

**T.C.**  
**Mersin Üniversitesi**  
**Eđitim Bilimleri Enstitüsü**  
**Eđitim Bilimleri Anabilim Dalı**  
**Eđitimde Ölçme ve Deđerlendirme Bilim Dalı**

**BİLİŐSEL TANI MODELLERİNDE PARAMETRE KESTİRİMİNİ VE SINIFLAMA**  
**TUTARLILIđINI ETKİLEYEN FAKTÖRLERİN İNCELENMESİ**

**DOKTORA TEZİ**

**Seçil ÖMÜR SÜNBÜL**

**Mersin, 2013**

**T.C.**  
**Mersin Üniversitesi**  
**Eđitim Bilimleri Enstitüsü**  
**Eđitim Bilimleri Anabilim Dalı**  
**Eđitimde Ölçme ve Deđerlendirme Bilim Dalı**

**BİLİŐSEL TANI MODELLERİNDE PARAMETRE KESTİRİMİNİ VE**  
**SINIFLAMA TUTARLILIđINI ETKİLEYEN FAKTÖRLERİN İNCELENMESİ**

**DOKTORA TEZİ**

**Seçil ÖMÜR SÜNBUĐ**

**Tez DanıŐmanı**  
**Doç. Dr. Adnan KAN**

**Mersin, 2013**

**KABUL VE ONAY**

Mersin Üniversitesi Eğitim Bilimleri Enstitüsü Müdürlüğü'ne,

Seçil ÖMÜR SÜNBÜL tarafından hazırlanan "Bilişsel Tanı Modellerinde Parametre Kestirimini ve Sınıflama Tutarlılığını Etkileyen Faktörlerin İncelenmesi" başlıklı bu çalışma, jürimiz tarafından Eğitimde Ölçme ve Değerlendirme Anabilim Dalı'nda DOKTORA TEZİ olarak kabul edilmiştir.

Başkan .....  
Prof. Dr. Adnan ERKUŞ

Üye.....  
Doç. Dr. Adnan KAN (Danışman)

Üye.....  
Doç. Dr. Cem Oktay GÜZELLER

Üye.....  
Yrd. Doç. Dr. Deyrim ALICI

Üye.....  
Yrd. Doç. Dr. Önder SÜNBÜL

Onay

Yukarıdaki imzaların, adı geçen öğretim üyelerine ait olduğunu onaylarım.

24.1.2016



## TEŞEKKÜR

Tezimin bütün aşamalarında bana destek olan, yol gösteren ve emek harcayan değerli hocam ve danışmanım Doç. Dr. Adnan KAN'a teşekkür ederim.

Lisansüstü eğitimim en başından itibaren benim akademik ve kişisel gelişimim için büyük çaba harcayan, desteğini ve sevgisini esirgemeyen, gerek tez aşamasında gerekse diğer çalışmalarında bilgisiyle katkı sunan çok değerli bilim hocam Prof. Dr. Adnan ERKUŞ'a teşekkür ederim.

Tezimin şekillenmesine yardımcı olan ve sorularıma kısa sürede cevap verip katkıda bulunan çok değerli hocam Doç. Dr. Robert HENSON'a ve Olga KUNINA-HABENICHT'e teşekkür ederim.

Yoğun çalışma sürecim boyunca sınırsız desteği ve sabrıyla her zaman yanımda olan, bana destek olan ve emek harcayan Yrd. Doç. Dr. Önder SÜNBÜL'e çok teşekkür ederim. Tez savunma jürimde bulunan emek ve zaman harcayarak çalışmama katkıda bulunan Yrd. Doç. Dr. Devrim ALICI'ya ve Doç. Dr. Cem Oktay GÜZELLER'e teşekkür ederim.

Hep yanımda oldukları, varlıklarıyla bana güç verdikleri için canım anneme ve babama sonsuz teşekkür ederim.

## ÖZET

# BİLİŞSEL TANI MODELLERİNDE PARAMETRE KESTİRİMİNİ VE SINIFLAMA TUTARLILIĞINI ETKİLEYEN FAKTÖRLERİN İNCELENMESİ

Seçil ÖMÜR SÜN BÜL

Doktora Tezi

Eğitim Bilimleri Enstitüsü

Doç. Dr. Adnan KAN (Danışman)

MERSİN, 2013

130 Sayfa

Bu çalışmanın amacı, Bilişsel Tanı Modelleri'nde madde parametre kestirimini ve sınıflama tutarlılığını etkileyen faktörlerin neler olduğunun incelenmesi ve tamamlayıcı model (DINO) ile tamamlayıcı olmayan modellerin (DINA) hangi durumlarda yanlılık ve sınıflama tutarlılığı açısından örtüştüğünün ya da ayrıştığının araştırılmasıdır.

Bu amaç doğrultusunda, tamamlayıcı olmayan model (DINA) kullanılarak çeşitli faktörlere (örneklem büyüklüğü, özellikler arası korelasyon, özellik sayısı, madde sayısı, s (kaydırma) ve g (tahmin) parametre düzeyleri) göre veri üretilmiştir. Üretilen veri ise, hem DINA hem de DINO modele göre analiz edilmiş ve her bir durum için 100 yineleme (replikasyon) yapılmıştır. Veri üretimi ve verinin modellere göre analizi R 3.0 programında CDM paketi kullanılarak gerçekleştirilmiştir. Parametre kestirimi, madde uyumu ve sınıflama tutarlılığı için elde edilen 576 tane çıktı dosyası değişimleme ölçütlerine göre hem temel etkiler hem de ortak etkiler bazında düzenlenmiştir.

DINA analiz modeli kullanılarak, g parametre kestirimi için elde edilen "Mutlak Ortalama Yanlılık (MOY)" ortalamalarına, örneklem büyüklüğünün, madde sayısının ve s

ve g parametre düzeylerinin anlamlı bir etkisinin olduğu gözlenmiştir. s parametre kestiriminden elde edilen MOY ortalamalarına ise, örneklem büyüklüğünün, özellikler arası korelasyon düzeyinin ve s ve g parametre düzeylerinin anlamlı bir etkisinin olduğu gözlenmiştir.

DINA analiz modeli kullanılarak madde uyumu için elde edilen RMSEA ortalama değerlerine, örneklem büyüklüğünün, özellik sayısının, madde sayısının ve s ve g parametre düzeylerinin anlamlı bir etkisinin olduğu gözlenmiştir.

DINA analiz modeli kullanılarak sınıflama tutarlılığı için elde edilen “Doğru Sınıflama Oranları (DSO) sonuçları incelendiğinde ise, özellik sayısının, madde sayısının ve s ve g parametre düzeylerinin anlamlı bir etkisinin olduğu gözlenmiştir.

DINO analiz modeli kullanılarak g ve s parametre kestirimi, madde uyumu ve sınıflama tutarlılığı hesaplamasından elde edilen sonuçlar incelendiğinde özellikler arası korelasyon düzeyinin, özellik sayısının, madde sayısının ve s ve g parametre düzeylerinin anlamlı bir etkisinin olduğu gözlenmiştir.

Genel sonuç olarak, hem g ve s parametre kestirimleri hem de madde uyumu hesaplamalarında, tüm faktörlerin her koşul düzeylerinde, DINA analiz modelinden elde edilen sonuçların, DINO analiz modelinden elde edilen sonuçlara göre daha düşük olduğu gözlenmiştir.

**Anahtar Kelimeler:** Bilişsel Tanı Modelleri, DINA model, DINO model, parametre kestirimi, sınıflama tutarlılığı

**ABSTRACT****FACTORS AFFECTING THE ITEM PARAMETER ESTIMATION AND  
CLASSIFICATION ACCURACY OF THE COGNITIVE DIAGNOSTIC MODELS****Seçil ÖMÜR SÜNBL**

PhD thesis

Institute of Education Sciences

Assoc. Prof. Dr. Adnan KAN (Advisor)

MERSİN, 2013

130 Pages

The purpose of this study is to investigate the factors affecting the item parameter estimation and classification accuracy of the Cognitive Diagnostic Models (CDM) and to determine in which case the compensatory models (DINO) and noncompensatory models (DINA) overlap.

For this purpose, the data is generated by using noncompensatory model (DINA) according to various factors (sample size, correlation between attributes, the number of attributes, the number of item, s and g parameters levels). For this study 576 experimental cells were designed for data simulation and 100 replications were conducted for each cell. The simulated data were analyzed by using DINA and DINO models. Data simulation and analyses were conducted by using R 3.0 with CDM package. The output files were organized for parameter estimation, item fit and classification accuracy for both main and interaction effects.

By using DINA analysis model, it was observed that there were significant effects of sample size, number of items and levels of g and s parameters on the mean "Absolute

Mean Bias” (AMB) values obtained for g parameter estimation. The results of DINA analysis model showed that there were significant effects of sample size, level of the correlation between attributes and level of the s and g parameters on the mean AMB values obtained for s parameter estimation.

Furthermore, by using DINA analysis model, it was observed that there were significant effects of sample size, number of item, number of attribute and levels of g and s parameters on the mean RMSEA values. The results of DINA analysis model showed that there were significant effects of number of item, number of attribute and levels of g and s parameters on the mean values of “Correct Classification Rate (CCR)”.

According to results of DINO analysis model, there were significant effects of number of item, level of the correlation between attributes, number of attribute and levels of g and s parameters on the mean AMB values obtained for g and s parameter estimation, the mean RMSEA and CCR values.

Additionally, it was observed that, the mean values of AMB and RMSEA obtained from DINA analysis model were lower than the values obtained from DINO analysis model both for all the factors and for all factors levels.

**Key Words:** Cognitive Diagnostic Models, DINA Model, DINO Model, parameter estimation, classification accuracy



## İÇİNDEKİLER

KABUL VE ONAY .....	ii
TEŞEKKÜR .....	iii
ÖZET .....	iv
ABSTRACT .....	vi
İÇİNDEKİLER.....	viii
TABLolar DİZİNİ .....	xii
ŞEKİLLER DİZİNİ .....	xv
GRAFİKLER DİZİNİ .....	xvi
SİMGELER VE KISALTMALAR DİZİNİ .....	xx
<b>BÖLÜM 1 : GİRİŞ .....</b>	<b>1</b>
1.1. Tanı Sınıflama Modelleri (Diagnostic Classification Models).....	4
1.1.1. Bilişsel Tanı Modeli Sınıflaması .....	7
1.1.2. Q Matrisi .....	9
1.1.3. Örtük Sınıf (Latent Class) .....	11
1.1.4. Bilişsel Tanı Modellerinin İstatistiksel Yapısı .....	13
1.1.5. Tamamlayıcı Olmayan Model .....	15
1.1.5.1. DINA (Deterministic Input Noisy “And”) Model .....	16

1.1.5.2. NIDA (Noisy Input Deterministic “And”) Model .....	19
1.1.5.3. Tamamlayıcı Olmayan RUM (Reparameterized Unified Model) Model .....	20
1.1.6. Tamamlayıcı Model .....	22
1.1.6.1. DINO (Deterministic Input Noisy “Or”) Model .....	22
1.1.6.2. NIDO (Noisy Input, Deterministic “Or”) Model .....	24
1.1.6.3. Tamamlayıcı RUM .....	25
1.1.7. Bilişsel Tanı Modellerinde Madde Parametre Kestirimi .....	25
1.1.8. Bilişsel Tanı Modellerinde Güvenirlik .....	26
1.2. BTM Modelleri Kullanılarak Yapılan Çalışmalar .....	28
1.3. Araştırmanın Amacı ve Önemi .....	35
1.4. Problem Cümlesi .....	36
1.4.1. Alt Problemler .....	36
1.5. Sınırlılıklar .....	38
<b>BÖLÜM II: YÖNTEM .....</b>	<b>39</b>
II. 1. Araştırmanın Türü .....	39
II. 2. Veri Üretim ve Veri Analiz Koşulları .....	39
II. 3. İşlem .....	43

II. 4. Verilerin Analizi .....	43
<b>BÖLÜM III: BULGULAR .....</b>	<b>47</b>
III.1.1. Çeşitli faktörlerin (örneklem büyüklüklerinin, özellikler arası korelasyonun, özellik sayılarının, madde sayılarının, s ve g parametre düzeylerinin ve DINA ve DINO analiz modellerinin), g parametre kestirimleri için elde edilen MOY ortalamalarına temel etkileri nasıldır? .....	47
III.1.2. Çeşitli faktörlerin (örneklem büyüklüklerinin, özellikler arası korelasyonun, özellik sayılarının, madde sayılarının, s ve g parametre düzeylerinin), g parametre kestirimleri için elde edilen MOY ortalamalarına ortak etkileri nasıldır? .....	57
III.2.1 Çeşitli faktörlerin (örneklem büyüklüklerinin, özellikler arası korelasyonun, özellik sayılarının, madde sayılarının, s ve g parametre düzeylerinin ve DINA ve DINO analiz modellerinin), s parametre kestirimleri için elde edilen MOY ortalamalarına temel etkileri nasıldır? .....	66
III.2.2. Çeşitli faktörlerin (örneklem büyüklüklerinin, özellikler arası korelasyonun, özellik sayılarının, madde sayılarının, s ve g parametre düzeylerinin), s parametre kestirimleri için elde edilen MOY ortalamalarına ortak etkileri nasıldır? .....	74
III.3.1. Çeşitli faktörlerin (örneklem büyüklüklerinin, özellikler arası korelasyonun, özellik sayılarının, madde sayılarının, s ve g parametre düzeylerinin ve DINA ve DINO analiz modellerinin), madde uyumu için elde edilen ortalama RMSEA ortalamalarına temel etkileri nasıldır? .....	84

