

**T.C.
MİMAR SİNAN GÜZEL SANATLAR ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**BİREYSEL TERCİHLERİN MODELLENMESİNE YÖNELİK
EKONOMETRİK YAKLAŞIMLAR**

YÜKSEKLİSANS TEZİ

Bahar KINAY

İstatistik Anabilim Dalı

İstatistik Programı

Tez Danışmanı: Yrd. Doç. Dr. Funda H. SEZGİN

MAYIS 2009

Bahar Kınay tarafından hazırlanan “Bireysel Tercihlerin Modellenmesine Yönelik Ekonometrik Yaklaşımlar” adlı araştırmanın Yüksek Lisans Tezi olarak uygun olduğunu onaylarım.

Yrd. Doç. Dr. Funda Sezgin

Bu çalışma Mimar Sinan Güzel Sanatlar Üniversitesi Fen Bilimleri Enstitüsü İstatistik Anabilim Dalı, İstatistik Programında Yüksek Lisans Tezi olarak kabul edilmiştir.

Danışman : Yrd. Doç. Dr. Funda Sezgin

İmza

Jüri Üyesi : Prof. Dr. Nalan Cinemre

İmza

Jüri Üyesi : Doç. Dr. Tuncay Can

İmza

BİREYSEL TERCİHLERİN MODELLENMESİNE YÖNELİK EKONOMETRİK YAKLAŞIMLAR

(Yüksek Lisans Tezi)

Bahar KINAY

MİMAR SİNAN GÜZEL SANATLAR ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

Mayıs 2009

ÖZET

Bu çalışmada amaç, bireysel tercih davranışı teorilerinin tercihler üzerindeki etkilerini pazarlama ve ekonomi disiplinlerine dayanarak açıklamaktır. Fayda maksimizasyonu teorisi dikkate alınarak tercihlerin ölçülmesi ve modellenmesinde kullanılan teknikler açıklanmıştır. Tercih teorisinin faktörleri olan karar verici, alternatifler, alternatiflerin nitelikleri ve karar kuralları ekonometrik teorilere göre açıklanmıştır. Çalışmanın ana amacı olan kesikli tercih modellerinin oluşumu ve özellikleri tanımlanıp, analizde kullanılan modeller ayrıntılı şekilde ele alınmıştır. Uygulama bölümünde STATA paket programı kullanılarak 300 haneye ilişkin restoran tercihlerinin modellenmesi incelenmiştir. Modelleme yapılırken kesikli tercih modellerinden nested logitin veriler için uygun olduğu Hausman testi ile saptanmıştır. Etkin tercih modeli kararlaştırıldıktan sonra restoran tercihlerini etkileyen faktörler belirlenmiş ve yorumlanmıştır.

Bilim Kodu :

Anahtar Kelimeler : Kesikli Tercih Analizi, Kesikli Tercih Modelleri, Nested Logit, Hausman Testi

Sayfa Adedi :

Tez Yöneticisi : Yrd. Doç. Dr. Funda H. SEZGİN

**ECONOMETRIC APPROACHES TO MODELLING INDIVIDUAL
PREFERENCES**

(M.Sc. Thesis)

Bahar KINAY

MIMAR SINAN FINE ARTS UNIVERSITY

INSTITUTE OF SCIENCE AND TECHNOLOGY

May 2009

ABSTRACT

The purpose of this study is to explain the effects of individual choice behaviour theories, based on marketing and economics, on preferences. By considering utility maximization theory, the techniques, measurement and modelling of preferences, are analyzed. According to econometric theories, the factors of choice theory – decision maker, alternatives, attribution of alternatives and decision rule - are explained. As the main aim of the study, constitution and properties of the discrete choice models are defined and the models used in analyzing are approached in details. By using STATA package program, restaurant preferences modelling, relating to 300 house, is examined. In modelling whether nested logit is appropriate for the data is decided by the Hausman test. After the effective model is decided, the factors which effect preferences of restaurant, are determined and commented.

Science Code :

Key Words : Discrete Choice Analysis, Discrete Choice Models, Nested Logit, Huasman Test

Page Number:

Supervisor : Ass. Prof. Funda H. SEZGİN

ÖNSÖZ

Bu çalışmanın her aşamasında göstermiş olduğu ilgi, görüş ve eleştirileri için danışman hocam Mimar Sinan Güzel Sanatlar Üniversitesi Fen Edebiyat Fakültesi İstatistik Bölümü Öğretim Üyesi Sayın Yrd. Doç. Dr. Funda H. SEZGİN'e, çalışmanın gerçekleşmesi için gerekli ortamı hazırlayan ve yazım aşamasında bana hep destek olan Mimar Sinan Güzel Sanatlar Üniversitesi Fen Edebiyat Fakültesi İstatistik Bölüm Başkanı Sayın Prof. Dr. Nalan CİNEMRE'ye, bu aşamada manevi desteklerini gördüğüm ailem ve çalışma arkadaşlarıma sonsuz teşekkürlerimi sunarım.

Mayıs 2009

Bahar KINAY

İÇİNDEKİLER

ÖZET.....	i
SUMMARY.....	ii
ÖNSÖZ.....	iii
ŞEKİL LİSTESİ.....	vi
TABLO LİSTESİ.....	vii
KISALTMALAR LİSTESİ.....	viii
1. GİRİŞ.....	1
2. BİREYSEL TERCİH DAVRANIŞI TEORİLERİ.....	3
2.1. Tercih Davranışı Teorilerinin Yapısı.....	4
2.1.1. Karar Verici.....	8
2.1.2. Alternatifler.....	8
2.1.3. Alternatiflerin Nitelikleri.....	9
2.1.4. Karar Kuralı.....	10
2.2. Ekonomik Açıdan Tercih Teorileri.....	11
2.2.1. Teori Geliştirme.....	12
2.2.1.1. Tercihlerin Yapıları.....	14
2.2.1.2. Tercih Alternatifleri.....	15
2.2.1.3. Tercih Kuralları.....	16
2.2.1.4. Ortaya Çıkan Tercihlerin Yapısı.....	18
2.2.2. Parametreleştirme.....	23
2.3. Tahmin.....	27
3. KESİKLİ TERCİH KAVRAMI VE ÖZELLİKLERİ.....	31
3.1. Kesikli Tercih Kavramı.....	31
3.2. Kesikli Tercih Modellerinin Özellikleri.....	33
3.2.1. Tercih Kümesi.....	34
3.2.2. Tercih Olasılıklarının Türetimi.....	35
3.2.3. Tercih Modellerinin Tanımlanması.....	38
3.2.3.1. Sadece Fayda Sorunundaki Farklılıklar.....	38
3.2.3.2. Fayda Ölçeği Kişiseldir.....	42
3.2.4. Toplulaştırma.....	47
3.2.4.1. Örneklemin Sıralanması.....	49
3.2.4.2. Bölümlendirme.....	50
3.2.5. Ön Kestirim.....	50
3.2.6. Sabitlerin Yeniden Düzenlenmesi.....	51
4. KESİKLİ TERCİH MODELLERİ.....	53
4.1. İkili Tercih Modelleri.....	53
4.1.1. Doğrusal Olasılık Modeli.....	54
4.1.2. Probit Model.....	56
4.1.3. Logit Model.....	58

4.2. Çoklu Tercih Modelleri.....	61
4.2.1. Çokterimli Logit Model.....	61
4.2.2. Çokterimli Probit Model.....	65
4.2.3. Sıralı Logit Model.....	67
4.2.4. Sıralı Probit Model.....	70
4.2.5. Genelleştirilmiş Extrem Değer Modeli.....	70
4.3. Çok Boyutlu Tercih Modelleri.....	72
4.3.1. Bileşik Logit Model.....	72
4.3.2. Nested Logit Model.....	72
4.3.2.1. Nested Logit Modellerin Normalleştirilmesi.....	76
4.4. Uyum İyiliği Ölçütleri.....	77
5. UYGULAMA.....	79
5.1. Kesikli Tercih Analizinin STATA Paket Programında Uygulanması.....	74
7. SONUÇ.....	96
KAYNAKLAR.....	99
ÖZGEÇMİŞ.....	104

ŞEKİL LİSTESİ

	Sayfa No
Şekil 2.1. Tüketici tercih modelleri ve ölçüm teknikleri	4
Şekil 2.2. Tercih modellerinin ayrıştırılması.....	20
Şekil 3.1.Ortalama olasılık ile ortalama temsilci faydada hesaplanan olasılık arasındaki fark	48
Şekil 3.2.Ortalama tepki ile ortalama temsilci faydada hesaplanan teпки arasındaki fark	48

TABLO LİSTESİ

	Sayfa No
Tablo 2.1. Teorilerin yapıları	18
Tablo 2.2. Bireyin tercih süreci	21

KISALTMALAR LİSTESİ

RUMs	: Rastlantısal Fayda Modelleri
PT	: Olası Müşteri Teorisi
EUT	: Beklenen Fayda Teorisi
AVM	: Alışveriş Mağazası
ŞM	: Şehir Merkezi
iid	: Bağımsız ve Özdeşçe Dağılan
GEV	: Genelleştirilmiş Ekstrem Değer
DOM	: Doğrusal Olasılık Modeli
SEKK	: Sıradan En Küçük Kareler
TEKK	: Tartılı En Küçük Kareler
IIA	: İlişkisiz Alternatiflerin Bağımsızlığı

1. GİRİŞ

Günümüzde artan küreselleşme eğilimi ve teknolojik gelişim süreci firmaların birçoğu için yeni fırsatlar ve pazarlar anlamına gelmektedir. Böyle bir ortamda firmalar tüketicilerin beklentileri doğrultusunda yeni ürünler oluşturmak ve bunların geliştirilmesi üzerinde çalışmak zorunda kalmışlardır. Rekabetin geliştiği piyasalarda ve tüketicinin daha seçici olduğu durumlarda firmalar farklı özelliklere ve etkin kalite kavramına ihtiyaç duymaktadır. Çünkü bu şekilde başarılı mal ve hizmetlerle tüketicilerin beklentilerini karşılayabilirler. Firmalar kendilerini geliştirebilmek için tüketicilerin dinamik bir yapı gösteren tercihlerini bilmek durumundadırlar. Bu nedenle tüketici tercihlerini ölçmek ve analiz etmek çok önemlidir.

Tüketici tercihlerinin iki önemli açılımı vardır. Bunlardan ilki modelleme; bir ürünün değerlendirilmesi ve sonucunda tercih edilmesi sürecini kapsamaktadır. İkincisi ölçümleme, belirli bir karar kuralının uygulandığını varsayarak olası bazı hatalarla tercihlerin sınıflandırılmasına dayanmaktadır. Karşılaşılan temel problem ayrıntılı alternatifler kümesinden yapılan tercihleri modellemektir. Dolayısıyla tercihlerin değerlendirilmesi ve ölçülmesi bazı istatistiksel modeller yardımıyla yapılmaktadır.

Tüketici tercihlerinin belirlenmesi için kullanılan yöntemlerden en yaygın olanı kesikli tercih analizidir. Kesikli tercih analizinde öncelikle tercih yapacak kişilere bazı alternatifler sunulup bu alternatiflerden birini ya da birkaçını tercih etmesi istenmektedir. Kişinin kendi faydasını maksimum yapan alternatifini tercih edeceği aşikârdır. Kesikli tercih analizinde fayda maksimizasyonu kuralı geçerlidir. Dolayısıyla en yüksek faydaya sahip alternatifin tercih edileceği varsayılarak modelleme yapılır. Model, gözlenen bağımsız değişkenlere ve bilinmeyen parametrelere göre ifade edilen fayda fonksiyonlarından, bunların değerlerinden ve tercih durumuyla karşılaşıldığında karar vericiler tarafından yapılan gözlemlenmiş tercihlerin örneklemeden tahmin edilen değerleri içermektedir. Bu tahminler her zaman başarılı olmamaktadır. Bu nedenle ilk olarak psikolojide ortaya çıkan ve alternatiflerin faydalarını rassal değişkenler olarak ele alan rassal fayda teorisi

dikkate alınmaktadır. Dolayısıyla, alternatifin tercih edilme olasılığı, mümkün alternatifler arasından en yüksek faydaya sahip olan olasılık olarak tanımlanmaktadır.

Çalışmanın ilk aşamasında bireysel tercih davranışı teorileri incelenirken, bireylerin alternatifini tercih etmesi satın alma öncesi, satın alma anı ve sonrası olarak üç safhalı bir süreçte değerlendirilmiştir. Tüketici davranışı teorisi karar verici, alternatifler, alternatiflerin nitelikleri ve karar kurallarından oluşmaktadır. Bu bölümde, özellikle karar kuralını etkileyen ekonomik tercih teorileri üzerinde durulmuştur. Bu teoriler Lancaster tarafından genişletilen şekliyle neoklasik ekonomik teori, von Neumann-Morgenstern tarafından geliştirilen belirsizlik altında risk-tercih teorisi, Luce fayda modeli ve Thurstone sabit fayda modelidir. İktisat disiplinine dayanan bu teorik sistemler açıklanarak, tüketicinin tercih tutumunun nasıl modellendiği üzerinde durulmuştur. Öncelikle, her bir teorinin nasıl geliştirildiği, fayda maksimizasyonu ile ilgili tercih aksiyomu, tercih alternatifleri ve ortaya çıkan tercihin yapısı açıklanmıştır. Ayrıca fayda teorisinin parametreleştirilmesi ve tahmininde kullanılan yöntemler açıklanarak, bu konuda yapılan geçmiş çalışmalara değinilmiştir. Ayrıca, Luce fayda modeli ve Thurstone sabit fayda modeli teorisinin dayandığı kesikli tercih kavramı ve özellikleri açıklanmıştır.

Uygulamanın temel amacı, tüketici tercihlerinin ölçümü ve analizi için uygun modelleme stratejilerinin aşamalarını ortaya koymak ve tercih davranışı teorilerinin nasıl kullanıldığını göstermektir. Teknik anlamda modelleme sürecinin ve uygunluk testlerinin nasıl işlediği ve sonuçların nasıl yorumlanacağı üzerinde durulmuş ve STATA paket programı yardımıyla 300 hane üzerinden 7 restoran için uygulaması yapılmıştır. Tercihleri etkileyen faktörlerin doğru bir biçimde belirlenmesinin pazarlama ve satış stratejilerine katkısı çok büyüktür. Bu sebepten bu tür analizlerin ekonomik getiriye olan katkısı vurgulanmaya çalışılmıştır.

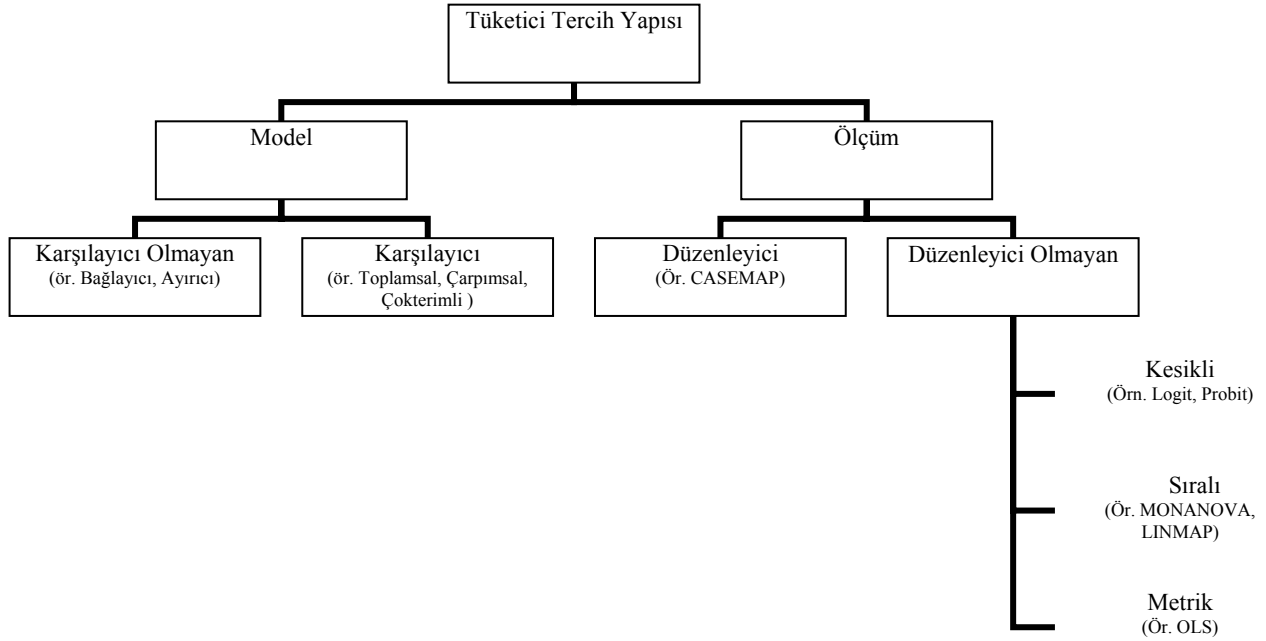
2. BİREYSEL TERCİH DAVRANIŞI TEORİLERİ:

Geleneksel tüketim teorisi, üretilen çeşitli mal ve hizmet gruplarından elde edilecek faydayı optimize eden tercihlerde bireylerin davranışlarıyla ilgilenmektedir. Böylece emek piyasası içinde bireysel üretici davranışları da tüketim teorisi, yani talep teorisi varsayımları içinde yer almaktadır. Geleneksel talep teorisi malın fiyatı, diğer malların fiyatı, tüketici geliri ve tüketici zevkleri gibi faktörleri ele almaktadır. Piyasa talebinin tüketici taleplerinin toplamı olduğu varsayıldığından geleneksel talep teorisi bireysel tüketici davranışının incelenmesiyle başlar (Koutsoyiannis, 1987). Bu teoride tüketicinin rasyonel olduğu varsayılmaktadır. Gelir ve fiyatlar verildiğinde tüketici, tüketimini maksimum tatmini ya da faydayı sağlayacak bir şekilde planlar. Bu özellik fayda maksimizasyonu aksiyomudur. Geleneksel talep teorisi tüketicinin tam bilgiye sahip olduğunu, yani tüketicinin tüm tüketilebilir malların neler olduğunu, bu malların fiyatlarını ve kendi gelirin ne olduğunu bildiğini varsayar (Koutsoyiannis, 1987).

Tüketici davranışı, bireyin mal ve hizmetleri tercih etme, satın alma, kullanma ve elden çıkarmadaki kararları ile ilgili faaliyetleri olarak tanımlanmaktadır. Böylece satın alma öncesi, satın alma anı ve sonrası olarak 3 safhalı bir süreçten söz edilir. Bir taraftan üreticiler ya da pazarlamacılar tüketicileri ürün ve hizmetlere yönlendirecek kararlar alırken, diğer taraftan tüketiciler de kendilerine sunulan alternatifler içerisinde ihtiyaçlarına en uygun olanı ve en yüksek faydayı sağlayanı tercih etmeye çalışmaktadır. Bu nedenle bireylerin faydalarının hesaplanması çok önemlidir. Bu hesaplamada bireysel tercihlerin belirlenmesi en önemli kısımdır ve hata yapılmaması gerekmektedir. Davranışları ve tercihleri modellemek her zaman için zor bir aşamayı oluşturmuştur. Bireysel tercih davranışlarını hatasız belirleyebilmek için tercih teorisinin yapısını, karar vericiyi, alternatifleri, alternatiflerin niteliklerini ve karar kuralını çok iyi bilmek gerekir.

2.1. TERCİH DAVRANIŞI TEORİLERİNİN YAPISI

Pazarlama ve ekonometride tüketici tercihlerini ölçmek ve analiz etmek en çok üzerinde araştırılan konulardır. Tüketici tercihlerinin modellenmesi ve ölçümü üzerinde durulan en önemli sorundur. Bu sebepten tüketici tercihlerinin modellenmesinde ve ölçülmesinde birçok teknik kullanılmaktadır. Şekil 2.1 tüketici tercih modellerine ve ölçüm tekniklerine genel bir bakışı göstermektedir.



Şekil 2.1 Tüketici tercih modelleri ve ölçüm teknikleri

Tüketici tercih yapısı modellenirken karşılıyıcı ve karşılıyıcı olmayan modeller kolaylıkla ayırt edilebilmektedir. Karşılıyıcı modeller özellikle nitelikleri dikkate alan bir strateji izlemektedir. En önemli karşılıyıcı modeller toplamsal, çarpımsal ve çokterimli modellerdir. Karşılıyıcı modellerde bilgi, mal ya da hizmetin genel değerlendirmesine (fayda ya da tercih) göre nitelendirilmektedir. Toplamsal modelde, her bir nitelik önemlilik derecelerine göre ağırlıklandırılmakta ve bu ağırlıklar genel değerlendirme oluşturmak için kullanılmaktadır. Çarpımsal modelde, benzer biçimde yapılan ağırlıklandırma çarpımsal şekilde birleştirilerek değerlendirmeye katılmaktadır. Çokterimli model ise her iki modelin karması şeklindedir.

Karşılıyıcı olmayan modellerin en önemlileri bağlayıcı ve ayırıcı modellerdir. Bağlayıcı modellerde tüketici bir mal ya da hizmeti bütün niteliklerini kabul ettiği taktir de dikkate almaktadır. Herhangi bir nitelik eksik ise mal ya da hizmetten vazgeçilmektedir. Ayırıcı modellerde ise tercih edilen mal ya da hizmetin istenilen bütün nitelik değerlerine sahip olmasına gerek yoktur. Tercih edilen mal ya da hizmetin en az bir üstün niteliğe sahip olması yeterlidir.

Tüketici tercihlerinin ölçümü ise düzenleyici ve düzenleyici olmayan yaklaşımlar şeklinde ikiye ayrılmaktadır. Düzenleyici yaklaşımlar davranış modellerinin beklenen değer sınıfına dayanmaktadır. Burada çok nitelikli ürün için toplam fayda ürünün nitelik değerleri ile karar verici tarafından karşılaştırılan birleşik değer oranlarının ağırlıklı toplamına eşittir. Kendi kendini açıklayan bu modeller uygulamada tüketici tercih yapısını oluşturmak için kullanılmaktadır (Zwerina, 1997). Bu modellerde birey ilk önce nitelik değerlerini istek derecesine göre değerlendirilmekte, daha sonra niteliklerin göreceli önemliliklerini nitelikler arasında pay ederek belirlemekte ve mal ya da hizmetin toplam faydası nitelik değerlerinin ağırlıklı toplamı olarak hesaplanmaktadır. Burada ağırlıklar karar verici bireyden bireye farklılıklar göstermektedir. Bu modellere verilebilecek en bilinen örnek CASEMAP'tir (Srinivasan, 1988).

Kendi kendini açıklayan modellerde bazı problemler ortaya çıkmaktadır. En önemli problem tercih yapılarının değerlendirilmesindeki yetersizliktir. Örneğin, niteliklerin önemleri karşılaştırılırken birey daha önemli bir niteliğe daha az değer ya da daha önemsiz bir niteliğe daha fazla değer biçebilmektedir. Bu sorunu çözmek için düzenleyici olmayan yöntemler kullanılmaktadır.

Düzenleyici olmayan yöntemler tüketici tercih yapısını tahmin ederken bireyin kendisine tercih yapısı hakkında da soru sormamakta ve farklı ürünler kümesinin genel değerlendirmesiyle ilgilenmektedir (Zwerina, 1997). Bireylerden ya fark edilen tercihlerini gösteren ürün çeşitlerini derecelendirmeleri ya da örneğin 100 puanlık satın-alma olasılığı ölçeği şeklinde oranlamaları istenmektedir. Daha sonra elde edilen bu tercih yapılarına istatistiksel yöntemler uygulanmaktadır. Oranlamada (metrik ölçüm) en küçük kareler yöntemi ve derecelendirmede MONANOVA ya da LINMAP gibi daha uzmanlaşmış yöntemler kullanılmaktadır. En küçük kareler

yönteminin kullanım kolaylığı ve yaygın kullanılabilirliği bu modeli daha da popüler bir yapmaktadır. Oran ve derece verilerine dayalı olan bu yöntemler konjoint analizlerin başlıcalarıdır.

Konjoint analizde ortaya çıkan başlıca model kesikli tercih modeli ya da diğer bir deyişle tercih-odaklı konjoint analizdir. Son yıllarda konjoint analiz ve kesikli tercih modelleri tüketici tercihlerini ölçmek ve analiz etmek için kullanılan yöntemlerdir. Bu yöntemler akademide ve endüstride kullanılan başlıca yöntemlerdir (Carroll ve Green, 1995). Burada özellikle iki popüler metot olan ve tüketici tercihlerini çalışan konjoint analiz yardımıyla kesikli tercih modelleri açıklanacak ve bu iki metot karşılaştırılacaktır.

Konjoint analiz bireylerin satın-alma olasılığı ölçeği gibi tüm profil kümesini sınıflandırmakta, derecelendirmekte ya da oranlamaktadır. Bu profiller çoklu faktörler (ya da nitelikler) ve mal ya da hizmetlerdir. Genel anlamda en küçük kareler yöntemi verilere uygulanmakta ve kısmi değerler olarak bilinen parametreler tahmin edilmektedir. Sonuçlar tüketicinin belirli bir ürünü nasıl algıladığını ve değerlendirdiğini açıklamaktadır ve yeni bir ürünün geliştirilmesinde pazar paylarını kestirmektedir.

Kesikli tercih modelleri ise doğrudan tüketici tercihlerini çalışan ve son yıllarda birçok bilim dalında popülerliği artan bir metottur. Bu metotta bireyler genellikle rekabetçi alternatiflerin tanımlandığı kümelerle karşılaşmaktadır (Zwerina, 1997). Bireylerden her bir kümeden en faydalı alternatifi tercih etmeleri istenmektedir. Stokastik tercih modelleri (çok terimli logit, probit modeller vb.) bu tür tercih verilerine uygulanmaktadır.

Kesikli tercih modelleri geleneksel konjoint analize oranla birçok avantaja sahiptirler. İlk olarak veriler olası satın-alma kararlarını içermektedir. Bireyler için bu kararların belirtilmesi oranlama ve derecelendirmeden daha gerçekçi, daha basit ve daha az belirsiz olan bir işittir. İkincisi doğrudan pazar paylarının tahmin edebilebilmesidir. 3.üncüsü fiyat belirlemede alternatiflerin spesifik nitelik ve değerlerinin kolay bir şekilde düzenlenebilmesidir. Son olarak da tercih etmeme

seçeneđi (ya da sabit alternatif) sadece pazar payları yerine talep derecesini de tahmin etmek için modele eklenebilmektedir.

Bu avantajların yanında kesikli tercihlerde tercihlerin bahsedilen oran ve derecelerden daha az bilgilendirici olması önemli bir dezavantajdır. Tercih uygulamaları genellikle daha güvenilir parametre tahminleri elde edebilmek için daha büyük sayıda gözlemlere ihtiyaç duymaktadır. Yani tercih uygulamaları bireysel değerler yerine toplam değere uygulanmaktadır.

Tercih problemine örnek olarak McFadden (1978)'ın her gün evden işe giden bir bireyin işe gidiş şekline karar vermesi verilebilmektedir. Birey çevresi ya da ulaşım hizmeti veren kurum gibi bütün alternatiflerden haberdar olmamasına rağmen ulaşım için uygun alternatif türlerine karar verebilmektedir. Bireyin alternatifleri otomobil ile ulaşım, otobüs ile ulaşım ve yürümek olduğunda karar sürecinin bir sonraki aşamasında birey, her mümkün alternatifin nitelikleri hakkındaki bilgileri toplamakta ve değerlendirmektedir. Bireyin tercihinde ulaşım süresi, ulaşım maliyeti ve konfor niteliklerinin dikkate alındığı varsayıldığında birey tercih yaparken bir karar kuralı uygulamaktadır. Uygulanan karar kuralı bireyin faydasını maksimize edecek şekilde olmaktadır. Karar verme sürecinin son aşaması ise tercih edilen ulaşım şekli kullanılarak evden işe yapılan yolculuktur.

Ulaşım talep problemlerinde, son 25 yıldır toplamsal olmayan modeller önemli bir rol oynamaktadır. Bu modeller talebin toplumdaki her bir bireyin farklı kararlarının sonucu olduğunu göz önünde tutmaktadır. Bu kararlar genellikle alternatiflerin sonlu kümesinden oluşan tercihleri içermektedir. Dikkate alınan sistem bir sonraki tercih tahminini, davranışları kontrol etmeyi ya da etkilemeyi ve performansı en iyi şekilde kullanmayı hesaba katmaktadır. Kısaca, tercih teorisi, aşağıdaki olmazsa olmaz faktörlerin toplamı olan bir süreç şeklindedir (Bierlaire, 1997):

1. Karar verici,
2. Alternatifler,
3. Alternatiflerin nitelikleri,
4. Karar kuralları.

2.1.1. Karar Verici

Tercih teorisinde bu faktör karar vericinin kim olduğunu ve karakterini açıklamaktadır. Karar verici bir birey, aile ya da hane halkı olabilmektedir. Pratikte bu varsayım kısıtlayıcı değildir. Birey kavramı uygulamaya göre genişletilebilmektedir. Karar verici bir şirket ya da kamu dairesi gibi organizasyonlar da olabilmektedir. Bu şekilde bir grup insan ya da bir organizasyon, tek bir karar verici olarak ele alındığında içerisindeki karmaşık etkileşimler de kısmen göz ardı edilebilmektedir.

Farklı tercih durumlarıyla karşılaşan karar vericiler farklı beğenilere sahiptir. Bu nedenle sürecin sonunda toplam taleple ilgilenilmesine rağmen, karar vericiler arasında oluşan karar verme sürecindeki farklılıkların da dikkate alınması gerekmektedir. Evden işe ulaşım tercihinde otomobil türü ve ulaşım maliyetleri değişkenleri dikkate alındığında tercih, otomobilin türü ve benzin çeşidine bağlı olmaktadır. Ayrıca, karar vericinin en yüksek maliyeti ödeme isteği aylık gelirine ilişkindir.

Kararları etkileyen grup içi etkileşimlerin değişkenliğinden dolayı, grup karar süreçleri arasında daha fazla farklılıklar ortaya çıkmaktadır. Örneğin, otomobil seçerken, bazı ev halkı kararları, baskın ev halkı üyesinin bireysel tercihi olabilmektedir (Ben-Akiva ve Lerman, 1985).

2.1.2. Alternatifler

Tercih alternatifleri karar vericinin olası özelliklerini kararlaştırmaktadır. Bireyin tercihi incelenirken neyin tercih edildiği bilgisi kadar neyin tercih edilmediği bilgisine gerek vardır. Bunun için bireyin tercihinin gerçekleştirirken dikkate aldığı fikir ya da alternatifler bilgisi dikkate alınmalıdır. Bu yüzden öncelikle, bu alternatifleri içeren “tercih kümesini” tanımlamak gerekmektedir (Bierlaire, 1997).

Tercih kümesinin tanımlanması uygulamanın içeriğine bağlıdır ve iki şekilde ifade edilmektedir. İlki sürekli tercih kümesidir. Bu tür tercih kümeleri, çalışmanın

kapsamı dışında olduđu için burada dikkate alınmayacaktır. İkincisi ise alternatiflerin sürekli olmadığı, yani kesikli tercih kümesidir.

Kesikli tercih kümesi açıkça listelenebilen sınırlı sayıda alternatifi içermektedir. Bireyin evden işe gitmek için tercih ettiđi ulaşım şekli kesikli tercih kümesi ile sonuçlanan tipik bir örnektir. Tercih kümesinin tanımlaması, öncelikle alternatiflerin listesinin tanımlanmasına dayanmaktadır. Bu tanımlamayı gerçekleştirmek için, tercih kümesinin iki kavramı göz önünde tutulmalıdır: evrensel tercih kümesi ve sınırlandırılmış tercih kümesi.

Evrensel tercih kümesi uygulama kapsamındaki bütün potansiyel alternatifleri içermektedir. Yani ulaşım tercihinde evden işe giderken kullanılacak tüm alternatifleri içermesi gerekmektedir. Bu alternatifler yürümek, bisiklet, otobüs, otomobil vb. olabilirken uçak da bir ulaşım aracı olsa da burada bir alternatif olamayacağından evrensel tercih kümesine eklenmemektedir.

Sınırlandırılmış tercih kümesi ise karar verici için hem uygun, hem de karar süreci sırasında bilinen alternatifleri içeren evrensel tercih kümesinin alt kümesidir. Bir alternatifin uygunluğu, en genel tanımıyla, fiziksel uygunluk (bireyin evi ile işyeri arasında kullanabileceđi ulaşım şekilleri), parasal kaynaklar (hususî otomobil ile gitmenin az gelirli çalışan için karşılanamaması), zamanın uygunluğu (evden işyerine gitmede trafik faktörü) ve bunun gibi kısıtlarla tanımlanmaktadır.

