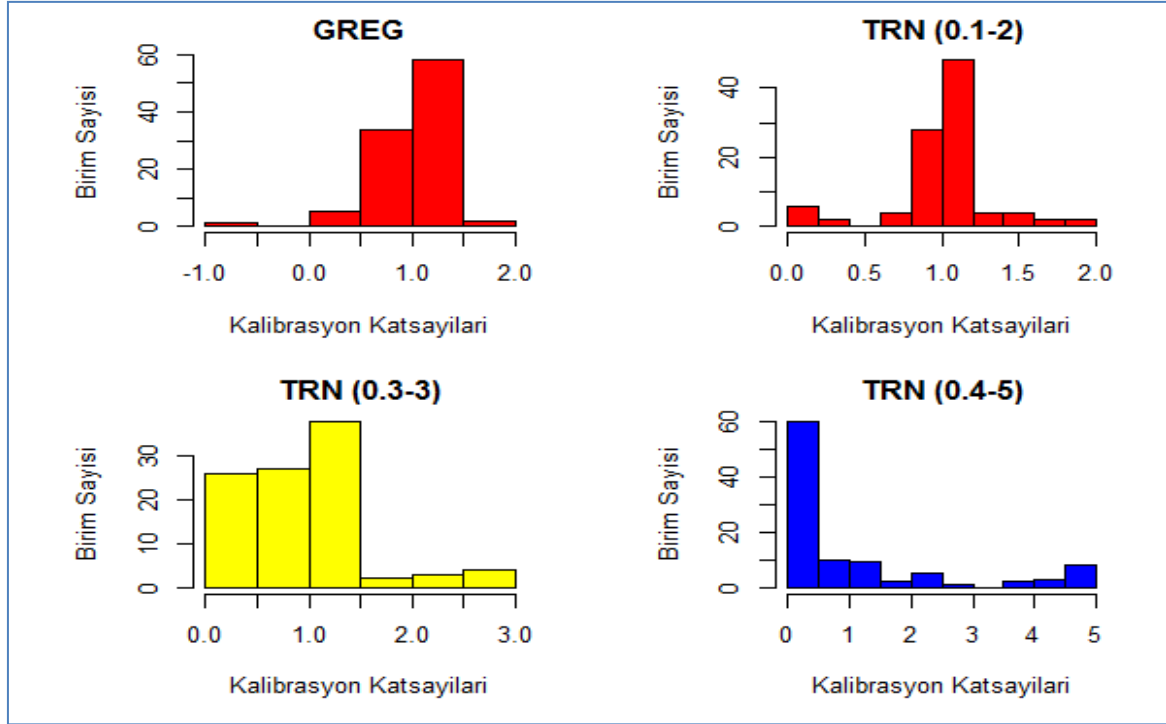
Sınırlandırılmış doğrusal kalibrasyon ve logit yaklaşımları kalibrasyon düzeltme katsayılarını belirlerken; A ve V alt-üst sınırlarını kalibrasyon eşitliklerinde kullanılmaktadırlar. Kalibrasyon işlemini gerçekleştiren kişi tarafından verilecek bu sınırların alternatif değerleri için farklı katsayılar, dolayısıyla farklı tahminler ortaya çıkabilecektir. Dördüncü bölümde gerçekleştirilen simülasyon çalışmasında ve bu bölümdeki gerçek veri uygulamasında, tekrarlı uygulamalar nedeniyle standartlaştırılmış alt ve üst sınırlar kullanılmıştır. Diğer yandan, seçilen her n büyüklüğündeki örnek için sınır değerlerinin özel olarak belirlenmesi durumunda TRN ve LOG yaklaşımları için daha etkin sonuçlar alınabileceği vurgulanmıştır. Bu bölümde seçilen tek bir örnek için alternatif sınır değerlerinin kalibrasyon katsayılarına olan etkisi gösterilecektir.

Gerçek veri için yapılan uygulamada $n=100$ olmak üzere $R=5000$ tekrardan bir tanesi alınarak alternatif sınır değerleri için incelenmiştir. Öncelikle, GREG katsayıları hesaplanan bu örnek veri setinde en küçük GREG katsayısı $\min(g^{(GREG)}) = -0,8671$; en büyük GREG katsayısı $\max(g^{(GREG)}) = 1,7965$ olarak gözlemlenmiştir. Negatif düzeltme katsayısı içermesi nedeniyle bu örnek için GREG yerine TRN yaklaşımının kullanılması bir ihtiyaç olarak görülmektedir. Bu noktada, alternatif alt ve üst sınırlar için kalibrasyon düzeltme katsayılarının aldığı değerler Şekil 5.1'de gösterilmiştir.




Şekil 5.1. GREG ve alternatif TRN'ler için kutu grafikleri ($\min(g^{(GREG)}) = -0,8671$)

Şekil 5.1 incelendiğinde, $\Lambda = 0,1$ ve $V = 2$ alternatif sınırları için GREG yöntemiyle bulunan katsayılar negatif olan hariç neredeyse aynı kalmıştır ve katsayıların ortalaması 1'e çok yakın olup; kalibrasyon ağırlığının tasarım ağırlığına çok yakın olması koşulu sağlanmaktadır. Bu yönleriyle başarılı bir sınırlandırma işlemi gerçekleştirildiği söylenebilir. Diğer alternatiflerin ise aynı başarıyı gösterdiği söylenemez. Şekil 5.2'de verilen histogramlara bakıldığında diğer alternatiflerin elde ettiği katsayıların 1'den uzaklaştığı net biçimde görülmektedir.

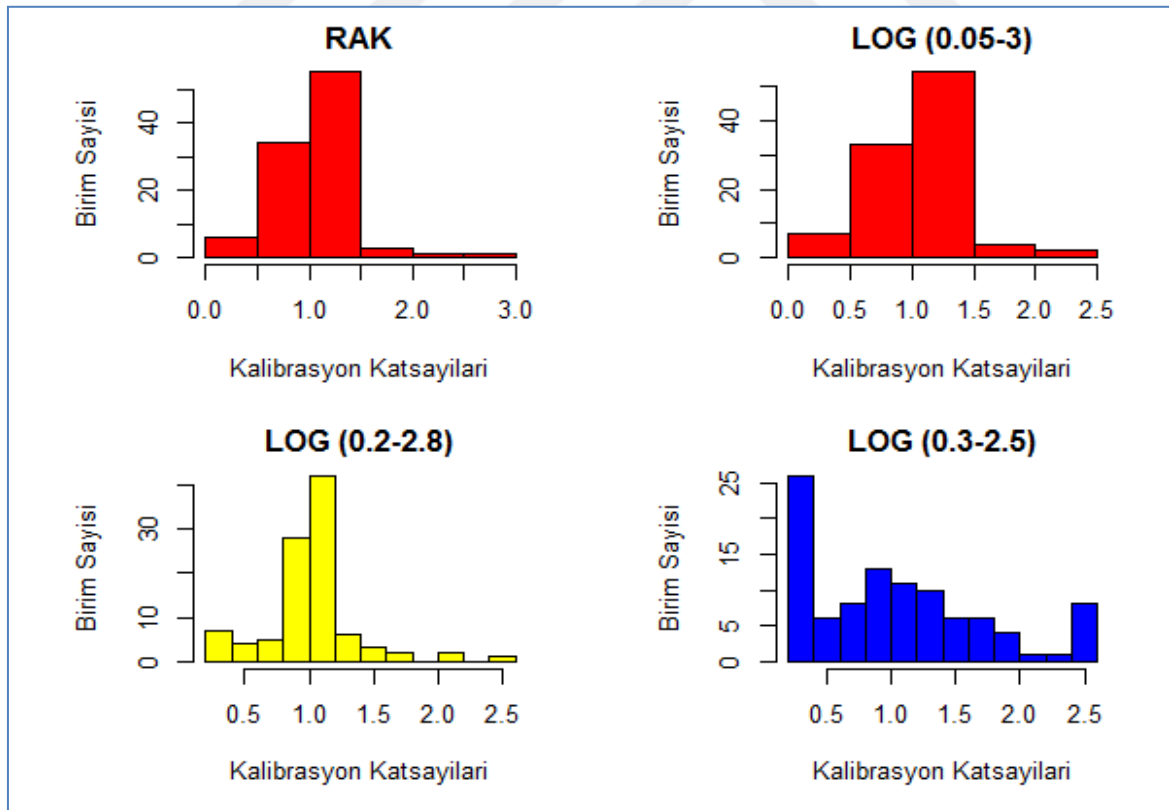


Şekil 5.2. GREG ve alternatif TRN'ler için histogramlar ($\min(g^{(GREG)}) = -0,8671$)