III.3.2. Çeşitli faktörlerin (örneklem büyüklüklerinin, özellikler arası korelasyonun, özellik sayılarının, madde sayılarının, s ve g parametre düzeylerinin), madde uyumu için elde edilen ortalama RMSEA ortalamalarına ortak etkileri nasıldır? .....92

III.4.1. Çeşitli faktörlerin (örneklem büyüklüklerinin, özellikler arası korelasyonun, özellik sayılarının, madde sayılarının, s ve g parametre düzeylerinin ve DINA ve DINO analiz modellerinin), Doğru Sınıflama Oranları (DSO) ortalamalarına temel etkileri nasıldır? .....101

III.4.2. Çeşitli faktörlerin (örneklem büyüklüklerinin, özellikler arası korelasyonun, özellik sayılarının, madde sayılarının, s ve g parametre düzeylerinin), sınıflama tutarlılığı için elde edilen DSO ortalamalarına ortak etkileri nasıldır? .....109

#### **BÖLÜM IV: TARTIŞMA ve YORUM .....116**

IV.1. g ve s Parametre Kestirimi İçin Elde Edilen Sonuçların Değerlendirilmesi .....116

IV.2. Madde Uyumu İçin Elde Edilen Sonuçların Değerlendirilmesi .....118

IV.3. Sınıflama Tutarlılığı İçin Elde Edilen Sonuçların Değerlendirilmesi .....119

#### **KAYNAKÇA .....122**

#### **EKLER.....128**

## TABLOLAR DİZİNİ

<b>Tablo 1:</b> Bilişsel Tanı Model Sınıflaması .....	7
<b>Tablo 2:</b> Tamamlayıcı ve Tamamlayıcı Olmayan Model Kuralları .....	8
<b>Tablo 3:</b> Q Matrisi Olası Tepkiler Örneği .....	10
<b>Tablo 4:</b> Olası Örtük Sınıf Örüntüleri .....	11
<b>Tablo 5:</b> Örnek Örtük Sınıf Örüntüleri.....	12
<b>Tablo 6:</b> DINA Modeldeki Tepki Olasılıkları.....	17
<b>Tablo 7:</b> Yapılan Değişimlemelere İlişkin Düzenek .....	42
<b>Tablo 8:</b> g Parametre Kestiriminde DINA Analiz Modeli Kullanıldığında Elde Edilen MOY Değerlerine İlişkin Faktörlerin Temel Etki Değerleri .....	48
<b>Tablo 9:</b> g Parametre Kestiriminde DINA Analiz Modeli Kullanıldığında Faktörlerin Temel Etkilerine İlişkin ANOVA Tablosu .....	49
<b>Tablo 10:</b> g Parametre Kestiriminde DINO Analiz Modeli Kullanıldığında Elde Edilen MOY Değerlerine İlişkin Faktörlerin Temel Etki Değerleri .....	52
<b>Tablo 11:</b> g Parametresi Kestiriminde DINO Analiz Modeli Kullanıldığında Faktörlerin Temel Etkilerine İlişkin ANOVA Tablosu .....	53
<b>Tablo 12:</b> g Parametresine İlişkin DINA ve DINO Analiz Modeli Karşılaştırılması.....	56
<b>Tablo 13:</b> s Parametre Kestiriminde DINA Analiz Modeli Kullanıldığında Elde Edilen MOY Değerlerine İlişkin Faktörlerin Temel Etki Değerleri .....	66

<b>Tablo 14:</b> s Parametresi Kestiriminde DINA Analiz Modeli Kullanıldığında Faktörlerin Temel Etkilerine İlişkin ANOVA Tablosu .....	67
<b>Tablo 15:</b> s Parametre Kestiriminde DINA Analiz Modeli Kullanıldığında Elde Edilen MOY Değerlerine İlişkin Faktörlerin Temel Etki Değerleri .....	70
<b>Tablo 16:</b> s Parametresi Kestiriminde DINO Analiz Modeli Kullanıldığında Faktörlerin Temel Etkilerine İlişkin ANOVA Tablosu .....	71
<b>Tablo 17:</b> s Parametresine İlişkin DINA ve DINO Analiz Modeli Karşılaştırılması .....	74
<b>Tablo 18:</b> DINA Analiz Modeli Kullanıldığında Faktörlerin RMSEA Ortalamalarına İlişkin Temel Etki Değerleri .....	84
<b>Tablo 19:</b> DINA Analiz Modeli Kullanılarak RMSEA Ortalamalarının Elde Edilmesinde Faktörlerin Temel Etkilerine İlişkin ANOVA Tablosu .....	85
<b>Tablo 20:</b> DINO Analiz Modeli Kullanıldığında Faktörlerin RMSEA Ortalamalarına İlişkin Temel Etki Değerleri .....	88
<b>Tablo 21:</b> DINO Analiz Modeli Kullanılarak RMSEA Ortalamalarının Elde Edilmesinde Faktörlerin Temel Etkilerine İlişkin ANOVA Tablosu .....	89
<b>Tablo 22:</b> Madde Uyumuna İlişkin DINA ve DINO Analiz Modeli Karşılaştırılması.....	91
<b>Tablo 23:</b> DINA Analiz Modeli Kullanıldığında Faktörlerin Doğru Sınıflama Oranları Ortalamalarına İlişkin Temel Etki Değerleri .....	102
<b>Tablo 24:</b> Sınıflama Tutarlılığı İçin DINA Analiz Modeli Kullanıldığında Faktörlerin Temel Etkilerine İlişkin ANOVA Tablosu .....	103

<b>Tablo 25:</b> DINO Analiz Modeli Kullanıldığında Faktörlerin Doğru Sınıflama Oranları Ortalamalarına İlişkin Temel Etki Değerleri .....	106
<b>Tablo 26:</b> Sınıflama Tutarlılığı İçin DINO Analiz Modeli Kullanıldığında Faktörlerin Temel Etkilerine İlişkin ANOVA Tablosu .....	107
<b>Tablo 27:</b> Sınıflama Tutarlılığına İlişkin DINA ve DINO Analiz Modeli Karşılaştırılması .....	109

## ŞEKİLLER DİZİNİ

Şekil 1: $c$ Örtük Sınıfında Yer Alan Kişinin $i$ Maddesine Vereceği Tepkinin Grafikselsel Gösterimi .....	18
--	----



## GRAFİKLER DİZİNİ

<b>Grafik 1:</b> DINA Analiz Modeli ve Düşük s ve g Parametre Düzeyleri Kullanıldığında, g Parametre Kestiriminden Elde Edilen Ortalama MOY Değerleri .....	59
<b>Grafik 2:</b> DINA Analiz Modeli ve Yüksek s ve g Düzeyleri Kullanıldığında, g Parametre Kestiriminden Elde Edilen Ortalama MOY Değerleri .....	59
<b>Grafik 3:</b> DINA Analiz Modeli ve Düşük s ve Yüksek g Parametre Düzeyleri Kullanıldığında, g Parametre Kestiriminden Elde Edilen Ortalama MOY Değerleri .....	60
<b>Grafik 4:</b> DINA Analiz Modeli ve Yüksek s ve Düşük g Parametre Düzeyleri Kullanıldığında, g Parametre Kestiriminden Elde Edilen Ortalama MOY Değerleri.....	60
<b>Grafik 5:</b> DINO Analiz Modeli ve Düşük s ve g Parametre Düzeyleri Kullanıldığında, g Parametre Kestiriminden Elde Edilen Ortalama MOY Değerleri .....	62
<b>Grafik 6:</b> DINO Analiz Modeli ve Yüksek s ve g Düzeyleri Kullanıldığında, g Parametre Kestiriminden Elde Edilen Ortalama MOY Değerleri .....	62
<b>Grafik 7:</b> DINO Analiz Modeli ve Düşük s ve Yüksek g Parametre Düzeyleri Kullanıldığında, g Parametre Kestiriminden Elde Edilen Ortalama MOY Değerleri .....	63
<b>Grafik 8:</b> DINO Analiz Modeli ve Yüksek s ve Düşük g Parametre Düzeyleri Kullanıldığında, g Parametre Kestiriminden Elde Edilen Ortalama MOY Değerleri .....	63
<b>Grafik 9:</b> DINA ve DINO Analiz Modelleri Kullanıldığında, g Parametre Kestiriminden Elde Edilen Ortalama MOY Değerleri.....	65
<b>Grafik 10:</b> DINA Analiz Modeli ve Düşük s ve g Parametre Düzeyleri Kullanıldığında, s Parametre Kestiriminden Elde Edilen Ortalama MOY Değerleri .....	76

<b>Grafik 11:</b> DINA Analiz Modeli ve Yüksek s ve g Düzeyleri Kullanıldığında, s Parametre Kestiriminden Elde Edilen Ortalama MOY Değerleri .....	76
<b>Grafik 12:</b> DINA Analiz Modeli ve Düşük s ve Yüksek g Parametre Düzeyleri Kullanıldığında, s Parametre Kestiriminden Elde Edilen Ortalama MOY Değerleri .....	77
<b>Grafik 13:</b> DINA Analiz Modeli ve Yüksek s ve Düşük g Parametre Düzeyleri Kullanıldığında, s Parametre Kestiriminden Elde Edilen Ortalama MOY Değerleri .....	77
<b>Grafik 14:</b> DINO Analiz Modeli ve Düşük s ve g Parametre Düzeyleri Kullanıldığında, s Parametre Kestiriminden Elde Edilen Ortalama MOY Değerleri .....	80
<b>Grafik 15:</b> DINO Analiz Modeli ve Yüksek s ve g Düzeyleri Kullanıldığında, s Parametre Kestiriminden Elde Edilen Ortalama MOY Değerleri .....	80
<b>Grafik 16:</b> DINO Analiz Modeli ve Düşük s ve Yüksek g Parametre Düzeyleri Kullanıldığında, s Parametre Kestiriminden Elde Edilen Ortalama MOY Değerleri .....	81
<b>Grafik 17:</b> DINO Analiz Modeli ve Yüksek s ve Düşük g Parametre Düzeyleri Kullanıldığında, s Parametre Kestiriminden Elde Edilen Ortalama MOY Değerleri .....	81
<b>Grafik 18:</b> DINA ve DINO Analiz Modelleri Kullanıldığında, s Parametre Kestiriminden Elde Edilen Ortalama MOY Değerleri .....	83
<b>Grafik 19:</b> DINA Analiz Modeli ve Düşük s ve g Parametre Düzeyleri Kullanıldığında, Madde Uyumu İçin Elde Edilen Ortalama RMSEA Değerleri .....	94
<b>Grafik 20:</b> DINA Analiz Modeli ve Yüksek s ve g Düzeyleri Kullanıldığında, Madde Uyumu İçin Elde Edilen RMSEA Ortalama Değerleri .....	94
<b>Grafik 21:</b> DINA Analiz Modeli ve Düşük s ve Yüksek g Parametre Düzeyleri Kullanıldığında, Madde Uyumu İçin Elde Edilen RMSEA Ortalama Değerleri .....	95