2.1.3. Alternatiflerin Nitelikleri

Tercih kümesindeki alternatiflerin her biri niteliklerle tanımlanmaktadır. Karar vericinin tanımlanmasına benzer şekilde, araştırmacı bireyin tercihini etkileyen alternatiflerin niteliklerini tanımlamalıdır. Bazı nitelikler farklı alternatifler için aynı olmakla birlikte bazıları her bir alternatif için spesifiktir. Ayrıca uygulamanın içeriğine bađlı olarak bazı kalitatif nitelikler de göz önünde bulundurulmaktadır.

Bir nitelik kesinlikle gözlenen bir veri olmak zorunda değildir. Mevcut verinin bir fonksiyonu olabilmektedir. Örneğin, ulaşım süresi yerine ulaşım süresinin logaritması da göz önünde tutulabilmektedir. Yapılan harcama, harcanan para ile

bireyin gelirinin oranı yer deęiřtirebilmektedir. Mevcut verinin bir fonksiyonu olarak niteliklerin tanımı probleme baęlıdır (Bierlaire, 1997).

Bir alternatifin tercih edilebilirlięi, niteliklerin deęer vektörü ile belirlenmektedir. Nitelik deęerleri sıralı ya da tercih edilebilirlik ölçekleri ile ölçülmektedir. Alternatifler homojen ya da heterojen olabilmektedir. Bu çalışmada alternatiflerin homojen olduęu ve karar vericilerin farklı tercih kümelerine sahip olduęu durum üzerinde durulmuřtur. Yani farklı alternatif nitelikleri deęerlendirilerek ve aynı alternatifin aynı nitelięi için farklı deęerler dikkate alınmıřtır.

2.1.4. Karar Kuralı

Karar kuralı, bir karar birimi tarafından tercih kümesindeki alternatiflerin niteliklerini deęerlendirmek ve alternatifini belirlemek üzere kullanılan bir kuraldır. Uygulamalarda kullanılan çoęu model fayda teorisine dayanmaktadır. Bu teori bir alternatif için karar vericinin tercihinin fayda olarak adlandırılan bir deęer tarafından belirlendięini ve karar vericinin tercih kümesinde en yüksek faydaya sahip alternatifini tercih ettięi varsayılmaktadır. Nitel tercihin fonksiyonel tanımında “Akılcı Tercih” olarak tanımlanan bu teori olasılık modellerinin tanımlanması için gerekli deęil, ancak yeterlidir.

Mikro ekonomide tüketim teorisi tarafından kullanılan bu kavram uygulama açısından büyük sınırlamalar içermektedir. Akılcı tercih yaklařımında alternatiflerin niteliklerinin gözden kaçırmıř olma ihtimali vardır. Yani alternatiflerin bazı niteliklerinin ölçülmesinde hatalar olabilir. İnsan davranıřının karmařıklıęı kararın olasılıklı boyutlar içermesi gerektirdięini önermektedir. Mikro ekonomide bu konu ile ilgili pek çok teorem ortaya atılmıřtır. (Aslan, 2006). Corstjens ve Gautschi (1983) ekonomik alanda tercih modellerini incelerken bireylerin tercihlerinin karar sürecinde etkili olan teorileri üzerinde durmuřlardır. Bu teoriler ařaęıda gösterilmektedir.

Teori I: Lanchaster tarafından genişletildięi řekliyle neoklasik ekonomik teori (Lanchaster, 1966, 1971),

Teori II: Belirsizlik altında risk-tercih teorisi (von Neumann-Morgenstern, 1947),

Teori III: Luce fayda modeli (Luce, 1959),

Teori IV: Sabit fayda modeli (Thurstone, 1927).

2.2. EKONOMİK AÇIDAN TERCİH TEORİLERİ

Pazarlama arařtırmacıları getimiz 40 yıl boyunca psikoloji ve iktisat disiplinlerine dayanan teorik sistemleri uygulayarak tüketicinin tercih tutumunu modellemişlerdir. Son yıllarda bu disiplinlerde tercih teorileri konusunda birçok başarılı alıřma görölmüřtür. Psikolojide Hansen (1976), Luce ve Suppes (1965) ve Luce (1977)'un alıřmaları en ok bilinenlerdendir. Barten (1977), Brown ve Deaton (1972), McFadden (1981) ve Amemiya (1981)'nın eleřtirel alıřmaları ise ekonomik tercih modelinde gelişmişlik seviyesini göstermektedir.

Tüketicinin tercih modeline yönelik ok nitelikli modern yaklaşımlar konusunda başlıca iki makale (Green ve Srinivasan, 1978 ve Shocker ve Srinivasan, 1979) bu konuyu hem metodolojik hem de uygulama açısından açıklamaktadır.

Bu kesimün amacı, birçok modern, uygulamalı tercih modeli arařtırmasının altında yatan teorik gelenekleri Cortjens ve Gautschi (1983)'nin vurguladıđı şekilde incelemektir. Bu teorik gelenekler ok geniş sınırlara ulaşmıştır. Bu sebepten uygulamalı tercih modellerinin orijinal perspektif ve bu perspektiflerin açılımlarından bakılabilmesi belirli bir görüş oluşmuřtur. Böyle bir görüş temelde yatan modern tüketici arařtırmalarında sıkça başvurulan farklı formal teorilerle ilgili varsayımları, kısıtlamaları ve deneysel talepleri aydınlatmakta yararlı olmaktadır (Cortjens ve Gautschi, 1983).

Tercih modellerinin yapısı incelenirken, model oluřturma süreci 3 temel adımdan oluşmaktadır: teori geliştirme, parametreleřtirme ve tahmin. Tercih modellerinde teori geliştirme tercih fonksiyonunun oluřturulması ve tercih yapısının bir tercih

modeline dönüştürülmesidir. Son adım olan tahmin ise tercih yapılarını nitelendiren, ölçülen fonksiyonel oluşumların deneysel uygulaması anlamına gelmektedir. Bu 3 adımın her biri alt bölümlerde sistematik bir şekilde analiz edilmiştir.

2.2.1. Teori Geliştirme

Fayda fonksiyonu oluşturulurken birey A_1, A_2, \dots, A_N alternatifleri ile karşılaşmaktadır. Bu alternatiflerin nitelikleri Z_1, Z_2, \dots, Z_M şeklinde ifade edilir ve her bir alternatif bu nitelikler üzerinden değerlendirilir: $Z^i = Z_1(A_i), Z_2(A_i), \dots, Z_M(A_i)$. Bu durumda j.inci bireyin fayda fonksiyonu $U_j(Z^i)$ şeklinde gösterilmektedir. j.inci bireyin fayda fonksiyonu $U_j(Z^i)$, $Z_1(A_i), \dots, Z_M(A_i)$ 'yi sayısal bir tercih indeksiyle birleştiren gerçek değerli bir fonksiyondur. Birey tercih kararlarına bu indeksle ulaşmaktadır.

Kesim 2.5.'te bahsedilen teorik kategoriler birbirinden bağımsız değildir. Tercih modeline bu 4 teorik yaklaşımın tanımlanmasının sebebi bu teorilerin her birinin kapsamlı olarak (i) tercihlerin yapısı, (ii) tercih alternatiflerinin yapısı, (iii) niteliklerin yapısı ve (iv) ortaya çıkan tercihin yapısı üzerinde durmalarıdır. Bu teorik yaklaşımların her biri bu 4 farklı konu üzerinde durduğu için diğer ekonomik teorilerden ayrılmaları gerekmektedir.

Neoklasik ekonomik teori en basit ifade ile sosyal tercih teorisi üzerine kurulmuştur. Sosyal tercih teorisinde ekonomistlerin en önemli amacı, insanların ekonomik alternatifler arasında nasıl tercih yaptıklarının belirlenebilmesidir. Bunun için akılcılık olarak ifade edilen rasyonel davranış kavramından yararlanılır (Aslan, 2006). Lancaster'in neoklasik teoriyi tercih modellerine genişletmesi iki sebebe dayanmaktadır. Öncelikle klasik ekonomik teori yeni bir ürün piyasaya sürüldüğünde tüm modelin baştan parametreleştirilmesini ve yeniden tanımlanmasını gerektirmektedir. Lancaster bu sorunu bir malı ya da hizmeti niteliklerinin bileşimi olarak ele alarak ve fayda fonksiyonunu nitelikler bakımından açıklayarak

çözmüştür. Böylece yeni ürün için fayda fonksiyonu tekrardan tanımlanmadan düzenlenmektedir. İkinci sebep ise klasik ekonomik teoriden farklı olarak nitelikler yaklaşımı diğer mallarla bağlantılı olan ikame ve tamamlayıcı ürünlerin yorumunu daha anlamlı kılmaktadır (Corstjens ve Gautschi, 1983).

Risk-tercih modellerinde von Neumann-Morgenstern (1947)'in belirsizlik altında tercih teorisi temsilci teori olarak ele alınmaktadır. Bu teorinin en büyük katkısı, tercih fonksiyonundaki birleştiriciliğidir. Üstelik von Neumann-Morgenstern'in beklenen fayda modeli, kuralsal olduğu kadar betimsel anlamda da ekonomi teorisindeki kaynakların riskli dağılımında bir standart oluşturmaktadır. Rastlantısal fayda teorisi neoklasik ekonomik teori gibi karar vericinin mükemmel bir ayırım kabiliyeti olduğunu varsaymaktadır. Bununla beraber araştırmacı elindeki bilginin tam olmadığını ve belirsizliğin 4 kaynağı olduğunu varsaymaktadır. Bunlar gözlenmemiş alternatiflerin özellikleri, gözlenmemiş bireysel özellikler ya da gözlenmemiş beğeni değişimi, ölçme hataları ve araç ya da enstrümantal değişkenlerdir (Akın, 2002).

Luce'un mutlak fayda teorisi sabit fayda modelleri olarak adlandırılan olasılıklı tercih modellerinin küresel gelişimini en iyi şekilde gözlemlemektedir. Matematikçi psikologlar sabit fayda modelini özellikle gözlenen tercihlerin geçişsiz olduğu durumlarda tercihleri olasılıklı olarak açıklamak için geliştirmişlerdir. Mutlak fayda modeli zayıf ve güçlü sabit fayda modellerinin açılımıdır. Güçsüz bir sabit fayda modeli sadece bir sıralı fayda fonksiyonu gerektirmekte ve ikili bir tercih durumunda (örneğin x ve y alternatifleri ele alındığında) sadece x alternatifinin faydası y alternatifininkini geçer ise karar vericinin x alternatifini tercih etme eğiliminin daha fazla olacağını savunmaktadır. Güçlü sabit fayda modeli ise ikili bir tercih durumunda karar vericinin y yerine x 'i tercih etmesi olasılığı, x ile y alternatiflerinin fayda farklarının azalmayan fonksiyonuna bağlıdır. Benzer şekilde güçlü sabit fayda modeli aralık ölçeği fayda fonksiyonlarını gerektirmektedir. Luce, ikili sabit fayda modellerini çoklu alternatif tercih yapılarına genişletmiştir. Luce model tercih edilen alternatif x 'in olasılığının, x 'in faydasının uygun tercih yapısındaki bütün alternatiflerin faydalarının toplam oranına eşit olduğunu kabul etmektedir. Bu durum

kesinlikle oran ölçümlü bir fayda fonksiyonunun varlığını kabul etmektedir (Corstjens ve Gautschi, 1983).

Thurstone tercih modeli, karşılaştırmalı değerlendirme için ölçüm araçları geliştirmeye ilgilene psikofizikte bir dizi araştırmadan oluşmaktadır. Thurstone benzer tercih durumlarında bile karar vericinin her zaman aynı tercihleri yapmadığını belirterek; birey seviyesinde rastlantısal bir ölçüm fonksiyonu kabul etmiştir. Yani Thurstone fayda teorisine dayanan tercih modellerini rastlantısal fayda modelleri (RUMs) olarak tanımlanmıştır ve matematiksel psikolojide ve ekonomide zengin bir geçmişten yararlanmıştır. Bu teorik yapının ayırıcı özelliği potansiyel stokastik yapısının bireysel faydaya atfedilmiş olmasıdır. Özel durum faydasının stokastik bileşenin belli ölçümleri altında, değerlendirme için indirgenmiş bir şekil elde edilmektedir. Bu indirgenmiş şekil Luce'un mutlak fayda modelinin tercih kuralı ile tutarlıdır.

2.2.1.1 Tercihlerin Yapıları

Kesim 2.5.'de açıklanan 4 teoriden ilk 3'ü teori deterministik tercih yapısına sahiptir. Buna karşılık Thurstone modeli stokastik tercihlere dayanmaktadır. Luce teorisinde bir bireyin aynı tercih alternatifleri için tek bir fayda fonksiyonu söz konusudur. Thurstone modeline göre ise birey her bir tercih için birkaç fayda fonksiyonundan herhangi birisini tercih etmektedir. Farklı alternatifler için fayda seviyeleri, alternatiflerin tutumlarına dayanan faydaların ortalama seviyelerinde dağıtılır. Bundan dolayı Thurstone teorisinde e_{ij} rastlantısal fayda bileşeni ve \bar{u}_{ij} değeri j.inci alternatifin faydasının ortalama seviyesi ise j alternatif için i.inci bireyin faydası $u_{ij} = \bar{u}_{ij} + e_{ij}$ biçiminde ifade edilebilmektedir.

Pazarlama alanında deterministik tercih yapılarının belirlenmesi ile ilgili geleneksel bir görüş vardır. Bu noktada, Rosenberg (1956)'in beklenen değer modelleri karşılayıcı (toplamsal, çarpımsal, çok terimli modeller) çok nitelikli tercih fonksiyonlarını belirlemede kullanılmıştır.

2.2.1.2. Tercih Alternatifleri

Tercihlerin tanımlandığı tercih yapıları ve alternatiflerin yapılarını birbirinden ayırmak çok önemlidir. Bunlar tercih aşamasında farklı boyutlara sahip olsalar dahi birbirlerinden tamamen bağımsız değildirler. Deterministik tercih durumunda karar verici tercih alternatifleri için nitelikler hakkında kesin yargılara sahiptir ve tercih fonksiyonunda değişikliğe gerek yoktur. Ancak karar veren birey tercih alternatiflerinin niteliklerinin değerleri konusunda kararsız ise tercih alternatiflerine stokastik olarak yaklaşmak uygun olmaktadır. Yani karar veren bireyin tercih alternatiflerini tanımlayan niteliklere farklı olasılıklar ataması gerekmektedir.

Von Neumann-Morgenstern teorisi tercih alternatiflerinin stokastik yapısına farklı bir yorum getirmiştir. Birçok deneysel çalışmada beklenen fayda teorisi için belirli koşullar her zaman sağlanamamaktadır. Deneysel olarak gözlemlenen bu tercih davranışlarıyla Kahneman ve Tversky (1979) “Olası Müşteri Teorisi” (Prospect Theory) adını verdikleri alternatif bir teori geliştirmişlerdir. Olası müşteri teorisi (PT) ve beklenen fayda teorisi (EUT) arasında iki fark vardır. Birincisi EUT değerleri olasılıklarla ölçülen satım-alım kararlarına bağlanırken PT'nin kazançlara ve kayıplara ayrı değerler ataması ve kararların ağırlıkları ile ortaya çıkan EUT olasılıklarını değiştirmesidir. Marschak ve arkadaşları (1963), Thurstone ve Luce modellerinin stokastik tercih alternatiflerini içerecek şekilde sadece teorik anlamda genişletilebileceklerini ortaya çıkarmışlardır.

Lancaster'in geliştirdiği haritalama matrisi tercih alternatiflerinin yapısının belirlenmesinde kullanılan başlıca yöntemlerden biridir. Bu yöntemde ürünler yerine sadece nitelikler ile alternatifleri tanımlayacak bir mekanizma oluşturulmuştur. Bu mekanizma objektif bir teknoloji matrisinin şeklini almaktadır. Bu haritalama matrisi birçok alanda araştırmacıların dikkatini de çekmektedir. Örneğin Hauser and Simmie (1981) Lancaster yaklaşımına bazı bilgi işlem teorilerini de ekleyerek algular ile tercihleri eşleştiren yeni bir teknoloji geliştirmişlerdir.

2.2.1.3. Tercih Kuralları

Tercih yapıları ve tercih davranışı arasındaki ilişkiyi tanımlamak için tercihler açısından bir karar kuralı oluşturmak gerekmektedir. En çok tercih edilen karar kuralı tercih alternatifleri üzerindeki faydanın maksimizasyonu biçimindedir. Risk-tercih teorisinde tahmini faydanın maksimizasyonu bireylerin davranışlarıyla birebir ilişkilidir.

Luce ise fayda maksimizasyonu ile ilgili bir tercih aksiyomunu önermiştir. Bu aksiyomda A_i alternatifinin tüm alternatifler arasından tercih edilme olasılığı aşağıdaki şekilde bulunmaktadır.

$$P(A_i; T) = P(R; T)P(A_i; R) \quad (2.1)$$

A_1, \dots, A_j tercih alternatifleri için T'nin toplam alternatifler kümesi ve R'nin de A_i 'yi içeren T'nin altkümesi olduğu varsayılmaktadır. A_i 'nin R altkümesinden tercih edilme olasılığı $P(A_i; R)$ olarak gösterilmiştir. Luce'un tercih aksiyomundan aşağıdaki tercih kuralı çıkarılabilmektedir:

$$P(A_i; T) = \frac{V(A_i)}{\sum_{j=1}^N V(A_j)} = \frac{V(f(Z^i))}{\sum_{j=1}^N V(f(Z^j))} = \frac{U(Z^i)}{\sum_{j=1}^N U(Z^j)}. \quad (2.2)$$

Burada Z^i , A_i alternatifinin niteliklerinin vektörü ve $V(A_i) = V(f(Z^i)) = U(Z^i)$ eşitliği değer fonksiyonu olarak verilmektedir. Bu karar kuralında tercih olasılıkları kümesi Luce tercih aksiyomuna uyuyor ise $V(A_i)$ tercih olasılıklarını yansıtacaktır.

Luce modelinin önemli bir özelliği de basit ölçeklenebilirliğidir. Bir modelin basit ölçeklenebilir olması için aşağıdaki 4 durumun sağlanması gerekmektedir (Luce ve Suppes, 1965 ve Luce, 1977):

(i) Tercih alternatifleri için bir u fayda fonksiyonu bulunur (A_1, \dots, A_N) ;

(ii) N tercih alternatifi için bir F fonksiyonu bulunur;

(iii) $P(A_n) = F_n(U(A_1); \dots; (A_N))$,

(iv) $F_n, u(A_n)$ için artan bir fonksiyon ve geriye kalan $N-1$ alternatifi için azalan bir fonksiyondur.

Tversky (1972) Luce modelin bu önemli özelliğini basit bir şekilde aşağıdaki eşitsizlikle ifade etmektedir.

$$P_{i,j} > P_{j,i} \quad \text{eğer} \quad P_{i,k} > P_{j,k} \quad (2.3)$$

$P_{i,j}$, i .inci alternatifi j .inci alternatife tercih edilme olasılığını göstermektedir. Bu özellik geçişlilik özelliğine benzemektedir. (2.3) eşitsizliğindeki koşul Cortjens ve Gautschi'nin (1983) iki örneğiyle açıklanabilmektedir. Birinci örnekte bir bireyin şehir merkezi (ŞM) ile şehir dışındaki alışveriş merkezi (AVM) arasında tercih yapacağı varsayılmaktadır. Bu bireyin şehir merkezinin mal çeşitliliğini sevdiği fakat şehir dışındaki alışveriş merkezinin de erişilebilirliğini (bireyin evinden alışveriş merkezine olan ulaşım süresi olarak) aynı oranda sevdiği farz edilmektedir. Bu örnek bireyin %50 olasılıkla şehir merkezini şehir dışındaki alışveriş merkezine tercih edeceğini göstermektedir. Böylece oran,

$$P(\text{ŞM}) / P(\text{AVM}) = 1 \quad (2.4)$$

şeklinde olmaktadır. İkinci örnekte ise eski alışveriş merkeziyle aynı erişilebilirlik oranına sahip başka bir planlı alışveriş merkezinin yapıldığı ve bu alışveriş merkezinin eski alışveriş merkeziyle eşit uzaklıkta fakat ters istikamete inşa edildiği varsayılmıştır. Böylece oran $P(\text{Yeni AVM}) = P(\text{Eski AVM})$ şeklini almaktadır. Öngörüsül olarak bireyin şehir merkezini 0.50 olasılıkla, alışveriş merkezlerinden her birini 0.25'er olasılıkla tercih edeceği düşünülmektedir. Fakat öngörülenin aksine Luce modeli şehir merkezinin eski alışveriş merkezine tercih edilmesinin eşitsizlik oranını 1 ile sınırlandırmaktadır. Bu sınırlama eski alışveriş merkezinin tercih edilme olasılığının yanı sıra şehir merkezinin tercih edilme olasılığını da düşürmektedir. Oransal olarak Luce modeli her bir alternatifin 0.33'lük bir olasılıkla tercih edileceğini öne sürmektedir.

2.2.1.4. Ortaya Çıkan Tercihin Yapısı

Kesim 2.5. başlığında belirtilen 4 teoride ortaya çıkan tercihin iki ayırıcı özelliği vardır: (1) sürekli ve kesikli tercih arasındaki ayırım ve (2) stokastik ve deterministik tercih arasındaki ayırım. Yalın bir stokastik durum arz eden von Neumann-Morgenstern teorisinde deterministik tercihler ortaya çıkabilmektedir. Fakat deterministik durumlar üzerine kurulu olan Luce teorisinde de stokastik tercihler görülebilmektedir. Bu 4 teori dikkate alındığında tercih davranışları ve teori yapıları Tablo 2.1'deki gibi ortaya çıkmaktadır.

Tablo 2.1. Teorilerin yapıları

	Teoriler			
	Lancaster	Risk-Tercih	Luce	Thurstone
Tercihin Yapısı	$u_i = u_i(Z^i)$	$u_i = u_i(Z^i)$	$u_i = u_i(Z^i)$	$u_i = \bar{u}_i(Z^i) + e$
Tercih Alternatifleri	Deterministik	Stokastik	Deterministik ve Stokastik	Deterministik ve Stokastik
Tercih Kuralı	u_i 'yi maksimum yap	$E(u_i)$ 'yi maksimum yap	$P(A_i) = \frac{u_i}{\sum_{j=1}^N u_j}$ ile $A_i \in A$ 'yi seç.	
Tercihin Yapısı	Deterministik	Deterministik	Stokastik Kesikli	Stokastik Kesikli

	Sürekli	Sürekli		
--	---------	---------	--	--

Bu 4 teori tercih yapısının belirlenmesinde ayrı ayrı kısıtlar altında farklı tercih kuralları oluşturmaktadırlar. Neoklasik ekonomik teoride $u(Z)$ ya da $U(BA)$, $Z - BA \leq 0$ ve $p^T A - y \leq 0$ kısıtları altında maksimum yapılmaktadır. Burada p tercih alternatifleri için fiyat vektörü, y bütçeyi ifade etmekte olup B her bir alternatif için toplanan nitelik miktarını temsil eden matristir. Ayrıca A alternatifler vektörü, Z ise nitelikler vektörüdür.

Von Neumann-Morgenstern'in belirsizlik altında tercih teorisinde mal ya da hizmetler yerine nitelikleri dikkate alan Kihlstorm (1974) yeni bir kavramsal model ileri sürmüştür. Bu kavramsal model $Z = BA$ eşitliği ve $B = [\tilde{b}_{ij}]$ ve $p^T A - y \leq 0$ kısıtları altında $EU(Z)$ 'yi maksimum yapmaktır. Burada \tilde{b}_{ij} j.inci tercih niteliği için i.inci nitelik değerini gösteren rassal değişkendir. Her bir \tilde{b}_{ij} için bir F^{ij} olasılık dağılımı belirlenmektedir. Rassal değişkenlerin birleşik olasılık dağılımı $\tilde{B} = (\tilde{b}_{11}, \dots, \tilde{b}_{mn}) F$ ve yöndeş yoğunluk fonksiyonu f ile gösterilmiştir. Dolayısıyla tercih kuralı aşağıdaki gibidir.

$$\text{Max} \int_{\alpha} U(\tilde{B}A) f(\tilde{b}) d\tilde{b} \quad (2.5)$$

Burada $\alpha = \times_{i=1}^m \times_{j=1}^J \alpha_{ij}$ ve $\alpha_{ij} \in [0, \infty)$ olduğundan $F(\alpha_{ij}) = 1$ eşitliği gerçekleşmektedir.

Luce teoride ise A_i alternatifinin tercih edilme olasılığı,

$$P_v(A_i) = \frac{u(Z^i)}{\sum_{j=1}^N u(Z^j)}$$

(2.6)

şeklinde gösterilmektedir. Buradaki $P_v(A_i)$ birey v'nin i.inci alternatifini tercih etme olasılığını göstermektedir.

Thurstone teorisinde A_i alternatifinin tercih edilme olasılığı ise,

$$P_n(A_i) = P((V_{in} + \varepsilon_{in}) > (V_{kn} + \varepsilon_{kn}))$$

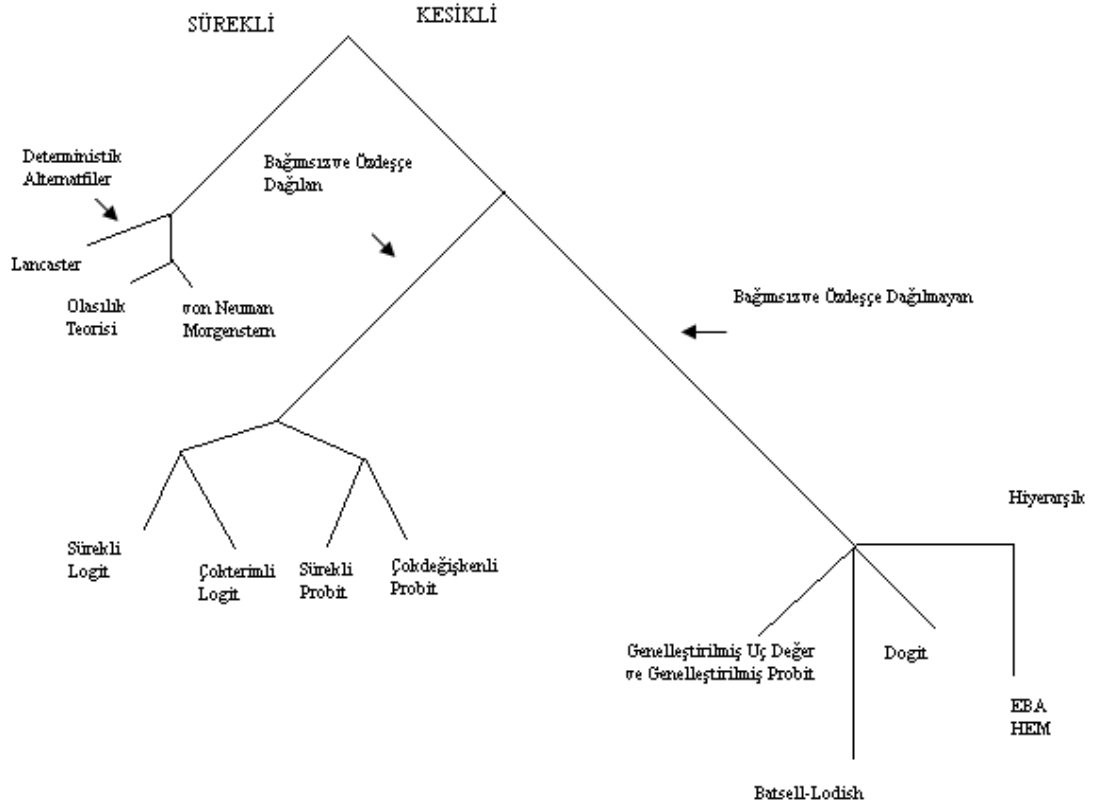
(2.7)

şeklinindedir. Bütün k 'lar için ($k = 1, \dots, i-1, i+1, \dots, J$) olasılık yoğunluk fonksiyonu $\int (\varepsilon_{1n}, \dots, \varepsilon_{Jn})$ olmaktadır. Buna göre olasılık fonksiyonu aşağıdaki gibi tanımlanmaktadır.

$$P_n(A_i) = \int_{-\infty}^{V_{in}-V_{1n}} \int_{-\infty}^{V_{in}-V_{2n}} \dots \int_{-\infty}^{V_{in}-V_{Jn}} f_n((\varepsilon_{1n} - \varepsilon_{in}), \dots, (\varepsilon_{Jn} - \varepsilon_{in})) \times d((\varepsilon_{1n} - \varepsilon_{in}), \dots, (\varepsilon_{Jn} - \varepsilon_{in}))$$

(2.8)

Tercih teorilerinin belirlenmesinin diğer bir amacı da modellerin kesikli mi yoksa sürekli mi olduklarının belirlenmesi içindir. Bu ayırım öncelikle alternatiflerden kaynaklanmaktadır. Teori I ve II sürekli tercih teorileri olarak kabul edilirken Teori III ve IV kesikli tercih teorileri olarak kabul edilmektedir. Şekil 2.2. tercih modellerinin birbirlerinden nasıl ayrıştırıldığını göstermektedir.



Şekil 2.2. Tercih modellerinin ayrıştırılması

Tercih modellerinin sürekli türleri, tüketicinin alternatifleri nitelikleri ve bütçe sınırlamaları açısından ayrı ayrı değerlendirmesi sonucunda harcamasını tercih alternatifleri kümesi üzerinde nasıl bölüştüreceği sorusuna cevap aramaktadır. Bu yüzden sürekli tercih modelleri bölüştürme karar miktarını tahmin etmede kullanılmaktadır.

Kesikli tercih teorilerinde ise cevabı aranan sorunun şekli farklıdır. Tüketicinin alternatifleri niteliklerine göre değerlendirdiği varsayılarak tüketicinin verilen bir tercih alternatifleri kümesinin hangisini tercih edeceği üzerinde durulmaktadır. Bu sebepten kesikli tercih modelleri, tercih olasılıklarının ya da pazar paylarının tahmin edilmesinde kullanılmaktadır. Kesikli tercih modellerinde *yoğun marj* terimi bazen tüketicinin bir alternatifi tercih etme ya da etmeme isteğine bağlı olarak değişmektedir. Bireyin tercihi ise kesikli olaylar dizisinin sonucuymuş gibi tasarlanmaktadır. Böylece verilen N elemanlı, A_1, \dots, A_N , tercih alternatifi kümesine bakılarak bireyin hangi alternatifi ya da alternatifleri tercih ettiği anlaşılmaktadır. R

sayıda tercih durumu olması halinde bireyin tercih süreci Tablo 2.2.'de açıklandığı gibidir.

Tablo 2.2. Bireyin tercih süreci

Tercih Durumları	Tercih Alternatifleri					Tercih Marjı
	A_1	...	A_n	...	A_N	
1	S_{11}	...	S_{1n}	...	S_{1N}	1
.	.					.
.	.					.
r	S_{r1}	...	S_{rn}	...	S_{rN}	1
.	.					.
.	.					.
R	S_{R1}	...	S_{Rn}	...	S_{RN}	1
Alternatif						
Marj	T_1	...	T_n	...	T_R	R

Tablo 2.2.'de gösterilen bireyin tercih durumu

$$T_n = \sum_{m=1}^N S_{rm} \quad n = 1, \dots, N \text{ için}$$

(2.8)

şeklinde gösterilmektedir. Bu eşitlikte bulunan S_{rm} , $A_j \in A$ r.inci tercih durumda tercih edildiğinde 1, diğer durumlarda ise 0 değerini almaktadır. Bu durumda

$$\sum_{j=1}^J S_{rj} = 1 \quad \text{her bir } r = 1, \dots, R \text{ için}$$

(2.9)

olmaktadır. T_1, \dots, T_n 'nin rassal deęişken ve R tercih durumlarının bağımsız ve özdeş olduğu varsayıldığında T_1, \dots, T_n 'nin çokterimli dağıldığı kabul edilmektedir. P_{rj} , bireyin r.inci tercih durumunda $A_n \in A$ 'ni tercih etmesi olasılığını ve P_n 'de bireyin R tercih durumu üzerinden $A_n \in A$ 'ni tercih etmesi olasılığını belirtmektedir.