Aynı veri setinde RAK katsayıları hesaplandığında en küçük RAK katsayısı $\min(g^{(RAK)}) = 0,058$; en büyük RAK katsayısı $\max(g^{(RAK)}) = 2,9849$ olarak gözlemlenmiştir. En küçük RAK katsayısının tasarım ağırlığı ile birlikte kullanımı sonrasında, nihai ağırlık 1'den küçük olabilecektir. Bu nedenle, bu katsayıların da logit yaklaşımı kullanılarak sınırlandırılması yerinde olacaktır. Şekil 5.3 ve Şekil 5.4'te sırasıyla kutu grafikleri ve histogramlar yardımıyla alternatif sınırlar sonucunda elde edilen LOG kalibrasyon katsayıları karşılaştırılmıştır. $\Lambda = 0,2$ ve $V = 2,8$ alternatif sınırları kullanıldığında, RAK yaklaşımından fazla uzaklaşmayarak katsayılar sınırlandırılmıştır. Şekil 5.4'e bakıldığında, sınırların daha da daraltılması sonucunda katsayıların 1 etrafında yığılması durumunda azalma olduğu görülmektedir.




Şekil 5.3. RAK ve alternatif LOG'lar için kutu grafikleri ($\min(g^{(RAK)}) = 0,0583$)

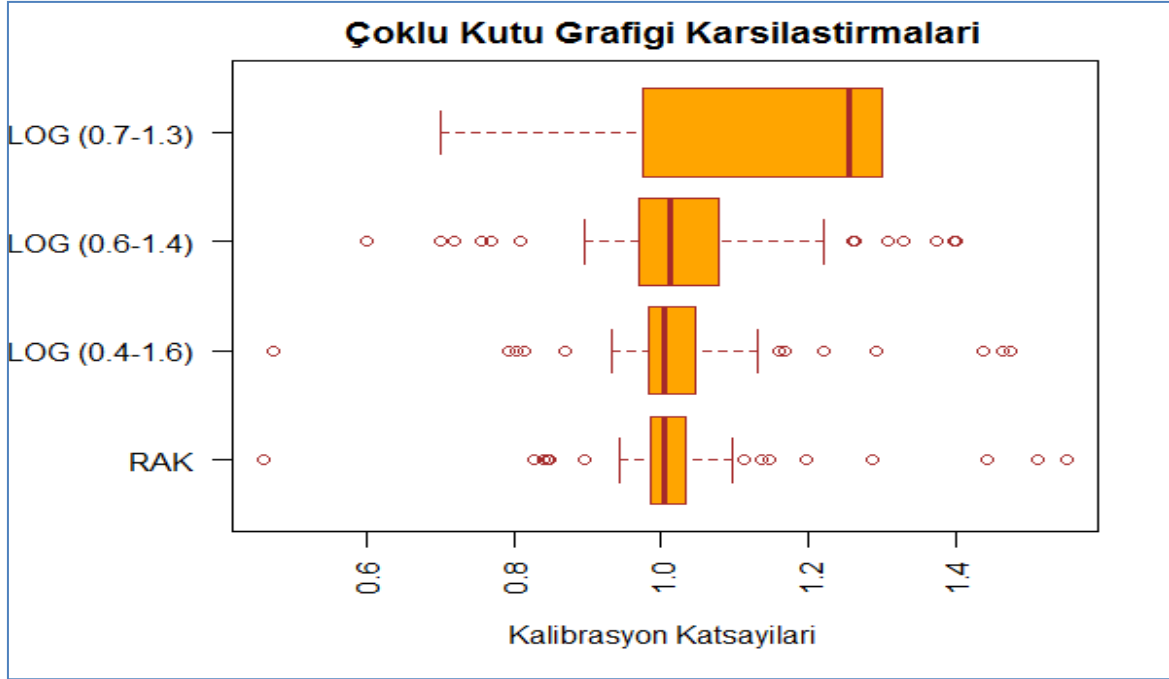


Şekil 5.4. RAK ve alternatif LOG'lar için histogramlar ($\min(g^{(RAK)}) = 0,0583$)

GREG yaklaşımında negatif kalibrasyon düzeltme katsayısı ile karşılaşıldığında ve/veya RAK yaklaşımında çok küçük kalibrasyon düzeltme katsayıları elde edildiğinde; bunların yerine sırasıyla TRN ve LOG yaklaşımlarının kullanılması aykırı ağırlıklardan korunmayı sağlayacaktır. Ancak; Şekil 5.1 ve Şekil 5.4 arasındaki grafiklerden de görüldüğü gibi alt ve üst sınırların özensiz biçimde belirlenmesi; kalibrasyon düzeltme katsayılarının 1 değerinin uzağında yığılmasına neden olmaktadır. Diğer yandan; aykırı kalibrasyon düzeltme katsayısı içermeyen GREG ve RAK yaklaşımlarında katsayıları daha dar bir aralığa getirmek için yapılacak sınırlandırmalar olumsuz sonuçlar doğurabilecektir. $n=100$ olmak üzere $R=5000$ tekrardan alınan diğer bir örnek için bu durum Şekil 5.5 ve Şekil 5.6'da incelenmiştir. GREG katsayıları hesaplanan bu örnek veri setinde en küçük katsayı $\min(g^{(GREG)}) = 0,3988$; en büyük katsayı ise $\max(g^{(GREG)}) = 1,5446$ olarak gözlemlenmiştir. Aynı veri setinde RAK katsayıları hesaplandığında en küçük katsayı $\min(g^{(RAK)}) = 0,4610$; en büyük katsayı ise $\max(g^{(RAK)}) = 1,5498$ olarak gözlemlenmiştir. Bu değerlere bakıldığında kalibrasyon katsayıları için bir sınırlandırma ihtiyacı olmadığı söylenebilir. Aksi düşünülerek yapılan sınırlandırmanın olumsuz etkisi özellikle Şekil 5.5 ve Şekil 5.6'da $\Lambda = 0,7$ ve $V = 1,3$ alternatif sınırları için gözlemlenebilir.




Şekil 5.5. GREG ve alternatif TRN'ler için kutu grafikleri ($\min(g^{(GREG)}) = 0,3988$)