<b>Grafik 22:</b> DINA Analiz Modeli ve Yüksek $s$ ve Düşük $g$ Parametre Düzeyleri Kullanıldığında, Madde Uyumu İçin Elde Edilen RMSEA Ortalama Değerleri .....	95
<b>Grafik 23:</b> DINO Analiz Modeli ve Düşük $s$ ve $g$ Parametre Düzeyleri Kullanıldığında, Madde Uyumu İçin Elde Edilen RMSEA Ortalama Değerleri .....	97
<b>Grafik 24:</b> DINO Analiz Modeli ve Yüksek $s$ ve $g$ Düzeyleri Kullanıldığında, Madde Uyumu İçin Elde Edilen RMSEA Ortalama Değerleri .....	97
<b>Grafik 25:</b> DINO Analiz Modeli ve Düşük $s$ ve Yüksek $g$ Parametre Düzeyleri Kullanıldığında, Madde Uyumu İçin Elde Edilen RMSEA Ortalama Değerleri .....	98
<b>Grafik 26:</b> DINO Analiz Modeli ve Yüksek $s$ ve Düşük $g$ Parametre Düzeyleri Kullanıldığında, Madde Uyumu İçin Elde Edilen RMSEA Ortalama Değerleri .....	98
<b>Grafik 27:</b> DINA ve DINO Analiz Modelleri Kullanıldığında, Elde Edilen RMSEA Ortalama Değerleri .....	100
<b>Grafik 28:</b> DINA Analiz Modelinde ve Özellikler arası Korelasyonun Düşük Düzeyinde Elde Edilen DSO Ortalama Değerleri .....	110
<b>Grafik 29:</b> DINA Analiz Modelinde ve Özellikler arası Korelasyonun Orta Düzeyinde Elde Edilen DSO Ortalama Değerleri .....	111
<b>Grafik 30:</b> DINA Analiz Modelinde ve Özellikler arası Korelasyonun Yüksek Düzeyinde Elde Edilen DSO Ortalama Değerleri .....	111
<b>Grafik 31:</b> DINO Analiz Modelinde ve Özellikler arası Korelasyonun Düşük Düzeyinde Elde Edilen DSO Ortalama Değerleri .....	112
<b>Grafik 32:</b> DINO Analiz Modelinde ve Özellikler arası Korelasyonun Orta Düzeyinde Elde Edilen DSO Ortalama Değerleri .....	113

<b>Grafik 33:</b> DINO Analiz Modelinde ve Özellikler arası Korelasyonun Yüksek Düzeyinde Elde Edilen DSO Ortalama Değerleri .....	113
<b>Grafik 34:</b> DINA ve DINO Analiz Modelleri Kullanıldığında, Elde Edilen Ortalama DSO Değerleri .....	115

## SİMGELER VE KISALTMALAR DİZİNİ

**BTM:** Bilişsel Tanı Modelleri

**KTK:** Klasik Test Kuramı

**TBMTK:** Tek Boyutlu Madde Tepki Kuramı

**ÇBMTK:** Çok Boyutlu Madde Tepki Kuramı

**DINA:** Deterministic Input Noisy “And”

**NIDA:** Noisy Input Deterministic “And”

**RUM:** Reparameterized Unified Model

**DINO:** Deterministic Input Noisy “Or”

**NIDO:** Noisy Input, Deterministic “Or”

**MOY:** Mutlak Ortalama Yanlılık

**DSO:** Doğru Sınıflama Oranı

$N$  : Örneklem Büyüklüğü

$N_1$  : Örneklem büyüklüğünün 200 olduğu koşul

$N_2$  : Örneklem büyüklüğünün 500 olduğu koşul

$N_3$  : Örneklem büyüklüğünün 1000 olduğu koşul

$N_4$  : Örneklem büyüklüğünün 5000 olduğu koşul

$c$  :Özelikler Arası Korelasyon

$c_1$  : Özellikler arası korelasyonun 0.2 olduğu koşul

$c_2$  : Özellikler arası korelasyonun 0.5 olduğu koşul

$c_3$  : Özellikler arası korelasyonun 0.8 olduğu koşul

$a$  : Özellik sayısı

$a_3$  : Özellik sayısının 3 olduğu koşul

$a_4$  : Özellik sayısının 4 olduğu koşul

$MS$  : Madde Sayısı

$MS_1$  : Madde sayısının 15 olduđu kořul

$MS_2$  : Madde sayısının 30 olduđu kořul

$MS_3$  : Madde sayısının 45 olduđu kořul

$s_d g_d$  : s ve g dűřük

$s_d g_y$  : s dűřük - g yűksek

$s_y g_d$  : s yűksek - g dűřük

$s_y g_y$  : s ve g yűksek

## BÖLÜM I: GİRİŞ

Bilimin amaçlarından biri, olayları açıklayabilen ilke ve kuramlar geliştirmektir. Bilimsel araştırma sürecinde hem kuram geliştirmenin önü açılır hem de geliştirilen bu kuramlar sınanır. Kuramları birbirleriyle karşılaştırmak, gerçek durumda hangi kuramın daha işlevsel olduğunu belirlemek, kuramların birbirleriyle benzerlikleri ve farklılıklarını ortaya çıkarmak bilimsel çalışmaların önemli bir bölümünü oluşturmaktadır. Kuramların altında çeşitli modeller yer alabilir ve bu modellerin karşılaştırılması kuramlara önemli katkılar sağlamaktadır.

Eğitim ve psikolojide ölçme, çoğunlukla üzerinde çalışılan yapıyla ilgili davranışlara dayalı olarak, dolaylı yoldan yapılmaktadır. İlgilenilen yapıyı ortaya çıkarabilmek, daha iyi incelemek ve açıklamak için, eğitim ve psikolojide de çeşitli kuramlar geliştirilmiştir ve geliştirilmeye devam edilmektedir.

Gulliksen (1961), test kuramlarının, bireylerin testteki gözlenen puanları ile test ile ölçülmek istenilen yetenekleri arasındaki ilişkiye odaklandığına dikkat çekmiştir. Bu açıdan bakıldığında, geliştirilen kuramlardan ilki, Klasik Test Kuramı'dır. Klasik Test Kuramı (KTK), gerçek puanı gözlenen puanlardan kestirmeye çalışan kuramlardan biridir (Baykul, 2000). Bu nedenle "*gerçek puan*" kuramı olarak da bilinir. Gerçek puan, var olduğu bilinen ancak ulaşılamayan hipotetik bir puandır (Gulliksen, 1950). Ölçmelere karışan seçkisiz (random) hatalar nedeniyle, bireylerin ölçülen niteliğine ait gerçek puanları ile gözlenen puanları farklılaşır. Buradan hareketle, ölçekten elde edilen gözlenen puanlar gerçek puan ve hata puanı olarak modellenebilir. Klasik Test Kuramı uygulamalarının ve parametre kestirimlerinin daha kolay olması, bu kuram üzerinde çok çalışılması, bu kuramın yaygın olarak kullanılmasını sağlamaktadır. Ancak bu kuramda

madde ve test istatistikleri elde edildiği örnekleme, bireylerin yetenekleri de kendilerine uygulanan teste bağımlıdır. Ayrıca, KTK'de bütün yetenek ranjı için bir tek hata kestirimi yapılması ve bu kuramın sayılısının (assumption) çok olması gibi bazı sınırlılıkları bulunmaktadır (Lord ve Novick, 1968; Lord, 1980; Hambleton ve Swaminathan, 1985; Crocker ve Algina, 1986).

KTK'nin yukarıda bahsedilen sınırlılıklarını giderebileceği iddiasıyla, Örtük Özellikler Kuramı olarak da bilinen Madde Tepki Kuramı geliştirilmiştir. Ölçülmek istenilen değişkenin tek boyutlu ya da çok boyutlu olmasına göre Madde Tepki Kuramı Tek Boyutlu Madde Tepki Kuramı ya da Çok Boyutlu Madde Tepki Kuramı olarak adlandırılmıştır.

Tek Boyutlu Madde Tepki Kuramı (TBMTK), örneklemeden bağımsız madde ölçeklemesini ve maddeden bağımsız olarak yetenek kestirimini matematiksel modellerle olanaklı hale getirmek iddiasındadır (Hambleton ve Swaminathan, 1985). KTK gözlenen puandan gerçek puan hakkında çıkarımlar yapmaya çalışırken, TBMTK bireyin yetenek düzeyine göre maddeyi doğru cevaplama olasılığı üzerine yoğunlaşır.

Yukarıda bahsedilen her iki kuram (KTK ve TBMTK) için ölçülmek istenilen yapının tek boyutlu olması büyük önem taşımaktadır. Eğitimde ve psikolojide yer alan testlerle ölçülmek istenilen birçok değişkenin yapısı çok boyutludur ve saf tek boyutluluk sayılısını sağlamak güçleşir. Bir başka ifadeyle, ilgilenilen yapı çok boyutlu olduğunda tek boyutluluğu temel alan ölçme kuramları, bu yapıyı ölçmekte yetersiz kalabilir (Hambleton ve Swaminathan, 1985). Bu yetersizliği giderebilmek için, Çok Boyutlu Madde Tepki Kuramı (ÇBMTK) geliştirilmiştir.



Psikolojik deęişkenlerin bir tek boyutla ifade edilemeyeceęi, başarı testlerinde maddeye tepki verilirken birden çok bilişsel sürecin etkili olabileceęi ve bu süreçlerin bireyden bireye farklılık göstereceęi düşünceleri savunulmaya başlamış ve Ackerman (1996), psikoloji ve eğitimle ilgili birçok testin deęişik derecelerdeki çoklu özelięi veya özellik bileşkesini ölçtüęünü belirtmiştir (akt: Sünbül, 2011). ÇBMTK’nda, bireylerin maddeye doęru cevap verme olasılıkları birden fazla yetenek düzeyine baęlı olarak belirlenir. Temel olarak ÇBMTK modelleri, ikili puanlanan maddeler için tamamlayıcı (compensatory) ve tamamlayıcı olmayan (noncompensatory) olarak ayrılabilir (Ackerman, 1996; Reckase, 2009).

KTK’de elde edilen gözlenen puanlar ve MTK’de elde edilen yetenek puanları bireylerin görel olarak sıralanmasında kullanılır ve bu kuramların uygulanması sonucunda tek bir puan rapor edilir. Bu sonuca bakılarak, bireyler hakkında önemli kararlar verilmektedir. Bireylerin ilgilenilen özellik açısından güçlü ya da zayıf yönlerinin ortaya çıkarılmasında bu kuramların yetersiz kalması nedeniyle, daha zengin bilgi verebilecek kuramlara ihtiyaç duyulmuştur. Bu tür eksiklikler göz önünde bulundurularak Tanı Sınıflama Modelleri geliştirilmiştir. Amerika’da eğitim alanında yapılan araştırmalarda, öğretmenlerin ve ailelerin, öğrencilerin bilgi, beceri ve yeteneklerinin güçlü ve zayıf yönleri hakkında daha detaylı bilgiler elde etmeye çalıştıkları ve bu konuya önem verdikleri ortaya çıkmıştır (Huff ve Goodman, 2007). Özellikle 2001 yılında, “No Child Left Behind” hareketinin başlamasıyla öğrencilerin, öğretmenlerin ve ailelerin sosyal talepleri daha belirgin hale gelmeye başlamış ve bilişsel tanı yaklaşımı yaygınlık kazanmıştır (Kato, 2009). Bu hareketle birlikte, anne babalar, öğretmenler ve okul yöneticileri için, öğrencilerin neyi öğrendiklerini ya da öğrenme eksikliklerinin neler olduğunu gösteren tanı puan raporları hazırlanmıştır.

Bu raporların oluşturulmasına kaynaklık eden çok çeşitli Tanı Sınıflama Modelleri geliştirilmiştir. Aşağıdaki bölümde bu modeller kısaca açıklanmıştır.

### 1.1. Tanı Sınıflama Modelleri (Diagnostic Classification Models)

Tanı Sınıflama Modelleri, özellikle eğitim ve psikolojide, bireylerin zihinsel tepki süreçleri hakkında daha zengin, anlamlı bilgi elde edilmesi istenildiğinde sıklıkla kullanılan önemli modellerdendir. Bu modeller, bireylerin tepkilerinin altında yatan zihinsel becerilerine bağlı olarak, ölçülmek istenilen değişkenin tüm bileşenlerinin profillerinin çıkarılmasını ve bunların çok değişkenli olarak sınıflanmasını sağlar (Rupp ve Templin, 2008b). Bu durum, ölçülmek istenilen değişkenlerin bütün bileşenlerine ilişkin olarak, bireylerin üstün ve zayıf yönlerinin belirlenmesine yardım eder. Bu modellerde, her bir bireyin her bir beceriye sahip olup olmadığı belirlenirken, özellikler ve maddeler arasındaki ilişki anlaşılmaya çalışılır.

Literatür incelendiğinde, Tanı Sınıflama Modelleri şeklinde ifade edilen modellere farklı isimler verildiği görülmektedir. Örneğin, *bilişsel psikolojik modeller (cognitive psychometric models)* (Rupp, 2007); *bilişsel tanı modelleri (cognitive diagnostic models)* (Nichols, Chipman ve Brennan, 1995); *örtük tepki modelleri (latent response models)* (Maris, 1995); *sınırlandırılmış örtük sınıf modelleri (restricted latent class models)* (Haertel, 1989; Macready ve Dayton, 1976); *çoklu sınıflandırma örtük sınıf modelleri (multiple classification latent class models)* (Maris, 1995, 1999) ve *yapısal madde tepki kuramı modelleri (structured item response theory models)* (Mislevy, 2007; Rupp ve Mislevy, 2007).

Rupp ve Templin'e (2008b) göre, bütün bu farklı tanımlamaların her biri, modellerin ilgili yönlerini belirli çağrışımlarla ifade etmektedir. Bazı tanımlamalar,

modellerin teorik alt yapısını, bazıları modellerin amacını ve bazıları da modellerin istatistiksel özelliklerini yansıtmaktadır.