Bu durumda (T_1, \dots, T_{N-1}) 'nin birleşik yoğunluk fonksiyonu şu şekilde olmaktadır:

$$f_{T_1, \dots, T_{N-1}}(t_1, \dots, t_{N-1}) = R! \left(\prod_{n=1}^N t_n! \right)^{-1} \prod_{n=1}^N P_{.j}^{t_n} \quad (2.10)$$

Burada $n = 1, \dots, N$, $t_n = 0, \dots, R$, (T_1, \dots, T_{N-1}) 'in $\sum_{n=1}^N t_n = R$ şeklinde gözlemleridir. ($T_N = R - \sum_{n=1}^{N-1} T_n$ şeklindedir.)

Tablo 2.2.'deki sıralar, $\sum_{n=1}^N S_{rn} = 1$ ve $N \geq 2$ olması durumunda Bernoulli denemelerine benzerler. Bireylerin tercih süreci bağımsız olduklarından tüm $n = 1, \dots, N$ için $P_{1n} = \dots = P_{rn} = P_{.n}$ olduğu varsayılmaktadır. Bu durumda tercih süreci sabit bir model olarak dikkate alınmaktadır. Fakat bu durumun aksi de mümkündür. İlk deneme birey dięer bir alternatifini tercih eder ise alternatifler yeniden deęerlendirilecektir. Ayrıca bireyin daha önce tercih ettięi alternatifine olan tutumu deęişir ise tercih olasılıkları da bu durumdan etkilenecektir. Böylece araştırmacının tercih sürecini yeniden parametreleştirmesi gerekecektir.

2.2.2. Parametreleştirme

Fayda teorisinin parametreleştirilmesi konusunda yapılan çalışmalar genellikle karşılayıcı (vektör, parça deęer ve ideal nokta modelleri) ve karşılayıcı olmayan

(bitişik, ayrık ve sözlüksel) fayda işlevleri üzerinde yoğunlaşmaktadır. Özellikle mikro ekonomistler ve matematikçi psikologlar parametre konusunda yoğun biçimde çalışmışlar ve parametreleştirme sorununa yönelik farklı alternatif yaklaşımlar geliştirmişlerdir.

Neo-klasik ekonomik teoride ekonomistler faydanın parametreleştirilmesi konusunda iki farklı yaklaşım benimsemişlerdir: fayda ağaçları ve açıklanmış tercih.

Fayda ağacı yaklaşımı, ilişkili ürünlerin faydalarının belirlenmesi konusunda yaşanan sorunu çözmek için teorik olarak ortaya konulmuştur. Amaç, birbiriyle yakından ilişkili ürünlerin belirgin şekilde gruplandırılabilmesidir. Her bir ürün grubu tüketicinin fayda “dalı”nı temsil etmektedir. Bu da bir gruptaki ürünler ile diğer bir gruptaki ürünler arasında bulunan çapraz esnekliğin yalnızca gelir etkilerine duyarlı olduğu fakat ikame mallarını dikkate almadığı anlamına gelmektedir.

Fayda ağacı yaklaşımında klasik ekonomik teori, tercih kümesine ve tercih sıralamasının özelliklerine yoğunlaşarak parametreleştirme yapmaktadır. Bu özelliklerden en önemlisi ise ayrılabilirliktir (Goldman ve Uzawa, 1964).

Ayrılabilirlik kavramı tüketicinin aynı grup içerisinde bulunan ürünleri birbirleriyle ilişkili olduğunu algılayacağı şekilde sınıflandırması anlamına gelmektedir. Bu tanıma göre farklı gruplara ait olan ürünler tüketici için birbirleriyle ilişkisiz ürünlerdir. Fayda fonksiyonunda ayrılabilirliğe bazı derecelerin yüklenebilmesi tüketicinin tercih sorununu ortadan kaldırılmasında yardımcı olmaktadır. Yani herhangi bir ayrılabilirlik yaklaşımında mevcut olan varsayım bireyin ürünlerin birbirleriyle ikame edebilme güçlerine göre tercihleri gruplayabildiği şeklindedir. Bu nedenle bölüştürme sorunu ilk olarak ürünlerin genel gruplandırılmasında ve sonrasında da ayrı ayrı gruplandırılmasında ortaya çıkmaktadır.

Ekonomistler tarafından faydanın ölçülebilirliği konusuna yönelik olarak kullanılan diğer bir yaklaşım ise açıklanmış tercih teorisidir. Bu teoride tercihlerin yapıları

pazar fiyatlarına göre şekillenmektedir. Talep fonksiyonları için tercih sıralamasının özelliklerini belirlemek mümkün olmaktadır. Bu nedenle açıklanmış tercih uygulaması fayda fonksiyonunun parametrelerle açıklanması gerekliliğini ortadan kaldırmakla birlikte yeterli düzeyde bireysel talep verisi olmadığından açıklanmış tercih teorisinin bireysel düzeyde uygulanması oldukça güçtür. Ayrıca açıklanmış tercih teorisi bireyin satın alma ortamı ve satın almanın ortaya çıkmasına sebep olan faktörler gibi önemli ara değişkenleri kontrol edemediğinden iyi bir seçenek değildir.

Olasılıklı tercih alternatiflerinin parametreleştirilmesinde fayda fonksiyonunun özelliklerini belirten aksiyomatik çerçeve ilk olarak von Neumann-Morgenstern (1947) tarafından geliştirilmiş ve Pollak (1967) ve Keeney (1972) tarafından genişletilmiştir. Bu çerçeve uygun fonksiyonel biçimlerin parametrelerinin doğrudan hesaplanmasına olanak tanımaktadır. Fakat hesaplanmak istenen parametrenin öncelikle söz konusu olduğu ürün kategorilerine uygun olması gerektiğinden parametreleştirme ürün bazlı olarak gerçekleştirilebilmektedir.

Kahneman ve Tversky (1979) tarafından PT’de ortaya konulan değer fonksiyonunun parametreleştirilmesi von Neumann-Morgenstern’in fayda fonksiyonundan iki önemli şekilde ayrılmaktadır. Birincisi fayda fonksiyonunun faydanın ürün yerine kazanç ve kayıpları dikkate alarak oluşturulduğunda duyarlı olmasıdır. İkincisi bireyler kayıplara kazançlardan daha duyarlı olduğundan fonksiyonun kayıp kısmının kazanç kısmından daha kesin olmasıdır.

Asıl teorisinde Luce u’nun belirleyici etkenlerinden daha çok u’nun parametreleştirilmesi konusuyla ilgilenmekteydi. Tercih kuralının karmaşık yapısı ve parametre tercihi konusundaki uygunluğu göz önünde bulundurulduğunda özel bir fonksiyonel fayda biçimi tercih edilmektedir. Bu nedenle Luce fayda fonksiyonlarının çeşitlendirilmesi konusunda çalışmalar yapmıştır.

Luce teorisine pek çok atıfta bulunulmuştur. Özellikle rassal ve sabit fayda modellerinde marka tercihi Luce tercih kuralını temel almaktadır ve tercih

alternatiflerinin faydasının bireyler için gamma dağıldığı ($u_i = \Gamma(\alpha_i, \beta)$) varsayılmaktadır.

Batsell ve Lodish (1981) alternatiflerin benzerliğini açıklayan Luce modelinden yararlanarak yeni bir ölçüm yöntemi ortaya çıkarmışlardır. Bu yöntem bir tercih kümesinin alt kümesinde olan ve tekrarlanan tercihler hakkında gözlemler yapılmasını gerektirmektedir. Bunun nedeni yöntemin yeni eklenen ve alt kümelerde var olan benzer niteliklere sahip alternatiflerin bu ilişkili kümelere dahil edilmesini sağlamaktadır.

Rassal fayda modeli ise \bar{u}_i ve e_i 'nin parametrelerle açıklanmasını gerektirmektedir. Bu modelde asıl önemli olan ve parametrelerle ifade edilmesi yüksek derecede kapsamlılık gerektiren e_i 'dir. \bar{u}_i 'nin ise parametreler açısından doğrusal olduğu varsayılmaktadır.

İkili tercih durumunda e_i 'nin bağımsız olduğunun varsayılması ya da Cauchy modeline göre parametrelerle açıklanması sırasıyla doğrusal olasılık ya da arttan modellerini ortaya çıkarmaktadır (Domencich ve McFadden, 1975). Doğrusal olasılık modelinin sağlam olmayışı (örn. (0,1) aralığı dışında tahmin edilen olasılıklar) ve arttan modelinin kesin sayısal koşullar gerektirmesinden dolayı Teori IV'ün parametrelerle açıklanması probit ve logit modellerle sınırlı tutulmaktadır. Bu iki model ikili ve çoklu tercih ortamlarında yaygın bir şekilde kullanılmaktadır ve bu modeller teorik açıdan bazı yöntemlerle doğrulanmaktadır.

McFadden (1973) Thurstone tercih yapısının bir ekonomist için çok önemli olduğunu savunmaktadır. Bunun iki sebebi vardır. Birincisi bir bireyin tekrarlanan tercih ortamlarında bağımsız fayda fonksiyonlarını tercih edeceği, ikincisi ise tercihlerini maksimize edeceği varsayımdır. Ayrıca biçimsel olarak araştırmacının sabit fayda fonksiyonlarına sahip bireyleri seçtiğini ve her birine tek bir seçenek önerdiğini öne

sürmektedir. McFadden (1973)'nın parametreleştirme konusuna yaklaşımı aşağıdaki şekilde özetlemektedir:

“Üyelerinin kişisel özellikleri bakımından homojen bir yapı sergilediği bir toplum içerisinde tüm bireylerin ortalama zevklerine denk zevkleri olan sembolik bir bireyin mevcut olduğunu varsayalım. Ayrıca bu sembolik bireyin tüm alternatiflerde tanımlı bir fayda fonksiyonuna, u , sahip olduğunu varsayalım. Bu sembolik bireyin (deterministik) faydasının fonksiyonel yapısı benimsendiğinde faydanın kısmen stokastik özelliği sembolik faydadan bireyin özel faydasını ayıran gözlenmemiş fayda unsurlarını açıklamak için kullanılabilir.”

Bu stokastik koşulla ($\bar{u}_i - u_i = e_i$) ilgili belli başlı açıklamalar aşağıda özetlenmiştir (Cortjens ve Gautschi,1983):

- (1) Bireylerin davranışları rassaldır. Bu nedenle sürekli aynı alternatif kümesiyle karşılaşılır ve aynı birey farklı tercihler yapar,
- (2) Bir stokastik tercih her bir birey ve değişen zevkler için yapılan her bir gözlemede mevcut olan durumsal kısıtlamalar da dâhil olmak üzere gözlemlenmeyen veri tarafından eyleme geçirilir,
- (3) Ölçüm ve örnekleme hatası mevcuttur.

2.3. TAHMİN

Temel teori ve parametreleştirme göz önüne alındığında matematik modelleri oluşturmanın son adımı parametreler ile açıklanan fonksiyonel formların ve olasılık dağılımlarının hesaplanması ya da tahmin edilmesidir.

Neo-klasik ekonomide mikro ekonomistler fayda fonksiyonlarını hesaplama probleminde iki ayrı yaklaşım getirmişlerdir. Genel olarak bu iki yaklaşım

niteliklerden ziyade ürünlere uygulanmıştır. İki yaklaşım arasındaki fark tahminde kullanılan veri türünden kaynaklanmaktadır; yani pazardan elde edilen veri deneysel olarak elde edilen veriye karşı yarışmaktadır (Corstjens ve Gautschi, 1983).

Pazardan elde edilen veriye dayalı çalışmalar ikiye ayrılmaktadır. Bunlar (i) pazarın bireyle aynı şekilde davrandığı varsayımıyla elde edilen toplam tüketim verilerine dayalı çalışmalar, (ii) bütün bireylerin benzer olduğu varsayılan çapraz kesikli bireysel verilerin kullanıldığı çalışmalardır. Hemen hemen bütün bu çalışmalarda en küçük kareler uygulaması ya da en çok olabilirlik tahmin yöntemleri kullanılmaktadır. Genelde talep fonksiyonlarının tahmin edilen değişkenleri normalden farklı çıkmaktadır. Gözlenen talepteki bütün değişimler sadece fiyat ve gelirdeki değişimlerle açıklanamamaktadır. Ekonomistler talep fonksiyonları yaklaşımını, taleplerdeki sistematik değişimleri etraflıca incelemekten çok gelir ve fiyatlardaki değişikliğin talebe etkisini belirleme çabası olarak görmektedirler.

Deneysel veriye dayalı çalışmalar temelinde fayda ve ekonomi teorisi olan aksiyomatik sistem denemeleriyle yönetilmektedirler. Bu çalışmalar pazarın denge kabiliyetini değerlendirme ve bireylerin belirli koşulları ihlal edip etmediğinin belirlenmesi amacıyla yürütülmektedir. En son yapılan çalışmalar deterministik tercih modelleri yöntemlerine yöneltilmiştir. Tekdüze regresyon, MONANOVA ve matematiksel programlama gibi bir dizi tahmin yöntemleri yaygın olarak kullanılmaktadır (Cortjens ve Gautschi, 1983). Deneysel veriye dayalı çalışmalarda veri toplama yöntemleri, nitelik belirleme ve belge kalibrasyon konularına önem verilmektedir.

Tüketici araştırmalarında tercih modellerini en iyi tanımlayan analiz şekli konjoint analizdir. Bu kavram Luce ve Tukey (1964)'in aksiyomatik sisteminin bir uygulaması olarak önerilmiştir. Aksiyomatik sistem, faydayı ifade etmede spesifik basit polinomal fonksiyonların oluşumu için gereken entegre koşullar dizisidir. Bu yüzden fayda fonksiyonunun doğru parametrelerle ifade edilebilmesi sorununu açıkça ele almaktadır. Ancak konjoint analizde spesifik fayda fonksiyonunun parametrelerinin hesaplanması oldukça karmaşık bir süreçtir. Birden fazla

fonksiyonel biçimin olduğu varsayılan bu durumda doğru parametrelerin seçimi aksiyomatik kriterlerden çok uyum derecesine ya da tahmin kriterlerine bakılarak yapılmaktadır.

Von Neumann-Morgenstern yaklaşımı ise fayda fonksiyonunun parametrelerini doğrudan değerlendirme olanağı sağlamaktadır. Değerlendirme (ve aynı zamanda parametreleştirme) prosedürü bireyin karşılaşacağı rastlantısal durumların tercih önceliği analizlerine dayanmaktadır. Bu sistem özellikle itfaiye tatbikatları, havaalanı geliştirme, sağlık tesis ve imkanlarının geliştirilmesi ve mekan ısıtması gibi yönetsel uygulamalarda sıklıkla kullanılmaktadır.

Ekonometri ve piyasa araştırmasında kesikli tercih modelleri için çok yönlü tahmin tekniklerinin geliştirilmesi konusunda büyük adımlar atılmıştır. Theil (1969) ve McFadden (1973) çoklu tercih durumları için ikili logit modellerini geliştirmişlerdir. Bu noktada bireysel tercihteki verinin niteliğinin, logit fonksiyonların kullanılıp kullanılmayacağına belirleyici bir etmen olduğu söylenebilmektedir. Bireysel düzeydeki tercih gözlemlerinin vektörü tercih edilmeyen alternatiflerle ilişkili olan N-1 sıfırlı Boolean vektörü olmaktadır ve çok terimli logit modelin özel bir durumu olan *koşullu logit* kullanılmaktadır (McFadden, 1973).

McFadden'ın koşullu logiti geliştirmesindeki temel sebeplerden biri bireysel tercihlerde ekonomik verinin her bir bireye bir tane tercih edilmiş alternatif sağlamasıdır. Tercih gözlemleri tekrarlı ise araştırmacı gelir ve maliyet dengesini dikkate almak zorundadır. Bireysel tercihin farklı tercih durumlarında sabit olduğu varsayılabilir ise (fiyatlar ve gelirler değişmeyecek şekilde) bağımlı değişken için oransal tercih frekansının kullanımı uygun olur. Fakat burada dikkat edilmesi gereken diğer bir husus, tercih sürecinin durgun ya da hareketli olmasıdır. Tercih sürecinin durgun ya da hareketli olarak ele alınması tahmindeki esneklik açısından gelir ve maliyet dengesiyle bağlantılıdır.

Arařtırmacı tercihlerin tahmininde maksimum benzerlik ya da en küçük kareler yöntemlerden hangisini kullanacağına iki şekilde karar vermektedir. Bunlardan ilki tercih sürecinin şeklidir. Maksimum benzerlik tahmini tercih süreci hareketli olduđunda en küçük karelerden daha iyi sonuçlar vermektedir. Yöntemlerden hangisinin kullanılacağına karar vermede etkili olan diđer durum ise deđişen varyans sorunudur. Cox (1970), Domencich ve McFadden (1975) açıklayıcı deđişkenin kesikli olduđu durumlarda ađırlıklı en küçük karelerin kullanılmasını önermişlerdir. Böyle durumlarda veri çok yöntemli bir başlangıç tablosuyla temsil edilebilmektedir. Yani verinin bađımsız deđişkenlerle birlikte sınıflandırılabilmesi gerekmektedir. Verilerin ađırlıklara bölünen hücre frekanslarını kapsadıđı ađırlıklı en küçük kareler prosedürleri sadece her hücrede büyük rakamlar gözlemlendiđinde kullanılabilir. Bu koşul araştırma verilerinin kullanıldıđı tüketici tercih uygulamaları için ađırlıklı küçük kareler tahmini yöntemini uygunsuz kılmaktadır. Bu sebepten maksimum benzerlik tahmin yöntemi hücre frekansı sorunundan kolay etkilenmeyecek şekilde geliştirilmiştir.

Kesikli tercih modellerinin tahmininde en karmaşık sorun 0 dıřı kovaryanslara izin verilmesi durumudur. İki ya da daha fazla alternatifin niteliklerinin benzerliđe yatkın olduđu özellikle çoklu tercih düzenlemelerinde ortaya çıkmaktadır. GEV modeli ile kovaryans probit modeli böyle bir bađımlılıđı gösteren modellere örnek verilebilir. GEV modelinin bir tercih ađacıyla temsil edilebilerek uygulandıđı varsayılmaktadır. Böyle bir temsilde GEV modeli logit modeller dizisi yoluyla yinelemeli olarak tahmin edilebilmektedir. Hausman ve Wise (1978) kovaryans probit modelinin parametrelerini tahmin etmek için bir sayısal yöntem önermişlerdir. Bu yöntem sayısal olarak sadece az sayıda alternatifler grubu için uygundur. Daganzo (1980) tarafından ise kovaryans probit modelleri için daha etkili algoritmalar geliştirilmiştir.

Farklı tercih modellerinin parametrelerini deđerlendirmede kullanılan başka bir model sınıfı ise Nakanishi ve Cooper (1974)'ın pazar payı modelleridir. Bu modellerde pazar payı verilerine genelleştirilmiş en küçük kareler yöntemi uygulanmaktadır. Bu yöntemler tek tercih frekanslarına da uygulanabilmektedirler ve 0 olmayan kovaryansların koşullarına uyum sağlamaktadır.

3. KESİKLİ TERCİH KAVRAMI VE ÖZELLİKLERİ

3.1. KESİKLİ TERCİH KAVRAMI

Sosyal bilimler, bireylerin davranışını açıklamaya ve öngörmeye çalışırlar. Çoğu durumda tercihler, harcama miktarı, çalışma süresi gibi sürekli durumlar üzerine yapılır. Fakat bazı durumlarda çalışıp çalışmama, ulaşım yolu, yaşanacak yer, aile büyüklüğü gibi tercihler sınırlı sayıdaki mümkün durumlar ya da alternatifler arasından yapılır. Bir regresyon denkleminde bağımlı değişkenin sürekli olmayıp, dayanıklı bir malı satın alma-almama, emek gücüne katılma-katılmama ya da bir ulaşım yolunu seçme-seçmeme gibi kesikli bir tercihi vermesi durumunda kesikli tercih modelleri söz konusudur (Akin, 2002).

Son yıllarda pazarlama araştırmalarında ve ulaşım problemlerinde özellikle tüketici tercihleri incelenirken kesikli tercih modelleri kullanılmaktadır. Bu yöntemde genel olarak bireylere alternatifler verilmekte ve kendi faydalarını maksimize edecek şekilde bu alternatiflerden birisini tercih etmeleri istenmektedir. Kesikli tercih modelleri sonucun iki ya da daha fazla alternatif arasında tercih olup olmadığına göre iki durumlu (binomial) ve çok durumlu (multinomial) kesikli tercih modelleri olarak iki gruba ayrılabilir (Greene, 1993).

Yani tercihler sınırlı sayıda mümkün durumlar ya da alternatiflerden yapılmaktadır. Çalışıp-çalışmama, ulaşım yolu, yaşanacak yer, çalışılacak konum ve aile büyüklüğü bu tür tercihlere örnektir. Böyle kararların belirleyicilerinin bilinmesi; örneğin gelir iyileştirme programları, kentsel onarım projeleri, tıbbi eğitim programları, kamu ulaşım ağları gibi tasarım yapmada politikacı için de önemlidir (Akin, 2002).

Tüketicilerin çok nitelikli alternatifler arasından tercihlerini nasıl yaptıklarını analiz etmek başlı başına bir problemdir. Çünkü firmaların bu süreci bilmeleri, onlara farklı tüketiciler açısından bireysel tercihlerin kümülatif etkisi yardımıyla pazar paylarını

kestirmelerini ve fiyat, ürün özellikleri ve diğer pazarlama değişkenleriyle ilişkili olan pazar payları esnekliklerinin kritik ölçümlerini bilmelerini sağlayacaktır.

Bir analizcinin görüşüne göre, bir tüketici girdisi ürün, çıktısı satın-alma kararıyla optimize edilen bir “kara kutu”dur. Ekonomik tercih teorisi, iyi tanımlanmış istatistiksel özellikler ile kantitatif kestirimleri sağlamak için tasarlanan “kara kutu”yu modelleyen bir yaklaşımdır. Buna rağmen, pazardan elde edilen verilerde tercih durumlarının kontrol edilememesi istenmeyen istatistiksel özellikler yaratabilmektedir. Aksine varsayıma dayalı deneyimlerden toplanan veriler bazı önemli avantajlar sunmaktadırlar. Bu avantajlardan ilki, tercih durumunun doğal deneyim etkilerini çözme ihtiyacını göz ardı etmesidir. Böylece gerçek tercih tasarımı eksiksiz biçimde belirlenebilmektedir. İkincisi, belirli bir biçimde düzenlenmiş tercih tasarımları ilgi etkilerinin tahmin edilmesini sağlamaktadırlar (Zwerina, 1997). 3.üncüsü ise yeni ürünler ve hizmetlerin geliştirilmesi ve test edilmesi gibi deneyimlerde özellikle pazardan elde edilen verilerin kullanılmaması daha kullanışlı sonuçlar sağlamaktadır. Kısaca, kesikli tercih analizleri alan çalışmalarından toplanan verilerde ortaya çıkan birçok problemin üstesinden gelmektedir.

Araştırmanın objektifliği ve araştırma problemlerinin doğru ve etkin şekilde tasarlanması kesikli tercih analizinin başlıca sorunu olduğundan aşağıdaki 3 adım çok önemlidir (Zwerina, 1997).

Etkin tercih tasarımının ilkelerini oluşturmak: Tercih modelleri için tasarım oluşturmak lineer modellerde oldukça zor ve karmaşıktır. Tercih modelinin tasarımı için çok sayıda yöntem önerilmiştir. Bu yöntemlerin birçoğu (istatistiksel) etkinlik yerine modellerin tasarımının genişletilmesini hedeflemektedir. Deneysel tasarımlarda ise etkinlik oldukça önemli bir koşuldur. Daha etkin bir tasarım daha kesin tahminler yapmaktadır. Ayrıca tahminlerde belirli bir kesinlik derecesi sağlayabilmek için daha az yanıt gerekmektedir. Bu nedenle, etkinlik daha kaliteli sonuçlar doğurmaktadır. Bundan dolayı ilk adım etkin tercih tasarımlarını sağlayan ilkeleri geliştirmektir.

Etkin tercih tasarımları oluşturmak için yöntemler geliştirmek: Etkin bir tercih tasarımı oluşturduktan sonra ikinci adım, bu ilkeler ile bu tarz etkin tasarımlar oluşturmak için yöntemler geliştirmektir. Olasılıklı tercih modellerinin önemli bir özelliği tercih tasarımının istatistiksel etkinliğinin (bilinmeyen) bir parametre vektörüne dayanmasıdır. Bu özellik parametre tahminlerinin tercih tasarımına eklenmesi gerektiği anlamına gelmektedir. Tasarım problemi parametre vektörünün 0 olduğu varsayımıyla sadeleştirilmektedir. Araştırmacı bu varsayımı parametreler hakkında çok az bilgiye sahip iken kabul etmektedir. Fakat araştırmacı genellikle niteliklerin göreceli önemi ya da derecelerin göreceli değerleri hakkında geçmiş bilgi ve inanca sahiptir. Bu yüzden parametre vektörünün her zaman 0 olduğunu varsaymak etkinlik kayıplarına yol açmaktadır.

Bireysel düzeyde tercih modeli oluşturmak: Kesikli tercih modelleri tercihlerdeki bilgi eksikliğine bağlı olarak tüketici davranışlarının homojen olduğu varsayılarak tahmin edilmektedir. Heterojenlik problemini azaltmak için tercih analizlerine olanak sağlayan gizli sınıf modelleri kullanılmalıdır. Böylece heterojenlik probleminden tamamen kaçınılabilmektedir.

Model çok fazla tercih içerdiğinden bireysel tercih modelleri kolay ölçülemez ve analiz edilemezler. Bu yüzden tercih tasarımları etkin olmalıdır. Etkin bir tercih tasarımında her bir birey için kabul edilebilir sayıda tercihe dayanan tahmin sonuçları olmalıdır.

3.2. KESİKLİ TERCİH MODELLERİNİN ÖZELLİKLERİ

Kesikli tercih modellerinin özelliklerini incelemeye karar vericinin tercih yaparken kullandığı tercih kümesi ele alınarak başlanmıştır. Daha sonra tercih özelliklerinin türetilmesi ve tanımlanması açıklanıp kısaca ve ön kestirim üzerinde durulmuştur. Son olarak da alternatif-spesifik sabitlerin bu istatistiksel yöntemler için yeniden düzenlenmesinden bahsedilmiştir.

3.2.1. Tercih Kümesi

Kesikli tercih modellerinde karar vericiler sınırlı sayıda alternatif arasından tercih yapmaktadırlar. Bu alternatiflerin toplandığı kümeye “tercih kümesi” denilmektedir. Karar verici bir birey, firma ya da hane halkı olabilir. Alternatifler ise rakip ürünler ya da aralarında tercih yapılması gereken herhangi bir unsur olabilir (Train, 2002). Tercih kümesinin belirlenmesinde araştırmacının hedefleri ve elinde bulunan veriler önemli bir rol oynamaktadır. Bir tercih kümesinin aşağıdaki 3 özelliğe sahip olması gerekmektedir:

- 1) Ayrık olma: Karar verici için olaylar birbirinden ayrık olmalıdır. Bir alternatifin varlığı diğerinin yokluğunu zorunlu kıldığı durumdur, yani bir alternatifi tercih etmek diğerlerini tercih etmemeyi içerir. Karar verici sadece bir alternatifi tercih edebilir.
- 2) Geniş kapsamlı ve ayrıntılı olma: Bütün olası alternatifleri içermelidir ve karar verici bu alternatiflerden muhakkak birini seçmelidir.
- 3) Alternatif sayısının sonlu olması: Alternatifler sınırlı sayıda olmalı ve araştırmacı tarafından bilinmelidir.

Özelliklerden ilk ikisi kısıtlayıcı değildir. Zaten alternatiflerin ayrık, tercih kümesinin de geniş kapsamlı ve ayrıntılı olması çoğu zaman sağlanabilmektedir. Alternatifleri sadece A ve B diye tanımlamak bir tercih kümesini ayrık yapmamaktadır. Oysaki “sadece A”, “sadece B” ve “hem A hem de B” alternatifleri bireyi sadece bir alternatifi tercih etmeye yöneltmektedir. Fakat karar verici alternatiflerden hiçbirini tercih etmemek isteyebilmektedir. Bu durumda tercih kümesine “bu alternatiflerden hiçbiri” seçeneği de eklenmelidir. Bu alternatiflere sahip bir tercih kümesi hem ayrık hem de geniş kapsamlı ve ayrıntılı özelliklerini taşımaktadır. Genellikle bu iki özellik farklı yollarla da sağlanabilmektedir.

Ayrık ve geniş kapsamlı ve ayrıntılı özellikleri araştırmacının elde edebileceği özellikler iken alternatiflerin sonlu sayıda olması özelliği kısıtlayıcıdır. Bu özelliğiyle kesikli tercih modelleri regresyon modellerinden uygulama alanı olarak ayrılmaktadırlar. Regresyon modellerinde bağımlı değişkenin sürekli olması, sonsuz

sayıda olası çıktının olması anlamına gelmektedir. Diğer bir kısıtlayıcı durum da kesikli tercih modellerinin sonsuz sayıda alternatife uygulanamamasıdır.

Regresyon modelleri “ne kadar”, kesikli tercih modelleri ise “hangi” sorusunu yanıtlar. Böyle bir ayırım yapılsa da bazen kesikli tercih modellerinin “ne kadar” sorusunu yanıtladığı görülmektedir. Çünkü hane halkının kaç arabası olduğu sorusuna 0, 1, 2... vs. şeklinde araştırmacının dikkate alacağı sayıda cevap verilebilmektedir ya da eğer amaca uygun ise 0, 1, 2 ve daha fazlası şeklinde alternatif de olabilmektedir (Train, 2003). Yani, tercih modelinin hangi soruyu yanıtlayacağına araştırmacı karar vermektedir.

Böylece “ne kadar” sorusunun yanıtlarını içeren birçok tercih, kesikli tercih modeli çerçevesinde ele alınabilmektedir. Kesikli tercih modelinin kullanımı zorunlu değil ise bu gibi alternatiflerin olduğu durumlarda regresyon modelinin uygulanması daha kolay ve rahat olmaktadır. Train ve diğerleri (1987) hane halkının yaptığı telefon görüşmeleri, numaralarını ve sürelerini incelerken regresyon yerine kesikli tercih modellerini kullanarak analiz yapmışlardır. Çünkü kesikli tercih modelleri hane halkının karşılaştığı lineer olmayan fiyat değişkeninde daha fazla esnekliğe izin vermektedir. Araştırmacı kesikli tercih modelini kullanıp kullanmayacağına karar verirken araştırmanın amacını ve alternatif modellerin özelliklerini göz önünde tutmalıdır (Train, 2002).

3.2.2. Tercih Olasılıklarının Türetimi

Kesikli tercih modelleri genellikle karar verici tarafından fayda-maksimizasyonu davranışı varsayımı altında türetilmiştir. Thurstone (1927) başlangıçta psikolojik uyarıya dayanan kavramı geliştirmiştir. Thurstone bu kavramı kullanarak deneklerin uyarı seviyesindeki farklılıkları ayırt edip etmedikleri temelli iki terimli probit modelini önermiştir. Marschak (1960) psikolojik uyarıyı fayda olarak yorumlamış ve fayda maksimizasyonuna bir kaynak sağlamıştır. Bu yolla türetilen modellere RUMs denir (Train, 2002). Burada belirtilmesi gereken diğer önemli bir husus, fayda maksimizasyonundan türetilen modellerin fayda maksimizasyonunu gerektirmeyen karar alma sürecini açıklayabilmesidir. Ayrıca tercihin nasıl yapıldığıyla ilişkili

olmayan tercih çıktıları ile açıklayıcı değişkenler arasındaki ilişki de açıklanabilmektedir.

Rassal fayda modelleri açıklanırken n.inci karar verici, J alternatif ile karşılaşmaktadır. Her bir karar verici her bir alternatiften bir fayda seviyesi belirlemektedir ve n.inci karar vericinin j.inci alternatiften elde ettiği fayda U_{nj} , $J=1, \dots, J$ şeklinde gösterilmektedir. Karar verici en yüksek faydayı seçtiği için davranış modeli $U_{ni} > U_{nj} \forall j \neq i$ olmakta ve karar verici i.inci alternatifi tercih etmektedir.