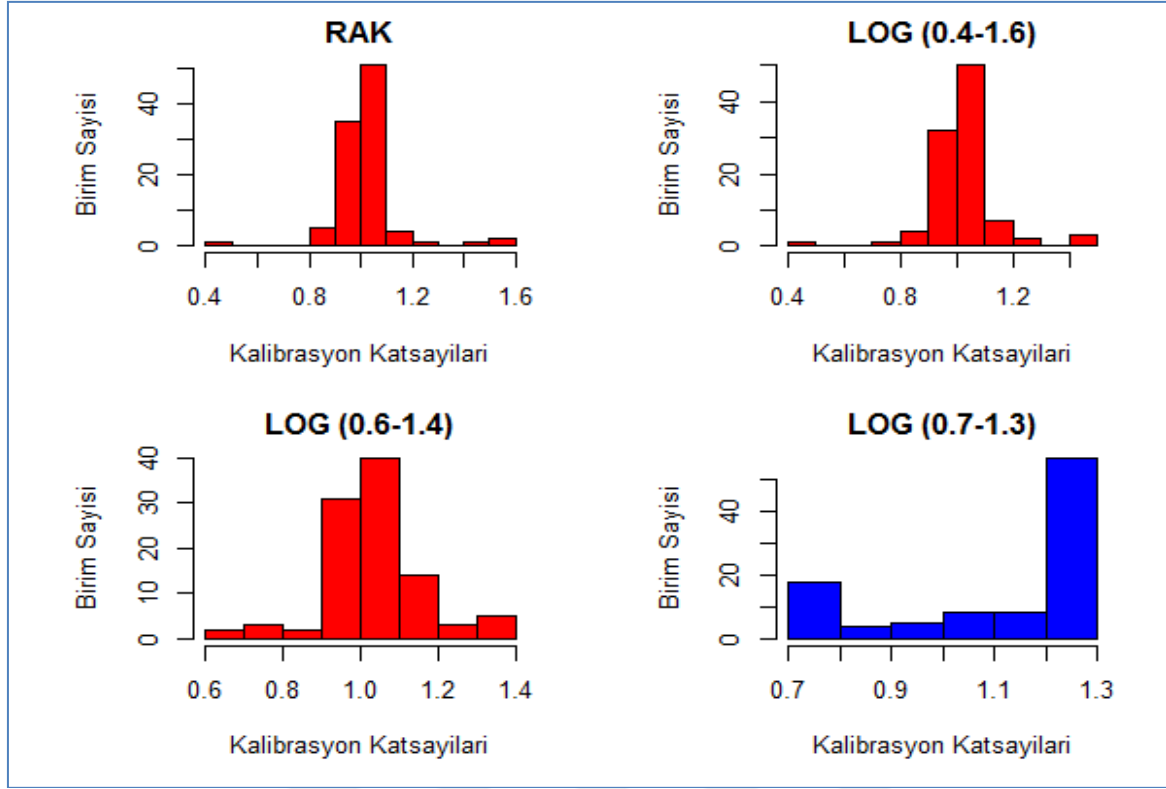


Şekil 5.6. RAK ve alternatif LOG'lar için kutu grafikleri ($\min(g^{(RAK)}) = 0,4610$)

Yapılan sınırlandırma belirli alt ve üst sınırlara kadar kalibrasyon katsayılarının dağılımını olumsuz etkilememektedir. Bu örnek için $\Lambda = 0,6$ ve $V = 1,4$ alternatif sınırları için kalibrasyon katsayılarının 1 etrafında yığılması düşüncesinden çok uzaklaşmadığı Şekil 5.7 ve Şekil 5.8'de görülebilmektedir.



Şekil 5.7. GREG ve alternatif TRN'ler için histogramlar ($\min(g^{(GREG)}) = 0,3988$)



Şekil 5.8. RAK ve alternatif LOG'lar için histogramlar ($\min(g^{(RAK)}) = 0,4610$)

Diğer yandan; negatif veya çok küçük katsayılar içermeyen GREG ve RAK katsayılarının sınırlandırılması Şekil 5.7 ve Şekil 5.8'deki gibi $\Lambda = 0,7$ ve $V = 1,3$ için 1 etrafında yığılma konusunda olumsuz durum oluşturacaktır. Dolayısıyla ihtiyaç olmayan durumlar için sınırlandırma gereksiz bir risk de içermektedir.

$n=100$ büyüklüğündeki iki farklı örnek verisinde kalibrasyon katsayıları için yapılan sınırlandırma uygulamaları değerlendirildiğinde; TRN ve LOG uygulamaları için sınırların dikkatli bir biçimde belirlenmesinin önemi gözükmemektedir. Sınırlar belirlenmeden önce GREG ve RAK için en küçük ve en büyük katsayıların belirlenmesi yol gösterici olacaktır. Diğer yandan, tek bir örnek veri seti için olumsuz etki yaratmayan sınırlandırılmış yaklaşımlarla (TRN ve LOG) klasik yaklaşımlar (GREG, RAK) arasından hangisinin kullanılacağı konusunda VIF hesaplanarak karar verilebilir.


5.4. Uygulama Sonuçları

YSHİ 2017 veri seti kullanılarak; 7 tahmin edicinin etkinliği "Ciro", "Çalışan sayısı", "Faktör Maliyetiyle Katma Değer" değişkenlerinin toplam tahminlerini yaparak karşılaştırılmıştır. Karşılaştırılan tahmin edicileri hatırlatacak olursak;


- Sadece tasarım ağırlığı kullanan Horvitz-Thompson (HT)
- Genelleştirilmiş Regresyon (GREG) } KALİBRASYON T.E.
- Raking Ratio (RAK) }
- Sınırlandırılmış Doğrusal (TRN) kalibrasyon, } SINIRLANDIRILMIŞ KALİBRASYON T.E.
- Logit (LOG) kalibrasyon, }
- GREG tahmin edicisine budama işlemiyle elde edilen (GREG_TRIM)
- RAK tahmin edicisine budama işlemiyle elde edilen (RAK_TRIM)

tahmin edicileridir. İlgili tahmin ediciler, kullanılan hedef ve yardımcı değişkenler için 3 farklı korelasyon yapısına sahip sektörde karşılaştırılmıştır. Elde edilen sonuçların özeti Şekil 5.9 ve Şekil 5.10'da verilmiştir. Şekiller incelendiğinde örneklem araştırmaları sonrasında birçok değişken için tahminler yapan araştırmacılara, bu aşamada yol gösterebilecek aşağıdaki bulgulara ulaşılmıştır:

- Tahmin aşamasında yardımcı değişkenlerin (idari kayıt vb. güvenilir dışsal kaynaktan) kullanılma olanağı söz konusuysa; bunlar kullanılarak elde edilen kalibrasyon tahmin edicileri HT tahmin edicisinden daha etkindir. Şekil 5.10'da görülebileceği gibi istisnai durumlar söz konusu olabilir. Tahmin edilen değişken ile kullanılan yardımcı değişkenler arasında korelasyon düşükse ve tahmin edilen değişken için değişkenlik çok fazla değilse HT tahmini, kalibrasyon tahmin edicilerinden daha etkin sonuç verebilir.
- Sınırlandırılmış kalibrasyon tahmin edicileri (TRN, LOG), sınırlandırılmamış kalibrasyon işlemi üzerine budama yapma sonrası elde edilen tahmin edicilerden (GREG_TRIM, LOG_TRIM) daha etkindir.



Şekil 5.9. Ciro değişkeninin tahmini için bulunan görel etkinlikler



Şekil 5.10. Çalışan sayısı ve FMKD değişkenleri tahmini için bulunan görel etkinlikler

- Sınırlandırılmış kalibrasyon tahmin edicileri (LOG, TRN) yaklaşık olarak sınırlandırılmamış alternatifleri (RAK, GREG) kadar etkin tahmin ediciler üretmektedir. Sınırlandırılmış yaklaşımlarda arařtırmacılar tarafından uzman görüşü ile belirlenebilecek sınır deęerleri bu tahmin edicilerin etkinliklerini arttırabileceęi gibi tahmin için kullanılacak nihai aęırlıkların 1'den küçük olmasını ve negatif olmasını da engelleyebilecektir. Bu özellikleri ile (LOG, TRN) pratik kullanımda çok büyük bir avantaj sağlamaktadırlar.
- Şekil 5.9'da "Gösteri Faaliyetleri" sektöründe görüldüğü gibi birden fazla yardımcı deęişkenin hedef deęişkenle yüksek korelasyonu olduęunda ve örnek çapı da büyük tutulduęunda görelilik yüksek deęerler almaktadır.
- Şekil 5.10'da "İş Bulma Acenteleri Faaliyetleri" sektörüne bakıldığında; kullanılan yardımcı deęişkenler arasında korelasyon olduęunda örnek çapının arttırılmasının kalibrasyon tahmin edicilerinin HT'ye göreliliklerini arttırmadığı görülmektedir. Özellikle "FMKD" deęişkeninin tahmininde örnek çapının arttırılmasının görelilikte azalmaya yol açtığı görülebilir. Bu sonuca bakarak yardımcı deęişkenler arasında yüksek korelasyon olduęunda örnek çapını arttırmanın HT tahmin edicisinde kalibrasyon tahmin edicilerinden daha fazla iyileştirme yaptığı söylenebilir.



6. SONUÇ VE ÖNERİLER

Örnekleme yöntemiyle yapılan arařtırmalarda temel hedef, yığın deęiřkenlerinin toplam, ortalama vb. gibi bilinmeyen parametrelerini minimum maliyetle en etkin biçimde tahmin etmektir. Olasılıklı örnekleme yöntemlerinin kullanımı ile tahmin hatalarının ölçülebilmesi mümkün olmaktadır. Buna ek olarak; yığındaki birimler için uygulama aşamasında farklı içerilme olasılıklarının kullanılması, operasyonel maliyetlerin azaltılması ve/veya tahminlerin etkinliğinin artırılması gibi nedenlerle tercih edilmektedir. Farklı içerilme olasılıklarının kullanımı için ilgili çalışmaya özel bir örnekleme tasarımı oluşturulması; dolayısıyla tasarım ağırlıklarının kullanılması gerekmektedir. Kendinden-ağırlıklı örnekleme tasarımları dışında kalan tasarımlarda ağırlıklar kullanılmadan yapılan tahminler sapmalı olacaktır.