*Bilişsel psikolojik modeller (cognitive psychometric models)* isimlendirmesi, uygulamanın teorik alt yapısını yansıtmaktadır. Bu tür sınıflama tanı modellerinde, bilişsel psikolojide yer alan tepki süreç teorilerinin ayrıntılandırılmasını gerektiren uygulamalara vurgu yapılır (Rupp ve Templin, 2008b).

*Bilişsel tanı modelleri (cognitive diagnostic models)* şeklindeki isimlendirmede, bilişsel psikolojide sadece bilgi-süreç bakış açısı yer almamaktadır. Bu modellerin temel amacında, yerleştirmenin ya da sertifikasyonun yapılmasından çok “*tanı*” yapılması düşüncesi yer almaktadır (Rupp, Templin ve Henson, 2010).

*Örtük tepki modelleri (latent response models)* şeklindeki isimlendirmede, modellerin istatistiksel özellikleri yansıtılmaktadır. Bu tür modellerdeki tepki süreçlerinde, örtük tepkiler, açıkça modellenen her bir bileşenine (yapı taşlarına) ayrıştırılır. Modellerdeki örtük tepkiler, açık tepkinin olasılık değerinden kestirilir (Rupp ve Templin, 2008b).

*Sınırlandırılmış örtük sınıf modelleri (restricted latent class models)* şeklindeki isimlendirmede de modellerin istatistiksel özellikleri yansıtılır. Bu tür modeller, bireylerin örtük sınıflanmasında kullanılır. Modellerde, cevaplayıcılar gözlenemeyen (örtük) sınıflara ayrılır ve kestirilecek olan örtük sınıf sayısı sınırlandırılır (Rupp ve Templin, 2008b; Rupp, Templin ve Henson, 2010).

*Çoklu sınıflandırma modeli (multiple classification latent class models)* şeklindeki isimlendirme de modellerin istatistiksel amacını yansıtmaktadır. Bu tür modeller, cevaplayıcıları her bir özeliğe sahip olma derecesine veya özellik konusundaki durumuna

göre sınıflayarak, onların çok deęişkenli profilinin ıkartılmasında kullanılır (Rupp, Templin ve Henson, 2010).

*Yapısal madde tepki kuramı modelleri (structured item response theory models)* şeklindeki isimlendirmede modellerin büyük ölçüde örtük özellik modelleri ailesiyle ilişkili olduğu belirtilir. Yapısal olmayan madde tepki kuramı modelleri, boyutsal yapıya ve karmaşıklığa baęlı olarak, bir veya daha fazla cevaplayıcı ve madde parametresi içerirken, yapısal modeller bunlara ek olarak açıklayıcı işleyişi veya heterojenliği içeren parametreler içerir (Rupp, Templin ve Henson, 2010).

Bu alıřmada, yukarıda bahsedilen isimlendirmeler arasında yaygın olarak kullanılan *Bilişsel Tanı Modelleri (BTM)* isimlendirmesi kullanılmıştır.

BTM'yle, bireyin bir maddeye doęru cevap verebilmesi için, sahip olduğu örtük özellik/ler ya da beceri/ler ortaya ıkarılmaya alışılır (Fu ve Li, 2007, Rupp ve Templin, 2008a). Test edilen bireylerin yeteneklerini, maddeleri doęru cevaplamak için gerekli olan özelliklere sahip olup olmama bakımından kategorik olarak belirleyen modellerdir (de la Torre, 2009). Bařka bir ifadeyle, BTM'nde bireylerin özellik profilleri kategorik örtük deęişkenleri içerir.

BTM, bireyin önceden belirlenmiş beceri ya da özelliklere sahip olup olmadığına ilişkin profil saęlar. Böylelikle bireyler hakkında daha zengin, anlamlı, yönlendirici bilgiler saęlanabilir. Ayrıca BTM, bireyin bir maddeyi özmede neden başarılı olamadığını da açıklar (Henson, Templin ve Willse, 2009).

BTM, bilişsel beceriler ya da örtük özellikler açısından genellikle ikili ya da ayrık olarak bölümlenen örtük uzayı daha ok ve iyi tanımlanmış şekilde bölümler ve bireyleri her bir özellikteki yetkinlik düzeylerine göre deęerlendirir (Hartz, 2002). Bu durumda, BTM yapısı ok boyutlu test yapılarına benzetilebilir.

### 1.1.1. Bilişsel Tanı Modeli Sınıflaması

Çeşitli BTM, ölçülen özelliklerin birbirleriyle etkileşimlerinin nasıl olacağına bağlı olarak farklı sayıtları içerir ve bireylerin sahip oldukları becerilerin onların test performanslarını nasıl etkileyeceğini göz önünde bulundurur. Örneğin; bazı modellerde bireyin bir maddeye doğru cevap verebilmesi için gerekli bütün özelliklere sahip olması gerektiği varsayılırken; bazı modellerde ise eksik olan özeliğin diğer özellikler tarafından tamamlanacağı varsayılır.

İlgili literatür tarandığında, BTM'nin içerdikleri sayıtlar açısından farklı şekillerde sınıflandırıldığı görülmektedir (DiBello, Roussos ve Stout, 2007; Rupp ve Templin, 2008). Tablo 1'de Rupp ve Templin'in 2008 yılında yapmış oldukları Bilişsel Tanı Modellerine ait sınıflama gösterilmektedir.

**Tablo 1:** Bilişsel Tanı Model Sınıflaması

	MODEL TİPİ			
	TAMAMLAYICI OLMAYAN MODEL		TAMAMLAYICI MODEL	
	Örtük Yordayıcı Değişkenler		Örtük Yordayıcı Değişkenler	
Açık Tepki Değişkenleri	İkili Puanlanan	Çoklu Puanlanan	İkili Puanlanan	Çoklu Puanlanan
İkili Puanlanan	RSM AHM DINA HO-DINA MS-DINA NIDA BIN MCLCM FULL NC-RUM REDUCED NC-RUM RERUM	BIN MCLCM FULL NC-RUM REDUCED NC-RUM	DINO NIDO BIN MCLCM C-RUM GDM H-GDM	BIN MCLCM C-RUM GDM H-GDM
Çoklu Puanlanan	RSM AHM BIN MCLCM FULL NC-RUM REDUCED NC-RUM	BIN MCLCM FULL NC-RUM REDUCED NC-RUM	BIN MCLCM C-RUM GDM H-GDM	BIN MCLCM C-RUM GDM H-GDM

Tablo 1 incelendiğinde, BTM’de ilk olarak model tipinin belirlendiği görülmektedir. ÇBMTK modellerinde olduğu gibi, BTM’nde de tamamlayıcı model ya da tamamlayıcı olmayan model olarak iki model tipi bulunmaktadır. Ayrıca, örtük ya da tepki değişkenlerinin puanlanma (ikili ya da çoklu) şekline göre çeşitli BTM bulunmaktadır.

Tamamlayıcı ve tamamlayıcı olmayan modeller arasındaki fark, örtük yordayıcı değişkenlerin, açık tepki değişkenlerini ortaya çıkaran farklı beceriler karşısında nasıl bağlanacağını belirlenmesinden kaynaklanmaktadır (Rupp ve Templin, 2008b). Tamamlayıcı modellerde, bir becerideki eksiklik diğer kalan beceriler tarafından giderilebilirken; tamamlayıcı olmayan modellerde ise, her bir beceri, doğru cevabın verilmesi için gereklidir. Başka bir ifadeyle, tamamlayıcı modellerde eksik olan beceri(ler)in, yetkin olunan beceri(ler) tarafından tamamlanması durumu söz konusu iken, tamamlayıcı olmayan modellerde, eksik olan beceri/lerin, yetkin olunan beceri(ler) tarafından tamamlanmaması durumu söz konusudur.

Tamamlayıcı ve tamamlayıcı olmayan modellere ilişkin belirtilen ortak kurallar Tablo 2’de gösterilmektedir.

**Tablo 2:** Tamamlayıcı ve Tamamlayıcı Olmayan Model Kuralları

KURAL	MODEL
$P(X_{ij} = 1) = \prod_{k=1}^K P(\xi_{ijk} = 1)$	Tamamlayıcı Olmayan
$P(X_{ij} = 1) = 1 - \prod_{k=1}^K (1 - P(\xi_{ijk} = 1))$	Tamamlayıcı

Tablo 2’de yer alan  $X_{ij}$ ,  $i$  kişinin  $j$  maddesine açık tepki değişkenini,  $\xi_{ijk}$  ise,  $j$  maddesi için gerekli  $k$  becerisine sahip  $i$  kişinin örtük tepki değişkenini belirtmektedir. Tamamlayıcı olmayan model kuralında, açık tepki değişkeninin sağlanması için bütün beceriler gereklidir. Tamamlayıcı modelde ise, herhangi eksik olan bir beceride, maksimum doğru açık tepki sağlanabilir.

Hem tamamlayıcı hem de tamamlayıcı olmayan modellerde, bireyin maddeye doğru cevap verilebilmesi için belirlenen özelliklerden hangisine sahip olması gerektiğini belirten bir  $Q$  matrisi yer almaktadır. Bu matrise ilişkin açıklamalar aşağıda belirtilmiştir.

### 1.1.2. Q Matrisi

BTM’de, cevaplama özeliğinin belirlendiği  $j \times k$  şeklinde oluşturulan ve 1-0 şeklinde kodlanan bir  $Q$  matrisi üzerinden hesaplama yapılır (Embretson, 1984; Tatsuoka, 1985). Matriste  $q_{jk}$  hücresi  $j$  maddesini doğru cevaplamak için,  $k$  özeliğine sahip olunması gerekip gerekmediğine işaret eder.  $q_{jk}$ ,  $k$  özeliği  $j$  maddesinde bulunuyorsa 1, bulunmuyorsa 0 değerini alır. Satırlarında maddeler, sütunlarında da özellikler yer alan  $Q$  matrisindeki hücrelerde yer alan 1’ler ve 0’lar aşağıda belirtilen şekilde yazılabilir.

$$q_{jk} \begin{cases} 1, k \text{ özeliği } j \text{ maddesinde bulunuyorsa} \\ 0, k \text{ özeliği } j \text{ maddesinde bulunmuyorsa} \end{cases}$$

Belirli bir görev üzerindeki başarılı performans, o görev için belirli özelliklerin bir dizi başarılı uygulamalarını gerektirir (de la Torre, 2009). Bu açıdan bakıldığında,  $Q$  matrisi, herhangi bir maddede başarılı bir performans gösterilebilmesi için belirli özelliklerden hangisine sahip olunması gerektiğini belirten bir matristir. Örneğin, bir bireyin başarılı bir şekilde müzik aleti çalabilmesi için, nota okuma becerisine ve bu

notaları müzik aletinde doğru çalabilme becerisine sahip olması istendiğinde, birey notaları doğru okuyup ve okuduğu notaları müzik aletine doğru aktarabildiği durumda, başarılı bir performans sergileyebilecektir. Tablo 3'te örnek bir Q matrisi gösterilmektedir.

**Tablo 3:** Q Matrisi Olası Tepkiler Örneği

<b>Madde</b>	$\alpha_1$	$\alpha_2$	$\alpha_3$
<b>1</b>	1	0	0
<b>2</b>	1	1	0
<b>3</b>	1	1	1
<b>4</b>	0	1	1
<b>5</b>	0	0	1

Tablo 3 incelendiğinde, satırlarında maddeler ve sütunlarında özellikler yer alan bir matris gösterilmektedir. Bu matrisin hücrelerinde ise, ilgili maddenin doğru cevaplanabilmesi için, belirtilen özelliğin gerekip gerekmediği belirtilmektedir. Örneğin, 1. maddeyi doğru cevaplayabilmek için sadece *1. özeliğe* sahip olunması gerektiği görülmektedir. Ayrıca, 2. maddeyi doğru cevaplayabilmek için hem *1. özeliğe* hem de *2. özeliğe*; 3. maddeyi doğru cevaplayabilmek için ise, *3 özeliğe* de sahip olunması gerektiği görülmektedir.

Q matrisi, test hazırlama sürecinde, bilişsel özelliklerin kavram haritasını temsil eder (Leighton, Gierl ve Hunka, 2004; Junker, 1999). Bu açıdan bakıldığında, Q matrisi, test geliştirme sürecinde önemli bir role sahiptir. Q matrisi, ölçme aracıyla elde edilen tanısal bilginin kalitesini belirleyen temel unsurdur (Tatsuoka, 1983; Rupp ve Templin, 2008). Ayrıca, Q matrisinin doğru belirlenmiş olması, elde edilen sonuçların geçerliği açısından



büyük önem taşımaktadır. Q matrisi ve bireylerin tepki verileri kullanılarak, her bir bireyin özellik profili kestirilebilmektedir (Dogan ve Tatsuoka, 2008).