Araştırmacı karar vericinin faydasını gözlemleyememektedir. Araştırmacı karar vericinin karşılaştığı alternatiflerin bazı niteliklerini; $x_{nj} \forall j$ ve karar vericinin bazı niteliklerini; s_n gözlemleyebilmektedir ve karar vericinin faydası ile ilgili olan bu gözlenen faktörlerden bir fonksiyon oluşturmaktadır. Bu fonksiyon $V_{nj} = V(x_{nj}, s_n) \forall j$ olarak belirtilmektedir ve *temsilci fayda* diye adlandırılmaktadır (Train, 2002). Araştırmacının gözlemlediği fayda V_{nj} ve gözlemleyemediği fakat faydayı etkileyen ε_{nj} 'nin modele eklenmesi ile fayda modeli $U_{nj} = V_{nj} + \varepsilon_{nj}$ şeklini almaktadır. Araştırmacı $\varepsilon_{nj} \forall j$ 'yi bilmediğinden bunların rassal olduklarını varsaymaktadır. Bu durumda rassal vektör $\varepsilon_n = \langle \varepsilon_{n1}, \dots, \varepsilon_{nj} \rangle$ 'nin birleşik yoğunluğu $f(\varepsilon_n)$ ile gösterilmektedir. Karar verici n'nin i.inci alternatifi tercih etme olasılığı,

$$\begin{aligned}
 P_{ni} &= P(U_{ni} > U_{nj} \forall j \neq i) \\
 &= P(V_{ni} + \varepsilon_{ni} > V_{nj} + \varepsilon_{nj} \forall j \neq i) \\
 &= P(\varepsilon_{nj} - \varepsilon_{ni} < V_{ni} - V_{nj} \forall j \neq i)
 \end{aligned} \tag{3.1}$$

şeklinde yazılmaktadır. Birikimli dağılım fonksiyonu birleşik yoğunluk, $f(\varepsilon_n)$, ile aşağıdaki şekli almaktadır:

$$\begin{aligned}
P_{ni} &= \mathbb{P}(\varepsilon_{nj} - \varepsilon_{ni} < V_{ni} - V_{nj} \quad \forall j \neq i) \\
&= \int_{\varepsilon} I(\varepsilon_{nj} - \varepsilon_{ni} < V_{ni} - V_{nj} \quad \forall j \neq i) f(\varepsilon_n) d\varepsilon_n
\end{aligned} \tag{3.2}$$

Eşitlik (3.2)'deki $I(\cdot)$ doğru ise 1, değil ise 0 değerini alan gösterge fonksiyonudur. Faydanın gözlenmeyen kısmının dağılımı hakkındaki farklı varsayımlardan dolayı farklı kesikli tercih modelleri gözlemlenmektedir. $f(\cdot)$ sadece belirli spesifikasyonlar için kapalı formdadır. Bu integral için lojit ve nested lojitin kapalı formulu anlatımları vardır. Faydanın gözlenmemiş kısmı bağımsız ve özdeşçe dağılan (iid) ekstrem değer ve GEV'in bir çeşidi olduğu varsayımı altında türetilmektedirler. Probit ise çok değişkenli Gauss dağılımı varsayımı altında türetilmektedir ve kapalı form almadığı gibi benzetim yolu ile sayısal olarak hesaplanabilmektedir.

Tercih olasılıkları türetilirken ε_n 'nin dağılımının bilinmesi gerekmektedir. Çünkü bu dağılım için yapılan yorum, araştırmacının tercih olasılıklarıyla ilgili yorumunu etkilemektedir. n.inci karar verici ile bir anakitlenin aynı gözlenmiş faktörlerle karşılaştığı göz önüne alındığında; bu kişilere ait gözlenmemiş faktörler değişmektedir ve böylece $f(\varepsilon_n)$ de faydanın gözlenmemiş kısmının dağılımı olmaktadır. Bu tanımla, P_{ni} n.inci karar verici gibi bu insanlar arasından i.inci alternatifi tercih edenlerin payını göstermektedir. İkinci olarak, dağılım kişisel açıdan ele alındığında gözlenmemiş fayda değerleri için kişisel olasılıklar dikkate alınmaktadır. Bu durumda araştırmacı tarafından karar vericinin faydasının gözlenmeyen kısmına karşılık gelen olasılık P_{ni} olur. Dağılımın karar vericiyi etkileyen faktörlerden etkilendiği dikkate alındığında P_{ni} , bireyin i.inci alternatifi tercih etmesini etkileyen ikna edici faktörlere ait olasılığı ifade eder.

3.2.3. Tercih Modellerinin Tanımlanması

Davranış karar sürecinin çeşitli durumları herhangi bir kesikli tercih modelini belirlemeyi ve tahmin etmeyi etkilemektedir. Bu süreç iki ifadeyle

özetlenebilmektedir: “Sadece fayda sorunundaki farklılıklar” ve “Fayda ölçeği kişiseldir”. Bu ifadelerin çıkarımı geniş kapsamlı, algılaması zor ve birçok durumda çok karmaşıktır (Train, 2002).

3.2.3.1. Sadece Fayda Sorunundaki Farklılıklar

Sadece fayda sorunundaki farklılıklar ifadesi, faydanın mutlak değerinin karar vericinin davranışı ve araştırmacının modeli ile ilgili olmadığını açıklamaktadır. Bütün alternatiflerin faydasına bir sabit eklendiğinde en yüksek faydalı alternatif değişmemekte, yani karar verici için $U_{nj} \forall j$ alternatifi ile $U_{nj} + k \forall j$ aynı şeyi ifade etmektedir. Kenneth Train (2002) bu durum için “Yükselen gelgit bütün botları yükseltir.” deyimini kullanmaktadır. Faydanın seviyesi araştırmacı için de önem taşımamaktadır. Çünkü tercih olasılığı olan $P_{ni} = P(U_{ni} > U_{nj} \forall j \neq i) = P(U_{ni} - U_{nj} > 0 \forall j \neq i)$ mutlak değer yerine sadece fayda sorunundaki farklılığa dayanmaktadır.

Sadece fayda sorunundaki farklılıklarda kesikli tercih modellerinin belirlenmesi ve tanımlanması için bir çok çıkarım vardır. Tahmin edilebilen parametreler sadece alternatifler arasındaki farklılıkları yakalayabilenlerdir. Bu durum alternatif-spesifik sabitler, sosyodemografik değişkenler ve bağımsız hata terimlerinin sayısı olarak 3 ana başlık altında açıklanabilmektedir.

Alternatif-spesifik bir sabit ile parametrelerde faydanın gözlenen kısmının lineer olduğunun belirtilmesi uygundur. Bu uygunluk aşağıdaki şekilde ifade edilmektedir.

$$V_{nj} = x'_{nj}\beta + k_j \forall j \quad (3.3)$$

Burada β değişkenlerin katsayısı, x_{nj} n.inci karar vericinin karşılaştığı j.inci alternatife ilişkin olan değişkenlerin vektörü ve k_j j.inci alternatif için spesifik olan sabittir. Bir alternatif için alternatif-spesifik sabit, modele eklenmeyen bütün faktörlerin fayda üzerindeki ortalama etkisini göstermektedir.

Alternatif-spesifik sabitler modele eklendiğinde faydanın gözlenmeyen kısmının, ε_{nj} , ortalaması 0 olmakta, bu durum geri kalan hatanın da 0 ortalamalı olmasını sağlamaktadır: $E(\varepsilon_{nj}^*) = k \neq 0$ ile $U_{nj} = x'_{nj}\beta + \varepsilon_{nj}^*$ ve $E(\varepsilon_{nj}) = 0$ ile $U_{nj} = x'_{nj}\beta + \varepsilon_{nj}$ olmaktadır. Yine de sadece fayda sorunundaki farklılıklardan dolayı alternatif-spesifik sabitlerdeki farklılıklar uygun fakat mutlak değerleri için uygun değildir. Bu durum aşağıdaki eşitliklerle açıklandığında,

$$\begin{aligned} U_0 &= \alpha T_0 + \beta M_0 + k_0^0 + \varepsilon_0, \\ U_1 &= \alpha T_1 + \beta M_1 + k_1^0 + \varepsilon_1, \end{aligned} \quad (3.4)$$

olan model,

$$\begin{aligned} U_0 &= \alpha T_0 + \beta M_0 + k_0^1 + \varepsilon_0, \\ U_1 &= \alpha T_1 + \beta M_1 + k_1^1 + \varepsilon_1 \end{aligned} \quad (3.5)$$

modele denk olmaktadır. Eski sabitler arasındaki fark, yeni sabitler arasındaki farka eşittir: $k_1^1 - k_0^1 = d = k_1^0 - k_0^0$. Çünkü sabitleri arasındaki farkı eşit olan modeller denktir ve bu sabitleri tahmin etmek imkansızdır. Burada yapılması gereken sabitlerden birini 0'a normalleştirmektir. İlk alternatifinin sabiti sıfırlandığında aşağıdaki eşitlik oluşmaktadır:

$$\begin{aligned} U_0 &= \alpha T_0 + \beta M_0 + \varepsilon_0, \\ U_1 &= \alpha T_1 + \beta M_1 + k_1 + \varepsilon_1 \end{aligned} \quad (3.6)$$

Bu normalleştirme ile ikinci alternatifin sabiti k_1 'nin modele eklenmeyen faktörlerin ortalama etkisi (d) olduğu görülmektedir.

Kısaca, J alternatifin olduğu bir durumda en fazla J-1 tane alternatif-spesifik sabit modele eklenebilmektedir. Araştırmacı bu sabiti 0 yerine başka bir sayıya da normalleştirebilmekle birlikte 0'a normalleştirmek hem daha kolaydır hem de eşitlik (3.6)'daki gibi model sadeleştirilmektedir.

Aynı sorun sosyodemografik değişkenlerin modele eklenmesinde de görülmektedir. Alternatiflerin nitelikleri alternatiften alternatife değişmesine rağmen karar vericilerin nitelikleri alternatiflere göre değişmemektedir.

Karar vericinin gelirinin alternatifler üzerindeki etkisi dikkate alındığında daha yüksek gelirli kişi daha yüksek faydayı umar varsayımı altında model,

$$\begin{aligned} U_0 &= \alpha T_0 + \beta M_0 + \theta_0^0 Y + \varepsilon_0, \\ U_1 &= \alpha T_1 + \beta M_1 + \theta_1^0 Y + \varepsilon_1 \end{aligned} \quad (3.7)$$

şeklinde gösterilmektedir. Burada Y geliri, θ_0^0 ve θ_1^0 gelirdeki değişimleri yansıtır. Sadece fayda sorunundaki farklılıklardan dolayı θ_0^0 ve θ_1^0 nin kendileri değil farkları tahmin edilebilmektedir. Bu yüzden sabitler yerine sosyodemografik değişken olan gelirlerden biri 0'a normleştirilmekte ve model $\theta_d = \theta_1^0 - \theta_0^0$ ile aşağıdaki gibi gösterilmektedir.

$$\begin{aligned} U_0 &= \alpha T_0 + \beta M_0 + \varepsilon_0, \\ U_1 &= \alpha T_1 + \beta M_1 + \theta_1 Y + k_b + \varepsilon_1 \end{aligned} \quad (3.8)$$

Sosyodemografik değişkenler fayda modeline farklı yollarla da eklenebilmektedir. Örneğin maliyetin gelire oranı olan β / Y katsayısı kullanıldığında Y azaldığında karar vericinin kararlarında gelirin etkisi de azalmaktadır. Fark, $U_o - U_d = \dots \beta (M_o - M_d) / Y \dots$, gelirle değişir çünkü maliyetler alternatiflere bağlı olarak değişmektedir (Train, 2002). Sosyodemografik değişkenler alternatiflerin nitelikleriyle ilişkili olduğunda katsayıların normleştirilmesine gerek yoktur. Sosyodemografik değişkenler alternatiflerin nitelikleriyle ilişkili olduğunda faydadaki farkları etkilemektedirler.

Sadece fayda sorunundaki farklılıklar için bağımsız hata terimlerinin sayısı dikkate alındığında $\varepsilon_n = \langle \varepsilon_{nj} - \varepsilon_{ni} < V_{ni} - V_{nj} \forall j \neq i \rangle$ 'deki J hata teriminin yoğunluğu üzerinden J boyutlu integral,

$$P_{ni} = \int I(\varepsilon_{nj} - \varepsilon_{ni} < V_{ni} - V_{nj} \quad \forall j \neq i) f(\varepsilon_n) d\varepsilon_n \quad (3.9)$$

şeklindedir. Boyut sadece fayda sorunundaki farklılıkları kabul edilmesi durumunda küçültülebilmektedir. Çünkü J hatayla (her bir hata için bir tane) J-1 tane hata farkı vardır. Tercih olasılığı bu hata farklarının yoğunluğu üzerinden (J-1) boyutlu integral olarak açıklanabilmektedir (Train, 2002):

$$\begin{aligned} P_{ni} &= P(U_{ni} > U_{nj} \quad \forall j \neq i) \\ &= P(\varepsilon_{nj} - \varepsilon_{ni} < V_{ni} - V_{nj} \quad \forall j \neq i) \\ &= P(\tilde{\varepsilon}_{nji} < V_{ni} - V_{nj} \quad \forall j \neq i) \\ &= \int I(\tilde{\varepsilon}_{nji} < V_{ni} - V_{nj} \quad \forall j \neq i) g(\tilde{\varepsilon}_{ni}) d\tilde{\varepsilon}_{ni} \end{aligned} \quad (3.10)$$

Eşitlikte bulunan $\tilde{\varepsilon}_{nji} = \varepsilon_{nj} - \varepsilon_{ni}$ j.inci ve i.inci alternatif arasındaki farkı, $\tilde{\varepsilon}_{ni} = \langle \tilde{\varepsilon}_{ni1}, \dots, \tilde{\varepsilon}_{nji} \rangle$ hata farklarının (J-1) boyutlu vektörü ve $g(\cdot)$ bu hata farklarının yoğunluğunu ifade etmektedir. Orijinal hata farkının yoğunluğu olan $f(\cdot)$, $g(\cdot)$ ile ilişkilidir. $\varepsilon_n = \langle \varepsilon_{n1}, \dots, \varepsilon_{nJ} \rangle$ herhangi bir k için $\tilde{\varepsilon}_{nj} = \varepsilon_{nj} - \varepsilon_{nk}$ şeklinde ifade edilen J-1 hatalı ve $f(\varepsilon_n)$ 'den kaynaklanan $g(\tilde{\varepsilon}_{nk})$ yoğunluklu modele denktir. Tercih modelleri $g(\tilde{\varepsilon}_{nk})$ 'ya dayandığından $f(\varepsilon_n)$ 'nin yoğunluğunun boyutu değişmemektedir. Bu yüzden normalleştirme gerekmemektedir. $f(\varepsilon_n)$ 'yi normalleştirmede birçok yöntem kullanılabilir. Bunlardan en önemlisi lojit modelde hata terimlerinin dağılımının kısıtlanmasıyla normalleştirmenin kendiliğinden ortaya çıkmasıdır.

3.2.3.2. Fayda Ölçeği Kişiseldir

Fayda modeline bir sabit eklemek ya da katsayıları bir sabite bölmek karar vericinin tercihini değiştirmemektedir. Aynı durumla faydanın ölçeklenmesinde de karşılaşılacaktır. $U_{nj}^0 = V_{nj} + \varepsilon_{nj} \quad \forall j$ olan fayda modeli $\lambda > 0$ ölçeğiyle çarpıldığında $U_{nj}^1 = \lambda V_{nj} + \lambda \varepsilon_{nj} \quad \forall j$ şeklini almasına rağmen birbirlerine denktirler. Bu denkliğin sağlanması için ölçeğin, yani hata terimlerinin varyansının normalleştirilmesi

gerekmektedir. Çünkü fayda λ ile çarpıldığında her bir ε_{nj} 'nin varyansı λ^2 kadar değişmektedir: $Var(\lambda\varepsilon_{nj}) = \lambda^2 Var(\varepsilon_{nj})$. Burada iid hatalar, değişen varyanslı hatalar ve birbirleriyle ilişkili hatalar ile normalleştirme yapılmaktadır.

Hata terimleri iid iseler eş varyanslılık varsayımı ile normalleştirme çok kolaydır. Yani herhangi bir hatanın varyansı normalleştirildiğinde diğerlerinin varyanslarının da düzenlendiği görülmektedir. Hata terimlerinin varyansının $Var(\varepsilon_{nj}^0) = \sigma^2$ olduğu durumda model, $U_{nj}^0 = x'_{nj}\beta + \varepsilon_{nj}^0$ olmaktadır. Hata varyansının ölçeğini 1 olarak ele alınıp normalleştirme yapıldığında $Var(\varepsilon_{nj}^1) = 1$ olmakta ve model $U_{nj}^1 = x'_{nj}(\beta/\sigma) + \varepsilon_{nj}^1$ şeklini almaktadır. Modeldeki yeni katsayı (β/σ), gözlenmemiş faktörlerin standart sapmasıyla ilişkili olan gözlenmiş faktörlerin etkisini yansıtmaktadır.

Normalleştirme yapılırken kullanılan modele göre ölçeğin hangi sayıya normalleştirileceğinde değişiklikler olmaktadır. Probitte bu sayı 1 iken, logitte $\pi^2/6$ ($\cong 1.6$) olmaktadır. Araştırmacının normalleştirme yaparken hangi modeli ya da hangi sayıyı kullandığı önemli olmamakla birlikte model sonuçlarını yorumlarken bu sayıya dikkat edilmelidir. Çünkü örneğin lojit modelde 1.6 ve probit modelde 1 kullanıldığından lojit modelin katsayıları $\sqrt{1.6}$ kat daha büyük olmaktadır. Bu da lojit modeldeki karar vericilerin niteliklerinin daha fazla dikkate alındığı anlamına gelmektedir. Bu yanılgıdan kurtulmak için aynı veriler için tahmin yapıldığında ya logit modelin katsayıları $\sqrt{1.6}$ 'ye bölünmeli ya da probit modelin katsayıları $\sqrt{1.6}$ ile çarpılmalıdır.

Değişen varyanslı hatalar ile normalleştirmede varyans anakitlenin farklı kesimlerinde farklıdır. Bu farklılıktan dolayı bazen araştırmacı faydanın genel seviyesini bütün kesimler için normalleştirerek sabitleyememektedir. Bu yüzden araştırmacı ilk önce bir kesim için varyansı normalleştirir ve daha sonra bu kesimle ilişkili olan her bir kesim için varyansı (dolayısıyla ölçeği) tahmin ederek faydanın genel ölçeğini ayarlar (Train, 2002).

Bu konu daha ayrıntılı olarak iki alternatif ele alınarak açıklanabilmektedir. x ve y alternatiflerinden ayrı alınan veriler için modellerin ayrı ayrı tahmin edildiği ve normalleştirildiği varsayılmaktadır. Böyle bir model her iki alternatif için farklı varyanslara sahip olduğundan araştırmacı tahmin sürecinde gözlenmemiş faktörlerin varyansını aynı sayıya sabitleyememektedir. Bu durumda yapılacak tek şey x alternatifinin varyansını normalleştirmek ve y alternatifinin varyansını tahmin ederek faydanın genel ölçeğini ayarlamaktır.

Orijinal formda, x alternatifi için $U_{nj} = \alpha T_{nj} + \beta M_{nj} + \varepsilon_{nj}^x \forall n$, y alternatifi için $U_{nj} = \alpha T_{nj} + \beta M_{nj} + \varepsilon_{nj}^y \forall n$ olan modelde varyansların oranını $k = Var(\varepsilon_{nj}^x) / Var(\varepsilon_{nj}^y)$ olarak belirtilmektedir. x alternatifindeki karar vericiler için faydanın katsayıları \sqrt{k} 'ya bölünmektedir. Burada k'ya "ölçek parametresi" denir ve α ve β ile tahmin edilir. Bu işlem karar vericilerin tercihlerini etkilemediğinden tercih ölçeği sorun oluşturmaktadır. Normalleştirme işlemi yapıldıktan sonra model aşağıdaki şekli almaktadır:

$$x \text{ alternatifi için } U_{nj} = \alpha T_{nj} + \beta M_{nj} + \varepsilon_{nj} \forall n, \quad (3.11)$$

$$y \text{ alternatifi için } U_{nj} = (\alpha / \sqrt{k}) T_{nj} + (\beta / \sqrt{k}) M_{nj} + \varepsilon_{nj} \forall n. \quad (3.12)$$

Böylece her iki alternatifte de ε_{nj} 'nin varyansı bütün n'ler için aynı olmuştur. Tahmin edilen \hat{k} , x alternatifleriyle ilişkili olan y alternatifine ait gözlenmemiş faktörlerin varyansını vermektedir. $\hat{k}=1.4$ x alternatifindeki gözlenmemiş faktörlerin varyansının y alternatifininkinden % 40 daha büyük olduğunu göstermektedir.

Hata terimlerinin varyansı coğrafi bölgeler, veri kümeleri, zaman ya da diğer faktörler çerçevesinde değişiklik göstermektedir. Her bir durumda araştırmacı varyanslardan birini normalleştirmekte ve daha sonra normalleştirilen ile birbiriyle ilişkili olan diğer varyansları tahmin edip faydanın genel ölçeğini ayarlamaktadır. Swait ve Louviere (1993) varyansın gözlemler üzerinde değişiklik göstermesinin sebeplerini açıklayarak ölçek parametresinin kesikli tercih modellerindeki rolünü

araştırmışla, gözlenmemiş faktörlerin varyansının tercih durumuna ve araştırmacının yorumuna bağlı olarak psikolojik faktörlerden etkilendiğini göstermişlerdir.

Hatalar alternatifler ile ilişkilendirildiğinde ölçeğin normalleştirilmesi daha karmaşıktır. Sadece fayda sorunundaki farklılıklar faktörü yüzünden fayda farklarının ölçeğini ayarlamak daha uygundur. Hatalar ilişkili olduğunda fayda farklarının ölçeğini ayarlamak için bir alternatifin hata varyansını normalleştirmek yeterli olmamaktadır. Bu sorun 4 alternatif ele alınarak en kolay şekilde açıklanmaktadır. Bu alternatifler için fayda, $U_{nj} = V_{nj} + \varepsilon_{nj}$, $j = 1, \dots, 4$ 'dür. Hata vektörü, $(\varepsilon_n = \langle \varepsilon_{n1}, \dots, \varepsilon_{n4} \rangle)$ 'nin ortalaması 0'dır ve kovaryans matrisi aşağıdaki gibidir.

$$\Omega = \begin{pmatrix} \sigma_{11} & \sigma_{12} & \sigma_{13} & \sigma_{14} \\ \cdot & \sigma_{22} & \sigma_{23} & \sigma_{24} \\ \cdot & \cdot & \sigma_{33} & \sigma_{34} \\ \cdot & \cdot & \cdot & \sigma_{44} \end{pmatrix} \quad (3.13)$$

Bu matristeki noktalar simetrik matrisin üst kısmına karşılık gelen elemanları ifade etmektedir. Sadece fayda sorunundaki farklılıklardan dolayı denk model şu şekli almaktadır: $\tilde{U}_{nj1} = \tilde{V}_{nj1} - \tilde{\varepsilon}_{nj1}$ $j = 2, 3, 4$ için. Burada $\tilde{U}_{nj1} = U_{nj} - U_{n1}$, $\tilde{V}_{nj1} = V_{nj} - V_{n1}$ ve hata farkları vektörü $\tilde{\varepsilon}_{nj1} = \langle (\varepsilon_{n2} - \varepsilon_{n1}), (\varepsilon_{n3} - \varepsilon_{n1}), (\varepsilon_{n4} - \varepsilon_{n1}) \rangle$ 'dir. Her bir hata farkı orijinal hataların varyansı ve kovaryanslarıyla ilişkilidir. Birinci ve ikinci hatalar arasındaki farkın varyansı şöyledir.

$$Var(\tilde{\varepsilon}_{n21}) = Var(\varepsilon_{n2} - \varepsilon_{n1}) = Var(\varepsilon_{n1}) + Var(\varepsilon_{n2}) - 2Cov(\varepsilon_{n1}, \varepsilon_{n2}) = \sigma_{11} + \sigma_{22} - 2\sigma_{12} \quad (3.14)$$

Aynı şekilde $\tilde{\varepsilon}_{n21}$ (1. ve 2. hataların farkı) ve $\tilde{\varepsilon}_{n31}$ 'nin (1. ve 3. hataların farkı) kovaryansı hesaplanabilmektedir:

$$\begin{aligned} Cov(\tilde{\varepsilon}_{n21}, \tilde{\varepsilon}_{n31}) &= E(\varepsilon_{n2} - \varepsilon_{n1})(\varepsilon_{n3} - \varepsilon_{n1}) = E(\varepsilon_{n2} \varepsilon_{n3} - \varepsilon_{n2} \varepsilon_{n1} - \varepsilon_{n3} \varepsilon_{n1} + \varepsilon_{n1} \varepsilon_{n1}) \\ &= \sigma_{23} - \sigma_{21} - \sigma_{31} + \sigma_{11} \end{aligned} \quad (3.15)$$

Hata farklarının vektörü için ise kovaryans matrisi,

$$\tilde{\Omega}_1 = \begin{pmatrix} \sigma_{11} + \sigma_{22} - 2\sigma_{12} & \sigma_{11} + \sigma_{23} - \sigma_{12} - \sigma_{13} & \sigma_{11} + \sigma_{24} - \sigma_{12} - \sigma_{14} \\ & \sigma_{11} + \sigma_{33} - 2\sigma_{13} & \sigma_{11} + \sigma_{34} - \sigma_{13} - \sigma_{14} \\ & & \sigma_{11} + \sigma_{44} - 2\sigma_{14} \end{pmatrix} \quad (3.16)$$

olmaktadır. Hata farklarının varyansını ayarlamak için orijinal hatalardan birinin varyansını ayarlamak yeterli değildir. Eğer bir alternatif için varyans $\sigma_{11} = k$ 'ya sabitlenir ise ilk 2 alternatif için hatalar arası farkın varyansı $k + \sigma_{22} - \sigma_{12}$ olmakta ve $\sigma_{22} - \sigma_{12}$ değerleri için sonsuz sayıda denk model ortaya çıkmaktadır.

Faydanın ölçeğini ayarlamamanın genel yolu, hatalar iid olmadığında hata farklarından birinin varyansını herhangi bir sayıya normalleştirmektir. Bir hata farkının varyansını ayarlamak fayda farklarının ölçeği ile faydanın ölçeğini ayarlamaktadır. $\tilde{\varepsilon}_{n21}$ 'in varyansı 1'e normalleştirildiğinde hata farklarının kovaryans matrisi aşağıdaki gibidir.

$$\begin{pmatrix} 1 & (\sigma_{11} + \sigma_{23} - \sigma_{12} - \sigma_{13})/m & (\sigma_{11} + \sigma_{24} - \sigma_{12} - \sigma_{14})/m \\ & (\sigma_{11} + \sigma_{33} - 2\sigma_{13})/m & (\sigma_{11} + \sigma_{34} - \sigma_{13} - \sigma_{14})/m \\ & & (\sigma_{11} + \sigma_{33} - 2\sigma_{13})/m \end{pmatrix} \quad (3.17)$$

şeklinde olmaktadır. Burada $m = \sigma_{11} + \sigma_{22} - 2\sigma_{12}$ 'dir. Bu ölçeğin ayarlanması için fayda $\sqrt{\sigma_{11} + \sigma_{22} - 2\sigma_{12}}$ 'ye bölünmektedir.

Hata terimleri iid olduğunda ise bu hatalardan birinin varyansını normalleştirmek diğer hata farklarının varyansını da normalleştirmektedir. Yani iid hatalar ile $\sigma_{jj} = \sigma_{ii}$ ve $\sigma_{ij} = 0$; $i \neq j$ olmaktadır. Bu yüzden σ_{11} k 'ya normalleştirilirse, hata farkının varyansı $\sigma_{11} + \sigma_{22} - 2\sigma_{12} = k + k - 0 = 2k$ 'ya denk olmaktadır. Aslında iid ve iid olmayan hata farklarının varyansı aynı şekilde normalleştirilmektedir.

Kovaryans matrisin tahmin edilebilen parametrelerinin sayısının belirlenmesinde özel bir yöntem kullanılmaktadır. Orijinal hataların kovaryansının (Ω) 4 alternatifli örnek için 10 elemanı vardır. Buna rağmen, hata farklarının kovaryans matrisinin 6 elemanı vardır çünkü fayda farklarından biri ölçeğin sabitlemesi için normalleştirilmiştir (Train, 2002). İlk hata farkının varyansı k 'ya normalleştirildiğinde, hata farkları için kovaryans matrisi aşağıdaki 5 elemanlı biçimi almaktadır.

$$\tilde{\Omega}_1^* = \begin{pmatrix} k & \omega_{ab} & \omega_{ac} \\ \cdot & \omega_{bb} & \omega_{bc} \\ \cdot & \cdot & \omega_{cc} \end{pmatrix} \quad (3.18)$$

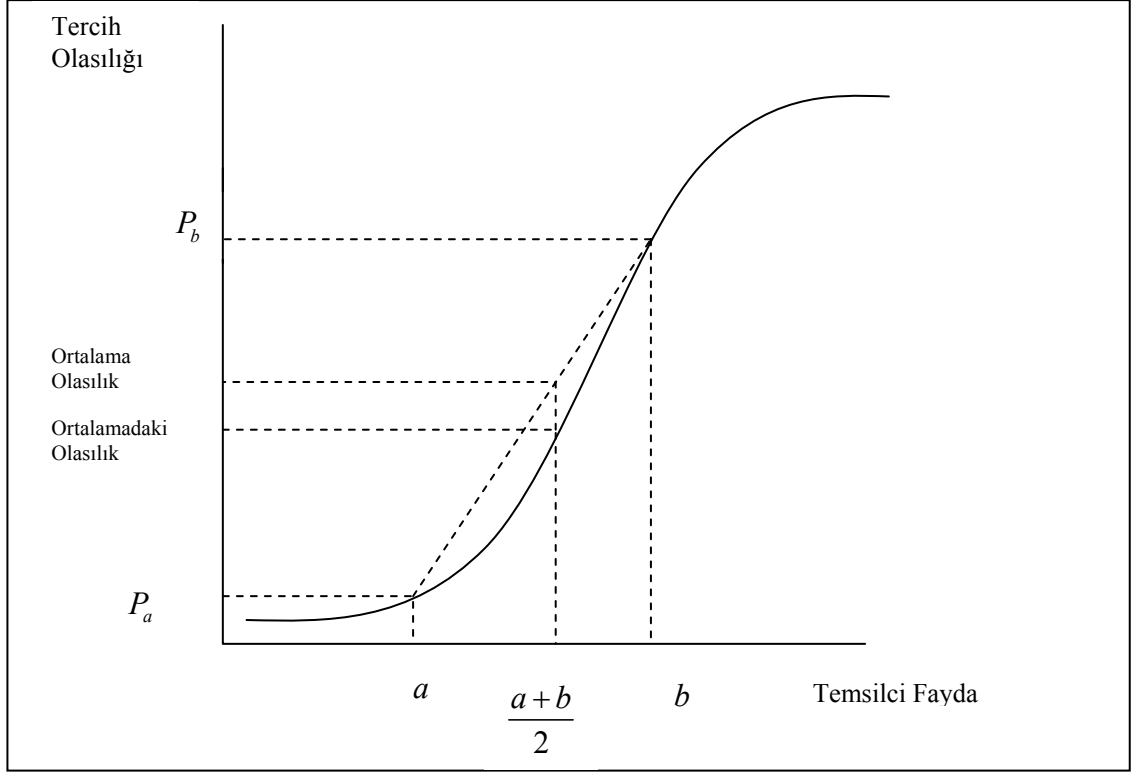
Sadece farklılıklar sorunundan ve faydanın ölçeğinin kişisel olmasından dolayı kovaryans parametrelerinin sayısı 10'dan 5'e düşmektedir. Normalleştirmeden sonra J alternatifli modelin en fazla $J(J-1)/2-1$ kovaryans parametresi olmaktadır.

Modelin tanımı da normalleştirmeden etkilenmektedir. Yukarıdaki (3.18) eşitliğindeki matris elemanları tahmin edilmek istendiğinde ω_{bb} , birinci ve ikinci alternatiflerin hatalar arası farkının varyansı ile ilişkili olan birinci ve 3.üncü alternatiflerin hatalar arası farkının varyansıdır. İki alternatifin hatalar arası farkının varyansı, diğer alternatifler arasındaki kovaryansı etkilediği gibi varyanslarını da etkilemektedir. Logit ve nested logit modellerde hata terimleri, dağılım ile ilgili varsayımlarla kendiliğinden normalleşmektedirler. Bu varsayımlar altında modelin tanımının anlaşılması daha kolaydır. Mixed logit ve probit için hata terimlerinde daha az varsayım söz konusu olduğunda normalleştirme kendiliğinden olmamaktadır.