Ağırlık kullanılmasının gerekli olduęu arařtırmalarda kaçınılmaz olarak bir ağırlıklandırma süreci gündeme gelmektedir. Örnek birimlerin seçildięi çerçeveden kaynaklanan sorunlar ile arařtırmalarda görülen cevapsızlık problemleri, çalışma öncesinde belirlenen tasarım ağırlıklarının doğrudan kullanımını engellemektedir. Cevapsızlık sorunu için, özellikle Metin ve Özdemir (2014) çalışmasında belirtilen; cevap vermeyen birimlerin eğilimlerinin farklılığı durumunda tasarım ağırlıklarının kullanımı sapmalı tahminlere neden olacaktır. Sapmalı sonuçların önüne geçebilmek için tasarım ağırlıkları cevapsızlık düzeltme katsayısı ile düzeltilmelidir. Farklı eğilimlerin etkisi, olabilecek en etkin biçimde cevapsızlık düzeltme katsayısının hesaplanma sürecine yansıtılmalıdır. Aksi durumda ilgili katsayı sapmayı gidermeyen basit bir genişletme katsayısı görevi yapacaktır.

Cevapsızlık düzeltmesi sonrasında elde edilen ağırlıklar kullanılarak hedef deęiřkenlerin ilgilenilen parametreleri tahmin edilebilir. Ancak, güvenilir dışsal kaynaklardan elde edilebilecek yardımcı bilgiler kullanılarak tahminlerin duyarlılığını geliřtirmek mümkündür. Bu işlem sonucunda, yardımcı deęiřkenler için örnekten elde edilen ağırlıklandırılmış bilgilerin örnekleme dağılımı ile ilgili deęiřkenlerin yığındaki bilgilerinin dağılımı uyumlu hale getirilecektir. Birçok farklı yöntemle yapılabilecek bu kalibrasyon işlemi için birim bazlı yardımcı bilginin yanı sıra, toplam düzeyinde yardımcı bilgi kullanımını da yeterli olabilmektedir.

Herhangi bir kalibrasyon yönteminin araştırma tahminlerinin doğruluğunda iyileştirme yapması beklenir. Bunun yanında, araştırmada çerçeveden kaynaklanan önemli düzeyde kapsam problemi ve/veya cevapsızlık sorunu varsa kalibrasyon işlemi tahminlerin sapmasını da azaltacaktır. Ancak; yardımcı değişken ile istatistiksel olarak anlamlı ilişkisi olmayan değişkenler için parametre tahminlerinin varyansı artabilecektir. Sapmayı gidermesi ve varyansı azaltması nedeniyle; ulusal istatistik ofisleri gibi büyük çaplı araştırma yürüten kullanıcılar tarafından kalibrasyon tahmin edicilerinin kullanımı her geçen gün artmaktadır. İşlem kolaylığı ve anlaşılır olması nedeniyle uygulamacılar genellikle sonradan tabakalama ve raking yöntemleri gibi hücre bazlı kalibrasyon yaklaşımlarını tercih etmektedirler. Deville ve Särndal (1992) tarafından önerilen minimum uzaklık yöntemiyle birçok kalibrasyon tahmin edicisi elde etmek mümkündür. GREG, raking ve sonradan tabakalama gibi çok kullanılan kalibrasyon tahmin edicileri, genellikle bu yöntemden bağımsız olarak tanımlanmakla birlikte minimum uzaklık yaklaşımı ile elde edilebilirler.

Ağırlıklandırma sürecinde kalibrasyon işlemi sonrasında aykırı ağırlıklar ortaya çıkabilir. Ayrıca tasarım ağırlıkları ile karşılaştırıldığında son ağırlıklarda büyük değişkenlikler görülebilir. Uygulamacılar bu sorunlarla mücadele etmek için genellikle budama yaklaşımından faydalanmaktadırlar. Aşırı büyük ağırlıklar budanarak; ağırlığa bağlı olarak oluşacak varyans azaltılmaktadır. Diğer yandan; bu işlem hem tahminlerde sapmaya neden olabilecek hem de kalibrasyon ile gerçekleştirmek istediğimiz dışsal kaynak uyumunu bozacaktır.

Bu tez çalışmasının simülasyon ve uygulama aşamalarında; iş istatistikleri için yapılacak tahminlerin aykırı ağırlıklardan etkilenmemesi için kullanılacak sınırlandırılmış kalibrasyon tahmin edicileri incelenmiştir. Ayrıca, hedef değişkenlerle yardımcı değişkenler arasındaki korelasyon yapılarının kalibrasyon tahmin edicileri üzerindeki etkisi incelenmiştir. Çalışma sonucunda, kalibrasyon tahmin edicilerinin HT tahmin edicisine göre daha etkin sonuç verdiği net bir şekilde görülmektedir. Hedef değişkenin çok düşük varyanslı olduğu ve büyük örnek çaplarında istisnai durumlar ortaya çıkabilir. Örnek oranının yeterince büyük olduğu durumlarda bütün kalibrasyon tahmin edicileri birbirine yakınsamaktadır. Bu bulgu, tüm kalibrasyon tahmin edicilerinin asimptotik olarak GREG tahmin edicisine eşit olduğu bilgisiyle örtüşmektedir. Diğer yandan; örnek oranının küçük olduğu durumlarda, kalibrasyon tahmin edicileri arasında farklılıklar belirgin hale

gelmektedir. Bunun yanında; uygulamada kullanılan veri setindeki "Ciro", "FMKD" gibi deęişkenlięi çok fazla olan deęişkenler tahmin edilmeye alıřıldığında büyük örnek oranları için de kalibrasyon tahmin edicileri arasında farklılıklar belirgin olarak gözükebilir. Arařtırmacılar gerçek veri seti üzerinden yapacakları uygulamalarda negatif ve 1'den küçük aęırlıklardan kaçınmak için TRN ve LOG gibi sınırlandırılmış kalibrasyon tahmin edicilerini veya budama uygulamalarını tercih etmelidir. Yapılan alıřma sonucunda, kalibrasyon kısıtlarına baęlı kalan TRN ve LOG sınırlandırılmış kalibrasyon tahmin edicilerinin, GREG ve raking kalibrasyon tahmin edicilerine yapılan budama iřleminden daha etkin sonuçlar verdięi görülmüřtür. Uygulamacıların sınırlandırılmış kalibrasyon tahmin edicilerini kullanırken dikkat etmesi gereken nokta sınırların belirlenmesidir. Aęırlıklar için alt ve üst sınırların doęru biçimde belirlenmemesi veya gerekli olmayan durumlarda aęırlıkların sınırlandırılması, tahminin etkinlięini arttırmak yerine azaltabilmektedir.