### 1.1.3. Örtük Sınıf (Latent Class)

Alt beceri ya da özeliğe sahip olup/olmama örüntüsü örtük sınıf olarak isimlendirilir (Gierl, Cui ve Zhou, 2009; Rupp, Templin ve Henson, 2010). K özellik için  $2^K$  tane örtük sınıf bulunmaktadır. Tablo 4'te 3 özelliğe ait olası örtük sınıf örüntüleri gösterilmektedir.

**Tablo 4:** Olası Örtük Sınıf Örüntüleri

Örüntü	1. Özellik	2. Özellik	3. Özellik
1	0	0	0
2	1	0	0
3	0	1	0
4	0	0	1
5	1	1	0
6	1	0	1
7	0	1	1
8	1	1	1

Yukarıdaki tablo incelendiğinde, 3 özeliğe ait 8 tane örüntü ( $2^3$ ) olduğu görülmektedir. Birinci örüntüde hiçbir özelliğe sahip olunmadığı ve 8. örüntüde bütün özelliklere sahip olduğu görülmektedir.

Örtük sınıf örüntülerine ait örnek aşağıda gösterilmektedir.

de la Torre (2009) tarafından hazırlanmış kesirlerde çıkarma işlemine ait bir madde ve bu maddeye ait seçenekler aşağıda gösterilmektedir.

$$2\frac{4}{12} - \frac{7}{12} = ? \quad \text{A) } 2\frac{3}{12} \quad \text{B) } 2\frac{1}{4} \quad \text{C) } 1\frac{9}{12} \quad \text{D) } 1\frac{3}{4}$$

Bu maddeye doğru cevap verebilmek için gerekli olan özellikler, Tatsuoka (1990) tarafından belirlenmiştir. Bunlar; (1) tam kısımdan almak, (2) pay çıkarmak ve (3) basit forma indirmektir.

Bireylerin yukarıda belirtilen seçenekleri işaretlemesi durumunda hangi özelliklere sahip olup olmadığı belirlenebilir. Bireylerin maddeye doğru cevap verebilmesi için, gerekli olan bütün özelliklere sahip olması gerekmektedir. Aşağıdaki tabloda, bireylerin seçenekleri işaretlemeleri durumundaki örtük sınıf örüntüleri gösterilmektedir.

**Tablo 5:** Örnek Örtük Sınıf Örüntüleri

Seçenek	(1) Tam kısımdan almak	(2) Pay çıkarmak	(3) Basit forma indirmek
A) $2\frac{3}{12}$	0	1	0
B) $2\frac{1}{4}$	0	1	1
C) $1\frac{9}{12}$	1	1	0
D) $1\frac{3}{4}$	1	1	1

Yukarıdaki tablo incelendiğinde, “A” seçeneğini işaretleyen bireyin sadece 2. özeliğe sahip olduğu, “D” seçeneğini işaretleyen bireyin ise, bütün özelliklere sahip olduğu görülmektedir.

#### **1.1.4. Bilişsel Tanı Modellerinin İstatistiksel Yapısı**

BTM, genel örtük sınıf modellerinin sınırlandırılmış versiyonudur. BTM'nin genel matematiksel yapısının anlaşılabilirliğinin sağlanabilmesi için, ilk olarak örtük sınıf modellerinin genel yapısından bahsedilecektir.

Örtük sınıf modelleri, örtük değişkenin kesikli olduğu örtük model türlerinden biridir. Örtük sınıf analizi, ilk olarak Lazarsfeld ve Henry (1968) tarafından önerilmiş ve 1974'de en çok olabilirlik algoritmasını (maximum likelihood algorithm) geliştiren Goodman tarafından formüle edilmiştir (Vermunt ve Magidson, 2004). Macready ve Dayton (1977), örtük sınıf modellerini eğitim alanında kullanmaya başlamışlardır. Örtük sınıf analizi, çok değişkenli kategorik verideki alt grupların belirlenmesinde kullanılmaktadır.

Örtük sınıf analizinde, örtük sınıf olasılıkları ve koşullu olasılıklar olmak üzere iki temel parametre kestirilmektedir (Vermunt ve Magidson, 2004). Örtük sınıf olasılıkları, sınıf sayısını ve bu sınıfların büyüklüğünü ifade ederken, koşullu olasılıklar, örtük değişkenin herhangi bir sınıfında yer alan bir bireyin/gözlemin, gözlenen değişkenin belli bir seviyesinde olma olasılığını göstermektedir (McCutcheon, 1987).

Bu bölüm ve daha sonraki bölümlerde anlaşılabilirliğin sağlanabilmesi açısından, bireyler (cevaplayıcılar) için “r”; maddeler için “i”; özellikler için “a”; örtük sınıflar için “c” indisi kullanılmıştır. Örneğin;  $X_{ri}$ , r cevaplayıcısının i maddesindeki gözlenen puanını;

$q_{ia}$ , i maddesi ve a özeliğinin Q matrisindeki ikili girdisini;  $\alpha_{ra}$ , r cevaplayıcısının a özeliğine sahip olduğunu ( $\alpha_{ra} = 1$ ) ya da sahip olmadığını ( $\alpha_{ra} = 0$ ) belirten örtük özellik değişkenini;  $\alpha_{ca}$ , c örtük sınıfında yer alan cevaplayıcının özeliğe sahip olduğunu ( $\alpha_{ca} = 1$ ) ya da sahip olmadığını ( $\alpha_{ca} = 0$ ) göstermektedir. Bunlara ek olarak, r cevaplayıcısının i maddesine doğru cevap vermesi  $X_{ri} = 1$ , yanlış cevap vermesi  $X_{ri} = 0$  ya da c örtük sınıfındaki cevaplayıcının i maddesine doğru cevap vermesi  $X_{ci} = 1$  yanlış cevap vermesi ise  $X_{ci} = 0$  şeklinde gösterilmektedir.

c örtük sınıfında yer alan r bireyinin i maddesine doğru cevap verme olasılığı 1' nolu eşitlikte belirtilmiştir.

$$P(X_{ri} = 1 / c) = \pi_{ic} \quad (1)$$

Örtük sınıf modelinde, her bir bireyin iki örtük sınıfın her birine ait olma olasılıkları  $\nu_1$  ve  $\nu_2$  şeklinde gösterilir. Bu olasılıklar, “karışık oranlar (mixed ratio)” olarak da bilinir (Rupp, Templin ve Henson, 2010). Başka bir ifadeyle, karışık oran, her bir örtük sınıftaki bireylerin oranını belirtir.

Genel olarak örtük sınıf modelde, olasılıkların matematiksel gösterimi 2 no'lu eşitlikte belirtilmiştir.

$$P(X_r = x_r) = \sum_{c=1}^C \nu_c \prod_{i=1}^I \pi_{ic}^{x_{ir}} (1 - \pi_{ic})^{(1-x_{ir})} \quad (2)$$

Yukarıdaki gösterimin çarpım kısmında, 1'den I'ya kadar olan tüm maddeler için eşitlikte yer alan değişkenler çarpılmaktadır. Bu değişkenler ise, i maddesi için 0 ya da 1 değerini alabilmektedir. Gösterimin bu kısmı, gözlenen değişkenler ile gözlenemeyen

örtük değişkenleri doğrudan bağlayan bileşen olduğundan “ölçme bileşeni” olarak düşünülebilir (Rupp, Templin ve Henson, 2010).

Gösterimin toplam kısmı ise, 1’den C’ye kadar olan karışık oranlar ile örtük sınıfların toplamını belirtir ve “yapısal bileşen” olarak düşünülebilir (Rupp, Templin ve Henson, 2010).

BTM için yukarıda yer alan matematiksel gösterim kullanıldığında, modelin ölçme bileşeninde yer alan  $\pi_{ic}$  tepki olasılıklarının parametreleştirilmesi farklılık göstermektedir. Başka bir ifadeyle BTM, örtük sınıf modellerinden “ölçme bileşeni” kısmında farklılaşmaktadır. BTM’nde ölçme bileşeninde kestirilecek parametrelerin sayısı modelden modele farklılık göstermektedir.

Aşağıda BTM türlerinden olan Tamamlayıcı Model ve Tamamlayıcı Olmayan Model kapsamında yer alan ve yaygın olarak kullanılan bazı modellerden bahsedilecektir. Her bir modelin matematiksel formülü verilmiş olup, modeldeki bütün bileşenler ve modelde yer alan parametreler açıklanmıştır.

### **1.1.5. Tamamlayıcı Olmayan Model**

Tamamlayıcı olmayan BTM’nde, birey tepkilerindeki becerilerin ortak etkisi modellenirken, bireyin testteki bir maddeye doğru cevap vermesi için gerekli olan bütün becerilere sahip olması gerekmektedir. Başka bir ifadeyle, bireyin gerekli olan becerilerden herhangi birine sahip olmaması durumu, o bireyin maddeye doğru cevap verme olasılığını düşürecektir. Henson, Templin ve Willse (2009), bağlayıcı modeli, gerekli olan özelliklerden bir tanesinin eksik olması, sahip olunan diğer özellikler tarafından giderilemeyen model olarak tanımlamışlardır. Tamamlayıcı olmayan modeller arasında,

Haertel'in (1989) DINA (Deterministic Input Noisy "And") modeli; Junker ve Sijtsma'nın (2001) NIDA (Noisy Input Deterministic "And") modeli ve Hartz'ın (2002) RUM modeli (Reparameterized Unified Model) örnek gösterilebilir. Tamamlayıcı olmayan bu modeller aşağıda kısaca anlatılmıştır.

### 1.1.5.1. DINA (Deterministic Input Noisy "And") Model

Bu model Haertel (1989) tarafından geliştirilmiş olup, cevaplayıcıları her özellik için iki boyutta sınıflar:

1. "*Yokluk sınıfı*": Belirlenen özeliğe sahip olmayanların oluşturduğu sınıftır. Birey, maddeyi doğru cevaplamak için gerekli özelliklerden sadece bir tanesine bile sahip değilse buraya atanır.

2. "*Tam sınıf*": Belirlenen özeliğe sahip olanların oluşturduğu sınıftır. Birey, maddeyi doğru cevaplamak için gerekli özelliklerin tamamına sahipse buraya atanır.

DINA model matematiksel olarak 3 no'lu eşitlikte belirtildiği şekilde ifade edilmektedir.

$$\xi_{ij} = \prod_{a=1}^A \alpha_{ca}^{q_{ia}} \quad (3)$$

DINA model için geliştirilen yukarıdaki formül incelendiğinde üç temel elemanın gerekli olduğu görülmektedir. Bunlardan ilki, örtük değişken olarak tanımlanan  $\xi_{ic}$ , c örtük sınıfında yer alan bireyin i maddesine vermiş olduğu ve  $\alpha$  tarafından belirlenen tepkidir. Bu, DINA modelin belirleyici (deterministic input) kısmını oluşturmaktadır. Fonksiyon bireyde bulunan özellikler ile maddenin doğru cevaplanabilmesi için gerekli olan özelliklerin eşleşmesi durumunda "*1*", eşleşmemesi durumunda ise "*0*" değerini alır.

İkinci gerekli olan eleman ise  $q_{ia}$  olarak gösterilmiş olup, i maddesine doğru cevap vermek için a özeliğinin gerekli olup olmadığını belirtir. Özellik gerekli olduğunda “1” gerekli olmadığında “0” değerini alır.

Üçüncü eleman olarak belirtilen  $\alpha_{ia}$  ise, ilgili özellik maddeyi doğru cevaplamak için gerekli değilse  $q_{ia} = 0$  değerini ve  $\alpha_{ca}^0 = 1$  değerini alır. İlgili özellik maddeyi doğru cevaplamak için gerekli ise  $q_{ia} = 1$  değerini ve c örtük sınıfında yer alan cevaplayıcının ölçülen özelliğe sahip olup olmaması durumuna göre  $\alpha_{ca} = 1$  ya da  $\alpha_{ca} = 0$  değerini alır (Rupp, Templin ve Henson, 2010).

DINA modelde, i maddesi için c örtük sınıfında yer alan bireyin maddeyi doğru cevaplama olasılığı 4 no’lu eşitlikte gösterilmektedir:

$$\pi_{ic} = P(X_{ic} = 1 / \xi_{ic}) = (1 - s_i)^{\xi_{ic}} g_i^{1 - \xi_{ic}} \quad (4)$$

P; maddeyi çözmek için gerekli bütün becerilere sahip olan bireyin maddeyi doğru cevaplama olasılığıdır. *Slip* ( $s$ ) “*kaydırma*” ve *guess* ( $g$ ) “*tahmin, şans*” parametreleridir ve Rupp, Templin ve Henson (2010),  $s$  ve  $g$  parametrelerini Tablo 6’da belirtildiği şekilde göstermişlerdir.