3.2.4. Toplulaştırma

Kesikli tercih modelleri bağımsız karar vericilerden etkileniyor olsa da araştırmacı genellikle bir anakitledeki ortalama olasılık ya da bazı faktörlerdeki değişime ortalama tepki gibi bazı toplam ölçümlerle ilgilenmektedir. Doğrusal regresyon modellerinde bağımlı değişkenin toplam değerlerinin tahmini açıklayıcı değişkenlerin toplam değerlerinin modele eklenmesiyle elde edilmektedir. h_n n kişinin hane halkı giderleri, y_n kişinin geliri ise model $h_n = \alpha + \beta y_n$ olmaktadır. Model doğrusal olduğundan hane halkının ortalama gideri $\alpha + \beta \bar{y}$ şeklinde hesaplanmaktadır. Burada \bar{y} ortalama geliri ve β gelirdeki bir birimlik değişikliğe her bir kişinin ortalama tepkisini yansıtmaktadır (Train, 2002).

Kesikli tercih modellerinde açıklayıcı değişkenleri modele eklemek ortalama olasılık ve ortalama tepkinin yansız tahminini sağlamaktadır. Çünkü kesikli tercih modellerinde açıklayıcı değişkenler doğrusal değildir. Şekil 3.1.'de faydanın (temsilci fayda) gözlenen kısmı ve iki birey için belirli bir alternatifi tercih etme olasılıkları a ve b olarak gösterilmektedir. Bu iki kişinin ortalama olasılığı $(P_a + P_b)/2$ ve ortalama temsilci faydanın olasılığı $(a + b)/2$ şeklindedir. Yani ortalama olasılık ortalama temsilci faydanın olasılığından büyüktür. Burada ortaya çıkan sorun bireylerin tercih olasılıkları düşük olduğunda ortalama temsilci faydada değerlendirilen olasılığa daha az değer, yüksek olduğunda da aşırı değer biçilmesidir. Ayrıca açıklayıcı değişkenlerin ortalamasındaki esneklik ve türevler hesaplandığında ortalama tepkinin tahmin edilmesi benzer şekilde sorunludur.



Şekil 3.1. Ortalama olasılık ile ortalama temsilci faydada hesaplanan olasılık arasındaki fark



Şekil 3.2. Ortalama tepki ile ortalama temsilci faydada hesaplanan tepki arasındaki fark

Şekil 3.2.'de iki bireyin temsilci faydaları a ve b olarak tanımlanmıştır. Temsilci faydadaki bir değişiklik için tercih olasılığının türetimi her iki kişi için de küçüktür (a ve b'nin üzerinde olan eğrinin eğimi). Bu nedenle ortalama türetim de küçüktür. Buna rağmen ortalama temsilci faydadaki türetim çok büyüktür ($(a+b)/2$ 'nin üstündeki eğim). Fakat bu yolla ortalama tepkiyi tahmin etmek yanıltıcı olmaktadır. Bu sebepten kesikli tercih modellerinden toplam çıktı değişkenleri iki yolla elde edilmektedir: örneklemin sıralanması ve bölümlendirme.

3.2.4.1. Örneklemin Sıralanması

Bu yöntemde her bir karar vericinin tercih olasılıkları toplanmakta ya da ortalaması alınmaktadır. Bu basit hesaplar bu yöntemi en basit ve en popüler yöntem yapmaktadır. N sayıda karar vericinin olduğu bir örnekleme karar verici n'nin i.inci alternatifi tercih etme olasılığı P_{ni} şeklindedir. Örneklenen her bir karar vericinin kendisiyle ilişkilendirilmiş ağırlığı da w_n 'dir. Bu ağırlık anakitledeki kendisine benzer karar vericilerin sayısını temsil etmektedir. Eğer örneklem tamamen rassal ise w_n bütün karar vericiler için, tabakalı ise bir tabakadaki bütün karar vericiler için aynıdır.

Bir anakitlede i.inci alternatifi tercih eden karar vericilerin sayısının tahmini (\hat{N}_i) bireylerin olasılıklarının ağırlıklandırılmış toplamıdır:

$$\hat{N}_i = \sum_n w_n P_{ni} . \quad (3.19)$$

Tahmin edilen pazar payı olan ortalama olasılık ise \hat{N}_i / N şeklindedir. Ortalama türetimler ve esneklikler her bir örneklenen kişi için türetim ve esnekliğin hesaplanması ve ağırlıklı ortalamanın alınmasıyla elde edilmektedir.

3.2.4.2. Bölümlendirme

Eğer açıklayıcı değişkenlerin sayısı az ve bu değişkenler sadece birkaç değer alıyorsa toplam çıktıyı tahmin etmek için örneklem kullanmaya gerek yoktur. Her bir alternatifin temsilci faydasına 2 değişken eklendiğinde ve bu değişkenlerden ilkinin 4, ikincisinin 2 değişkenli olduğu varsayıldığında tercih olasılıkları karar vericilerin oluşturacağı 8 farklı bölüm arasında değişmektedir.

Araştırmacının her bir bölüm için yeterli sayıda verisi olduğunda toplam çıktı değişkenleri tahmin edilebilmektedir. Her bir bölüm için tercih olasılığı hesaplanıp; bu olasılıkların ağırlıklı ortalamaları alındığında i.inci alternatifi tercih eden kişi sayısı tahmin edilebilmektedir:

$$\hat{N}_i = \sum_{b=1}^8 w_b P_{bi} .$$

(3.20)

Burada P_{bi} bölüm b'deki bir karar vericinin i.inci alternatifi tercih etme olasılığı ve w_b de bu olasılığın ağırlığıdır.

3.2.5 Ön Kestirim

Gelecek yıllara ait ön kestirimlerde de toplam değişkenler için Kesim 3.6'da açıklanan yöntemler uygulanmaktadır. Fakat ön kestirim yönteminde dışsal faktörler ve ağırlıklar zaman içinde kestirilen değişiklikleri yansıtmaktadır. Örneklemin sıralanmasında ise örneklem gelecek yıllara uygulanabilir şekilde düzenlenmektedir. Beş yıl sonra istenilen bir alternatifi tercih edecek kişi sayısı tahmin edilmek istendiğinde içinde bulunulan yıla ait verilerden oluşan bir örneklem oluşturulmaktadır. Örneklem bu beş yıl içerisinde sosyodemografik ya da diğer faktörlerde görülecek değişiklikleri yansıtacak şekilde düzenlenmektedir. Örneklem ya örneklenen her bir karar vericiyle ilişkilendirilmiş değişkenlerin değeri değiştirilerek (hane haklının toplam gelirini beş yıl sonraki duruma göre düzenlemek

gibi) ya da anakitledeki karar vericilerin zaman içerisindeki değişikliklerini yansıtmak için her bir karar vericiyle ilişkilendirilen ağırlık değiştirilerek (zaman içerisinde hane halkındaki sayı değişikliklerini yansıtmak için bir kişilik hane halkına daha yüksek ağırlık vermek gibi) düzenlenmektedir.

Bölümlendirme yaklaşımı için zaman içerisinde açıklayıcı değişkenlerde oluşacak değişiklikler her bir bölümdeki karar vericilerin sayısındaki değişiklikler tarafından açıklanmaktadır. Açıklayıcı değişkenlerin kendileri lojistik olarak düzenlenememektedir. Çünkü açıklayıcı değişkenlerin farklı değerleri her bir bölümü açıklamaktadır. Bir bölümdeki karar vericiyle ait olan değişkenleri değiştirmek, ancak karar vericinin bölümünü değiştirmektedir (Train, 2002).

3.2.6. Sabitlerin Yeniden Düzenlenmesi

Kesikli tercih modellerinde alternatif-spesifik sabitler gözlenmemiş faktörlerin ortalama etkisini göstermek için modele eklenmektedirler. Ön kestirimde ise bu sabitler gözlenmemiş faktörlerin ön kestirim alanı ya da zamanı için farklı olduğunu gösterecek şekilde düzenlenmektedirler. Ön kestirim yapılan alandan elde edilen pazar payı verileri sabitlerin yeniden düzenlenmesi için kullanılmaktadır. Bu yeniden düzenlenen model de açıklayıcı değişkenlerdeki değişikliklerden kaynaklanan pazar payları değişikliklerini kestirmek için kullanılmaktadır. Sabitlerin yeniden düzenlenmesini aşağıdaki eşitlik üzerinden açıklandığında,

$$\alpha_i^1 = \alpha_i^0 + \ln(S_i / \hat{S}_i^0)$$

(3.21)

elde edilir. Burada i.inci alternatif için α_i^0 tahmin edilen alternatif-spesifik sabit, S_i ise karar vericilerin temel yıldaki payları olduğu farz edilmektedir. “0” üst simgesi ise başlangıç değerini ifade etmektedir. Uygun kesikli tercih modeli kullanılarak ön kestirim alanındaki karar vericilerin payları kestirilmekte ve bu paylar $\hat{S}_i^0 \forall i$ olarak sınıflandırılmaktadır. Kestirilen paylarla asıl paylar karşılaştırılmaktadır. Eğer bir alternatif için asıl pay kestirilen paydan fazla ise sabit yükseltilmekte; tersi durumda da düşürülmektedir. Böylece yeni sabitlerle paylar tekrar kestirilmekte ve asıl

paylarla karşılaştırılmaktadır. Bu işlem kestirilen paylar asıllara en yakın şekilde oluncaya kadar sürdürülmektedir. Son olarak elde edilen bu sabitler karar vericilerin tercihini etkileyen gözlenen faktörlerdeki değişikliklerden kaynaklanan temel yıl paylarındaki değişiklikleri kestirmek için kullanılmaktadır.

4. KESİKLİ TERCİH MODELLERİ

4.1. İKİLİ TERCİH MODELLERİ

İki düzeyli kesikli tercih modeline göre bireyin karşı karşıya bulunduğu ölçülemeyen tercih alternatifleri vardır ve birey kendisi için en yüksek faydayı sağlayan alternatifi tercih etmektedir. Modelin temel amacı karar biriminin iki alternatif arasındaki tercih olasılığını belirlemesidir.

İkili modeller, tercih kolaylığı ve üstesinden gelinebilecek problemlerin varlığı nedeniyle birçok amaç için kullanılmaktadır.

Bireyin iki düzeyli durumda alternatifleri U_{i1} ve U_{i2} olduğunda $U_{i1} > U_{i2}$ ise birey 1. alternatifi tercih etmektedir. Bu tercih değerlerinin açıklayıcı değişkenlerin doğrusal bir fonksiyonu olduğu düşünüldüğünde,

$$\begin{aligned} U_{i1} &= \sum a_{k1} x_{ik} + \varepsilon_{i1} \\ U_{i2} &= \sum a_{k2} x_{ik} + \varepsilon_{i2} \end{aligned} \quad (4.1)$$

şeklini almaktadır. ε_i 'ler açıklanamayan hata terimlerini ifade etmektedir. Tercihler arasındaki farka Y_i^* denildiğinde,

$$U_{i1} - U_{i2} = Y_i^* = \sum (a_{k1} - a_{k2}) x_{ik} - (\varepsilon_{i2} - \varepsilon_{i1}) \quad (4.2)$$

olmaktadır. İfadeyi basitleştirmek için $b_k = a_{k1} - a_{k2}$ ve $w_i = (\varepsilon_{i2} - \varepsilon_{i1})$ eşitlikleri kullanıldığında,

$$Y_i^* = \sum b_k x_{ik} - w_i = Z_i - w_i \quad (4.3)$$

elde edilmektedir. Y_i^* değerinin 0'dan büyük olması halinde 1. alternatif tercih edilmektedir. Bireyin 1. alternatifi tercih etme olasılığı $P(Y_i^* > 0)$ olarak ifade edilebilmektedir. w_i 'nin olasılık dağılımı belli ise i.inci bireyin 1. alternatifi tercih etme olasılığı bulunabilmektedir. Bugüne kadar yapılan çalışmalarda w_i 'nin olasılık dağılımının en çok tekdüze, lojistik ve normal dağılımlara uyduğu ortaya çıkarılmıştır. İkili tercih modellerinde modeli oluşturabilmek için doğrusal olasılık modeli, probit modeli ve logit model gibi çeşitli olasılıklı fonksiyon kalıpları kullanılmaktadır.

4.1.1. Doğrusal Olasılık Modeli

Doğrusal olasılık modeli (DOM) kavramında bağımlı değişken, klasik regresyon modelinden farklı olarak 0 ya da 1 değerini alan bir kukla değişkendir. DOM açıklanamayan hata terimlerinin tekdüze dağıldığı kabul edilerek elde edilmektedir. Bu nedenle DOM'a "Tekdüze Dağılım" adı da verilmektedir (Goldfeld ve Quandt, 1972).

Tercih değerleri gözlemlenemediği için Y_i^* 'de gözlemlenememektedir. Gözlenen değer 1 ya da 0 değerlerini alan Y_i 'dir. Y_i^* ile Y_i arasındaki ilişki şöyle ifade edilmektedir:

$$\begin{aligned} Y_i^* > 0 \text{ ise } Y_i &= 1, \\ Y_i^* < 0 \text{ ise } Y_i &= 0. \end{aligned} \quad (4.4)$$

$P(Y_i^*)$ 'nin çözümünden,

$$\begin{aligned} P(Y_i^*) &= P(U_{i1} - U_{i2}) \\ &= P\left(\left(\sum a_{k1}x_{ik} + \varepsilon_{i1}\right) - \left(\sum a_{k2}x_{ik} + \varepsilon_{i2}\right)\right) \\ &= P\left(\sum (a_{k1} - a_{k2})x_{ik} + (\varepsilon_{i1} - \varepsilon_{i2})\right) \\ &= P\left(\sum b_k x_{ik} - w_i\right) \\ &= P(Z_i - w_i) \end{aligned} \quad (4.5)$$

elde edilmektedir. Bu durumda bireyin 1. alternatifi tercih etme olasılığı,

$$P(Y_i = 1) = P(Y_i^* > 0) = P(Z_i > w_i) \quad (4.6)$$

olmaktadır. Bu olasılığın hesaplanması için w_i 'nin olasılık dağılımının bilinmesi gerekmektedir. Olasılık dağılımı w_i 'nin (4.7)'deki gibi tanımlanan birikimli dağılım fonksiyonu ile elde edilebilmektedir.

$$P(Z_i > w_i) = \int_{-\infty}^{Z_i} f(w) \cdot dw \quad (4.7)$$

DOM'da bireyin 1. alternatifini tercih etme olasılığı aşağıdaki gibi tanımlanmaktadır.

$$P(Y_i = 1) = P_i = \sum b_k x_{ik}, \quad Y_i = 0, 1 \quad (4.8)$$

Y_i 'nin beklenen değeri ise aşağıdaki gibi gösterilmektedir.

$$E(Y_i) = 0(1 - P_i) + 1P_i \quad (4.9)$$

(4.8) ve (4.9) eşitlikleri birleştirildiğinde,

$$Y_i = \sum b_k x_{ik} + w_i, \quad Y_i = 0, 1 \quad (4.10)$$

yapısal modeli elde edilmektedir. DOM'da hata terimlerinin normal dağılmaması ve varyansının sabit olmaması nedeniyle Sıradan En Küçük Kareler (SEKK) yöntemi en iyi tahmin yöntemi değildir. Çünkü w_i binom dağılım göstermektedir. Yeterince büyük örneklerde ise merkezi limit teoremine göre gözlem sayısı arttıkça hata terimlerinin normal dağıldığı kabul edildiğinden SEKK ile tahmin yapılabilmektedir. Bu durumda w_i 'nin varyansı,

$$\begin{aligned} Var(w_i) &= E(w_i^2) = (-Z_i)^2 \cdot (1 - P_i) + (1 + Z_i)^2 \cdot P_i \\ &= \left(\sum b_k x_{ik} \right) \left(1 - \sum b_k x_{ik} \right) \end{aligned} \quad (4.11)$$

şeklinde ifade edilmektedir. SEKK tahmin edicileri değişen varyans sorunundan dolayı en iyi tahmin edici değildirler. Değişen varyans problemini ortadan kaldırmak için Tartılı En Küçük Kareler Yöntemi (TEKK) kullanılabilir (Gujarati, 1988).

Bir diğer sorun ise ortaya çıkabilecek anlamsız tahminlerdir. b_k ile x_{ik} $-\infty - +\infty$ arasında değiştiği için P_i 'nin SEKK tahminleri 0'dan küçük ya da 1'den büyük değerler alabilmektedir. Bu durumda 0'dan küçük değerler 0'a, 1'den büyük değerler 1'e yuvarlanabilmektedir. Fakat bu pek gerçekçi bir yaklaşım değildir.

$P_i = \sum b_k x_{ik}$ denkleminde görüldüğü üzere P_i ile x_{ik} arasında doğrusal bir ilişki vardır. Yani x_{ik} 'ların P_i üzerindeki marjinal etkisi sabittir. x_{ik} arttıkça P_i de artmakta, ancak 0 – 1 aralığının dışına çıkmamaktadır. x_{ik} 'nin küçük ve büyük değerlerinde P_i 'deki değişim nispeten yavaş olmalı ve P_i 0 ve 1'e giderek küçülen oranlarda yaklaşmalıdır (Aldrich ve Nelson, 1990). Bu koşulları probit ve logit olasılık modelleri sağlamaktadır.

4.1.2. Probit Model

Probit terimi “Olasılık Birimi” (Probability Unit) teriminin kısaltılmış şeklidir. Bütün doğrusal olmayan olasılık modelleri arasında en eski olanıdır.

Doğrusal olasılık modelindeki kısıtlamalar araştırmacıları hataların dağılımının daha uygun gösterimlerini araştırmaya yönlendirmiştir. Merkezi limit teoremine göre hataların dağılımı normal dağılıma uymaktadır. Probit modeli w_i 'nin normal dağıldığı varsayımı ile elde edilmektedir. $w_i = (\varepsilon_{i1} - \varepsilon_{i2})$ 0 ortalama ve $\sigma_1^2 + \sigma_2^2 - 2\sigma_{12} = \sigma^2$ varyansı ile normal dağılmaktadır. $P_i = P(Y_i = 1) = P(Z_i > w_i)$ denkleğinden,

$$P_i = F(Z_i) = \int_{-\infty}^{Z_i} \frac{1}{\sqrt{2\pi\sigma}} \exp\left[-\frac{1}{2}\left(\frac{w}{\sigma}\right)^2\right] dw, \quad \sigma > 0 \quad (4.12)$$

$$P_i = \phi\left(\frac{Z_i}{\sigma}\right) \quad (4.13)$$

elde edilmektedir. Burada $\frac{1}{\sigma}$ fayda fonksiyonunun ölçeğini, ϕ normal birikimli dağılım fonksiyonunu ifade etmektedir. $\frac{1}{\sigma}$ genelde 1 olarak ele alınmaktadır. Buradan hareketle,

$$P_i = \phi(Z_i) = \phi\left(\sum a_{k1}x_{ik} - \sum a_{k2}x_{ik}\right) \quad (4.14)$$

elde edilmektedir. Probit eğrisi $-\infty$ 'da 0'a, ∞ 'da 1'e yakınsamakta ve 0-1 aralığı dışına çıkmamaktadır.

Doğrusal olasılık modelinin aksine probit modelde hata terimlerinin beklenen değeri $E(w_i)$ 0 değildir ve x_{ik} 'ların bir fonksiyonudur.

$$w_i = Y_i - Z_i \quad (4.15)$$

$$E(w_i) = E(Y_i) - \sum b_k x_{ik} \quad (4.16)$$

$$E(w_i) = \phi(Z_i) - Z_i \neq 0 \quad (4.17)$$

x_{ik} 'nin P_i üzerindeki marjinal katkısı DOM'da olduğu gibi sabit değildir. Bu katkıyı bulmak için P_i 'nin x_{ik} 'ye göre kısmi türevi alınmaktadır.

$$\begin{aligned} \frac{\partial P_i}{\partial x_{ik}} &= \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{Z_i^2}{2}\right) b_k \\ &= \phi(Z_i) b_k \end{aligned} \quad (4.18)$$

x_{ik} 'nin P_i üzerindeki marjinal katkısı, b_k ile çarpılan ve düzeltme faktörü olarak adlandırılan $\phi(Z_i)$ 'ye de bağlıdır. x_{ik} 'nin P_i üzerindeki marjinal katkısında diğer

açıklayıcı değişkenler de rol aldığı için bu katkının açıklanması biraz sorunludur. Bu amaçla farklı x_{ik} değerlerinde bu katkıları gösteren tabloların ya da grafiklerin kullanılması faydalı olmaktadır.

4.1.3. Logit Model

Logit terimi Lojistik Olasılık Birimi (Logistic Probability Unit) teriminin kısaltılmış şeklidir. Bu model kümülatif lojistik olasılık fonksiyonuna dayanmakta ve aşağıdaki gibi tanımlanmaktadır.

$$P_i = P(Y_i = 1) = F(Z_i) = \frac{\exp(Z_i)}{1 + \exp(Z_i)} \quad (4.19)$$

Bilindiği gibi ikili logit modeli $w_i = \varepsilon_{i1} - \varepsilon_{i2}$ 'nin lojistik dağıldığı varsayımından elde edilmektedir. Kümülatif normal dağılımın integral içeren hesaplamalara oranla lojistik fonksiyonla yapılan hesaplamalar oldukça kolaydır. Bu dağılımın ortalaması 0, standart sapması ise $\pi / \sqrt{3}$ 'dür. Logit modeli de probit modeli gibi doğrusal olmayan bir modeldir ve Z_i , $-\infty$ ile $+\infty$ arasında, P_i ise 0 ile 1 arasında değerler almaktadır. Logit model probit modelinin aksine gerekli düzenlemeler yapılarak kolaylıkla doğrusallaştırılabilmektedir.

$$\ln\left(\frac{P_i}{1-P_i}\right) = Z_i \quad (4.20)$$

şeklinde model doğrusallaştırılmaktadır. Bahis oranı denilen $\left(\frac{P_i}{1-P_i}\right)$ oranının logaritması ise açıklayıcı değişkenlerin doğrusal bir fonksiyonudur.

$$L_i = \ln\left(\frac{P_i}{1-P_i}\right) = Z_i = \sum b_k x_{ik} \quad (4.21)$$

L 'ye logit denilir ve bu fonksiyon hem x_{ik} 'ya hem de anakitle katsayılarına göre doğrusaldır. Logit modeldeki açıklayıcı değişkenin P_i üzerindeki marjinal katkısını bulmak için, P_i 'nin açıklayıcı değişkene göre kısmi türevi alındığında,

$$\begin{aligned}\frac{\partial P_i}{\partial x_{ik}} &= \frac{\exp(Z_i)}{1 + \exp(Z_i)} \frac{1}{1 + \exp(Z_i)} b_i \\ &= P_i(1 - P_i)b_k\end{aligned}\quad (4.22)$$

elde edilmektedir. Logit modelde de probit modele benzer olarak b_k ile birlikte düzeltme faktörü $P_i(1 - P_i)$ rol almaktadır. Düzeltme faktörü pozitif olduğundan etkinin yönünü b_k belirlemektedir.

Kümülatif lojistik dağılımın eğimi $P = 1/2$ noktasında en yüksek değeri almaktadır. Bu da bağımsız değişkendirdeki değişimin olasılık değeri üzerindeki etkisinin dağılımının orta noktasında en büyük değeri aldığını göstermektedir. Çok düşük eğimler ise dağılımın uç noktasında yer almaktadır.

Normal dağılım ve lojistik dağılımın eğrileri birbirine benzemektedir. Normal dağılımın varyansı 1, lojistik dağılımın varyansı ise $\pi^2/3$ 'dür. Ancak yüksek sayıda örneklem ile çalışıldığında eğrilerin kuyruk kısımlarında farklılaşma görülmektedir. Bu durumda dahi olasılık değerleri arasındaki fark 0.02'yi geçmemektedir (Aldrich ve Nelson, 1990). Ayrıca lojistik dağılım 7 serbestlik derecesinde t dağılımını andırmakta iken normal dağılım sonsuz serbestlik derecesinde t dağılımlıdır (Gujarati, 1988).

İkili logit modelde lojistik dağıldığı varsayılan $w_i = \varepsilon_{i1} - \varepsilon_{i2}$ 'nin dağılım fonksiyonu,

$$F(w) = \frac{1}{1 + e^{-\mu w}}, \quad \mu > 0, \quad -\infty < w_i < +\infty \quad (4.23)$$

ve olasılık yoğunluk fonksiyonu,

$$f(w) = \frac{\mu e^{-\mu w_i}}{(1 + e^{-\mu w_i})^2} \quad (4.24)$$

şeklinde tanımlanmaktadır. Burada μ pozitif ölçek parametresidir. w_i 'nin lojistik dağıldığı varsayımı altında $\mu = 1$ alındığında 1. alternatifin tercih edilme olasılığı (4.25)'deki eşitliğe dönüşmektedir.

$$\begin{aligned} P(Y_i = 1) &= P(Y_i^* > 0) = P(Z_i > w_i) \\ &= \frac{1}{1 + e^{\mu Z_i}} = \frac{e^{\mu \sum a_{k1} x_{ik}}}{e^{\mu \sum a_{k1} x_{ik}} + e^{\mu \sum a_{k2} x_{ik}}} \end{aligned} \quad (4.25)$$

Probit ve logit modellerde tahmin yöntemi genellikle En Yüksek Olabilirlik (EYO) yöntemidir. EYO'nun tahmin yöntemi olarak tercih edilmesinin nedeni istatistiksel analizde tüm bilgilerin kullanılmasının amaçlanmasıdır. EYO yönteminde bu yapılar olabilirlik fonksiyonunda yer aldığı için birer bilgi olarak kullanılmaktadır. Bu durum diğer tahmin yöntemleri için geçerli değildir (Aldrich ve Nelson, 1990). Probit ve logit modellerinin EYO tahminlerinin sapmasız ve etkin olabilmeleri için aşağıdaki koşulların gerçekleşmesi gerekmektedir (Anas, 1983):

- Anakütledeki tüm bireylerin tercih fonksiyonları aynıdır ve bu fonksiyon bireye ve alternatiflere ait açıklayıcı değişkenlerin doğrusal fonksiyonudur.
- Tercih fonksiyonunun katsayıları bireyler arasında farklılık göstermez.
- Birey, tercih kümesi içinde her zaman faydasını en büyük yapan alternatifi tercih eder.
- Y_i , yalnızca 0 ve 1 değerlerini alır.
- Y dizisinde ardışık bağımlılık yoktur.
- Açıklayıcı değişkenler arasında ilişki yoktur.
- EYO mümkün olduğunca büyük örneklemelere uygulanmalıdır.

4.2. ÇOKLU TERCİH MODELLERİ

Alternatiflerin sayısının ikiden fazla olduğu durumlarda bireyin tercih davranışını açıklamak için çok düzeyli olasılık modelleri kullanılmaktadır. Model, kesikli bağımlı değişkenler ile alternatifleri açıklamaktadır. Alternatif (düzey) sayısı $m+1$ ise Y_{ij} 'de j değeri $j=0,1,2,\dots,m$ değerlerini almaktadır. Bağımlı değişken ikili gruplara ayrılarak incelenmektedir. Y_i j değerlerinden birini aldığı anda $Y_{ij} = 1$, başka değerler aldığı anda ise $Y_{ij} = 0$ olmaktadır. Böylece çoklu tercih modeli $m+1$ tane iki düzeyli denklemlerden oluşmaktadır. w_i 'nin tek değişkenli dağılımını belirtmek kolay değildir. Bunun yerine bütün hata terimlerinin birleşik dağılımı kullanılmaktadır.

Çok durumlu tercih modellerinin en basiti çok durumlu doğrusal olasılık modelidir. Doğrusal olasılık modelleri klasik regresyon modellerine çok benzese de bu modellerin bağımlı değişkeninin nitel olmasından dolayı çözüm teknikleri farklıdır. Düzey sayısı arttıkça bireyin tercih davranışını açıklamak zorlaşmaktadır. Bu amaçla kullanılan çok sayıda çok düzeyli model bulunmaktadır. Birçok durumda doğrusal olasılık modelleri yetersiz kalmakta ve çok terimli logit ya da probit gibi doğrusal olmayan modeller kullanılmaktadır (Greene, 1997).

4.2.1. Çokterimli Logit Model

Çokterimli logit modeller nominal kategorik cevap değişkenlerinin analizinde yaygın olarak kullanılan yöntemlerden biridir. Bu modelin binominal logit modelin doğal bir genelleştirmesi olması, gruplandırılmış veride loglinear modelin bir benzeri olması ve ayrıca birçok istatistik paket programında bu analizin yapılabilir olması bu modelin sık kullanılmasına neden olmaktadır (Power ve Xie, 2000). Yani çokterimli logit modeli çok düzeyli modeller içerisinde en basit yapıya sahip olan ve kullanımı en çok tercih edilen modeldir.

Mc Fadden (1974)'e göre çok terimli tercih modelleri AS yaklaşımı ile elde edilebilmektedir. Bu yaklaşıma göre birey kendi yararını maksimize eden alternatifi tercih etmektedir.

Bu model ikili logit modelin ikiden fazla durum için genişletilmiş şeklidir. $U_{ij} = Z_{ij} + \varepsilon_{ij}$ şeklinde ifade edilen çokterimli logit modeli rastlantısal bir fayda modelidir. Z_{ij} faydanın deterministik kısmını, ε_{ij} ise tesadüfi kısmını ifade etmektedir. ε_{ij} 'nin normal dağılımın bir yaklaşımı olan Gumbel dağıldığı kabul edilmektedir.

α ve β olmak üzere iki parametresi bulunan Gumbel dağılımı normal dağılımın bir yaklaşımıdır. β parametresi doğrudan tahmin edilemediği için bire eşit kabul edilmektedir (Akın, 2002). Gumbel dağılımının minimum olasılık fonksiyonu,

$$f(x) = \frac{1}{\beta} \exp\left[\frac{x-\alpha}{\beta}\right] \exp\left[-e^{\frac{x-\alpha}{\beta}}\right] \quad (4.26)$$

şeklinde gösterilmektedir. Standart Gumbel dağılımında $\alpha = 0$ ve $\beta = 1$ olarak tanımlanmaktadır ve denklem,

$$f(x) = \exp(x) \exp(-e^{-x}) \quad (4.27)$$

eşitliğine dönüşmektedir. Gumbel dağılımının maksimum olasılık fonksiyonu ise aşağıdaki gibidir.

$$f(x) = \frac{1}{\beta} \exp\left[-\frac{x-\alpha}{\beta}\right] \exp\left[-e^{-\frac{x-\alpha}{\beta}}\right] \quad (4.28)$$

Standart gumbel dağılımı,

$$f(x) = \exp(-x) \exp(-e^{-x}) \quad (4.29)$$

olarak ifade edilmektedir. Gumbel dağılımının maksimum ve minimum kümülatif dağılım fonksiyonları sırasıyla aşağıdaki eşitliklerde tanımlandığı gibidir.

$$F(x) = 1 - \exp(-e^{-e^x}) \quad (4.30)$$

$$F(x) = \exp(-e^{-e^x}) \quad (4.31)$$

Logit modeli ε_i 'nin tüm i değerlerinin iid ekstrem değer olduğu varsayımı altında elde edilmektedir. Bu varsayım kısıtlayıcı olmasına rağmen tercih olasılığı için çok uygun bir durum sağlamaktadır. Logit modelin kullanımı bu varsayımın uygunluğuna bağlıdır. Ancak bağımsızlık varsayımı bazı durumlarda uygun olmayabilmektedir. Bir alternatifte ilişkin gözlenmemiş faktörler, diğer alternatifte ilişkin gözlenmemiş faktöre benzeyebilmektedir. Logit modelde ise her bir alternatifin diğerlerinden bağımsız olduğu varsayılmaktadır (Train, 2002).

Çokterimli logit model,

$$P(Y_i = j) = \frac{\exp(x_i \beta_j)}{\sum_{k=1}^J \exp(x_i \beta_k)} \quad (4.32)$$

şeklinde tanımlanmaktadır. Burada Y_i , i .nci birey için bağımlı değişken, x_i bağımsız değişken vektörü, j ise tercih kümesindeki alternatiflerin sayısıdır. β_j , j alternatifinin tercihinde bağımsız değişken vektörünün katkısını ölçerken β_k bağımsız değişken vektörü k 'nin tercih edilme olasılığına katkısını ölçmektedir. Bağımsız değişken vektörü, X_i , karar vericinin değişmeyen özelliklerini temsil etmektedir. Bu nedenle modelde simge olarak j bulunmamaktadır.