KAYNAKLAR

- Alkaya, A. (2009). *Örnekleme kuramında ağırlıklandırma*, Doktora Tezi, Gazi Üniversitesi Fen Bilimleri Enstitüsü, Ankara, 16.
- Alkaya, A. ve Esin A. (2005). Calibration estimator. *Gazi University Journal of Science*, 18(4), 591-601.
- Ardilly, P. (2006). *Les techniques de sondage*. Paris: Editions Technip.
- Ardilly, P. and Tillé, Y. (2006). *Sampling methods: Exercises and solutions*. New York: Springer Science and Business Media, 264.
- Battaglia, M. P., Izrael, D., Hoaglin, D. C. and Frankel, M. R. (2004). Tips and tricks for raking survey data (aka sample balancing). *Abt Associates*, 4740-4744.
- Beale, E. M. L. (1962). Some uses of computers in operational research. *Industrielle Organisation*, 31(1), 27-28.
- Beaumont, J. F. (2008). A new approach to weighting and inference in sample surveys. *Biometrika*, 95(3), 539-553.
- Bergdahl, M., Black, O., Bowater, R., Chambers, R., Davies, P., Draper, D., ... and Lundström, S. (1999). *Model Quality Report in Business Statistics*. Eurostat, 7-8.
- Bethlehem, J. (2009). *The rise of survey sampling*. Statistics Netherlands, The Hague/Heerlen, Discussion paper (09015).
- Bethlehem, J., Cobben, F. and Schouten, B. (2011). *Handbook of nonresponse in household surveys* (Vol. 568). New Jersey: John Wiley and Sons, 3.
- Borazan Çelikkıçak, M. (2006). *Methods used in reduction of errors arising from nonresponse*, Yüksek Lisans Tezi, Dokuz Eylül Üniversitesi Fen Bilimleri Enstitüsü, Ankara.
- Bowley, A. L. (1906). Address to the economic science and statistics section of the british association for the advancement of science, *Journal of the Royal Statistical Society*, 69(3), 540-558.
- Brackstone, G. J. and Rao, J. N. K. (1979). An investigation of raking ratio estimators. *Sankhya*, 41, 97-114.
- Brick, J. M. (2013). Unit nonresponse and weighting adjustments: a critical review. *Journal of Official Statistics*, 29(3), 329-353.
- Brick, J. M. and Kalton, G. (1996). Handling missing data in survey research. *Statistical Methods in Medical Research*, 5(3), 215-238.
- Brick, J. M. and Montaquila, J. M. (2009). Nonresponse and weighting. *In Handbook of Statistics*, 29, 163-185.

- Brion, P. and Gros, E. (2015). Statistical Estimators Using Jointly Administrative and Survey Data to Produce French Structural Business Statistics. *Journal of Official Statistics*, 31(4), 589-609.
- Bureau of The Census Statistical Research Division. (2000). *A Bibliography of selected methods and development related to census 2000*. Washington, D.C. 20233, August 2000 (No. RR 2000/02). Tommy Wright and Joyce Farmer Statistical Research Division Methodology and Standards Directorate U.S. Bureau of the Census.
- Cassel, C. M., Särndal, C. E. and Wretman, J. H. (1976). Some results on generalized difference estimation and generalized regression estimation for finite populations. *Biometrika*, 63(3), 615-620.
- Cassel, C. M., Sarndal, C. E. and Wretman, J. H. (1983). Some uses of statistical models in connection with the nonresponse problem. *Incomplete data in sample surveys*, 3, 143-160.
- Cervantes, I. F. and Brick, J. M. (2016). Nonresponse adjustments with misspecified models in stratified designs. *Survey methodology*, 42(1), 161-177.
- Chakrabarty, R.P. (1979), Some ratio estimators, *Journal of the Indian Society of Agricultural Statistics*, 31(1), 49-57.
- Chen, Q., Elliott, M. R., Haziza, D., Yang, Y., Ghosh, M., Little, R. J., ... and Thompson, M. (2017). Approaches to improving survey-weighted estimates. *Statistical Science*, 32(2), 227-248.
- Chowdhury, S., Khare, M. and Wolter, K. (2007), Weight Trimming in the National Immunization Survey, *Proceedings of the Joint Statistical Meetings, Section on Survey Research Methods, American Statistical Association*, 2651-2658.
- Cochran W.G. (1942). Sampling theory when the sampling units are of unequal sizes, *Journal of the American Statistical Association*, 37, 199-212.
- Cochran W.G. (1953). *Sampling Techniques*. New York: Wiley.
- Cochran, W.G. (1977). *Sampling Techniques* (Third edition). New York: John Wiley and Sons, 8.
- Deming, W. E. (1950). *Some theories of sampling*. New York: John Wiley and Sons.
- Deming, W. E., Stephan, F. F. (1940). On a least squares adjustment of a sampled frequency table when the expected marginal totals are known. *Annals of Mathematical Statistics*, 11, 427-444.
- Deville, J.C. (1998). *La correction de la nonréponse par calage ou par échantillonnage équilibré*. Paper presented at the Congrès de l'ACFAS, Sherbrooke, Québec.
- Deville, J.C. (2002). *La correction de la nonréponse par calage généralisé*. Actes des Journées de Méthodologie, I.N.S.E.E., Paris.

- Deville, J. C. and Särndal, C. E. (1992). Calibration estimators in survey sampling. *Journal of the American statistical Association*, 87(418), 376-382.
- Deville, J. C., Särndal, C. E. and Sautory, O. (1993). Generalized raking procedures in survey sampling. *Journal of the American statistical Association*, 88(423), 1013-1020.
- Duchesne, P. (1999). Robust calibration estimators. *Survey Methodology*, 25, 43-56.
- EUROSTAT (2017). *Methodological guidelines and description of EU-SILC target variables*, 2017 operation (Version May 2017).
- Estevao, V.M. and Särndal, C.E. (2000). A functional form approach to calibration. *Journal of Official Statistics*, 16, 379-399.
- Estevao, V. M., and Särndal, C. E. (2006). Survey estimates by calibration on complex auxiliary information. *International Statistical Review*, 74(2), 127-147.
- Estevao, V. M. and Särndal, C. E. (2009). A new face on two-phase sampling with calibration estimators. *Survey Methodology*, 35(1), 3-14.
- Folsom, R.E. and Singh, A.C. (2000). The generalized exponential model for design weight calibration for extreme values, nonresponse and poststratification. *Proceedings, Section on Survey Research Methods*, American Statistical Association, 598-603.
- Fuller, W. A. (1973). *Regression for sample surveys*. Austria, Paper presented at meeting of International Statistical Institute, Vienna.
- Fuller, W. A. (1975). Regression analysis for sample survey. *Sankhya*, 37(3), 117-132.
- Fuller, W.A. (2002). Regression estimation for survey samples. *Survey Methodology*, 28, 523.
- Graunt, J. (1662). Natural and political observations. *Made upon the Bills of Mortality*. London.
- Griffin, R. (1995). Dealing with Wide Weight Variation in Polls. *In Proceedings of the Survey Research Methods Section of the American Statistical Association*, 908-911.
- Hansen, M. H. and Hurwitz, W. N. (1943). On the theory of sampling from finite populations. *The Annals of Mathematical Statistics*, 14(4), 333-362.
- Hansen, M. H., Hurwitz, W. N. and Gurney, M. (1946). Problems and methods of the sample survey of business. *Journal of the American Statistical Association*, 41(234), 173-189.
- Hansen, M. H., Hurwitz, W. N. and Madow, W. G. (1953). *Sample survey methods and theory*. New York: Wiley, 7.

- Haziza, D. and Beaumont, J. F. (2017). Construction of weights in surveys: A review. *Statistical Science*, 32(2), 206-226.
- Haziza, D. and Lesage, É. (2016). A discussion of weighting procedures for unit nonresponse. *Journal of Official Statistics*, 32(1), 129-145.
- Henry, K., Valliant, R. (2012a). Comparing Alternative Weight Adjustment Methods. *In Proceedings of the Survey Research Methods Section*, 4696-4710.
- Henry, K., Valliant, R. (2012b). Methods for Adjusting Survey Weights when Estimating a Total, *Proceedings of the Federal Committee on Statistical Methodology*, January, 10-12.
- Holt, D., and Smith, T. F. (1979). Post stratification. *Journal of the Royal Statistical Society: Series A (General)*, 142(1), 33-46.
- Horvitz, D. G. and Thompson, D. J. (1952). A generalization of sampling without replacement from a finite universe. *Journal of the American Statistical Association*, 47(260), 663-685.
- Isaki, C. T., Tsay, J. H. and Fuller, W. A. (2004). Weighting sample data subject to independent controls. *Survey Methodology*, 30, 3544.
- Jessen, R. J. (1942). *Statistical investigation of a sample survey for obtaining farm facts* (Raymond J. Jessen (No. 04; FOLLETO, 3619).).
- Kadilar, C., and Cingi, H. (2003). Ratio estimators in stratified random sampling. *Biometrical journal*, 45(2), 218-225.
- Kalton, G., Flores-Cervantes, I. (2003). Weighting Methods. *Journal of Official Statistics*, 19(2), 81-97.
- Kiaer, A. N. (1895). Observations et expériences concernant des dénombrements représentatifs. *Bulletin of the International Statistical Institute*, 9(2), 176-183.
- Kish, L. (1965). *Survey sampling*. New York: John Wiley and Sons, 21, 90.
- Kish, L. (1990, August). Weighting: Why, when, and how. *In Proceedings of the survey research methods section*, 121-130.
- Kish, L. (1992), Weighting for unequal π_i , *Journal of Official Statistics*, 8(2), 183-200.
- Kish, L. (1995). The hundred years' wars of survey sampling. *Statistics in Transition*, 2(5), 813-830.
- Kott, P. S. (2006). Using calibration weighting to adjust for nonresponse and coverage errors. *Survey Methodology*, 32(2), 133.
- Kott, P. S. and Liao, D. (2015). One step or two? Calibration weighting from a complete list frame with nonresponse. *Survey Methodology*, 41(1), 165-181.