**Tablo 6:** DINA Modeldeki Tepki Olasılıkları

	$X_{ic} = 1$ (Doğru tepki)	$X_{ic} = 0$ (Yanlış tepki)
$\xi_{ic} = 1$ (Ölçülen bütün özelliklere sahip)	$1 - s_i$	$s_i$
$\xi_{ic} = 0$ (Ölçülen özelliklerden en az birine sahip değil)	$g_i$	$1 - g_i$

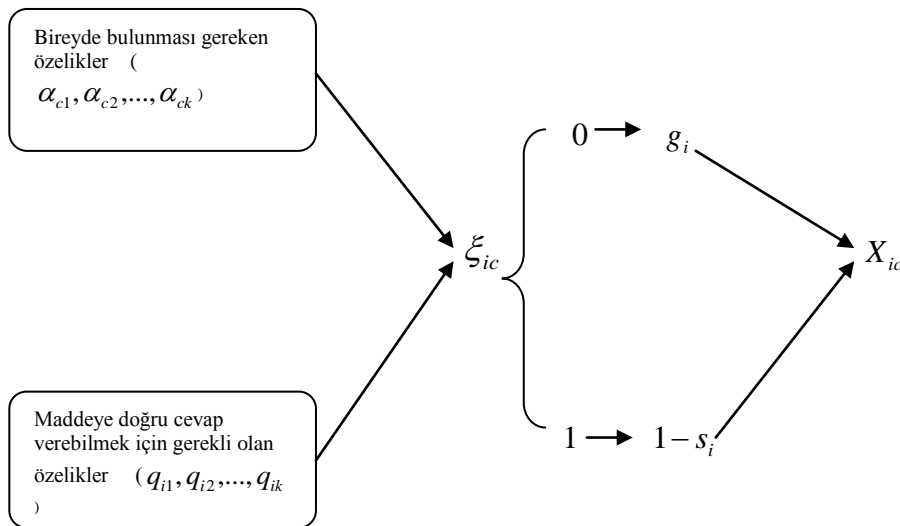
Tablo 6'dan görülebileceği gibi, ölçülen bütün özelliklere sahip iken maddeye yanlış cevap verme olasılığı “*kaydırma (slip) parametresi*” olarak adlandırılmaktadır. Kaydırma (slip) parametresi 5 no’lu eşitlikte gösterilmektedir.

$$s_i = P(X_{ic} = 0 / \xi_{ic} = 1) \quad (5)$$

Ölçülen özelliklerden en az birine sahip değilken maddeye doğru cevap verme olasılığı ise “*tahmin (guess) parametresi*” olarak adlandırılmaktadır. Tahmin parametresi 6 no’lu eşitlikte gösterilmektedir.

$$g_i = P(X_{ic} = 1 / \xi_{ic} = 0) \quad (6)$$

Şekil 1’de  $c$  örtük sınıfında yer alan bireyin  $i$  maddesine vereceği tepkinin grafiksel gösterimi yer almaktadır. Grafik incelendiğinde, kişide bulunan özellikler ile maddeye doğru cevap vermek için gerekli olan özelliklerin eşleşmesi ya da eşleşmemesi durumunda maddeye doğru cevap verme olasılıklarının hesaplanması gösterilmektedir.



**Şekil 1:**  $c$  Örtük Sınıfında Yer Alan Kişinin  $i$  Maddesine Vereceği Tepkinin Grafiksel Gösterimi



### 1.1.5.2. NIDA (Noisy Input Deterministic “And”) Model

Bu model, Junker ve Sijtsma (2001) tarafından geliştirilmiştir. DINA ve NIDA model arasındaki fark, örtük değişkenin farklı tanımlanmasında yatar. DINA modelin aksine bu modelde, istenmeyen tepki özellik düzeyinde modellenir. Kaydırma (slip) ve tahmin (guess) parametreleri özellik düzeyleri üzerinden kestirilir. Oysa ki, DINA modelde, örtük tepki değişkeni, madde düzeyinde belirlenmektedir (Junker ve Sijtsma, 2001). Bunun anlamı, NIDA modelde, her özellik için bir kaydırma ve bir tahmin parametresinin elde edilmesidir (Rupp, Templin ve Henson, 2010). Başka bir ifadeyle, örtük değişken DINA modelde  $\xi_{ic}$  şeklinde tanımlanırken, NIDA modelde ise,  $\zeta_{cia}$  şeklinde tanımlanmaktadır. Burada ayrı olarak beceri için ekstra bir  $a$  indisi bulunmaktadır.  $a$  indisi, özellik düzeyinde belirlenen örtük tepki değişkeninin sayısını belirtmektedir.

NIDA model için geliştirilen formül incelendiğinde üç temel elemanın olduğu görülmektedir. Bunlar; kaydırma parametresi ( $s_a$ ), tahmin parametresi ( $g_a$ ) ve örtük tepki değişkeni ( $\zeta_{cia}$ ) olarak adlandırılmaktadır.

NIDA model için kaydırma ve tahmin parametreleri 7 ve 8 no'lu eşitliklerde ifade edilmektedir;

$$s_a = P(\zeta_{cia} = 0 / \alpha_{ca} = 1) \quad (7)$$

$$g_a = P(\zeta_{cia} = 1 / \alpha_{ca} = 0) \quad (8)$$

Yukarıdaki formüllerde,  $\alpha_{ca} = 1$  ise,  $a$  özeliğine sahip  $c$  örtük sınıfındaki cevaplayıcıyı ve  $\alpha_{ca} = 0$  ise,  $a$  özeliğine sahip olmayan  $c$  örtük sınıfında yer alan

cevaplayıcıyı belirtmektedir. Ayrıca,  $\zeta_{cia}$ , c sınıfında yer alan cevaplayıcının i maddesi için a özeliğine sahip olması durumunda 1, sahip olmaması durumunda ise 0 değerini alır.

NIDA model için doğru cevaplama olasılığı ise 9 no'lu eşitlikte belirtilen şekilde hesaplanır:

$$\pi_{ic} = P(X_{ic} = 1 / \alpha_c) = \prod_{a=1}^A [(1 - s_a)^{\alpha_{ca}} g_a^{1-\alpha_{ca}}]^{q_{ia}} \quad (9)$$

P; olasılık,  $\pi_{ic}$ ; c örtük sınıfındaki i maddesinin doğru cevaplanma olasılığı,  $X_{ic}$ ; c örtük sınıfındaki i maddesi için gözlenen tepki,  $\alpha_{ca}$ ; c örtük sınıfındaki cevaplayıcının a özeliğine sahip olup olmadığının belirleyicisi,  $q_{ia}$ ; Q matrisinde i maddesi için a özelliğinin ölçülüp ölçülmediğinin belirleyicisidir (Rupp, Templin ve Henson, 2010).

### 1.1.5.3. Tamamlayıcı Olmayan RUM Model (Reparameterized Unified Model)

RUM, Birleştirilmiş Model (Unified Model) olarak tanımlanmakla birlikte “Fusion Model” olarak da bilinmektedir (DiBello, Stout ve Rousoss, 1995). Birleştirilmiş Model, ilk Bilişsel Model olarak kabul edilir. Bu modelin, “*Tam Tamamlayıcı RUM*” ve “*Sınırlandırılmış Tamamlayıcı RUM*” olmak üzere iki farklı biçimi bulunmaktadır (Rupp, Templin ve Henson, 2010).

Sınırlandırılmış Tamamlayıcı Olmayan RUM modeldeki ilk bileşen *temel parametre* ( $\pi_i^*$ ) olup, bu parametre, Q matrisinde belirlenen gerekli bütün özelliklere sahip cevaplayıcının doğru cevap verme olasılığını belirtmektedir. Olasılık madde düzeyinde tanımlanır böylece, her bir madde için temel parametre kestirilir. Temel parametre ( $\pi_i^*$ ), DINA modeldeki ( $1 - s_i$ ) olasılığına benzerdir ve 10 no'lu eşitlikte gösterilmektedir.

$$\pi_{ic} = P(\zeta_{cia} = 1 / \alpha_{ca} = 1) = (1 - s_{ia}) \quad (10)$$

İkinci bileşen *penalty (tahmin) parametresi* ( $r_{ia}^*$ ) olup, ölçülen a özeliğine sahip olmayan c sınıfındaki cevaplayıcı için penaltidir. Bu parametre ise, özellik düzeyindeki “tahmin” olasılığıdır ve 11 no’lu eşitlikte belirtilen şekilde hesaplanabilir.

$$r_{ia} = P(\zeta_{cia} = 1 / \alpha_{ca} = 1) = g_{ia} \quad (11)$$

Her bir madde için özellik düzeyindeki olasılıklar kullanılarak, i maddesi için temel olasılık 12 no’lu eşitlikte belirtilen şekilde hesaplanabilir:

$$\pi_i^* = \prod_{a=1}^A \pi_{ia}^{q_{ia}} \quad (12)$$

Eğer özellik ölçülüyorsa  $q_{ia} = 0$  ve böylece  $\pi_{ia}^0 = 1$  olur. Eğer özellik ölçülüyorsa,  $q_{ia} = 1$  olur ve böylece  $\pi_{ia}$  temel olasılıklar hesaplanarak bulunur. Temel olasılık  $\pi_i^*$ , her bir sahip olunan özeliğin olasılık değerlerinin çarpılmasıdır.

i maddesinin a özeliği için tahmin olasılığı 13 no’lu eşitlikte belirtilen şekilde hesaplanabilir:

$$r_{ia}^* = \frac{r_{ia}}{\pi_{ia}} \quad (13)$$

Ayrıca  $r_{ia}^*$ , i maddesinin a özeliği için ayırt edicilik parametresini göstermektedir (Henson, Roussos, Douglas ve He, 2008). Tamamlayıcı olmayan RUM modelinde doğru cevap verme olasılığı 14 no’lu eşitlikte belirtilmiştir.

$$\pi_{ic} = P(X_{ic} = 1 / \alpha_c) = \pi_i^* \prod_{a=1}^A r_{ia}^{*(1-\alpha_{ca})q_{ia}} \quad (14)$$

Yukarıdaki eşitlikte,  $\pi_{ic}$ , c örtük sınıfında, i maddesine doğru cevap verme olasılığını,  $X_{ic}$ ; c örtük sınıfında i maddesi için gözlenen tepkiyi,  $q_{ia}$ ; ölçülen i maddesi için a özeliğinin gerekli olup olmadığının Q matrisindeki göstergesini,  $\alpha_{ca}$ , c örtük sınıfında a özeliği için özellik başarı göstergesini belirtmektedir (Rupp, Templin ve Henson, 2010). Ayrıca  $r_{ia}^*$ , i maddesinin a özeliği için ayırt edicilik parametresini göstermektedir (Henson, Roussos, Douglas ve He, 2008). a özeliği gerekli olmadığında 1 değerini alırken, ayırt edicilik maksimum olduğunda 0 değerini alır.

### 1.1.6. Tamamlayıcı Model

Tamamlayıcı BTM'nde, birey tepkilerindeki becerilerin ortak etkisi modellenmektedir. Henson ve diğerleri (2009), tamamlayıcı modeli “bireyin testteki bir maddeye doğru cevap vermesi için en az bir gerekli beceriye sahip olması yüksek olasılık doğurur” şeklinde ifade etmişlerdir. Sonuç olarak, bütün becerilere sahip olan birey ile birkaç beceriye sahip olan bireyin maddeye tepkisinin benzer olması beklenir. Tamamlayıcı BTM; Maris'in (1999) MCLCM-D (Multiple Classification Latent Class Model- Disjunctive) modeli, Maris'in (1999) MCLCM-C (Multiple Classification Latent Class Model-Compensatory) modeli, Templin ve Henson'ın (2006) DINO (Deterministic Input Noisy “Or”) modeli, Templin, Henson ve Douglas'ın (2006) NIDO (Noisy Input, Deterministic “Or”) modeli ve von Davier'in (2005) GDM (The Generalized Diagnosis Model) örnek verilebilir. Aşağıda bu modellerden bazıları kısaca açıklanmıştır.