3 düzeyli durum için tercih değerleri U_{i0} , U_{i1} , U_{i2} olarak alındığında ve tercih değerlerinin bireye ve alternatifte ait açıklayıcı değişkenlerin doğrusal bağımlısı olduğu kabul edildiğinde tercih değerleri aşağıdaki gibi gösterilebilmektedir.

$$\begin{aligned} U_{i0} &= \sum a_{0k} x_{ik} + \varepsilon_{i0} = Z_0 + \varepsilon_{i0} \\ U_{i1} &= \sum a_{1k} x_{ik} + \varepsilon_{i1} = Z_1 + \varepsilon_{i1} \\ U_{i2} &= \sum a_{2k} x_{ik} + \varepsilon_{i2} = Z_2 + \varepsilon_{i2} \end{aligned} \quad (4.33)$$

Bireyin ikinci alternatifi tercih etmesi ancak $U_{i2} > U_{i1}$ ve $U_{i2} > U_{i0}$ ile gerçekleşmektedir. 2. alternatifin tercih edilme olasılığı ise aşağıdaki eşitlikte gösterildiği gibidir.

$$\begin{aligned}
P(Y_i = 2) &= P(Y_{i2} = 1) = P(U_{i2} > U_{i1}, U_{i2} > U_{i0}) \\
&= P(\varepsilon_2 + Z_2 - Z_1 > \varepsilon_1, \varepsilon_2 + Z_2 - Z_0 > \varepsilon_0) \\
&= \int_{-\infty}^{\infty} f(\varepsilon_2) \left[\int_{-\infty}^{\varepsilon_1 + Z_2 - Z_1} f(\varepsilon_1) d\varepsilon_1 \int_{-\infty}^{\varepsilon_2 + Z_2 - Z_0} f(\varepsilon_0) d\varepsilon_0 \right] d\varepsilon_2
\end{aligned} \tag{4.34}$$

(4.3) eşitliğinde integral fonksiyonunun çözülebilmesi için ε_2 , ε_1 ve ε_0 artık terimlerinin birbirinden bağımsız olması ve olasılık yoğunluk fonksiyonu $\exp(-e^{-\varepsilon})$ 'nin verilmesi gerekmektedir (McFadden, 1981). Bu dağılım “1. tip Ekstrem Değer” ya da log Weibull dağılımlıdır (Amemiya, 1981). Hata terimlerinin birbirinden bağımsız olması ve $\exp(-e^{-\varepsilon})$ değerinin verilmesi halinde fonksiyonun çözümü şöyle olmaktadır:

$$\begin{aligned}
P(Y_i = 2) &= \int_{-\infty}^{\infty} e^{-\varepsilon_2} \exp(-e^{-\varepsilon_2}) \exp(-e^{-\varepsilon_2 - Z_2 + Z_1}) \exp(-e^{-\varepsilon_2 - Z_2 + Z_1}) d\varepsilon_2 \\
&= \frac{e^{Z_2}}{e^{Z_0} + e^{Z_1} + e^{Z_2}}.
\end{aligned} \tag{4.35}$$

Alternatiflere ait tercih edilme olasılıkları ayrı ayrı gösterilmek istendiğinde ise aşağıdaki eşitlikler ile ifade edildiği gibidir.

$$P(Y_i = 2) = \frac{\exp(Z_2)}{\sum_{j=0}^2 \exp(Z_j)}, \tag{4.36}$$

$$P(Y_i = 1) = \frac{\exp(Z_1)}{\sum_{j=0}^2 \exp(Z_j)}, \tag{4.37}$$

$$P(Y_i = 0) = \frac{\exp(Z_0)}{\sum_{j=0}^2 \exp(Z_j)} = 1 - [P(Y_i = 2) + P(Y_i = 1)]. \quad (4.38)$$

Çokterimli logit modelin iki zayıf özelliği vardır. İlk olarak, hata terimlerinin olasılık dağılımları için kabul edilen log Weibull dağılımı keyfi seçilmiş bir dağılımdır. Bu dağılımın bireyin gösterdiği tercih eylemi ile kuramsal bir bağlantısı yoktur (Aldrich ve Nelson, 1990). Diğer zayıf özelliği ise ε_j 'lerin birbirinden bağımsız olması kabulüdür. Bu kabul bağımlı değişkenin düzeylerini oluşturan alternatiflerin birbirinden bağımsız ve ayrık olmalarını gerektirmektedir. Alternatiflerin birbirine benzer ya da ortak yönleri olmamalıdır (Börch-Supan, 1987). Bu zayıflıklar nedeniyle çok terimli logit modeli yerine zaman zaman çok terimli probit modeller tercih edilmektedir.

4.2.2. Çokterimli Probit Model

Logit modelin ilişkisiz alternatiflerin bağımsızlığı özelliğine bağlı olarak kısıtlayıcı kalıplar ortaya koymasından dolayı birçok uygulamada çokterimli logit model yerine çokterimli probit model tercih edilmektedir. Probit model logit modelin kısıtlarına esneklik getirerek nitel tercih modelleri için alternatif bir seçenek sunmaktadır. Probit model bir çok durumda normal dağılımın rastlantısal unsurlarının uygun temsilini sağlamakla birlikte bazı durumlarda normal dağılım uygun olmamaktadır. Log normal de olduğu gibi 0'ın sadece bir tarafında dağılımların kullanılması dağılımın pozitif olması gerektiği gerçeğiyle örtüşmesi açısından daha uygundur.

Birçok uygulama alana sahip olan iki durumlu probit model, biyometride kapsamlı bir şekilde kullanılmaktadır. Çok değişkenli model ise, Bock ve Jones (1968), Mc Fadden (1976), Hausman ve Wise (1978), Daganzo (1980), Manski ve Lerman (1981) ve Mc Fadden (1981) tarafından incelenmiştir (Train, 2002).

Logit ve nested logit modellerde ölçek ve seviyelerin normalizasyonu hata terimlerde yerleştirilmiş olan dağılımsal varsayımlarla birlikte kendiliğinden ortaya çıkmaktadır. Probit modelde bu normalizasyon kendiliğinden ortaya çıkmamaktadır. Araştırmacı modeli doğrudan normalize etmelidir. Modelin normalizasyonu

parametrenin belirlenmesine bağlıdır. $U_{ij} = Z_{ij} + k + \varepsilon_{ij}$ eşitliğinde k belirlenmemiş parametre örneğidir. Bu yolla tanımlanan faydayı ölçmek için k 'yı tahmin etmek mümkün olmamaktadır. Karar vericinin davranışı k tarafından etkilenmediğinden bu değer karar vericinin tercih ettiği alternatiflerden elde edilmektedir. Yani karar vericinin davranışını doğrudan etkilemeyen parametreler tahmin edilememektedir (Train,2002).

Probit modelin bir kısıtlaması ise ε_i hata değerlerinin çok değişkenli normal dağılıma sahip olmasıdır. Bu durum modelin hesaplamasında çoklu integral çözümü gerektirdiğinden en fazla 3 ya da 4 alternatif için probit model uygulanabilmektedir.

Çok terimli probit modeli AS yaklaşımı ile elde edilebilmektedir. 3 düzeyli bir durum için 3.üncü alternatifin tercih edilme olasılığı şöyle tanımlanmaktadır:

$$P(Y_i = 2) = P(U_{i2} > U_{i1}, U_{i2} > U_{i0}) \quad (4.39)$$

$$= \int_{-\infty}^{\infty} \int_{-\infty}^{U_{i2}} \int_{-\infty}^{U_{i2}} f(U_{i0}, U_{i1}, U_{i2}) dU_{i0} U_{i1} U_{i2}$$

f 3'lü değişen normal yoğunluk fonksiyonudur. Çok terimli probit modelin hesap maliyeti yüksektir ve düzey sayısı arttıkça model karmaşıklaşmakta ve çözümü zorlaşmaktadır. Sayısal integrasyon dört düzeyli modele kadar elverişlidir. Çözüm daha yüksek düzeyli modellerde kontrolden çıkmaktadır (Börch-Supan, 1987).

İkili probit modeli hataların 0 ortalama ve $J \times J$ boyutlu varyans-kovaryans matrisiyle çok değişkenli normal dağıldığı varsayımı altında oluşturulmuştur. Çok durumlu probit modelin tahmini için en yüksek olabilirlik yöntemi kullanılmaktadır. Tercih olasılıklarının elde edilebilmesi için $J_n - 1$ boyutlu integralin çözümü gerekmektedir. $J \geq 3$ için olasılıkların tahmin edilmesi çok durumlu logit modeli için uygulanan yöntem ile karşılaştırılabilmektedir. Ancak genellikle büyük veri kümelerinde $j \geq 5$ ve Ω kısıtlanmış ise olasılıkları elde etmek için tekrarlanan olasılık maksimizasyonunun tahmin süreci zor ve masraflıdır. Bir başka karmaşıklık da çok durumlu probit modelinin Hessian matrisinin negatif tanımlı olduğunun

bilinmemesidir. Dolayısıyla ikincil maksimayı önlemek için bir araştırma gerekmektedir (McFadden, 1978).

Çokterimli probit modelleri yakın zamana kadar çoklu normal integrallerin hesaplamaları ile ilişkili teknik konular nedeniyle çoğu araştırmacı için pratikte kullanılması zor olmuştur (Powers ve Xie, 2000). Problemin çözümündeki en önemli nokta modeldeki alternatif sayısıdır. Bilgisayar algoritmalarının dizaynında yapılan geliştirmeler ve bu modellerin standart istatistiksel paketlerde yer alması şimdilerde bu modelleri daha uygulanabilir yapmıştır.

4.2.3. Sıralı Logit Model

Sıralı nitel bağımlı değişkenleri açıklamak için oluşturulan bu modelde temel amaç tercih olasılığını belirlemek ve bir karar vericiye ait özellikler ile belirli bir tercihte bulunma olasılığı arasındaki ilişkiyi incelemektir.

Sıralı logit modelinde tercih kavramı, her biri mevcut değeri kabul etme ya da bir sonrakini kabul etme kararını içeren, ikili kararlar dizisinin bir sonucu olarak ele alınmaktadır. Bu durumda karar verici ilk yerel minimuma ulaştığında durmaktadır. Sıralı logit modelde i.inci alternatife ulaşıldığında bir sonraki alternatife ilerlemenin faydası U_{in}^C , durmanın faydası ise U_{in}^S şeklinde gösterilmektedir. Birey n tarafından i.inci alternatifin tercih edilme olasılığı,

$$P_n(i) = \Pr\left(U_{1n}^C \geq U_{1n}^S \cap U_{2n}^C \geq U_{2n}^S \cap \dots \cap U_{(i-1)n}^C \geq U_{(i-1)n}^S \cap U_{in}^S \geq U_{in}^C\right) \quad (4.40)$$

şeklindedir. $U_{in}^C - U_{in}^S$ fayda farklarının hata terimlerinin bağımsız lojistik dağıldığı varsayıldığında i.inci alternatifin tercih edilme olasılığı aşağıdaki eşitlikte verildiği gibidir.

$$\begin{aligned}
P_n(i) &= P(V_{1n}^C + \varepsilon_{1n}^C \geq V_{2n}^S + V_{2n}^S \cap \dots \cap V_{in}^S + \varepsilon_{in}^S \geq V_{in}^C + \varepsilon_{in}^C) \\
&= P(\varepsilon_{1n}^S - \varepsilon_{1n}^C \leq V_{1n}^C - V_{1n}^S \cap \dots \cap \varepsilon_{in}^C - \varepsilon_{in}^S \leq V_{in}^S - V_{in}^C) \\
&= \left(\frac{1}{1 + e^{-\left(V_{in}^S - V_{in}^C\right)}} \right) \left(\frac{1}{1 + e^{-\left(V_{(i-1)n}^C - V_{(i-1)n}^S\right)}} \right) \dots \left(\frac{1}{1 + e^{-\left(V_{(i-1)n}^C - V_{(i-1)n}^S\right)}} \right) \\
&= \left(\prod_{j=1}^{i-1} \frac{1}{1 + e^{-\left(V_{jn}^C - V_{jn}^S\right)}} \right) \left(1 - \frac{1}{1 + e^{-\left(V_{in}^C - V_{in}^S\right)}} \right)
\end{aligned} \tag{4.41}$$

Sıralı logit modelde hata terimleri lojistik dağılmaktadır. Sıralı logit modelde çok durumlu logit modelin aksine ilişkisiz alternatiflerin bağımsızlığı varsayımı geçerli değildir (Akın, 2002). Logitlerin hesaplanmasında keyfi bir referans düzeyi seçilmekte, referans değer belirtilmemiş ise ilk değer referans olarak alınmaktadır. Sıralı logit modelde ise kategorilerin birbirine paralel olduğu varsayıldığından alternatif olarak en büyük olan değer referans değeri olarak seçilmektedir. Sıralı logit modelin en zor yanı katsayıların yorumlanmasıdır. Literatürde katsayı tahminlerini yorumlamanın değişik yolları vardır. Bunlar; standartlaşmış katsayıları hesaplama, tahmin edilen olasılıkları hesaplama, tahmin edilen olasılıklardaki faktör değişimini hesaplama ve tahmin edilen olasılıklarda yüzde değişmeyi hesaplamadır (Emeç, 2002).

Bağımlı sıralı değişkenlerle kurulan modellerde doğrusal olmayan kalıplar kullanıldığından bu modellerin tahmini için çok durumlu logit modelde olduğu gibi EYO yöntemi kullanılmaktadır. Sıralı logit modeli w_i 'nin ortalaması 0 ve varyansı $\pi^2 / 3$ olan lojistik bir dağılım göstermektedir. Olasılık yoğunluk fonksiyonu,

$$f(\varepsilon) = \frac{\exp(\varepsilon)}{[1 + \exp(\varepsilon)]^2} \tag{4.42}$$

ve birikimli yoğunluk fonksiyonu ise,

$$F(\varepsilon) = \frac{\exp(\varepsilon)}{1 + \exp(\varepsilon)} \tag{4.43}$$

şeklinde tanımlanmaktadır. J alternatif için eşitlik aşağıdaki gibi olmaktadır.

$$G(Y_1, \dots, Y_j) = \sum_{j=1}^{j+1} \left(\frac{1}{2} Y_j^{1/\rho} + \frac{1}{2} Y_{j-1}^{1/\rho} \right)^\rho \quad (4.44)$$

(4.44) eşitliğinde $0 < \rho \leq 1$ iken $Y_0 = Y_{j+1} = 0$ olmaktadır. GEV modelinden elde edilebilen sıralı logit modeli için olasılıklar,

$$\begin{aligned} P_j &= F(\beta' X) \\ P_{j-1} &= F(\beta' X + \mu_1) - F(\beta' X) \\ P_{j-2} &= F(\beta' X + \mu_1 + \mu_2) - F(\beta' X + \mu_1) \end{aligned} \quad (4.45)$$

şeklinde bulunmaktadır. Bu denklemler,

$$\begin{aligned} P_j &= F(\beta' X) \\ P_j + P_{j-1} &= F(\beta' X + \mu_1) \\ P_j + P_{j-1} + P_{j-2} &= F(\beta' X + \mu_1 + \mu_2) \\ P_j + P_{j-1} + P_{j-2} + \dots + P_2 &= F(\beta' X + \mu_1 + \mu_2 + \dots + \mu_{j-2}) \end{aligned} \quad (4.46)$$

ve

$$P_j = 1 - F(\beta' X + \mu_1 + \mu_2 + \mu_3 + \dots + \mu_{j-2}) \quad (4.47)$$

anlamına gelmektedir. Burada $\mu_1 + \mu_2 + \mu_3 + \dots + \mu_{j-2} > 0$ olması gerekmektedir.

Sıralı logit modeller daha çok kalınacak yer araştırmasında ve ev halkı seyahatinin planlanmasında kullanılmaktadır. Bu modelin tek yönlü seyahatler yerine seyahat turlarının sıklık tahmininde de kullanıldığı görülmektedir. Amemiya (1981) ise sıralı logiti hane halkı tarafından alınan araba sayısı ve seyahat sayısı gibi sıralı kesikli alternatiflere uygulamıştır.

4.2.4. Sıralı Probit Model

Sıralı probit model, binomial probit modeldeki gibi aynı yolla görünmeyen (latent) bir regresyon denklem üzerine kurulur (Akın, 2002). Maksimum benzerlik yöntemi ile tahmin edilen sıralı probit modelde benzerlik fonksiyonu ve onun türevleri kolayca elde edilmektedir.

Sıralı logitten farklı olarak bu modelde, w_i 'nin ortalaması 0 ve varyansı σ^2 olan normal bir dağılım görülmektedir. Bu durumda n.inci birey tarafından i.inci alternatifin tercih edilme olasılığı aşağıdaki şekilde ifade edilmektedir.

$$\begin{aligned} P_n(i) &= \Phi(V_{1n}^C - V_{1n}^S) \Phi(V_{2n}^C - V_{2n}^S) \dots \Phi(V_{(i-1)n}^C - V_{(i-1)n}^S) \Phi(V_{in}^S - V_{in}^C) \\ &= \prod_{j=1}^{i-1} \Phi(V_{jn}^C + V_{jn}^S) \Phi(V_{in}^S - V_{in}^C) \end{aligned} \quad (4.48)$$

4.2.5. Genelleştirilmiş Ekstrem Değer Modeli

Genelleştirilmiş ekstrem değer (GEV) modeli çokterimli logit modele alternatif olarak sunulan bir modeldir. Yani çok terimli logit modelin genelleştirilmiş şeklidir. 1978 yılında McFadden tarafından geliştirilen bu model, çok terimli logit modelde ilişkisiz alternatiflerin bağımsızlığı varsayımının sınırlayıcı özelliğini aşabilmek için çok terimli logit modelden daha farklı modellere ihtiyaç duyulmasıyla ortaya çıkmıştır. GEV'de sınırsız sayıda model mümkün olmasına rağmen, şu anda az sayıda belirli modeller kullanılmaktadır.

GEV modellerinin temel özelliği tüm alternatifler için faydanın gözlenmemiş niteliklerinin GEV'de olduğu gibi ilişkili olarak dağılmasıdır. Bu dağılım alternatifler arasında korelasyonlara izin vermektedir ve standart logit modeller için kullanılan birinci tip ekstrem değer dağılımının genelleştirilmesidir. Bütün korelasyonlar 0 olduğunda GEV dağılımı bağımsız ekstrem değer dağılımının bir ürünü olur ve GEV modeli standart logit model olur. GEV modelleri sınıfı bu nedenle logit modeli içermektedir (Jackman, 2003).

$G(y_1, y_2, \dots, y_{j_n} \geq 0)$ aşağıdaki özelliklere sahip olan bir fonksiyondur:

- G negatif olmayan ($G > 0$) fonksiyon,
- G , $\mu > 0 > 0$ dereceden homojen,
- $\lim_{y_i \rightarrow \infty} G(y_1, y_2, \dots, y_{j_n}) = \infty$, ($i = 1, 2, \dots, J_n$),
- G^2 'nin y_i 'nin ($i = 1, 2, \dots, J_n$) belirli herhangi kombinasyonuna göre I. kısmi türevi eğer I tek ise, negatif olmayandır (> 0); eğer I çift ise, pozitif olmayandır (≤ 0).

G fonksiyonu bu koşulları sağladığında genelleştirilmiş ekstrem değer modelinde i.inci alternatifin tercih edilme olasılığı,

$$P_n(i) = \frac{e^{Z_{in}} G_i(e^{Z_{1n}}, e^{Z_{2n}}, \dots, e^{Z_{j_n n}})}{\mu G(e^{Z_{1n}}, e^{Z_{2n}}, \dots, e^{Z_{j_n n}})} \quad (4.49)$$

şeklindedir. Burada $G_i(y_1, y_2, \dots, y_{j_n})$ $i = 1, 2, \dots, J_n$, $\frac{\partial G}{\partial y_i}$ 'nin kısmi türevinin sonucudur.

Mc Fadden (1978)'in, GEV modelleri oluşturmak için geliştirdiği süreç kullanılarak yeni GEV modelleri geliştirilebilmektedir. GEV sınıfı içerisinde yer alan modellerin sadece küçük bir kısmı uygulanmış durumdadır. Bu modellerde tercih olasılıkları genellikle kapalı bir form almakta ve böylelikle simülasyonla sıralama olmaksızın olasılıklar yeniden hesaplanabilmektedir. Bu durum GEV modellerinin en önemli avantajıdır. Bu avantajından dolayı GEV modelleri araştırmacıların ihtiyaçlarını karşılamak üzere yeni ve güçlü modellerin kaynağı olmaya devam etmektedir.

4. 3. Çok Boyutlu Tercih Modelleri

4.3.1. Birleşik Logit Model

Elemanları mod ve hedef kombinasyonları olarak tanımlanan çok boyutlu C_k kümesi ele alınmaktadır. C_k 'nin bazı elemanlarının, bireylerin aynı modu ve hedefi paylaşıyor olmasının sonucu olarak, ortak gözlemlenmiş elemanları içerdiği varsayılmaktadır. U_{hm} ise m'nin modu ve h'nin de hedef olduğu C_k 'nin elemanlarının toplam faydasıdır. Toplam fayda sistematik ve rasgele bileşenlerine ayrıldığında,

$$U_{hm} = \tilde{V}_h + \tilde{V}_m + \tilde{V}_{hm} + \varepsilon_{hm} \quad \forall (h, m) \in C_k \quad (4.50)$$

şeklinde ifade edilmektedir. Bu eşitlikte \tilde{V}_h , h hedefini kullanan ve \tilde{V}_m , m modunu kullanan C_k 'nin tüm elemanlarında ortak olan faydanın sistematik bileşenidir. \tilde{V}_{hm} ise (h, m) kombinasyonuna ait faydanın geri kalan sistematik bileşenini ve ε_{hm} rasgele fayda bileşenini göstermektedir. ε_{hm} 'lerin alternatifler ve kitle üzerinden dağılımı tercih olasılıklarını tanımlamaktadır. Eğer hatalar bağımsız ve Gumbel dağılıyor ise μ ($\mu=1$) ölçek parametresi ile n kişinin h hedefini ve m modunu tercih etmesi olasılığı,

$$P_n(h, m) = \frac{e^{\tilde{V}_m + \tilde{V}_h + \tilde{V}_{hm}}}{\sum e^{\tilde{V}_{m'} + \tilde{V}_{h'} + \tilde{V}_{hm'}}} \quad (4.51)$$

eşitliği ile tanımlanmaktadır (Osmanoğlu, 2005). Bu eşitlik birleşik logit model olarak tanımlanmaktadır.

4.3.2. Nested Logit Model

Nested logit model ilk olarak Ben-Akiva (1973) tarafından geliştirilmiştir. Bu model alternatifler arasındaki korelasyonu yakalamak için tasarlanmış çoklu logit modelin genişletilmiş şeklidir. Ayrıca logit analizlerde yaygın olan IIA sorununu azaltmak için geliştirilmiş olan nested logit model, çokterimli logit modelin genelleştirilmiş

halidir. (4.52)'de açıklandığı gibi C çözüm kümesinin çeşitli C_k 'lara ayrılmasıyla oluşmaktadır.

$$C = \bigcup_k C_k \quad (4.52)$$

ve

$$C_k \cap C_l \neq 0, \forall k \neq l \quad (4.53)$$

Her bir alternatfin fayda fonksiyonu seçeneği özel bir koşuldan oluşmaktadır ve koşul yuvayla ilişkilendirilmektedir. $i, i \in C_k$ olduğunda,

$$U_i = V_i + \varepsilon_i + V_{C_k} + \varepsilon_{C_k} \quad (4.54)$$

elde edilmektedir. Hata terimleri ε_i ve ε_{C_k} 'nin bağımsız olmaları gerekmektedir. Ayrıca çoklu logit modelde hata terimi ε_i 'nin bağımsız olması ve σ_k ölçek parametresiyle Gumbel dağılımına uyması gerekmektedir. Rassal değişken ε_{C_k} ise μ ölçek parametresiyle Gumbel dağılımına uymaktadır.

Tercih kümesindeki her yuva birleşik fayda adı verilen bir sözde fayda ile ilişkilendirilmektedir. C_k yuvası için birleşik fayda şöyle tanımlanmaktadır:

$$V'_{C_k} = V_{C_k} + \frac{1}{\sigma_k} \ln \sum_{j \in C_k} e^{\sigma_k V_j} \quad (4.55)$$

V_{C_k} bütün C_k yuvalarının ortak fayda bileşenidir. Olasılık modeli ise aşağıdaki eşitliklerde gösterildiği şekilde oluşmaktadır.

$$P_C(i) = P_C(C_k) P_{C_k}(i) \quad (4.56)$$

ayrıca,

$$P_C(C_k) = \frac{e^{\mu V'_{Ck}}}{\sum_1^n e^{\mu V'_{C_i}}} \quad (4.57)$$

ve

$$P_{C_k}(i) = \frac{e^{\sigma_k v_i}}{\sum_{j \in C_k} e^{\sigma_k v_j}} \quad (4.58)$$

μ ve σ_k parametreleri C_k yuvasının alternatifleri arasındaki korelasyonu yansıtmaktadır. $i, j \in C_k$ olduğunda ise,

$$\frac{\mu}{\sigma_k} = \sqrt{1 - \text{corr}(U_i, U_j)} \quad (4.59)$$

ve

$$0 \leq \frac{\mu}{\sigma_k} \leq 1 \quad (4.60)$$

elde edilmektedir. Ben-Akiva ve Lerman (1985) (4.60) eşitsizliğindeki koşulu fayda teorisinden türetmişlerdir. Ayrıca, eğer $\frac{\mu}{\sigma_k}$ ise,

$$\text{corr}(U_i, U_j) = 0 \quad (4.61)$$

elde edilmektedir. Bu modelde μ ve σ_k parametreleri yakından ilişkilidir. Aslında sadece oranları anlamlıdır. Bu yüzden bu parametreleri ayrı ayrı adlandırmak mümkün değildir. Genel yaklaşım, bunlardan keyfi olarak birisini bir değere (genellikle 1'e) kısıtlamaktır.

Nested logit model yön tercih örneğiyle açıklandığında tercih kümesi $\{1, 2a, 2b\}$, $C_1 = \{1\}$ ve $C_2 = \{2a, 2b\}$ olarak ikiye bölünmektedir. Faydaların deterministik

bileşenleri; $V_{C_1} = T$, $V_1 = 0$, $V_{C_2} = T - \delta$ ve $V_{2a} = V_{2b} = \delta$ 'dir. Her yuvanın birleşik faydası ise şöyledir:

$$V'_{C_1} = V_{C_1} = T \quad (4.62)$$

ve

$$V'_{C_2} = T - \delta + \frac{1}{\sigma_2} \ln(e^{\sigma_2 \delta} + e^{\sigma_2 \delta}) = T + \frac{1}{\sigma_2} \ln 2 \quad (4.63)$$

Her bir yuvanın tercih edilme olasılığı ise,

$$P_C(C_1) = \frac{e^{V'_{C_1}}}{e^{V'_{C_1}} + e^{V'_{C_2}}} = \frac{e^T}{e^T + e^{\left(T + \frac{\ln 2}{\sigma_2}\right)}} = \frac{1}{1 + e^{\frac{\ln 2}{\sigma_2}}} = \frac{1}{1 + 2^{\frac{1}{\sigma_2}}} \quad (4.64)$$

ve

$$P_C(C_2) = 1 - P_C(C_1) = \frac{2^{\frac{1}{\sigma_2}}}{1 + 2^{\frac{1}{\sigma_2}}} \quad (4.65)$$

şeklinde ifade edilmektedir. μ değeri genellikle 1 olarak kabul edildiğinden her bir alternatifin tercih edilme olasılığı,

$$P_C(1) = P_C(C_1) = \frac{1}{1 + 2^{\frac{1}{\sigma_2}}} \quad (4.66)$$

ve

$$P_C(2a) = P_C(2b) = \frac{e^{\sigma_2 \delta}}{e^{\sigma_2 \delta} + e^{\sigma_2 \delta}} P_C(C_2) = \frac{1}{2} \frac{2^{\frac{1}{\sigma_2}}}{1 + 2^{\frac{1}{\sigma_2}}} \quad (4.67)$$

ile elde edilmektedir. $\mu = 1$ varsayımı altında $\frac{1}{\sigma_2} = 1$ olduğu zaman nested logit

model çoklu logit modellerle aynı sonuçları vermekte ve bütün olasılıklar $\frac{1}{3}$ 'e eşit

olmaktadır. Diğer taraftan σ_2 sonsuza ve $\frac{1}{\sigma_2}$ 0'a yaklaşırken her bir yuvanın olasılığı $\frac{1}{2}$ 'ye yaklaşmaktadır. Limit noktasında model, ikili tercih modeline benzemekte ve tercih sürecinde küçük sapmalar (a ve b) göz ardı edilmektedir.

4.3.2.1. Nested Logit Modellerin Normalleştirilmesi

(4.66) ve (4.67) eşitliklerindeki olasılıkları hesaplamak için $\mu = 1$ olarak kabul edilmektedir. Alternatif olarak σ_2 1'e kısıtlandığında ise,

$$P_c(1) = \frac{1}{1+2^\mu} \quad (4.68)$$

ve

$$P_c(2a) = P_c(2b) = \frac{1}{2} \frac{2^\mu}{1+2^\mu} \quad (4.69)$$

eşitlikleri elde edilir. $\mu = 1$ kısıtında kabul edilen model “tepeden normalleşmiş”, σ_k parametresi 1'e kısıtlanan model ise “tabandan normalleşmiş” olarak adlandırılmaktadır.

Nested logit model bazı yuvaların ya da tamamının alt yuvalara ayrılmasıyla genişlemektedir. Bu alt yuvalar da kendi alt yuvalarına bölünebilmektedir. Bu modellerin karmaşıklığı nedeniyle yapıları ağaç olarak ifade edilmiştir. Açık olarak potansiyel yapıların sayısı alternatifler arasındaki korelasyonu yansıtmakta ve çok sayıda olabilmektedir.

Bu model her bir yuvadaki alternatiflerin ilişkili olduğu tercih sorunlarını yakalamak için tasarlanmıştır. Alternatifler arasındaki korelasyonunun yansıtılabilmesi için iyi ayrılmış yuvalara bölünmesi gerekmektedir. Aksi bir durumda nested logit modeller uygulanamamaktadır. Logit ailesindeki çeşitli modeller özel korelasyon yapılarını yakalamak için tasarlanmıştır. Örneğin, Koppelman ve Wen (1997) alternatif

çiftlerinin arasındaki korelasyonunu yakalamış ve birden fazla yuvaya ait olan alternatifler için cross-nested modeli önermiştir.

4.4. Uyum İyiliği Ölçütleri

Nitel bağımlı değişkenler için uyum iyiliği ölçüsü olarak belirlilik katsayısı yerine başka ölçütler kullanılmaktadır. En temel uyum iyiliği ölçütü modellerin log olabirlik değerlerini karşılaştırmaktır. Olasılık oranı endeksi olarak adlandırılan bu istatistik modellerin veriye ne kadar iyi uyduğunu ölçmek için kullanılmaktadır.

Olasılık oranı endeksi,

$$\rho = 1 - \frac{LL(\hat{\beta})}{LL(0)} \quad (4.70)$$

olarak tanımlanmaktadır. $LL(\hat{\beta})$ tahmin edilmiş parametrelerde log-olasılık fonksiyonunun değeridir ve $LL(0)$ ise modeldeki sabit terim hariç tüm eğim katsayılarının modelden çıkarıldığı zaman elde edilen log-olabirlik değeridir.

Regresyonda kullanılan R^2 , tahmin edilmiş model tarafından açıklanan bağımlı değişkendeki değişimin yüzdesini ifade etmektedir. Olasılık oranı 0 parametrelerde alınan değer üzerinde log-olasılık fonksiyonunda yüzde artıştır. Aynı alternatifler seti ile aynı veri üzerinden hesaplanmış olan iki modeli kıyaslamada ($LL(0)$, her iki modelde aynıdır) ρ 'si daha yüksek olan modelin verilere daha iyi uyduğu söylenebilmektedir. Fakat benzer olmayan örnekleme hesaplanmış iki model ya da herhangi bir örnekleme için farklı alternatif setleri olan iki model, kendilerinin olasılık oran endeks değerleri üzerinden kıyaslanamamaktadır.

Regresyonlarda olduğu gibi, standart t-istatistikleri nitel tercih modellerinde, katsayıların ayrı ayrı anlamlılıklarını test etmek üzere kullanılmaktadır. Katsayıların birlikte anlamlılıklarının sınanmasında ise olabirlik oran testinden yararlanılmaktadır.