- Koyuncu, N. (2012). *Örnekleme kuramında tahmin edicilere kalibrasyon yönteminin uygulanması*, Doktora Tezi, Hacettepe Üniversitesi Fen Bilimleri Enstitüsü, Ankara.
- Koyuncu, N., and Kadilar, C. (2016). Calibration weighting in stratified random sampling. *Communications in Statistics-Simulation and Computation*, 45(7), 2267-2275.
- Laplace, P. S. (1786). Sur Les Naissances, Les Mariages et les Morts. *Histoire de L'Academic Royale des Sciences*, 1783, Paris, 693-702
- Lindstrom, H. (1979). Standard Methods for Nonresponse Treatment in Statistical Estimation. *National Central Bureau of Statistics*, Sweden.
- Little, R. J. and Rubin, D. B. (2002). *Statistical analysis with missing data*. (Second Edition), New York, Wiley Interscience, 16-19.
- Liu, B., Ferraro, D., Wilson, E. and Brick, J. M. (2004). Trimming extreme weights in household surveys. *Proceedings of the Joint Statistical Meetings, Section on Survey Research Methods, American Statistical Association*, 3905-3912.
- Lohr, S. L., (2010). *Sampling: Design and Analysis* (Second Edition). USA: Brooks/Cole, Cengage Learning, 39,342,344.
- Lundström, S. and Särndal, C.E. (1999). Calibration as a standard method for treatment of nonresponse. *Journal of Official Statistics*, 15, 305-327.
- Metin, C. B. ve Özdemir, Y. A. (2014). Cevaplamama Hatası ve Ortalama Tahmini Üzerindeki Etkisinin İncelenmesi: İki Alt Grup Çalışması. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 18(2), 54-63.
- Montanari, G. E., and Ranalli, M. G. (2003). On calibration methods for design based finite population inferences. *Bulletin of the International Statistical Institute*, 54.
- Montanari, G. E., and Ranalli, M. G. (2005). Nonparametric model calibration estimation in survey sampling. *Journal of the American Statistical Association*, 100(472), 1429-1442.
- Neyman, J. (1934). On the two different aspects of the representative method: the method of stratified sampling and the method of purposive selection. *Journal of the Royal Statistical Society*, 97(4), 558-625.
- Oh, H. L., and Scheuren, F.J. (1983). *Weighting Adjustment for Unit Nonresponse, Incomplete Data in Sample Surveys 2*, edited by Madow, W., Olkin, I., Rubin, D., Academic Press, New York, 143-184.
- Oh, H. L., and Scheuren, F. J. (1987). Modified raking ratio estimation. *Survey Methodology*, 13(2), 209-219.
- Özgül, N. (2018). New calibration estimator in stratified sampling. *Journal of Statistical Computation and Simulation*, 88(13), 2561-2572.

- Pedlow, S. and Porras, J. (2003). O. Muirheartaigh, C., and Shin, H.(2003),—Outlier Weight Adjustment in Reach 2010. *In Proceedings of the Joint Statistical Meetings, Section on Survey Research Methods*, 3228-3233.
- Plikusas, A. (2006, August). Non-linear calibration. *In Proceedings, Workshop on survey sampling, Venspils, Latvia. Riga: Central Statistical Bureau of Latvia.*
- Potter, F. (1988). Survey of procedures to control extreme sampling weights. *In Proceedings of the section on survey research methods, American Statistical Association*, 453-458.
- Potter, F. J. (1990). A study of procedures to identify and trim extreme sampling weights. *In Proceedings of the American Statistical Association, Section on Survey Research Methods*, 225-230.
- Quenouille, M. H. (1956). Notes on bias in estimation. *Biometrika*, 43(3/4), 353-360.
- Ray, S. K. and Singh, R. K. (1981). Difference-cum-ratio type estimators. *Journal of Indian Statistical Association*, 19, 147-151.
- Reynolds, P.D. and Curtin, R.T. (2009), *Business Creation in the United States: Initial Explorations with the PSED II Data Set*. New York: Springer.
- Royall, R. M. and Cumberland, W. G. (1981). The finite-population linear regression estimator and estimators of its variance—An empirical study. *Journal of the American Statistical Association*, 76(376), 924-930.
- Rueda, M., Martínez, S., Martínez, H., and Arcos, A. (2007). Estimation of the distribution function with calibration methods. *Journal of statistical planning and inference*, 137(2), 435-448.
- Särndal, C. E. (2007). The calibration approach in survey theory and practice. *Survey Methodology*, 33(2), 99-119.
- Särndal, C. E., Swensson, B. and Wretman, J. (1992). *Model assisted survey sampling*. New York: Springer-Verlag, 27, 29, 31, 44, 235.
- Särndal, C.E. and Lundström, S. (2005). *Estimation in Surveys with Nonresponse*. New York: John Wiley and Sons, Inc.
- Schouten, B. (2007). A selection strategy for weighting variables under a not-missing-at-random assumption. *Journal of Official Statistics*, 23(1), 51.
- Sen, A. R. (1953). On the estimate of the variance in sampling with varying probabilities. *Journal of the Indian Society of Agricultural Statistics*, 5(1194), 127.
- Singh, H. P. and Kakran, M. S. (1993). A modified ratio estimator using known coefficient of kurtosis of an auxiliary character. *unpublished paper*.

- Singh, A. C. and Mohl, C. A. (1996). Understanding calibration estimators in survey sampling. *Survey methodology*, 22, 107-116.
- Singh, S. and Sedory, S. A. (2016). Two-step calibration of design weights in survey sampling. *Communications in Statistics-Theory and Methods*, 45(12), 3510-3523.
- Singh, H. P. and Tailor, R. (2003). Use of known correlation coefficient in estimating the finite population mean. *Statistics in Transition*, 6(4), 555-560.
- Skinner, C. (1998). *Calibration weighting and nonsampling errors*. Proceedings International Seminar on New Techniques for Statistics, Sorrento, November 46, 55-62.
- Sisodia, B. V. S. and Dwivedi, V. K. (1981). Modified ratio estimator using coefficient of variation of auxiliary variable. *Journal-Indian Society of Agricultural Statistics*. 33, 13-18.
- Srivastava, S. K. (1965). An estimate of the mean of a finite population using several auxiliary variables. *Journal of the Indian Statistical Association*, 3, 189-194
- Stephan, F. F. (1948). History of the uses of modern sampling procedures. *Journal of the American Statistical Association*, 43(241), 12-39.
- Stukel, D.M., Hidiroglou, M.A. and Särndal, C.E. (1996). Variance estimation for calibration estimators: A comparison of jackknifing versus Taylor linearization. *Survey Methodology*, 22, 117-125.
- Şahin, S. T. (2004). *Sonradan tabaklama yönteminde boş tabaka olması durumunda yığın ortalamasına ilişkin tahmin edicilerin karşılaştırılması*, Yüksek Lisans Tezi, Gazi Üniversitesi Fen Bilimleri Enstitüsü, Ankara.
- Théberge, A. (2000). Calibration and restricted weights. *Survey Methodology*, 26, 99-107.
- Thompson, S. K. (1992). *Sampling*. New York: J. Wiley and Sons, 109.
- Tin, M. (1965). Comparison of some ratio estimators. *Journal of the American Statistical Association*, 60(309), 294-307.
- Toprak, A.Ö. (1999). *İstatistiksel Tahmin Üretiminde Dışsal Veri Kullanımı*, Uzmanlık Tezi, Devlet İstatistik Enstitüsü, Ankara.
- Upadhyaya, L. N. and Singh, H. P. (1999). Use of transformed auxiliary variable in estimating the finite population mean. *Biometrical Journal*, 41(5), 627-636.
- Ünüvar, T.G. (1997). *Data Weighting Procedures in Sample Surveys*, Yüksek Lisans Tezi, ODTÜ Fen Bilimleri Enstitüsü, Ankara.
- Ünver, B. (1998). *Veri Ağırlıklandırma Nedenleri, Yöntemleri 1992 Genel Sanayi ve İşyerleri Sayımı II. Aşama Tahminlerine Sonradan Tabakalama Uygulaması*, Uzmanlık Tezi, Devlet İstatistik Enstitüsü, Ankara.