#### 1.1.6.1. DINO (Deterministic Input Noisy “Or”) Model

Templin ve Henson (2006), tamamlayıcı modellerden DINO modelini DINA modele bağlı olarak geliştirmişlerdir. DINA modelde olduğu gibi bu modelde de kaydırma

ve tahmin süreçleri madde düzeylerinde modellenir. DINO modelinin formülü incelendiğinde; örtük tepki değişkeni ( $w_{ci}$ ), kaydırma ve tahmin parametrelerinin yer aldığı görülür. Örtük tepki değişkeni c. madde için gerekli özelliklerden en az birine sahip olan i. bireyi belirtmektedir. Bu modelde, bireyleri iki gruba ayırmak için, i maddesi için verilen Q matrisinde en az bir ya da daha fazla özelliğe sahip olan birey için ( $w_{ic} = 1$ ) ve verilen Q matrisinde herhangi bir özelliğe sahip olamayan birey için ise ( $w_{ic} = 0$ ) olmaktadır.  $w_{ci}$  ; 15 no'lu eşitlikte belirtilen şekilde hesaplanabilir.

$$w_{ic} = 1 - \prod_{a=1}^A (1 - \alpha_{ca})^{q_{ia}} \quad (15)$$

DINO modeldeki kaydırma ve tahmin parametreleri incelendiğinde; *tahmin parametresi*, ölçülen özelliklerden hiçbirisine sahip olunmadığında maddeye doğru cevap verme olasılığını belirtirken; *kaydırma parametresi* ise, ölçülen özelliklerden en az birisine sahip iken olasılık değerinin sıfır olması durumunu belirtmektedir. DINO model için kaydırma ve tahmin parametreleri 16 ve 17 no'lu eşitliklerde belirtilen şekilde ifade edilmektedir;

$$s_i = P(X_{ic} = 0 / w_{ic} = 1) \quad (16)$$

$$g_i = P(X_{ic} = 1 / w_{ic} = 0) \quad (17)$$

Örtük tepki değişkeni, kaydırma ve tahmin parametrelerinin bir fonksiyonu olarak, doğru cevap olasılığının kestirilmesi 18 no'lu eşitlikte gösterilmektedir:

$$\pi_{ic} = P(X_{ic} = 1 / w_{ic}) = (1 - s_i)^{w_{ic}} g_i^{(1-w_{ic})} \quad (18)$$

### 1.1.6.2. NIDO (Noisy Input, Deterministic “Or”) Model

Templin, Henson ve Douglas (2006), tamamlayıcı modellerden NIDO modeli geliştirmişlerdir. Bu model NIDA modelin tamamlayıcı versiyonudur. Bu modelin formülü incelendiğinde; sabit (*intercept*,  $\lambda_{0,(a)}$ ) ve eğim (*slope*,  $\lambda_{1,(a)}$ ) parametrelerini içerdiği görülmektedir. NIDO modelde, her bir özellik için bir sabit ve bir eğim parametresi kestirilmektedir. Model için doğru cevap olasılığı, 19 no’lu eşitlikte gösterilmektedir;

$$\pi_{ic} = P(X_{ic} = 1 / \alpha_c) = \frac{\exp\left(\sum_{a=1}^A (\lambda_{0,(a)} + \lambda_{1,(a)} \alpha_{ca}) q_{ia}\right)}{1 + \exp\left(\sum_{a=1}^A (\lambda_{0,(a)} + \lambda_{1,(a)} \alpha_{ca}) q_{ia}\right)} \quad (19)$$

Yukarıdaki eşitlikte; P; olasılık değeri,  $\pi_{ic}$ ; c örtük sınıfındaki i maddesine doğru cevap verme olasılığını,  $X_{ic}$ ; c örtük sınıfındaki i maddesi için gözlenen tepkiyi,  $q_{ia}$ ; Q matrisinde i maddesi için a özeliğinin gerekli olup olmadığının göstergesini,  $\alpha_{ca}$ ; c örtük sınıfındaki a özeliğine sahip olup olunmadığının göstergesini,  $\lambda_{0,(a)}$ ; a özeliği için sabit parametresini ve  $\lambda_{1,(a)}$ ; a özeliği için eğim (ayrıt edicilik) parametresini belirtmektedir.

NIDO modelede dikkat edilirse, doğru cevap olasılığı belirlenirken, her beceri için sadece iki tane parametre kullanılmaktadır. Ayrıca bu modelde, aynı beceri içindeki madde parametreleri aynı değerlere sahip olmaktadır (Rupp, Templin ve Henson, 2010). Sonuç olarak, aynı Q matrisinin verilmesinde, maddeler için maddeye doğru cevap verme olasılığı aynı olmaktadır.

### 1.1.6.3. Tamamlayıcı RUM

Tamamlayıcı RUM, R-RUM modelin tamamlayıcı olan versiyonudur. Modelin formülü incelendiğinde, NIDO modele benzer olarak sabit ve eğim parametrelerinin olduğu görülmektedir. Ancak sabit parametresi ( $\lambda_{0,(a)}$ ), bu modelde özellik düzeyinde değil, madde düzeyinde tanımlanmaktadır. Eğim parametresi ( $\lambda_{1,(a)}$ ) ise, her bir madde için özellik düzeyinde tanımlanmaktadır (Rupp, Templin ve Henson, 2010). Eğim parametresi temel etki terimi gibi düşünülebilir. Bu model için, bir sabit parametresi ve Q matrisindeki 1'ler kadar eğim parametresi kestirilmektedir. Model için doğru cevap olasılığı 20 no'lu eşitlikte belirtildiği gibi hesaplanmaktadır.

$$\pi_{ic} = P(X_{ic} = 1 / \alpha_c) = \frac{\exp(\lambda_{i,0} + \sum_{a=1}^A \lambda_{i,1(a)} \alpha_{ca} q_{ia})}{1 + \exp(\lambda_{i,0} + \sum_{a=1}^A \lambda_{i,1(a)} \alpha_{ca} q_{ia})} \quad (20)$$

### 1.1.7. Bilişsel Tanı Modellerinde Madde Parametre Kestirimi

Bilişsel Tanı Modellerinde madde parametre kestiriminde yaygın olarak kullanılan farklı iki istatistiksel yöntem bulunmaktadır. Bunlardan ilki, frekansların kestirimiyle ilgili olan E-M (Expectation- Maximization) yaklaşımı ve diğeri Bayes kestirim prensipleriyle ilgili olan MCMC (Markov-chain Monte Carlo) yaklaşımıdır. Haertel (1984, 1990) ile Gitomer ve Yamamoto (1991), DINA modeli için E-M algoritmasını geliştirmişlerdir. de la Torre ve Douglas (2004) ise, DINA, NIDA ve tamamlayıcı MCLCM için MCMC algoritmasını geliştirmişlerdir. Ayrıca, Templin ve Henson (2006), DINO model için; Templin vd. (2006) NIDO model için MCMC algoritmasını geliştirmişlerdir. Her iki yaklaşımın da avantajları ve dezavantajları bulunmaktadır.

E-M algoritmasında, madde parametrelerinin kestirilebilmesi için başlangıç değerinin belirlenmesi gerekmektedir. Diğer yaklaşımlarla kıyaslandığında, birçok durumda oldukça hızlı yapılabilmekte ve örtük sınıf modelleri ya da örtük değişken modellerinde kestirim hesaplamaları için yaygın olarak kullanılabilir (Rupp, Templin ve Henson, 2010). E-M algoritmasının, birtakım sınırlılıkları da bulunmaktadır. Farklı başlangıç değerlerinin seçilmesi, madde parametre değerlerinde küçük değişikliklere neden olabilmektedir. Örtük sınıf sayısı arttıkça, E-M algoritmasının hesaplanması sayısal olarak daha yoğun hale gelmektedir (Rupp, Templin ve Henson, 2010). BTM karmaşıklıklaştıkça daha karmaşık sınırlılıklar içerir. Böyle durumlarda, E-M kestirimleri pratik olarak sakıncalar yaratabilmektedir.

E-M algoritmasının aksine, MCMC algoritmasının kullanılması durumunda, madde parametrelerinin en çok olabirlik kestiricisinin herhangi bir ön hesaplaması gerekmemektedir. Her iki yöntemin uygulanabildiği durumlarda, MCMC algoritması E-M algoritmasına göre daha yavaş çalışmaktadır. MCMC algoritması, E-M algoritmasının gerçekçi şekilde uygulanamadığı durumlarda, alternatif bir uygulama olarak geliştirilmiştir (Rupp, Templin ve Henson, 2010). MCMC kestiriminde, madde parametrelerinin sonsal dağılımlarının elde edilebilmesi için Bayes kestirimi kullanılır.

### **1.1.8. Bilişsel Tanı Modellerinde Güvenirlik**

BTM uygulamalarında, iki önemli konu, birey sınıflamasının güvenilirliği ve model uyumunun değerlendirilmesidir. Tek boyutlu örtük özellik modellerinde kullanılan güvenilirlik hesaplamaları, daha karışık olan BTM gibi modellerde doğrudan kullanılamamaktadır. Gierl, Cui, ve Zhou (2009) BTM'nde özellik güvenilirliğini, uygulanan testte, bireylerin özeliğe sahip olup olmamalarına göre verilen puanlara ilişkin kararların



kesinliği şeklinde ifade etmişlerdir. BTM’nde güvenilirliğin kestiriminde birçok yöntem geliştirilmiştir (Gierl, Cui,ve Zhou, 2009; Henson vd., 2004; Zhang vd., 2006). Ancak güvenilirlik kavramı, kestirilen ya da gerçek özellik arasındaki ilişki ya da aynı uygulamanın aynı bireylere bağımsız olarak iki kere uygulanmasından sonraki yapılan sınıflamaların tutarlılığı şeklinde kavramsallaştırılmaktadır (DiBello, Roussos, ve Stout, 2007). Özellik güvenilirliğinin kestiriminde kullanılan yöntemlerden biri, bir maddede araştırılan her bir özeliğin gözlenen puan varyansının, gerçek puan varyansına oranının hesaplanması (Gierl, Cui,ve Zhou, 2009) iken, bir diğer yöntem ise, bireyleri özellik profillerine göre sınıflayıp tutarlılığın hesaplanmasıdır (Henson vd., 2004).

Sınıflama tutarlılığının hesaplanmasına ilişkin kullanılan yöntemler, çeşitli kriterlere göre incelenebilir. Bu kriterler; a) her bir özellik için doğru sınıflama oranları, b) replikasyon başına sınıflanan bireysel özellikler için  $N \times K$  toplam doğru sınıflama oranı, c) bütün  $K$  özellikleri için doğru sınıflanan bireylerin oranı, d) en  $K-1$  özellik için doğru sınıflanan bireylerin oranı ve e)  $K$  ya da  $K-1$  özellik için yanlış sınıflanan bireylerin oranı şeklinde belirtilmiştir (Huebner ve Wang, 2011).

Bireylerin sınıflanmasında yaygın olarak, Ençok Olabilirlik Kestirimi (maximum likelihood estimation, MLE), Maksimum Sonsal (maximum a posteriori, MAP) ve Beklenen Sonsal (expected a posteriori, EAP) yaklaşımları kullanılmaktadır (Huebner ve Wang, 2011).

MLE sınıflamasında, her bir özellik profilindeki olabilirlik hesaplanır. Bireyler kestirilen özellik profillerini maksimize edecek şekilde sınıflandırılır. MAP sınıflaması ise, Bayes teorimi kullanılarak sonsal olasılıklar hesaplanarak yapılır. MLE ve MAP, her bir özellik için olasılık kestirimi sağlamazken, EAP ise, her bir özellik için olasılık kestirimi sağlar (Huebner ve Wang, 2011). MLE ve MAP yaklaşımlarında, sonsal dağılımın modu

bulunurken, EAP yaklaşımında ise, sonsal dağılımın ortalaması bulunur (Embretson ve Reise, 2000). EAP, bireylerin her bir özeliği için başarı olasılıklarını hesaplar ve bu olasılık değerlerinden hareketle, özeliğe sahip olup olmama açısından sınıflama yapmak için bir kesim noktası (genellikle 0.5) belirler (Huebner ve Wang, 2011).