Olabilirlik oran istatistiđi,

$$-2LL(\hat{\beta}^H) - LL(\hat{\beta}) \quad (4.71)$$

olarak ifade edilmektedir. $LL(\hat{\beta}^H)$; kısıtlanmış modelin en yüksek olabilirlik deđerinin logaritması, $LL(\hat{\beta})$ ise kısıtlanmamış modelin en yüksek olabilirlik deđerinin logaritmasıdır.

Bu test istatistiđi H_0 hipotezi tarafından verilen kısıtlamaların sayısına eşit serbestlik dereceli ki-kare dağılımına uymaktadır. Olabilirlik oran testi hem kısıtlanmış hem de kısıtlanmamış modellerin tahmin sonuçlarını dikkate alan bir testtir. Test istatistiđi deđeri uygun serbestlik dereceli ki-kare kritik deđerinden büyükse H_0 hipotezi reddedilmektedir.

5. UYGULAMA

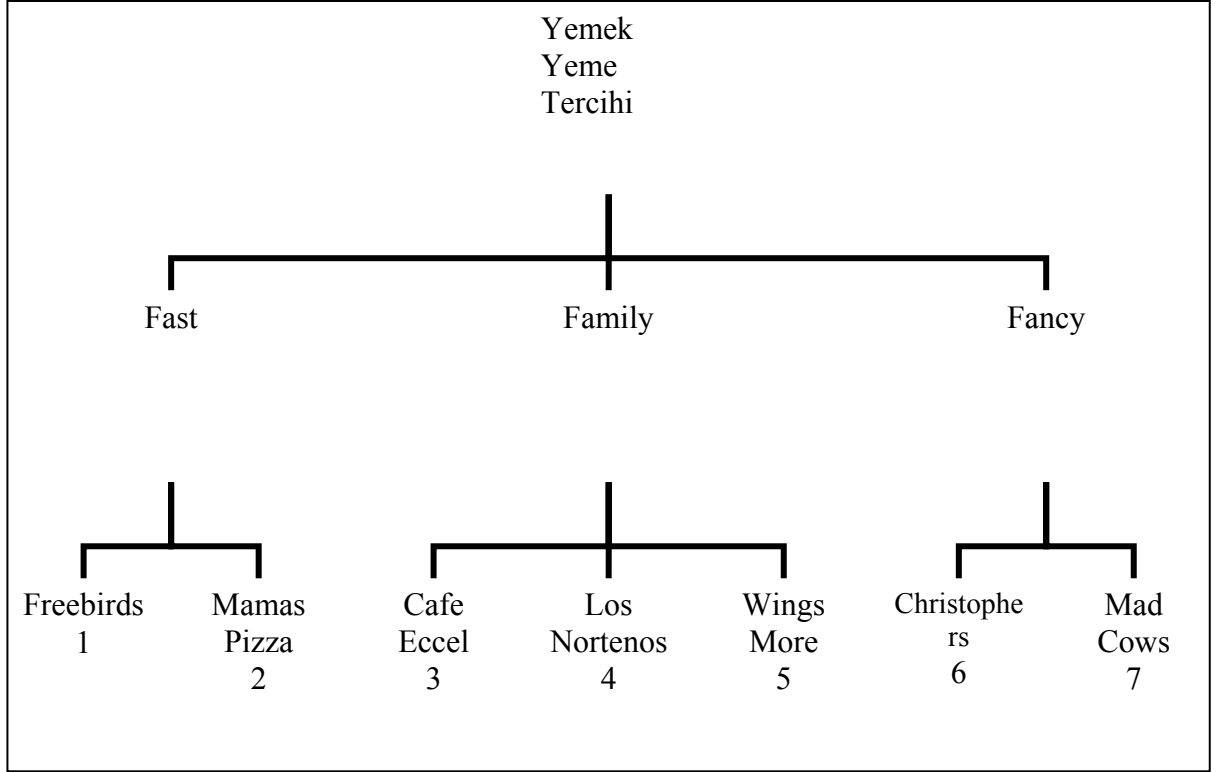
Bu bölümde kesikli tercih analizi STATA paket programından yararlanılarak STATA yayınları elkitabında bulunan temel referans kılavuzunda (Base Reference Manual [R]) yer alan restoran veri kümesi üzerinde uygulanacaktır. Veriler www.stata-press.com/data/r10/restaurant adresinden alınmıştır. Burada amaç, tercihlerin en iyi yorumlanabileceği ideal model kalıbını belirlemek ve bir tercih modeli seçiminin aşamalarını ve yorumlanmasını ortaya koymaktır.

Veriler STATA programında, kesikli tercih modellerinden yaygın kullanıma sahip olan çokterimli logit, koşullu logit ve nested logit uygulamaları ile gerçekleştirilmiştir. Söz konusu modellerin birbiri arasındaki geçiş ve uygulanma koşullarına değinilerek, ideal modellemenin aşamaları kullanılmıştır. Uygulamanın ilk aşamasında, verilerin hangi model kalıbına göre analiz edileceğinin belirlenmesi için bazı ön testlerin yapılması gerekmektedir. Veriler, ayrıldıkları kategorilerin herhangi birindeki ilişkisiz alternatiflerin bağımsızlığının (IIA) sağlandığı durumlarda nested logit için uygundur. Ters durumlar için farklı model seçenekleri bulunmaktadır. Araştırmacılar, kesikli tercih modellerinin analizinde, genellikle nested logit model kalıbı üzerinde çalışma eğilimi gösterirler. Bunun nedeni, marjinal etkilerin daha rahat yorumlanabilmesidir. Böylece, logit analizlerinde genellikle IIA varsayımının ihlalinden ortaya çıkan problemleri azaltmak için geliştirilmiş olan nested logit kullanılmaktadır. IIA'nın sağlanıp sağlanmadığı ise Hausman testi ile yapılmıştır. Veriler nested logit ile modelleme yapılmadan önce çokterimli logit ve koşullu logit ile Hausman IIA testine tabi tutulmuşlardır.

5.1. KESİKLİ TERCİH ANALİZİNİN STATA PAKET PROGRAMINDA UYGULANMASI

STATA el kitabından alınan restoran verileri 300 hane için hazırlanmıştır. Tercih kümesi 7 restoran alternatifinden (chosen) oluşmaktadır. Tercihler ise 3 ana kategoriye göre düzenlenmiştir. Tercih kümesinde yer alan Freebirds ve Mama's

Pizza fast-food restoranlar (fast), Cafe Eccel, Los Nortenos ve WingsNmore aile restoranları (family) ve Christophers ve Mad Cows ise lüks restoranlardır (fancy). Bu kategorilerine ayrılmış restoranlar Şekil 5.1’de gösterilmektedir.



Şekil 5.1 Kategorilerine göre tercih edilen restoranlar

Hane halkının hangi restoranı tercih edeceği bağımsız değişkenlere bağlıdır. Modele eklenen bağımsız değişkenler gelir (income) (bin \$), hanedeki çocuk sayısı (kids), restoranın notu (rating), bir kişinin bir öğünde ödediği ücret (cost) ve ev ile restoran arasındaki mesafedir (distance). Gelir ile çocuk sayısı hanenin niteliği, restoran notu alternatiflerin niteliği ve ödenen ücret ile mesafe hane halkı tarafından fark edilen alternatiflerin niteliğidir. Ödenen ücret ile mesafe hanedeki her bir bireye göre değişiklik göstermektedir. Uygulamaya başlamadan önce veriler STATA’ya girildikten sonra komutların ve çıktıların not defteri şeklinde alınabilmesi için bir isim altında kaydedilmiştir.

```
. log using C:\restaurants.log
```

Uygulamaya başlanmadan önce yapılan diğer bir işlem ise verilerin tanımlayıcı istatistiklerinin STATA çıktısı olarak alınmasıdır. Verileri ait bilgiler “describe”

komutu ile elde edilmektedir. Bu çıktı ile bağımsız değişkenlerin neler olduğu, ne anlama geldikleri, türleri, örneklem büyüklüğü ve hangi değişkene göre sınıflandırıldığı bilgileri elde edilmektedir.

```
. describe
```

```
Contains data from C:\Discrete Choice\restaurant.dta
  obs:      2,100
  vars:      22      18 May 2009 17:46
  size:     180,600 (82.6% of memory free)
-----
-----
variable name  storage  display  value  variable label
              type   format   label
-----
family_id      float   %9.0g
restaurant     float   %12.0g   names
income         float   %9.0g
cost           float   %9.0g
kids           float   %9.0g
household      float   %9.0g
rating         float   %9.0g
guide          float   %9.0g
distance       float   %9.0g
restaurant     float   %9.0g
chosen         float   %9.0g
-----
Sorted by:  family_id
```

Ayrıca veriler STATA çıktısı olarak görülmek istendiğinde program aşağıdaki gibi bir çıktı vermektedir. Aşağıda sadece 14 birey için çıktı oluşturulmuştur.

```
. list family_id restaurant chosen kids rating distance in 1/14
```

	family~d	restaurant	chosen	kids	rating	distance
1.	1	Freebirds	1	1	0	1.245553
2.	1	MamasPizza	0	1	1	2.82493
3.	1	CafeEccell	0	1	2	4.21293
4.	1	LosNortenos	0	1	3	4.167634
5.	1	wingsNmore	0	1	2	6.330531
6.	1	Christophers	0	1	4	10.19829
7.	1	MadCows	0	1	5	5.601388
8.	2	Freebirds	0	3	0	4.162657
9.	2	MamasPizza	0	3	1	2.865081
10.	2	CafeEccell	0	3	2	5.337799
11.	2	LosNortenos	1	3	3	4.282864
12.	2	wingsNmore	0	3	2	8.133914
13.	2	Christophers	0	3	4	8.664631
14.	2	MadCows	0	3	5	9.119597

Analizden önceki son adım ise kategorilere ayrılan restoranların STATA'ya tanımlanmasıdır. Kategorik olan ve 1. alternatifleri içeren (fast, family, fancy)

değişkenlere göre tercihler yapılmaktadır. Hane halkı önce hangi tür restoranı tercih edeceğine karar vermektedir. Daha sonra karar verilen kategorinin alt kümesi olan restoran tercih edilmektedir. Böylece tercih daha spesifik olmaktadır. Restoranları kategorilere ayırmak “nlogitgen” komutu ile yapılmaktadır. Bu kategorik değişken tercih edilen restoran Freebird ya da MamasPizza ise 1 değerini, Cafe Eccell, Los Nortenos ya da WingsNmore ise 2 değerini ve Christophers ya da Mad Cows ise 3 değerini almaktadır. Bu kategorilerin alt kümesi olan her bir restoran “nlogittree” komutu ile gösterildiği gibi bir çıktı vermektedir.

```
. nlogitgen type=restaurant(fast:Freebirds|MamasPizza, family:
CafeEccell|LosNortenos|WingsNmore, fancy:Christophers|MadCows)
```

new variable type is generated with 3 groups

```
label list lb_type
lb_type:
    1 fast
    2 family
    3 fancy
```

```
. nlogittree restaurant type
```

tree structure specified for the nested logit model

top	-->	bottom
type		restaurant
fast		Freebirds MamasPizza
family		CafeEccell LosNortenos WingsNmore
fancy		Christophers MadCows

Gelir ve çocuk sayısı hane halkı niteliği olduğundan ve değişiklik göstermediğinden kesikli tercih modellerinde restoran kategorilerine göre yeniden tanımlanmaktadır. 3 kategori bulunduğundan sadece 2 (N-1) restoran ile tanımlanması yeterlidir.

```
. gen incfast=(type==1)*income
. gen incfancy=(type==3)*income
. gen kidfast=(type==1)*kids
. gen kidfancy=(type==3)*kids
```

Burada yapılması gereken diğer bir tanımlama ise değişiklik göstermeyen bu değişkenlerin her bir restorana göre tanımlanarak modele eklenmesidir.

```
. gen incfast1=(restaurant==1)*income
. gen incfast2=(restaurant==2)*income
. gen incfam3=(restaurant==3)*income
```

```
. gen incfam4=(restaurant==4)*income
. gen incfam5=(restaurant==5)*income
. gen incfancy6=(restaurant==6)*income
. gen incfancy7=(restaurant==7)*income
```

Değişkenler tanımlandıktan sonra kesikli tercih verilerine nested logitin uygulanıp uygulanmayacağı test edilmiştir. Bunun için Hausman testi ile her bir kategori için IIA'nın sağlanıp sağlanmadığına bakılmıştır. Hausman testinde ilk olarak veriler çokterimli logit tekniği kullanılarak modellenmiştir. Modelde bağımlı değişken olarak restoran tercihleri, bağımsız değişken olarak not, ödenen ücret, mesafe ve 2 restoran kategorisine göre tanımlanan gelir ve çocuk sayısı kullanılmıştır. Çokterimli logit modelinin sonuçları istenilen bir isim (hepsi) altında STATA hafızasına kaydedilmiştir.

```
. mlogit chosen rating cost distance incfast incfancy kidfast kidfancy
Multinomial logistic regression                Number of obs    =
2100                                           LR chi2(7)       =
206.41                                        Prob > chi2      =
0.0000                                        Pseudo R2       =
Log likelihood = -758.03923
0.1198
-----
----
      chosen |          Coef.   Std. Err.      z    P>|z|     [95% Conf.
Interval]
-----+-----
1
rating |          .3682693   .151583     2.43   0.015     .0711721
.6653665
cost |         -.1526019   .0344557    -4.43   0.000     -.2201338
.08507
distance |        -.1918726   .0472994    -4.06   0.000     -.2845778
.0991675
incfast |        -.0449218   .0090819    -4.95   0.000     -.0627219
.0271217
incfancy |         .0358527   .0069805     5.14   0.000     .0221711
.0495343
kidfast |        -.2143928   .1030507    -2.08   0.037     -.4163685
.0124171
kidfancy |        -.3272182   .1040745    -3.14   0.002     -.5312005
.1232359
_cons |         .3238583   .3291059     0.98   0.325     -.3211775
.968894
-----
----
(chosen==0 is the base outcome)
. est store hepsi
```

2. adım, her bir kategorinin modelden tek tek çıkartılarak çokterimli logit ile modellemesidir. İlk olarak 1. kategori olan fast-food restoranlar modelden çıkartılmış ve yine istenilen bir isim (nofast) ile hafızaya kaydedilmiştir.

```
. mlogit chosen rating cost distance incfast incfancy kidfast kidfancy if
type!=1
```

note: incfast dropped due to collinearity
 note: kidfast dropped due to collinearity

Iteration 0: log likelihood = -711.61901
 Iteration 1: log likelihood = -659.02785
 Iteration 2: log likelihood = -651.68446
 Iteration 3: log likelihood = -651.12123
 Iteration 4: log likelihood = -651.11556
 Iteration 5: log likelihood = -651.11556

Multinomial logistic regression
 1500 Number of obs =
 121.01 LR chi2(5) =
 0.0000 Prob > chi2 =
 Log likelihood = -651.11556 Pseudo R2 =
 0.0850

```
-----+-----
```

chosen	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
1					
rating	.2221972	.1743087	1.27	0.202	-.1194416
cost	-.1398042	.0358632	-3.90	0.000	-.2100947
distance	-.1932584	.0492043	-3.93	0.000	-.289697
incfancy	.0367174	.007033	5.22	0.000	.022933
kidfancy	-.3163954	.1044353	-3.03	0.002	-.5210848
_cons	.5830569	.3675902	1.59	0.113	-.1374067

```
-----+-----
```

(chosen==0 is the base outcome)

. est store nofast

3. adımda ise Hausman testi ile 1. kategori için IIA'nın sağlanıp sağlanmadığı ki-kare tablo değeri ile karşılaştırılarak bulunmuştur. Teste sabit sayının (constant) eklenip eklenmemesi tamamen analizeciye göre değişmektedir, fakat modele sabit sayı eklendiğinde daha kesin sonuçlar alındığı görülmüştür.

. hausman nofast hepsi, alleq constant

```
-----+-----
```

V_B))	---- coefficients ----		(b-B)	sqrt(diag(V_b- S.E.
	(b)	(B)		
	nofast	hepsi	Difference	
rating	.2221972	.3682693	-.1460721	.0860588
cost	-.1398042	-.1526019	.0127977	.0099485
distance	-.1932584	-.1918726	-.0013858	.0135582
incfancy	.0367174	.0358527	.0008647	.0008575
kidfancy	-.3163954	-.3272182	.0108228	.0086732
_cons	.5830569	.3238583	.2591986	.1637433

```
-----+-----
```

b = consistent under Ho and Ha; obtained from
 mlogit

```

mlogit      B = inconsistent under Ha, efficient under Ho; obtained from
Test: Ho: difference in coefficients not systematic
          chi2(6) = (b-B)'[(V_b-V_B)^(-1)](b-B)
              =      22.32
Prob>chi2 =      0.0011
          (V_b-V_B is not positive definite)

```

Çıktıdan görüldüğü gibi fast-food restoran kategorisi çıkartılarak yapılan test sonucunda H_0 : sistematik hata yoktur hipotezi red edilmiş ve IIA'nın sağlandığı ortaya çıkmıştır. Fakat bu sonuç yeterli bir cevap içermemektedir. Çünkü eğer herhangi bir kategori de H_0 red edilir yani IIA sağlanmaz ise nested logitin kullanılması doğru olacaktır. Bu yüzden her bir kategori için benzer işlemler aynı sırayla yapılmıştır. 2. kategori olan aile restoranları modelden çıkartılarak çokterimli logit uygulandığında aşağıdaki sonuçlara ulaşılmıştır.

```

. mlogit chosen rating cost distance incfast incfancy kidfast kidfancy if
type!=2

Iteration 0:  log likelihood = -288.61092
Iteration 1:  log likelihood = -266.84954
Iteration 2:  log likelihood = -257.02023
Iteration 3:  log likelihood = -256.84738
Iteration 4:  log likelihood = -256.84715

Multinomial logistic regression                                Number of obs   =
1200                                                         LR   chi2(7)      =
63.53                                                         Prob > chi2      =
0.0000                                                         Pseudo R2       =
Log likelihood = -256.84715
0.1101

-----
---
      chosen |          Coef.   Std. Err.      z    P>|z|      [95% Conf.
Interval] +-----+-----+-----+-----+-----+-----+
---
1          |
  rating   |   .3130136     .2649442     1.18   0.237     -.2062675
.8322947   |
  cost     |  -.0991852     .0572247    -1.73   0.083     -.2113435
.0129731   |
 distance  |  -.2499696     .0732915    -3.41   0.001     -.3936183  -
.1063209   |
  incfast  |  -.0318336     .0109383    -2.91   0.004     -.0532723  -
.0103948   |
  incfancy |   .0387495     .0073445     5.28   0.000     .0243545
.0531444   |
  kidfast  |  -.053652      .131153     -0.41   0.682     -.3107072
.2034032   |
  kidfancy |  -.300386      .1074522    -2.80   0.005     -.5109884  -
.0897836   |
   _cons   |  -.6695929     .6858944    -0.98   0.329     -2.013921
.6747354   |
-----
---
(chosen==0 is the base outcome)

```

Sonuçlar bir isim (nofamily) altında hafızaya kaydedilerek bu kategorinin IIA'yı sağlayıp sağlamadığı Hausman testi ile analiz edilmiştir.

```
. est store nofamily
. hausman nofamily hepsi, alleqs constant
```

V_B))	---- Coefficients ----		(b-B)	sqrt(diag(V_b- V_B))
	(b)	(B)		
	nofamily	hepsi	Difference	S.E.
rating	.3130136	.3682693	-.0552557	.2172971
cost	-.0991852	-.1526019	.0534167	.0456888
distance	-.2499696	-.1918726	-.058097	.0559858
incfast	-.0318336	-.0449218	.0130882	.0060965
incfancy	.0387495	.0358527	.0028968	.0022834
kidfast	-.053652	-.2143928	.1607408	.0811274
kidfancy	-.300386	-.3272182	.0268322	.0267295
_cons	-.6695929	.3238583	-.9934511	.601781

```
-----
b = consistent under Ho and Ha; obtained from
mlogit
B = inconsistent under Ha, efficient under Ho; obtained from
mlogit
Test: Ho: difference in coefficients not systematic
      chi2(8) = (b-B)'[(V_b-V_B)^(-1)](b-B)
            = 2.19
      Prob>chi2 = 0.9748
      (V_b-V_B is not positive definite)
```

Aile restoran kategorisi modelden çıkarılıp analiz yapıldığında elde edilen sonuçlar ki-kare tablo değeri ile karşılaştırılmış (Prob>chi2 = 0.9748) ve H_0 hipotezi reddedilmiştir. Yani IIA varsayımının sağlanmadığı görülmüştür. Bu durumda bu ihlalden kaynaklanan problemlerin çözümü için nested logit ile analiz yapılmasının uygun olduğu ortaya çıkmıştır. 3. kategori modelden çıkartılarak yapılan çokterimli logit analizi sonuçları aşağıdaki gibidir.

```
. mlogit chosen rating cost distance incfast incfancy kidfast kidfancy if
type!=3

note: incfancy dropped due to collinearity
note: kidfancy dropped due to collinearity
Iteration 0: log likelihood = -674.22997
Iteration 1: log likelihood = -615.71534
Iteration 2: log likelihood = -606.33155
Iteration 3: log likelihood = -605.21406
Iteration 4: log likelihood = -605.18226
Iteration 5: log likelihood = -605.18222

Multinomial logistic regression              Number of obs   =
1500
LR chi2(5)                                  =
138.10
Prob > chi2                                  =
0.0000
Log likelihood = -605.18222                  Pseudo R2       =
0.1024
```



```

-----
----
      chosen |          Coef.   Std. Err.      z    P>|z|      [95% Conf.
Interval] +-----+
----
1      rating |      .3133622    .2235311      1.40   0.161     -.1247507
.751475      cost |     -.0846828    .1176567     -0.72   0.472     -.3152856
.14592      distance |      -.1685     .0589564     -2.86   0.004     -.2840523
.0529476      incfast |     -.0421115    .0093273     -4.51   0.000     -.0603926
.0238304      kidfast |     -.1825953    .1065487     -1.71   0.087     -.3914269
.0262364      _cons |     -.265909    .7452392     -0.36   0.721     -1.726551
1.194733
-----

```

(chosen==0 is the base outcome)

Çokterimli logit analizi sonuçları hafızaya bir isim (nofancy) altında kaydedilip Hausman testi yapıldığında aşağıdaki çıktı elde edilmiştir.

```

. est store nofancy
. hausman nofancy hepsi, alleq constant

```

```

-----
----
              Coefficients
              (b)          (B)          (b-B)          sqrt(diag(V_b-
V_B))          |          |          |          |
              |          |          |          |
-----+-----+-----+-----+
rating |      .3133622    .3682693    -.0549071    .1642825
cost   |     -.0846828    -.1526019    .0679191    .1124984
distance |      -.1685     -.1918726    .0233727    .035194
incfast |     -.0421115    -.0449218    .0028103    .0021256
kidfast |     -.1825953    -.2143928    .0317975    .0270773
_cons  |     -.265909    .3238583    -.5897673    .6686335
-----

```

```

-----
              b = consistent under Ho and Ha; obtained from mlogit
              B = inconsistent under Ha, efficient under Ho; obtained from
mlogit

```

Test: Ho: difference in coefficients not systematic

$$\begin{aligned} \text{chi2}(6) &= (b-B)'[(V_b-V_B)^{-1}](b-B) \\ &= 1.79 \\ \text{Prob>chi2} &= 0.9377 \end{aligned}$$

(V_b-V_B is not positive definite)

Lüks restoran kategorisi çıkartılıp Hausman testi yapıldığında elde edilen sonuçlar ki-kare tablo değeri ile karşılaştırılmış (Prob>chi2 = 0.9377) ve H₀ hipotezi tekrar reddedilmiştir. Yani IIA 3. kategori için de sağlanmamaktadır. Fakat çoklu logit modellerinin verilere uygun olabilmesi için tüm kategorilerde IIA'nın sağlanması gerekmektedir. Çoklu logit modellerinin geçerli olmadığı durumlarda alternatif olarak nested logit modeli kullanılabilir. IIA'nın 2. ve 3. kategorilerde

sağlanmadığı görüldüğü için bu verilerin çözümlenmesinde çoklu logit modelin kullanılmasının başarılı sonuçlar vermeyeceği anlaşılmıştır.

Çoklu logit modelin veriler için uygun olup olmadığının anlaşılması için ikinci bir yöntem de Hausman testini koşullu logit ile yapmak ve IIA'nın kategoriler için sağlanıp sağlanmadığının araştırmaktır. Bu model çokterimli logitten farklı komutlarla yapılmakta fakat içeriği ve işlemlerin uygulanma sırası benzerdir. Aralarındaki en önemli fark analiz yapılırken modelde grup no'su olan hane sıra nolarının (group_id) dikkate alınmasıdır. Hane sıra no'ları dikkate alındığında analiz her bir birey yerine her bir hane için yapılmaktadır. Koşullu logit tekniğinde tüm veriler "clogit" komutu kullanılarak modellenmiş ve çıktı hafıza kaydedilerek işlemler aynı sırayla yapılmıştır.

```
. clogit chosen rating cost distance incfast incfancy kidfast kidfancy,
group(family_id)
```

```
Iteration 0: log likelihood = -490.4956
Iteration 1: log likelihood = -488.91277
Iteration 2: log likelihood = -488.90834
Iteration 3: log likelihood = -488.90834
```

```
Conditional (fixed-effects) logistic regression      Number of obs      =
2100
LR chi2(7)                                          =
189.73
Prob > chi2                                         =
0.0000
Log likelihood = -488.90834                          Pseudo R2          =
0.1625
```

```
-----
----
      chosen |          Coef.   Std. Err.      z    P>|z|     [95% Conf.
Interval]
-----+-----
----
      rating |   .3066622     .1418291     2.16   0.031     .0286823
.584642
      cost   |  -.1367799     .0358479    -3.82   0.000    -.2070404
.0665193
      distance | -.1977505     .0471653    -4.19   0.000    -.2901927
.1053082
      incfast |  -.0390183     .0094018    -4.15   0.000    -.0574455
.0205911
      incfancy |   .0407053     .0080405     5.06   0.000     .0249462
.0564644
      kidfast |  -.2398757     .1063674    -2.26   0.024    -.448352
.0313994
      kidfancy | -.3893862     .1143797    -3.40   0.001    -.6135662
.1652061
-----
----
```

```
. est store hepsi
```

Analiz çokterimli logit tekniğinde olduğu gibi kategorilerin sırayla çıkartılarak modellenmesi ile devam etmektedir. Öncelikle 1. kategori modelden çıkartılmıştır. Hafızaya “nofast” ismi altında kaydedilen çıktıya Hausman testi yapılmıştır.

```
. clogit chosen rating cost distance incfast incfancy kidfast kidfancy if
type!=1, group(family_id)
```

```
note: incfast dropped due to collinearity
note: kidfast dropped due to collinearity
note: 27 groups (135 obs) dropped due to all positive or
      all negative outcomes.
```

```
Iteration 0: log likelihood = -386.06312
Iteration 1: log likelihood = -384.16911
Iteration 2: log likelihood = -384.16186
Iteration 3: log likelihood = -384.16186
```

```
Conditional (fixed-effects) logistic regression      Number of obs      =
1365
LR chi2(5)                                           =
110.43
Prob > chi2                                         =
0.0000
Log likelihood = -384.16186                          Pseudo R2          =
0.1257
```

```
-----
---
chosen |          Coef.   Std. Err.      z    P>|z|    [95% Conf.
Interval]
-----+-----
rating |   .2167134   .1580077     1.37   0.170   -.0929761
.5264029
cost   |  -.134805   .036582    -3.69   0.000   -.2065043
.0631056
distance | -.1945914   .0492249    -3.95   0.000   -.2910705
.0981124
incfancy |  .042067   .0081139     5.18   0.000   .026164
.0579699
kidfancy | -.3590991   .1142534    -3.14   0.002   -.5830316
.1351666
-----
---
```

```
. est store nofast
```

```
. hausman nofast hepsi, alleq constant
```

```
-----
---- coefficients ----
          |          (b)          (B)          (b-B)          sqrt(diag(V_b-
V_B))          |          S.E.
-----+-----
rating   |   .2167134   .3066622   -.0899488   .0696489
cost     |  -.134805   -.1367799   .0019749   .0072918
distance | -.1945914   -.1977505   .003159    .01409
incfancy |  .042067   .0407053   .0013617   .0010888
kidfancy | -.3590991   -.3893862   .0302871   .
-----
---
```

b = consistent under Ho and Ha; obtained from clogit

```

      B = inconsistent under Ha, efficient under Ho; obtained from
clogit
      Test: Ho: difference in coefficients not systematic
             chi2(5) = (b-B)'[(V_b-V_B)^(-1)](b-B)
                   =      7.84
             Prob>chi2 =      0.1651
                   (V_b-V_B is not positive definite)

```

Hausman test sonuçları ki-kare tablo değeriyle karşılaştırıldığına (Prob>chi2 = 0.1651) çokterimli logit tekniği ile aynı sonuca ulaşılmıştır. Yani H_0 reddedilmiş ve IIA'nın bu kategori için sağlanmadığı saptanmıştır. Aynı işlemler 2. kategori olan aile restoranı çıkartılarak yapıldığında çok uzun tekrarlar (iteration) ile karşılaşmıştır. Tekrarlamaların altında yer alan "more" ifadesi bu sürecin devam ettiğini göstermektedir. STATA'da more ifadesi birçok kez uygulanmış fakat tekrarlamalar devam ettiği için 840. tekrarlama işlemi sonlandırılmıştır. Sürekliliği göstermek amacıyla sadece 46 tekrarlar gösterilmiştir.

```

. clogit chosen rating cost distance incfast incfancy kidfast kidfancy if
type!=2, group(family_id)

```

```

note: 222 groups (888 obs) dropped due to all positive or
      all negative outcomes.

```

```

Iteration 0:  log likelihood = -86.129836 (not concave)
Iteration 1:  log likelihood = -86.008609 (not concave)
Iteration 2:  log likelihood = -85.973381 (not concave)
Iteration 3:  log likelihood = -85.96475 (not concave)
Iteration 4:  log likelihood = -85.960513 (not concave)
Iteration 5:  log likelihood = -85.959681 (not concave)
Iteration 6:  log likelihood = -85.95909 (not concave)
Iteration 7:  log likelihood = -85.958582 (not concave)
Iteration 8:  log likelihood = -85.958088 (not concave)
Iteration 9:  log likelihood = -85.957771 (not concave)
Iteration 10: log likelihood = -85.957488 (not concave)
Iteration 11: log likelihood = -85.9572 (not concave)
Iteration 12: log likelihood = -85.95699 (not concave)
Iteration 13: log likelihood = -85.956802 (not concave)
Iteration 14: log likelihood = -85.956611 (not concave)
Iteration 15: log likelihood = -85.956467 (not concave)
Iteration 16: log likelihood = -85.956339 (not concave)
Iteration 17: log likelihood = -85.956213 (not concave)
Iteration 18: log likelihood = -85.956113 (not concave)
Iteration 19: log likelihood = -85.956026 (not concave)
Iteration 20: log likelihood = -85.955944 (not concave)
Iteration 21: log likelihood = -85.955875 (not concave)
Iteration 22: log likelihood = -85.955813 (not concave)
Iteration 23: log likelihood = -85.955758 (not concave)
--more--

```

```

Iteration 24: log likelihood = -85.955709 (not concave)
Iteration 25: log likelihood = -85.955666 (not concave)
Iteration 26: log likelihood = -85.955627 (not concave)
Iteration 27: log likelihood = -85.955593 (not concave)
Iteration 28: log likelihood = -85.955563 (not concave)
Iteration 29: log likelihood = -85.955536 (not concave)
Iteration 30: log likelihood = -85.955512 (not concave)
Iteration 31: log likelihood = -85.955491 (not concave)
Iteration 32: log likelihood = -85.955472 (not concave)
Iteration 33: log likelihood = -85.955456 (not concave)
Iteration 34: log likelihood = -85.955441 (not concave)
Iteration 35: log likelihood = -85.955428 (not concave)
Iteration 36: log likelihood = -85.955416 (not concave)
Iteration 37: log likelihood = -85.955406 (not concave)

```

```

Iteration 38: log likelihood = -85.955396 (not concave)
Iteration 39: log likelihood = -85.955388 (not concave)
Iteration 40: log likelihood = -85.955381 (not concave)
Iteration 41: log likelihood = -85.955375 (not concave)
Iteration 42: log likelihood = -85.955369 (not concave)
Iteration 43: log likelihood = -85.955364 (not concave)
Iteration 44: log likelihood = -85.95536 (not concave)
Iteration 45: log likelihood = -85.955326 (not concave)
Iteration 46: log likelihood = -85.955326 (not concave)
--more--

```

Çok uzun tekrarlamaların görüldüğü durumda yapılacak tek şey diğer herhangi bir kategori çıkartıldıktan sonra uygulanan koşullu logit analizinin sonucunu gözden geçirmek ve çoklu doğrusal bağlantı sorununun görüldüğü değişkenleri (incfast ve kidfast) modelden çıkartmaktır. Bu iki değişken ve 2. kategori modelde çıkartılarak tekrar koşullu logit analizi yapılmış ve aşağıdaki sonuca ulaşılmıştır.

```

. clogit chosen rating cost distance incfast kidfast if type!=2,
group(family_id)

```

```

note: 222 groups (888 obs) dropped due to all positive or
all negative outcomes.