- Valliant, R. (2004). The effect of multiple weighting steps on variance estimation. *Journal of Official Statistics*, 20(1), 1.
- Vanderhoeft, C., Waeytens, E., and Museux, J. M. (2001). Generalised calibration with SPSS 9.0 for Windows baser. *Enquêtes, Modèles et Applications*, 404-415
- Verma, V. (2007). Recent advances in survey sampling, Recent Advances in Statistics, (Editing) Ayhan H.Ö., Batmaz İ., Ankara, *Turkish Statistical Institute Press*, 77-101.
- Verma, V. (2014). *Sampling: An Introduction*, University of Siena, Siena, September 2014, 16, 17, 18, 85-93.
- Webber, M., Latouche, M., and Rancourt, E. (2000). Harmonised calibration of income statistics. *Statistics Canada*, internal document.
- Wu, C. (2003). Optimal calibration estimators in survey sampling. *Biometrika*, 90(4), 937-951.
- Wu, C., and Sitter, R. R. (2001). A model-calibration approach to using complete auxiliary information from survey data. *Journal of the American Statistical Association*, 96(453), 185-193.
- Yates, F. (1949). *Sampling methods for censuses and surveys*. London: Charles Griffin and Co.
- Yates, F. (1981). *Sampling methods for censuses and surveys* (Fourth edition). London: Charles Griffin and Company Ltd, 1.
- Yates, F. and Grundy, P. M. (1953). Selection without replacement from within strata with probability proportional to size. *Journal of the Royal Statistical Society: Series B (Methodological)*, 15(2), 253-261.



EKLER

EK-1. Simülasyon Kodu

```

#### SİMÜLASYON ####
#### ALTERNATİF 1 ####
### Korelasyonlu Rastgele Sayı Üretme ###

R <- matrix(cbind(1,0.5,0.35,
                 0.5,1,0.5,
                 0.35,0.5,1),nrow=3)
U <- t(chol(R))
nvars <- dim(U)[1]
numobs <- 10000
set.seed(1)
random.exp <- matrix(rexp(nvars*numobs,.000001), nrow=nvars, ncol=numobs) # üssel
dağılımdan veri üretimi
X <- U %*% random.exp
newX <- t(X)
veri<-as.data.frame(newX)
orig.veri <-as.data.frame(t(random.exp))
names(veri) <- c("Y","X1","X2")
cor(veri) # korelasyon matrisinin kontrol edilmesi
Y_TOP<-sum(veri$Y)
write.csv(veri,file="veri.csv")

### MONTE CARLO ###

r<-5000
HT<- matrix(0,r,1)
CAL_LIN<-matrix(0,r,1)
CAL_RAK<-matrix(0,r,1)
CAL_TRN<-matrix(0,r,1)
CAL_LOG<-matrix(0,r,1)

for(i in 1:r){

### ÖRNEK ÇEKİMİ ###
N<-10000
n<-500

# Örnekleme paketinin yüklenmesi #
library(sampling)
s<-srswor(n,N)
ornekler<-getdata(veri,s)
write.csv(ornekler,file="ornekler.csv")

### Seçim Olasılıklarının Dataya yazdırılması ###
dw<-c(rep(N/n,n))
ornekler$dw<-dw

```

EK-1.(devam) Simülasyon Kodu

```

#### HT TAHMİN EDİCİSİ ####
HT[i]<-sum(ornekler$Y*ornekler$dw)
#### GREG Calib funtion için (linear) ####
total<-c(sum(veri$X1),sum(veri$X2))
Xs<-cbind(ornekler$X1,ornekler$X2)
gw_linear<calib(Xs,d=ornekler$dw,total,q=rep(1,length(dw)),method=c("linear"),
description=FALSE,max_iter=500)
ornekler$gw_linear<-gw_linear
CAL_LIN[i]<-sum(ornekler$Y*ornekler$dw*ornekler$gw_linear)

#### GREG Calib funtion için (raking) ####

gw_raking<calib(Xs,d=ornekler$dw,total,q=rep(1,length(dw)),method=c("raking"),
description=FALSE,max_iter=500)
ornekler$gw_raking<-gw_raking
CAL_RAK[i]<-sum(ornekler$Y*ornekler$dw*ornekler$gw_raking)

#### GREG Calib funtion için (truncated) ####

a<-min(ornekler$gw_linear)
b<-max(ornekler$gw_linear)
kat<-b/a

if (kat>5)

{aa<-a+a*0.1
bb<-b-b*0.1
}else
{aa<-a
bb<-b}

if(aa>1)

{alt<-0.99
}else
{alt<-aa}

if(bb<1)

{ust<-1.01
}else
{ust<-bb}

gw_truncated<calib(Xs,d=ornekler$dw,total,q=rep(1,length(dw)),method=c("truncated"),b
ounds=c(low=alt,upp=ust),description=FALSE,max_iter=500)
ornekler$gw_truncated<-gw_truncated
CAL_TRN[i]<-sum(ornekler$Y*ornekler$dw*ornekler$gw_truncated)

```

EK-1.(devam) Simülasyon Kodu

```
### GREG Calib funtion için (logit) ###  
gw_logit<calib(Xs,d=ornekler$dw,total,q=rep(1,length(dw)),method=c("logit"),description  
=FALSE,max_iter=500)  
ornekler$gw_logit<-gw_logit  
CAL_LOG[i]<-sum(ornekler$Y*ornekler$dw*ornekler$gw_logit)  
  
}  
  
sonuclar<-cbind(HT,CAL_LIN,CAL_RAK,CAL_TRN,CAL_LOG)  
cikti<-as.data.frame(sonuclar)  
names(cikti) <- c("HT","CAL_LIN","CAL_RAK","CAL_TRN","CAL_LOG")  
write.csv(cikti,file="cikti.csv")
```



EK-2. Uygulama Kodu (NACE 7810 için)

```
### NACE 7810 ###
```

```
library(sampling)
```

```
setwd("C:\\Users\\tuik\\Documents\\C_Veri")
```

```
veri<-read.csv("C:\\Users\\tuik\\Documents\\C_Veri\\NACE_7810.csv",header=TRUE)
```

```
### MONTE CARLO ###
```

```
r<-50000
```

```
HT<- matrix(0,r,3)
```

```
CAL_LIN<-matrix(0,r,3)
```

```
CAL_RAK<-matrix(0,r,3)
```

```
CAL_TRN<-matrix(0,r,3)
```

```
CAL_LOG<-matrix(0,r,3)
```

```
LIN_TRIM<-matrix(0,r,3)
```

```
RAK_TRIM<-matrix(0,r,3)
```

```
kontrol<-vector("list",r)
```

```
for(i in 1:r){
```

```
### ÖRNEK ÇEKİMİ ###
```

```
N<-1542
```

```
n<-250
```

```
# Örnekleme paketinin yüklenmesi #
```

```
set.seed(i)
```

```
s<-srswor(n,N)
```

```
ornekler<-getdata(veri,s)
```

```
### Seçim Olasiliklarinin Dataya yazdirilmesi ###
```

```
dw<-c(rep(N/n,n))
```

```
ornekler$dw<-dw
```

```
### HT TAHMİN EDİCİSİ ###
```

```
HT[i,1]<-sum(ornekler$CIRO*ornekler$dw)
```

```
HT[i,2]<-sum(ornekler$FMKD*ornekler$dw)
```

```
HT[i,3]<-sum(ornekler$TMSA*ornekler$dw)
```

```
### GREG Calib funtion için (linear) ###
```

```
total<-c(sum(as.numeric(veri$CAL_SAY)),sum(as.numeric(veri$MHSA)))
```

```
Xs<-cbind(ornekler$CAL_SAY,ornekler$MHSA)
```