```

```

Iteration 0: log likelihood = -88.608092
Iteration 1: log likelihood = -85.974978
Iteration 2: log likelihood = -85.955347
Iteration 3: log likelihood = -85.955324
Iteration 4: log likelihood = -85.955324

```

```

Conditional (fixed-effects) logistic regression      Number of obs      =
312                                                    LR chi2(5)          =
44.35                                                    Prob > chi2         =
0.0000                                                    Pseudo R2          =
Log likelihood = -85.955324
0.2051

```

```

-----
---
chosen |      Coef.   Std. Err.   z     P>|z|     [95% Conf.
Interval]
-----+-----
rating |   .1659001   .2832041    0.59   0.558     -.3891698
.72097
cost   |  -.0616621   .067852    -0.91   0.363     -.1946496
.0713254
distance | -.244396   .0995056   -2.46   0.014     -.4394234
.0493687
incfast | -.0737506   .0177444   -4.16   0.000     -.108529
.0389721
kidfast |  .4105386   .2137051    1.92   0.055     -.0083157
.8293928
-----
---

```

```

. est store nofamily

```

Aile restoran kategorisi çıkartılarak yapılan koşullu logit analizi “nofamily” ismi altında hafızaya kaydedilmiş ve Hausman testi yapılmıştır.


```

rating | .2302111 .213412 1.08 0.281 -.1880688
.648491
cost | -.0831837 .1145961 -0.73 0.468 -.307788
.1414205
distance | -.1702452 .0607536 -2.80 0.005 -.2893201 -
.0511704
incfast | -.0375268 .0095785 -3.92 0.000 -.0563004 -
.0187533
kidfast | -.2248554 .1100109 -2.04 0.041 -.4404729 -
.009238
-----

```

```
. est store nofancy
```

```
. hausman nofancy hepsi, alleq constant
```

```

----- Coefficients -----
          |          (b)          (B)          (b-B)          sqrt(diag(V_b-
V_B))    |          nofancy          hepsi          Difference          S.E.
-----+-----
rating   |          .2302111          .3066622          -.076451          .1594654
cost     |          -.0831837          -.1367799          .0535961          .1088448
distance |          -.1702452          -.1977505          .0275052          .038294
incfast  |          -.0375268          -.0390183          .0014915          .0018314
kidfast  |          -.2248554          -.2398757          .0150202          .0280781
-----

```

```

          b = consistent under Ho and Ha; obtained from clogit
          B = inconsistent under Ha, efficient under Ho; obtained from
clogit

```

```
Test: Ho: difference in coefficients not systematic
```

```

chi2(5) = (b-B)' [(V_b-V_B)^(-1)] (b-B)
          =          0.32
Prob>chi2 =          0.9973

```

```
(V_b-V_B is not positive definite)
```

3. kategori modelde çıkartılarak yapılan Hausman testi sonuçları ki-kare tablo değeriyle karşılaştırılmış (Prob>chi2 = 0.9973) ve H₀ red edilmiştir. Yani bu kategori için IIA varsayımı sağlanmamaktadır.

Çokterimli logit ve koşullu logit modelleri ile yapılan Hausman testleri sonucunda çoklu logit modellerin geçerli olmadığı görülmüştür. Bu durumda verilerimiz için nested logitin en iyi model olduğuna karar verilmiştir.

Nested logit model ile hane halkı bireylerinin restoran tercihlerinde etkili olan bağımsız değişkenlerin bulunmaya çalışılmıştır. Modelde neyin irdelenmek istendiği

önemli olduğundan kategorilere ayırma da çok önemlidir. Burada restaurant tercihini doğrudan etkileyen not, mesafe, gelir öncelikli olarak ele alınırken, hane halkı bireyleri için değişmeyen gelir ve çocuk sayısı restoran kategorileri üzerinden modele eklenmiştir.

Ayrıca uygulamada alternatif-spesifik sabitlerin bütün restoranlar üzerindeki etkileri ve hane halkı-spesifik niteliklerinin üç kategori üzerindeki etkileri araştırılmıştır.

$$P(\text{restaurant} | \text{type}) = P(\beta_{\text{cost}} \text{cost} + \beta_{\text{rating}} \text{rating} + \beta_{\text{dist}} \text{distance})$$

$$P(\text{type}) = (\alpha_{\text{ifast}} \text{incfast} + \alpha_{\text{ifancy}} \text{incfancy} + \alpha_{\text{kfast}} \text{kidfast} + \alpha_{\text{kfancy}} \text{kidfancy} + \tau_{\text{fast}} IV_{\text{fast}} + \tau_{\text{family}} IV_{\text{family}} + \tau_{\text{fancy}} IV_{\text{fancy}})$$

```
. nlogit chosen (restaurant= rating distance cost) (type= incfast incfancy kidfast kidfancy), group(family_id)
```

```
tree structure specified for the nested logit model
```

```
top --> bottom
type restaurant
-----
fast      Freebirds
          MamasPizza
family    CafeEccell
          LosNorte~s
          WingsNmore
fancy     Christop~s
          MadCows
```

```
initial:      log likelihood = -541.93581
rescale:      log likelihood = -516.99294
rescale eq:   log likelihood = -510.39664
Iteration 0:  log likelihood = -510.39664
Iteration 1:  log likelihood = -508.75368 (backed up)
Iteration 2:  log likelihood = -505.23722 (backed up)
Iteration 3:  log likelihood = -498.08005 (backed up)
Iteration 4:  log likelihood = -494.93474 (backed up)
Iteration 5:  log likelihood = -492.89435 (backed up)
Iteration 6:  log likelihood = -492.41033 (backed up)
Iteration 7:  log likelihood = -492.31709
Iteration 8:  log likelihood = -491.45947
Iteration 9:  log likelihood = -487.75138
Iteration 10: log likelihood = -486.50434
Iteration 11: log likelihood = -485.85764
Iteration 12: log likelihood = -485.05754
Iteration 13: log likelihood = -484.82224
Iteration 14: log likelihood = -484.65287
Iteration 15: log likelihood = -484.48107
Iteration 16: log likelihood = -484.3647
Iteration 17: log likelihood = -484.27657
Iteration 18: log likelihood = -484.23657
Iteration 19: log likelihood = -484.20561
Iteration 20: log likelihood = -484.12751
Iteration 21: log likelihood = -484.07884
Iteration 22: log likelihood = -484.04556
Iteration 23: log likelihood = -484.01043
Iteration 24: log likelihood = -483.96585
Iteration 25: log likelihood = -483.96055
Iteration 26: log likelihood = -483.96021
Iteration 27: log likelihood = -483.96009
Iteration 28: log likelihood = -483.96001
Iteration 29: log likelihood = -483.95975
```


Iteration 30: log likelihood = -483.95859
 Iteration 31: log likelihood = -483.95841

Nested logit regression
 Levels = 2 Number of obs =
 2100
 Dependent variable = chosen LR chi2(10) =
 199.6293
 Log likelihood = -483.9584 Prob > chi2 =
 0.0000

	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
restaurant rating	.1793759	.126895	1.41	0.157	-.0693338
distance	-.1745797	.0433352	-4.03	0.000	-.2595152
cost	-.0944352	.03402	-2.78	0.006	-.1611131
type					
incfast	-.0287502	.0116242	-2.47	0.013	-.0515332
incfancy	.0458373	.0089109	5.14	0.000	.0283722
kidfast	-.0704164	.1394359	-0.51	0.614	-.3437058
kidfancy	-.3626381	.1171277	-3.10	0.002	-.5922041
(incl. value parameters)					
type					
/fast	5.715758	2.332871	2.45	0.014	1.143415
/family	1.721222	1.152002	1.49	0.135	-.5366608
/fancy	1.466588	.4169075	3.52	0.000	.6494642

Nested logit analizinin sonuçları değerlendirilirken önemli olan değişkenlerin aldığı katsayı değerleridir. Bu değer bağımsız değişkenler ile bağımlı değişkenin arasındaki ilişkinin yönünü göstermektedir. Birinci blokta görüldüğü üzere notu yüksek olan restoran daha çok tercih edilmektedir. Bunun yanı sıra mesafe ve ödenen ücret arttığında uzak ve pahalı olan restoranın tercih edilme olasılığı azalmakta, yani mesafe ve ödenen ücret azaldıkça yakın ve ucuz olan restoranın tercih edilme olasılığı artmaktadır. Not restoran kategorileri tercihleri üzerinde pozitif bir etki yaratırken, mesafe ve ödenen ücret negatif bir etki yaratmaktadır.

İkinci blok ise farklı değişkenlerin (gelir ve çocuk sayısı) kategori tercih olasılığına etkilerini göstermektedir. Burada gelirin artması aile restoranına göre fast-food restoranlarının tercih olasılığını azaltmakta; lüks restoranlarını arttırmaktadır. Çocuk sayısındaki artış ise aile restoranlarına göre fast-food ve lüks restoranların

tercih olasılığını azaltmaktadır. Yani hanedeki çocuk sayısı arttıkça aile restoranı tercihi de artmaktadır. Çocuk sayısı aile restoranı tercihi etme olasılığını pozitif yönde etkilemektedir.

Diğer bir modelde bağımsız değişkenlerin kategoriler yerine 3 kategorinin alt grubu olan 7 restoranın tercih edilme olasılığı üzerindeki etkileri araştırılmıştır. Yapılan analizde yine nested logit kullanılmış ve aşağıdaki sonuçlar elde edilmiştir.

```
. nlogit chosen (restaurant= incfast1 incfam3 incfam4 incfancy6 rating
distance cost) (type= incfast incfancy kidfast kidfancy), group(family_id)
```

```
tree structure specified for the nested logit model
```

```

      top --> bottom
      type   restaurant
-----
      fast   Freebirds
            MamasPizza
family     CafeEccell
            LosNorte~s
            wingsNmore
fancy     Christop~s
            MadCows

```

```

initial:      log likelihood = -533.81288
rescale:      log likelihood = -510.46776
rescale eq:   log likelihood = -505.47998
Iteration 0:  log likelihood = -505.47998
Iteration 1:  log likelihood = -503.01693 (backed up)
Iteration 2:  log likelihood = -502.30797 (backed up)
Iteration 3:  log likelihood = -499.09695 (backed up)
Iteration 4:  log likelihood = -498.57137 (backed up)
Iteration 5:  log likelihood = -498.51287 (backed up)
Iteration 6:  log likelihood = -498.26433 (backed up)
Iteration 7:  log likelihood = -497.99086 (backed up)
Iteration 8:  log likelihood = -497.60857 (backed up)
Iteration 9:  log likelihood = -494.82095 (backed up)
Iteration 10: log likelihood = -491.28028
Iteration 11: log likelihood = -490.22786 (backed up)
Iteration 12: log likelihood = -489.8298
Iteration 13: log likelihood = -488.75992
Iteration 14: log likelihood = -488.26451
Iteration 15: log likelihood = -487.95983
Iteration 16: log likelihood = -485.553
Iteration 17: log likelihood = -484.84185
Iteration 18: log likelihood = -484.5002
Iteration 19: log likelihood = -484.03505
Iteration 20: log likelihood = -483.90726
Iteration 21: log likelihood = -483.80935
Iteration 22: log likelihood = -483.77382
Iteration 23: log likelihood = -483.74347
Iteration 24: log likelihood = -483.71657
Iteration 25: log likelihood = -483.67725
Iteration 26: log likelihood = -483.66281
Iteration 27: log likelihood = -483.6571
Iteration 28: log likelihood = -483.64194
Iteration 29: log likelihood = -483.6252
Iteration 30: log likelihood = -483.61929
Iteration 31: log likelihood = -483.61584
Iteration 32: log likelihood = -483.60495
Iteration 33: log likelihood = -483.60113
Iteration 34: log likelihood = -483.60017
Iteration 35: log likelihood = -483.59995
Iteration 36: log likelihood = -483.59985
Iteration 37: log likelihood = -483.59974
Iteration 38: log likelihood = -483.59929

```

Iteration 39: log likelihood = -483.59748
Iteration 40: log likelihood = -483.59723
Iteration 41: log likelihood = -483.59722

Nested logit regression
Levels = 2 Number of obs =
2100
Dependent variable = chosen LR chi2(14) =
200.3516
Log likelihood = -483.59722 Prob > chi2 =
0.0000

	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
restaurant					
incfast1	.0028015	.0102819	0.27	0.785	-.0173507
incfam3	.0001905	.0038176	0.05	0.960	-.0072918
incfam4	-.0045515	.0058302	-0.78	0.435	-.0159784
incfancy6	.0004867	.0056919	0.09	0.932	-.0106691
rating	.3099319	.2093162	1.48	0.139	-.1003203
distance	-.1682909	.0454619	-3.70	0.000	-.2573945
cost	-.0902937	.0292026	-3.09	0.002	-.1475297
type					
incfast	-.0383177	.0323529	-1.18	0.236	-.1017281
incfancy	.0430348	.012134	3.55	0.000	.0192525
kidfast	-.0750373	.1378352	-0.54	0.586	-.3451893
kidfancy	-.374557	.1200802	-3.12	0.002	-.6099098
(incl. value parameters)					
type					
/fast	5.645649	2.463268	2.29	0.022	.8177325
/family	1.597138	1.236103	1.29	0.196	-.8255791
/fancy	1.777938	.8327754	2.13	0.033	.1457284

Birinci blokta farklı değişkenlerin restoran tercihi edilme olasılıklarına olan negatif ya da pozitif etkileri görülmektedir. Yani herhangi bir faktördeki değişimin hangi restoranın tercih olasılığını arttırdığı ya da azalttığı incelenmiştir. Gelir arttığında Mamas Pizza'ya göre Freebird'ün tercih edilme olasılığı artmaktadır. Aile restoranları için ise gelirdeki artış WingsNmore'a göre Caffè Eccell'in tercih edilme olasılığını artırıyor iken Los Nortenos'un tercih edilme olasılığını azaltmaktadır. Yani hane halkı geliri arttıkça WingNmore yerine Caffè Eccell'i tercih etmektedir.

Aynı durum lüks restoran kategorisinde şöyle olmaktadır. Gelirdeki artış Mad Cows'a göre Christophers'in tercih edilme olasılığını arttırmaktadır. Ayrıca Blok 1'de marjinal etki olmayan restoran notu arttıkça; notu artan restoranın tercih edilme olasılığı pozitif yönde etkilenmekte, mesafe ve ödenen ücretteki artışlar restoranları negatif yönde etkilemektedir.

İkinci blokta ise yine farklı değişkenlerin kategori tercih edilme olasılığına etkileri görülmektedir. Gelirin artışı aile restoranlarına göre fast-food restoranların tercih edilme olasılığını pozitif yönde etkiliyor iken lüks restoranın tercih edilme olasılığını negatif yönde etkilemektedir, yani hane halkı geliri arttıkça aile restoranı fast-food restoran tercih etmektedirler. Fakat geliri artan hane halkı aile restoranı yerine lüks restoranları tercih etmektedir diyebiliriz. Çocuk sayısının restoran tercihi üzerindeki etkisi ise şöyle açıklanabilir. Çocuk sayısı fazla olan hane halkı bireyleri aile restoranına göre sayı arttıkça fast-food ve lüks restoranların tercih edilme olasılıkları negatif yönde etkilenmekte yani azalmaktadır.

Bu modeller araştırmanın ne şekilde olmasına bağlı olarak değişmektedir. Bu değişim hem bağımsız değişkenleri hem kategorilere ayırmayı hem de kategorileri etkileyen değişkenlerin nasıl modele katılacağını etkilemektedir. Çünkü yorumlar araştırmacının belirlediği karşılaştırma kategorilerine göre ortaya çıkmaktadır.

6. SONUÇ

Tercih modelleri bireysel tercih davranışı teorilerinden yararlanarak tüketici tercihlerinin ölçüm ve modellenmesinin yapıldığı ekonometrik bir yöntemdir. Tercih davranışı teorisi karar verici, alternatif, alternatiflerin nitelikleri ve karar kuralları gibi faktörlerin toplamı olan bir süreçtir. Karar vericiler bir birey ya da hane halkı olabilmesinin yanı sıra şirket gibi kurumsal birimlerde olabilir. Alternatifler karar vericinin tercih kümesinde yer almaktadır. Tercih kümesi uygulamanın içeriğine bağlı olarak kesikli ya da sürekli olmaktadır. Uygulama kapsamında kullanılan kesikli tercih kümesi sonlu sayıda alternatif içermektedir. Alternatiflerin nitelikleri bireyin tercih yaparken etkilendiği faktörlerdir. Bazı nitelikler her bir alternatif için spesifik iken bazıları için ortaktır. Karar verici bu alternatifleri ve nitelikleri değerlendirdikten sonra faydasını maksimize eden alternatifi tercih etmektedir. Fayda maksimizasyonu karar verici için bir karar kuralıdır. Mikro ekonomide karar kuralları ile ilgili birçok teori bulunmaktadır, fakat karar sürecinde etkili olan en temel teoriler Lancaster'in genişlettiği neoklasik teori, von Neumann-Morgenstern'in belirsizlik altında tercih teorisi, Luce fayda modeli ve Thurstone'un psikoloji alanında kullandığı sabit fayda modelidir.

Neoklasik ekonomik teorinin amacı karar vericilerin ekonomik alternatifler arasından nasıl tercih yaptıklarının belirlenmesidir. Bu teorinin tercih modelleri için genişletilmesinin ilk sebebi Lancaster'in alternatifleri niteliklerin bir bileşeni olarak tanılaması ve böylece yeni bir ürün piyasaya çıktığında tekrardan parametreleştirilmeye gerek duyulmamasıdır. İkincisi ise ikame ve tamamlayıcı ürünlerin yorumlanması daha anlamlı kılabilir.

Von Neumann-Morgenstern teorisinde ise araştırmacının elinde yeterli kaynak bulunmadığı ortamda ve gözlenmemiş alternatiflerin nitelikleri, gözlenmemiş bireysel nitelikler ve gözlenmemiş beğeni değişimi gibi değişkenler ile tercih yapıldığını varsaymaktadır.

Luce fayda modeli ise Thurstone sabit fayda modelinin özel bir durumudur. Sabit fayda modellerini gözlenen tercihlerin geçişsiz olduğu durumlarda tercihleri olasılıklı olarak açıklamak için geliştirilmiştir.

Bu teorilerden Luce ve Thurstone modelleri kesikli tercih yapına sahiptirler. Kesikli tercih modellerine dayanan bu teorilerde cevabı aranan soru, karar vericinin alternatifleri niteliklerine göre değerlendirildiği varsayıldığında tercih kümesinin hangisini tercih edeceğidir.

Kesikli tercih modelleri genellikle pazarlama araştırmaları ve ulaşım problemlerinde kullanılmaktadır. Modele kesikli denmesinin başlıca sebebi bağımlı değişkenin kesikli değerler almasıdır. Kesikli bağımlı değişkenin aldığı değerler karar vericiye sunulan alternatiflerdir. Modelin bağımsız değişkenleri ise karar vericiyi ve tercih alternatifinin tanımlamaktadır.

Tüketicilerin çok nitelikli alternatifler arasından tercihlerini nasıl yaptıklarını analiz etmek başlı başına bir problemdir. Öncelikle karar vericinin tercih yaparken kullandığı tercih kümesi, tercih olasılıkları ve bunların nasıl kestirileceğinin bilinmesi gerekmektedir.

Tercih kümesinin 7 restorandan oluştuğu ve 300 ailenin hanenin ele alındığı tercih durumunda bağımsız değişkenler gelir, çocuk sayısı, restoran notu, bir öğüne ödenen fiyat ve ev ile restoran arasındaki mesafedir. Bu değişkenler 4. bölümde tanımlanan modeller kullanılarak çözümlenmiştir. Ancak kesikli tercih modellerinin her birinin kullanıldığı durumlar farklıdır. Örneğin çokterimli logit ve koşullu logit modellerinde bağımlı değişken ikiden fazla düzeye sahip olmalıdır. Koşullu logiti çokterimli logitten ayıran en önemli fark verilerin modellenmesinde hane halkı no'sunun (group id) dikkate alınmasıdır. Nested logit modelde ise nitelikler arasında kategorilere ayırma söz konusudur ve IIA varsayımının sağlanmaması gerekmektedir.

Verilerimiz için bu modellerden hangisinin uygun olduğunun belirlenmesinde STATA ile yapılan Hausman testi sonucunda bazı kategoriler için IIA'nın sağlanmadığı görülmüştür. Çokterimli logit model yardımıyla yapılan testler

sonucunda 2. ve 3. kategori için IIA'nın sağlanmadığı saptanmıştır. Koşullu logit model ile yapılan testlerde ise tüm kategorilerde IIA'nın sağlanmadığı görülmüştür. Bu durumda verilerimiz için kullanılacak en uygun kesikli tercih modeli nested logittir.

Nested logit ile yapılan analiz sonucunda notu yüksek, ev ile mesafesi yakın ve ödenen ücretin düşük olduğu restoranın tercih edilme olasılığı yüksektir. Yani bu üç bağımsız değişken restoran tercih olasılığını pozitif yönde etkilemektedir. Geliri artan hane halkı ise aile restoranı yerine lüks restoranları tercih etmektedir. Hanedeki çocuk sayısındaki artış ise aile restoranlarının tercih edilmesini sağlamaktadır. Bu bağımsız değişkenlerin kategoriler yerine daha spesifik olan restoranlar üzerinde yarattığı etkiler de incelenmiştir. Geliri artan hane halkı fast-food restoranlarından Freebird'ü, aile restoranlarından Cafee Eccell'i ve lüks restoranlardan Christopher'ı tercih etmektedir.

Kesikli tercih modelleri istatistiksel bir modelleme tekniği olduğundan kullanılan model yardımı ile geleceğe ilişkin tahminler yapılabilmektedir. İleriye dönük tahminler için kullanılan kesikli tercih modelinin doğru bir şekilde belirlenmesi çok önemlidir. Bu sebepten verilere uygulanacak modelin belirlenmesinde öncelikli olarak modelin varsayımlarının sağlanması gerekmektedir. Etkin modelin belirlenmesinden sonra elde edilen sonuçların istenilen ayrıntıya sahip olabilmesinde kullanılan istatistiksel paket programın önemli bir payı vardır. Çokterimli logit, koşullu logit ya da nested logit gibi modellerin STATA ile ayrıntılı ve daha pratik sonuçlar verdiği görülmüştür.

KAYNAKLAR

- Akın, F.**, 2002. Kalitatif Tercih Modelleri Analizi, Motif Matbaası, İstanbul.
- Anas, A.**, 1983. Discrete Choice Theory, Information Theory and The Multinational Logit and Gravity Models, *Transportation Research*, **17B**, 13-23.
- Amemiya, T.**, 1981. Qualitative Response Models: A Survey, *Journal of Economic Literature*, **19**, 1483-1536.
- Aslan, H.**, 2006. Bireylerin Otomobil Seçiminin Çoklu Tercih Modelleri ile Analizi, Yüksek Lisans Tezi, *Marmara Üniversitesi, Sosyal Bilimler Enstitüsü*, İstanbul.
- Barten, A.**, 1977. The Systems of Consumer Demand Functions Approach: A Review, *Econometrica*, **47**, 23-52.
- Batsell, R., Lodish, L.**, 1981. A Model and Measurement Methodology for Predicting Individual Consumer Choice, *Journal of Marketing Research*, **18**, 1-12.
- Ben-Akiva, M., Lerman, S., 1985. Discrete Choice Analysis, MIT Press, Mass.
- Bierlaire, M.**, 1997. Discrete Choice Models, <http://roso.epfl.ch/mbi/papers/discretechoice/paper.html> 20 Haziran 2008
- Börsch-Supan, A.**, 1987. Econometric Theory of Discrete Choice, *Lecture Notes in Economics and Mathematical Systems*, Springer-Verlag, Berlin, Heidelberg.
- Brown, A., Deaton, A.**, 1972. Surveys in Applied Economics: Models of Consumer Behavior, *Economic Journal*, **82**, 1142-1236.
- Carroll, J.D., Green, P.E.**, 1995. Psychometric Methods in Marketing Research: Part I, Conjoint Analysis, *Journal of Marketing Research*, **32**, 385-391.
- Corstenjs, M.L., Gautschi, D.**, 1983. Formal Choice Models in Marketing, *Marketing Science*, **2**, 19-56.
- Cox, D.**, 1970. Analysis of Binary Data, Methuen Press, London.
- Daganzo, C.**, 1980. Multinomial Probit: The Theory and Its Applications to Demand Forecasting, Academic Press, New York.

Domencich, T., Mc Fadden, D., 1975. Urban Travel Demand, North-Holland, Amsterdam.

Emeç, H., 2002. Ege Bölgesi Tüketim Harcamaları İçin Sıralı Logit Tahminleri ve Senaryo Sonuçları, *Dokuz Eylül Üniversitesi Sosyal Bilimler Enstitüsü Dergisi* , Cilt 4, 2, s.5-6.

Fishbein, M., 1967. A Behaviour Theory Approach to the Relations between Beliefs about an Object and the Attitude toward Object, in *Readings in Attitude Theory and Measurement*, p. 394-396, Ed. Fishbein, M., Academic Press, New York.

Goldfeld, S.M., Quandt, R.E., 1972. Nonlinear Methods in Econometrics, North-Holland Publishing Company, Amsterdam.

Goldman, S., Uzawa, H., 1964. A Note on Separability in Demand Analysis, *Econometrica*, **35**, 485-494.

Gujarati, D., 1988. Basic Econometrics, 2. basım, McGraw-Hill Inc, New York.

Greene, W.H., 1993. Econometric Analysis, Macmillan Publishing Company, New York.

Greene, W.H., 1997. Econometric Analysis, Prentice Hall, Upper Saddle River.

Green, P., Srinivasan, V., 1978. Conjoint Analysis in Consumer Research: Issues and Outlook, *Journal of Consumer Research*, **5**, 103-123.

Hansen, F., 1976. Psychological Theories of Consumer Choice, *Journal of Consumer Research*, **3**, 117-142.

Hauser, J., Simmie, P., 1981. Profit Maximizing Perceptual Positions, *Management and Science*, 33-56.

Hausman, J., Wise, D., 1978. A Conditional Probit Model for Qualitative Choice: Discrete Decisions Recognizing Interdependence and Heterogeneous Preferences, *Econometrica*, **48**, 403-426.

Kahneman, D., Tversky, A., 1979. Prospect Theory: An Analysis of Decision under Risk, *Econometrica*, **43**, 263-291.

- Keeney, R.**, 1972. Utility Functions for Multiattributed Consequences, *Management Science*, **18**, 276-287.
- Kihlstrom, R.**, 1974. A General Theory of Demand for Information about Product Quality, *Journal of Economic Theory*, **7**, 413-439.
- Koppelman, F. S., and Wen, C.H.**, 1997. Alternative Nested Logit Models: Structure, Properties and Estimation, Submitted to *Transportation Research Board, Washington*.
- Koutsoyiannis, A.**, 1987. Modern Mikro İktisat, Özkan Matbaası, Ankara.
- Lancaster, K.**, 1966. A New Approach to Consumer Theory, *Journal of Political Economy*, **74**, 132-157.
- Lancaster, K.**, 1971. Consumer Demand: A New Approach, Columbia University Press, New York.
- Luce, R.**, 1959. Individual Choice Behaviour, John Wiley and Sons, New York.
- Luce, R.**, 1977. The Choice Axiom after Twenty Years, *Journal of Mathematical Psychology*, **15**, 215-233.
- Luce, R., Suppes, R.**, 1965. Preference, Utility and subjective Probability, in *Handbook of Mathematical Psychology*, **15**, p. 249-410, Eds. Luce, R., Bush, R. And Galanter, E., John Wiley and Sons, New York.
- Luce, R., Tukey, J.**, 1964. Simultaneous Conjoint Measurement: A New Type of Fundamental Measurement, *Journal of Mathematical Psychology*, **1**, 1-27.
- Marschak, J.**, 1960. Binary Choice Constraints on Random Utility Indications, Stanford Symposium on Mathematical Methods in Social Sciences, Stanford, CA, 312-329.
- Marshak, J., Meyer, R. ve Becker, G.**, 1963. Stochastic Models of Choice Behavior, *Behavioral Science*, **8**, 51-55.
- Mc Fadden, D.**, 1973. Conditional Logit Analysis of Qualitative Choice Behavior, in *Frontiers in Econometrics*, p. 105-142, Ed. Zarembka, P., Academic Press, New York.

McFadden, D., 1978. Modelling the Choice of Residential Location, in *Spatial Interaction Theory and Planning Models*, p. 75-96, Eds. Karlqvist, A., Lundqvist, L. Snickors, F. And Weibull, J., North Holland, Amsterdam.

McFadden, D., 1981. Econometric Models of Probabilistic Choice, in *Structural Analysis of Discrete Data*, p. 198-272, Eds. Manski, C., Mc Fadden, D., MIT Press, Cambridge.

Nakanishi, M., Cooper, L., 1974. Parameter Estimation for a Multiplicative Competitive Interaction Model-Least Squares Approach, *Journal of Marketing Research*, **11**, 303-311.

Osmanoğlu, S., 2005. Kesikli Seçim Analizi ve Bir Uygulama, *Yüksek Lisans Tezi*, Hacettepe Üniversitesi, Fen-Edebiyat Fakültesi, Ankara.

Pollak, R., 1967. Additive von Neumann-Morgenstern Utility Functions, *Econometrica*, **35**, 485-494.

Power, D.A., Xie, Y., 2000. Statistical Methods for Categorical Data Analysis, Academic Press, New York.

Rosenberg, M., 1956. Cognitive Structure and Attitudinal Affect, *Journal of Abnormal Psychology*, **53**, 367-372.

Schocker, A., Srinivasan, V., 1979. Multiattribute Approaches for Product Concept Evaluation and Generation: A Critical Review, *Journal of Marketing Research*, **16**, 159-180.

Srinivasan, V., 1988. A Conjunctive-Compensatory Approach to Self-Explication of Multiattributed preference, *Decision Sciences*, **19**, 295-305.

Swait, J., Louviere, J., 1993. The Role of the Scale Parameter in the Estimation and use of Multinomial Logit Models, *Journal of Marketing Research*, **30**, 305-314.

Theil, H., 1969. A Multinomial Extension of the Linear Logit Model, *International Econometric Review*, **10**, 251-259.

Thurstone, L., 1927. A Law of Comparative Judgement, *Psychological Review*, **34**, 273-286.

Train, K.E., Mc Fadden, D. ve Ben-Akiva, M., 1987. The Demand for Local Telephone Service: A Fully Discrete Models of Residential Calling Patterns and Service Choice, *Rand Journal of Econometrics*, **18**, 109-123.

Von Neuman, J., Morgenstern, O., 1947. The Theory of Games and Economic Behavior, Princeton University Press, Princeton.

Zwerina, K., 1997. Discrete Choice Experiment in Marketing, Physica-Verlag Heidelberg, Germany.

Stata Reference Manual, Release 7, Volume 2 H-P, Stata Press, College Station, Texas.

www.stata-press.com/data/r10/restaurant

ÖZGEÇMİŞ

Bahar KINAY, 11.02.1983'te İstanbul'da doğdu. İlkokulu Lütfi Banat İlköğretim Okulu'nda, ortaokul ve liseyi Kadıköy Anadolu Lisesi'nde okudu. 2002 yılında Dođuş Üniversitesi İktisadi ve İdari Bilimler Fakültesi İşletme bölümünü burslu olarak kazandı. 2006 yılında Dođuş Üniversitesi'nden mezun olup, bu üniversitede araştırma görevlisi olarak işe başladı. 2007 yılında Mimar Sinan Güzel Sanatlar Üniversitesi Fen Bilimleri Enstitüsü İstatistik yüksek lisans programına başladı ve halen devam etmektedir. 2009 yılında Mimar Sinan Güzel Sanatlar Üniveritesi İstatistik bölümünde araştırma görevlisi olarak işe başladı.