EK-2.(devam) Uygulama Kodu (NACE 7810 için)

```

gw_lineer<-
calib(Xs,d=ornekler$dw,total,q=rep(1,length(dw)),method=c("linear"),description=FALSE
,max_iter=50000)
ornekler$gw_lineer<-(1/mean(gw_lineer))*gw_lineer
CAL_LIN[i,1]<-sum(ornekler$CIRO*ornekler$dw*ornekler$gw_lineer)
CAL_LIN[i,2]<-sum(ornekler$FMKD*ornekler$dw*ornekler$gw_lineer)
CAL_LIN[i,3]<-sum(ornekler$TMSA*ornekler$dw*ornekler$gw_lineer)

```

GREG Calib funtion için (raking)

```

gw_raking<-
calib(Xs,d=ornekler$dw,total,q=rep(1,length(dw)),method=c("raking"),description=FALSE
,max_iter=50000)
ornekler$gw_raking<-(1/mean(gw_raking))*gw_raking
CAL_RAK[i,1]<-sum(ornekler$CIRO*ornekler$dw*ornekler$gw_raking)
CAL_RAK[i,2]<-sum(ornekler$FMKD*ornekler$dw*ornekler$gw_raking)
CAL_RAK[i,3]<-sum(ornekler$TMSA*ornekler$dw*ornekler$gw_raking)

```

GREG Calib funtion için (truncated)

```

a1<-min(gw_lineer)
b1<-max(gw_lineer)
if (a1<0){a<-0.3
b<-3}else{a<-a1
b<-b1}
kat<-b/a

```

```

if (kat>10)
{fark<-(b-10*a)/13
}else
{fark<-0}

```

```

aa<-a+fark
bb<-b-(3*fark)

```

```

if(aa>1)
{alt1<-0.99
ust1<-9.9
}else
{alt1<-aa
ust1<-bb}

```

```

if(bb<1)
{ust<-1.01
alt<-0.101
}else

```


EK-2.(devam) Uygulama Kodu (NACE 7810 için)

```
{ust<-ust1
  alt<-alt1}
say<-1

repeat{
gw_truncated<-
calib(Xs,d=ornekler$dw,total,q=rep(1,length(dw)),method=c("truncated"),bounds=c(low=
alt,upp=ust),description=FALSE,max_iter=50000)
ust<-ust+0.1
say<-say+1;
if(min(gw_truncated)>0|say>10){break}
}

ornekler$gw_truncated<-(1/mean(gw_truncated))*gw_truncated
CAL_TRN[i,1]<-sum(ornekler$CIRO*ornekler$dw*ornekler$gw_truncated)
CAL_TRN[i,2]<-sum(ornekler$FMKD*ornekler$dw*ornekler$gw_truncated)
CAL_TRN[i,3]<-sum(ornekler$TMSA*ornekler$dw*ornekler$gw_truncated)

kontrol[[i]]<-cbind(gw_truncated)

### GREG Calib funtion için (logit) ###

gw_logit<-
calib(Xs,d=ornekler$dw,total,q=rep(1,length(dw)),method=c("logit"),description=FALSE,
max_iter=50000)
ornekler$gw_logit<-(1/mean(gw_logit))*gw_logit

CAL_LOG[i,1]<-sum(ornekler$CIRO*ornekler$dw*ornekler$gw_logit)
CAL_LOG[i,2]<-sum(ornekler$FMKD*ornekler$dw*ornekler$gw_logit)
CAL_LOG[i,3]<-sum(ornekler$TMSA*ornekler$dw*ornekler$gw_logit)

### WEIGHT TRIMMING ###

repeat{
w1<-gw_lineer/mean(gw_lineer)
scale<-mean(w1)
for(j in 1:n){
if(w1[j]<0.3){w1[j]=0.3}
else if (w1[j]>3){w1[j]=3}
else(w1[j]=w1[j])
}
gw_lineer<-w1*(scale/mean(w1));
if(max(gw_lineer)/min(gw_lineer)<10){break}
}
ornekler$trim<-(1/mean(gw_lineer))*gw_lineer
LIN_TRIM[i,1]<-sum(ornekler$CIRO*ornekler$dw*ornekler$trim)
LIN_TRIM[i,2]<-sum(ornekler$FMKD*ornekler$dw*ornekler$trim)
LIN_TRIM[i,3]<-sum(ornekler$TMSA*ornekler$dw*ornekler$trim)
```

EK-2.(devam) Uygulama Kodu (NACE 7810 için)

```

repeat{
  w2<-gw_raking/mean(gw_raking)
  scale2<-mean(w2)
  for(j in 1:n){
    if(w2[j]<0.3){w2[j]=0.3}
    else if (w2[j]>3){w2[j]=3}
    else(w2[j]=w2[j])
  }
  gw_raking<-w2*(scale2/mean(w2));
  if(max(gw_raking)/min(gw_raking)<10){break}
}
ornekler$trim2<-(1/mean(gw_raking))*gw_raking
RAK_TRIM[i,1]<-sum(ornekler$CIRO*ornekler$dw*ornekler$trim2)
RAK_TRIM[i,2]<-sum(ornekler$FMKD*ornekler$dw*ornekler$trim2)
RAK_TRIM[i,3]<-sum(ornekler$TMSA*ornekler$dw*ornekler$trim2)

}

write.csv(kontrol,file="kontrol.csv")
sonuclar<-
cbind(HT,CAL_LIN,CAL_RAK,CAL_TRN,CAL_LOG,LIN_TRIM,RAK_TRIM)
cikti<-as.data.frame(sonuclar)
names(cikti) <-
c("HT_CIRO","HT_FMKD","HT_TMSA","LIN_CIRO","LIN_FMKD","LIN_TMSA","R
AK_CIRO","RAK_FMKD","RAK_TMSA","TRN_CIRO",

"TRN_FMKD","TRN_TMSA","LOG_CIRO","LOG_FMKD","LOG_TMSA","LTRIM_C
IRO","LTRIM_FMKD","LTRIM_TMSA","RTRIM_CIRO","RTRIM_FMKD","RTRIM_
TMSA")
write.csv(cikti,file="cikti.csv")

```

ÖZGEÇMİŞ

Kişisel Bilgiler

Soyadı, adı : METİN, Cenker Burak
 Uyuşuğu : T.C.
 Doğum tarihi ve yeri : 05.04.1983, Ankara
 Medeni hali : Evli
 Telefon : 0 (505) 617 35 16
 e-mail : cenkermetin@gmail.com



Eğitim

Derece	Eğitim Birimi	Mezuniyet Tarihi
Doktora	Gazi Üniversitesi / İstatistik	Devam ediyor
Yüksek Lisans	Gazi Üniversitesi / Ekonometri	2010
Lisans	ODTÜ / İstatistik	2005
Lise	Ankara Gazi Anadolu Lisesi	2001

İş Deneyimi

Yıl	Yer	Görev
2011-Halen	Türkiye İstatistik Kurumu	TÜİK Uzmanı
2006- 2011	Türkiye İstatistik Kurumu	TÜİK Uzman Yardımcısı

Yabancı Dil

İngilizce

Yayınlar

1. Metin, C. B., Özdemir, Y. A. (2014). Cevaplamama Hatası ve Ortalama Tahmini Üzerindeki Etkisinin İncelenmesi: İki Alt Grup Çalışması. *Journal of Natural and Applied Science*, 18(2), 54-63.
2. Tekin, S. T. Ş., Özdemir, Y. A. and Metin, C. B. (2017). A New Comprromise Allocation Method In Stratified Random Sampling. *Gazi University Journal of Science*, 30(3), 181-194.
3. Tekin, S. T. Ş., Metin, C. B. and Özdemir, Y. A. (2019). A New Power Allocation Method with a Nonlinear Cost Constraint in Stratified Random Sampling. *Journal of Natural and Applied Sciences*, 23, 99-107.

Hobiler

Voleybol, Masa Tenisi, Bowling, Kitap





GAZİ GELECEKTİR..