## **1.2. BTM Modelleri Kullanılarak Yapılan Çalışmalar**

de la Torre ve Douglas (2004), yüksek dereceden yapılar üzerinde, DINA ve LLTM (Linear Logistic Model) modellerini kullanarak incelemelerde bulunmuşlardır. Yaptıkları simülasyon çalışmasında, modelin yanlış tanımlanmasının ve MCMC (Markov Chain Monte Carlo) algoritmasının parametre kestirimi üzerindeki etkisini incelemişlerdir. Simülasyon dizaynlarında, 1000 birey, 30 madde, 5 özellik kullanılmış ve 25 replikasyon yapılmıştır. Bütün replikasyonlarda, kaydırma ve tahmin parametreleri sabit tutulmuştur. Çalışma sonucunda, tasarlanan veriye uygun model kullanıldığında, özelliklerin doğru sınıflanmasının yüksek olduğu görülmüştür. DINA model kullanılarak üretilen veride, DINA model kullanılıp parametre kestirimi yapıldığında, özelliklerin doğru sınıflama oranları yüksek bulunmuştur (test edilen bütün 5 özellik için .88 ile .97 arasında). Ancak, DINA model kullanılarak üretilen veride, kestirim için LLTM kullanıldığında, sınıflamalarda önemli farklılıklar olduğu görülmüştür.

de la Torre ve Douglas (2008), örtük özelliklerin yüksek dereceden modellenmesiyle elde edilen veriler üzerinde çeşitli tanılayıcı modelleri karşılaştırmışlardır. Bu çalışmada, bireylerin sınıflanmasında, tamamlayıcı modellerden, NIDA, tek strateji DINA ve çoklu strateji DINA modelleri kullanılmıştır. Yüksek dereceden parametrelerin, çoklu strateji DINA model ve çoklu strateji NIDA model kullanarak tutarlı bir şekilde kesirilmesi amaçlanmıştır. Bu nedenle iki simülasyon dizaynı oluşturmuşlardır. İlk simülasyon dizaynında, veriler hem NIDA hem de tek strateji DINA

modele uyum sađlayan yksek dereceden NIDA modele gre retilmiřtir. Veri retiminde 5 zelik, 20 madde, 2000 birey kullanılmıř ve 25 replikasyon yapılmıřtır. 25 replikasyonda yapısal parametreler ( $\lambda$ ,  $s$  ve  $g$ ) sabit tutulmuř;  $\theta_i$  Normal dađılımdan (0,1) ve  $\alpha_i$  Bernoulli dađılımından ekilmiřtir. İkinci simlasyon dizaynı iki kısımdan oluřmuřtur. İlk dizaynda, hem tek hem de oklu strateji DINA modele uyum sađlayan, tek strateji DINA modele gre veriler retilmiřtir. İkinci dizaynda ise, oklu strateji DINA'ya uyum sađlayan veriler retilmiřtir. Her iki dizaynda 3 zellik ortak olmak zere toplam 5 zelik, 20 madde, 2000 birey kullanılmıř ve iki dizayn iin ayrı ayrı 25 replikasyon yapılmıřtır. Model uyumunu deđerlendirmede BIC, AIC ve DIC indeksleri kullanılmıřtır. Parametre deđerlendirmede ise,  $\theta$  ve  $\hat{\theta}$  arasında RMSE ve ortalama korelasyon kullanılmıřtır. Birinci simlasyon alıřması sonucunda, korelasyon deđer RMSE deđerinden yksek bulunmuřtur. Korelasyon ve RMSE deđerleri sırasıyla NIDA iin 0.75 ve 0.66 iken, DINA iin, 0.74 ve 0.67 bulunmuřtur. Test edilen beř zeliđin dođru sınıflama yzdeleri ise, NIDA iin %94 ile %96 arasında deđerirken, DINA iin %92 ile %95 arasında deđeritiđi gzlenmiřtir. İkinci simlasyon sonuları da parametre kestiriminin tutarlılıđı ve dođru sınıflama yzde oranı aısından birinci simlasyon sonularına benzer bulunmuřtur. Sonu olarak, her iki modelin veriye uyum sađladıđını ve parsimoni ilkesine dayanarak tek strateji DINA modelin oklu strateji DINA modele tercih edilebileceđini belirtmiřlerdir.

Henson ve Douglas (2005) alıřmalarında, bireylerin sınıflanmasında, ayırt ediciliđi yksek olan maddelerin seilmesinde kullanılan, Kullback- Leibler bilgisine dayalı olarak ıkartılan genel BTM ayırt edicilik indeksini nermiřlerdir. Bu indeksin etkililiđine, DINA ve RUM modellerinde simlasyon dizaynı sonucu oluřturulan testlerden ve madde havuzundan sekisiz olarak seilen maddelerden oluřturulan testlerden elde edilen sonulara bakılarak karar verilmiřtir. Simlasyonda her iki model iin 10.000 birey

kullanılmıştır. DINA model için veri üretiminde 20 madde, 4-8 özellik kullanılmış ve gerekli olan madde parametreleri  $\sigma_j$  ve  $\sigma_j^*$ 'nin her ikisi U (.05, .40) olan dağılımdan elde edilmiştir. RUM model için veri üretiminde ise, 20 madde, 4-8 özellik kullanılmış ve gerekli olan parametrelerden  $\pi_j^*$ , U (.75, .95) olan dağılımdan,  $r_{jk}^*$  ise, U (.2, .95) olan dağılımdan elde edilmiştir. Her iki modelde özellikler arasındaki korelasyon  $\rho=.0$  ya da  $\rho=.5$  olarak ayarlanmıştır. Çalışma sonucunda DINA modelde 4 özellik ve  $\rho=.0$  olduğunda, deneysel olarak hazırlanan testteki bireylerin doğru sınıflama oranının, madde havuzundan seçkisiz olarak seçilerek hazırlanan testteki bireylerin doğru sınıflama oranından %32.5 daha fazla olduğu görülmüştür. Marjinal durumda ise, deneysel olarak hazırlanan testteki bireylerin doğru sınıflama oranının, madde havuzundan seçkisiz olarak seçilerek hazırlanan testteki bireylerin doğru sınıflama oranından %13.5 daha fazla olduğu görülmüştür. DINA modelde 8 özellik ve  $\rho=.0$  olduğunda, bu oranların sırasıyla %18.3 ve %16 daha fazla olduğu görülmüştür. Aynı sonuçlar DINA modelde  $\rho=.5$  olduğunda da elde edilmiştir. RUM modeli ile elde edilen sonuçlar incelendiğinde,  $\rho=.0$  koşulunda, 4 ve 8 özellik için, deneysel olarak hazırlanan testteki bireylerin doğru sınıflama oranının, madde havuzundan seçkisiz olarak seçilerek hazırlanan testteki bireylerin doğru sınıflama oranından %26 daha fazla olduğu görülmüştür. Aynı sonuçlar RUM modelde  $\rho=.5$  olduğunda da elde edilmiştir. Bu çalışmada, Q matrisinin etkisi çalışma dışı bırakılmış ve bu durumun seçkisiz olarak oluşturulan testlerde ayırt edicilik indeksinin (CDI) daha iyi çalışmasına neden olmuş olabileceği sonucuna varılmıştır. Bu problemin, belirli koşullarla belirlenen Q matrisine dayalı olarak seçilen maddelerden oluşturulan testlerle çözülebileceğini önermişlerdir.

Rupp ve Templin (2008) çalışmalarında, DINA model kullanarak Q matrisinin yanlış belirlenmesinin parametre kestirimine ve sınıflama tutarlığına etkisini

araştırmışlardır. Yaptıkları simülasyon çalışmasında, yüksek dereceden DINA model kullanarak yanlış belirlenen farklı Q matrislerinin kullanılmasıyla kestirilen parametreler ve elde edilen sınıflama tutarlılıklarını, doğru Q matrisi kullanılarak kestirilen parametrelerle ve elde edilen sınıflama tutarlılıklarıyla karşılaştırmışlardır. Q matrisinin yanlış belirlenmesini iki şekilde tasarlamışlardır. Bunlar: 1. Belirli sayıda özellik gerektiren maddeler için, a) Q matrisinin altında-uyum (underfitting); 1'leri 0 ile değiştirme b) Q matrisinin üstünde-uyum (overfitting); 0'ları 1 ile değiştirme c) Q matrisinin dengeli olarak uyumsuzluğu; 0 ve 1'leri baştan başa kontrollü bir şekilde değiştirmek. 2. İki özellik arasında doğru olmayan bağılık sayıltısı oluşturmak. Çalışma sonucunda, Q matrisinin yanlış belirlenmesi DINA modelin kaydırma ve tahmin parametreleri üzerinde bölgesel (Q matrisinin yanlış belirlendiği bölge) etki yaptığı bulunmuştur. Çalışmada, Q matrisinden özellikler doğru olmayan bir şekilde çıkartıldığında, DINA model kaydırma parametresinin daha yüksek kestirildiği, Q matrisine özellikler gereğinden çok eklendiğinde ise, DINA model tahmin parametresinin daha düşük kestirildiği sonucuna ulaşılmıştır. Ayrıca, Q matrisinin yanlış belirlenmesi sonucu bireylerin sınıflanmalarında da yanlışlıklar olduğu görülmüştür.

de la Torre (2008), DINA model için kullanılan Q matrisinin geçerliği sınamak için yaptığı çalışmasında, amprik temelli yöntem geliştirmiş ve bu yönteme de “delta yöntemi” adını vermiştir. Delta yöntemini araştırmak için oluşturduğu simülasyon dizaynında, veri üretiminde, 5000 birey, 5 özellik ve 30 madde kullanılmıştır. Her madde en fazla 3 özelliği ölçmektedir. Ayrıca bütün maddelerin kaydırma ve tahmin parametreleri .20 olarak ayarlanmıştır. Q matrisinin etkisinin incelenmesi için, 1 tane q vektörü yanlış tanımlanan 10 Q matrisi ve 3 tane q vektörü yanlış tanımlanan 1 tane Q matrisi oluşturulmuştur. Araştırma sonuçları incelendiğinde, doğru Q matrisi kullanıldığında, parametre

kestirimlerinin çok az yanlış olduğu ve ortalama ayırt edicilik indeksinin  $\delta = .61$  olduğu görülmüştür. Diğer taraftan, Q matrisinin yanlış tanımlanması durumunda, parametrelerin çok yanlış kestirildiği ve  $\delta$ 'nın küçülmüş olduğu görülmüştür. Bu çalışmada, EM dayalı delta yönteminin Q matrisinin uygunluğunun kontrolünde kullanabileceğini ve delta yönteminin Q matrisi hakkında istatistiksel bilgi sağlayacağını belirtmişlerdir.

Liu, Douglas, ve Henson (2009), yaptıkları çalışmada bilişsel tanı testlerinde birey uyumunu araştırmak için iki çeşit olabilirlik oran test istatistiği kullanmışlardır. Bir sapkın davranıştaki cevaplanma olasılığını " $\rho$ " ile tanımlamışlar ve " $\rho$ ", bireyin gerçek özeliğinin ötesinde sapkın davranma eğiliminin büyüklüğünü ölçtüğünü belirtmişlerdir. İki çeşit uyumsuz olan birey durumu olduğunu ve bunların: a) maddeye doğru cevap veren gerekli özelliklerin bulunmadığı (yapay yüksek puan alanlar) b) maddeye doğru cevap veremeyen gerekli olan özelliklerin bulunduğu (yapay düşük puan alanlar) olduğunu belirtmişlerdir. Yaptıkları simülasyon çalışmasında, DINA modeli kullanmışlar ve a) istatistiksel testlerin, normal/sapkın davranışları ne kadar doğrulukta belirlediğini b) test uzunluğuna ve sapkınlığa karşı eğilimin derecesine bağlı olarak testin gücünün nasıl olduğunu c) model parametrelerinin yanlış kestiriminde testin duyarlılığını incelemişlerdir. Yaptıkları çalışmanın sonucunda, genelleştirilmiş olabilirlik testlerinin uyum göstermeyen bireylerin belirlenmesinde kullanılabileceğini belirtmişlerdir.

de la Torre ve Young-Sun (2010), yaptıkları çalışmada Bilişsel Tanı Modeli olan DINA modelin parametrelerinin değişmezliğini araştırmışlardır. Çalışmada, Doymuş (saturated) ve yüksek-dereceden formülasyonunu kullanarak, parametrelerin yetenek dağılımlarına karşı değişmezliğini incelemişlerdir. Bu çalışma kapsamında hem simülasyon hem de gerçek veri kullanmışlardır. Kestirim yöntemi olarak Markov Chain

Monte Carlo (MCMC) yöntemi ile maksimum olabilirlik yöntemlerini kıyaslamışlardır. Yüksek dereceden dağılım için, ortalamaları  $\mu_{\theta}=\{-1.0,0.0,1.0\}$  ve standart sapması  $\sigma_{\theta}=1.0$  olan üç tane yetenek düzeyi belirlemişlerdir. Bu çalışmada, veri-model uyumuna ulaşıldığında, özellik dağılımına karşı değişmezlik olacağını, veri-model uyumuna ulaşılmadığında ise, özellik dağılımına karşı değişmezliğin olmayacağını sınımlamışlardır. Madde parametre kestiriminin tutarlılığını mutlak ortalama yanlılık (MAB) ile belirlemişlerdir. Tahmin parametresi için MAB değerinin 0.000 ile 0.006 arasında, kaydırma parametresi için MAB değerinin 0.000 ile 0.002 arasında değiştiğini bulmuşlardır. Üretilen simülasyon verisi ise, modele mükemmel derecede uyum gösterdiğini belirtmişlerdir. Yapılan bu simülasyon çalışması sonucunda, model veriye iyi uyum gösterdiğinde, DINA parametrelerinin değişmediği görülmüştür.

de la Torre ve Karalitz (2009), yaptıkları simülasyon çalışmasında, üretilen veriyle, Madde Tepki Kuramı modellerinden 2 parametrelili lojistik modelin (2PL) ve DINA modelin, tanılayıcı bilgi verme yeteneğini sınımlamışlardır. 2PL ve DINA model hem veri üretiminde hem de verilerin analizinde kullanılmıştır. Çalışmada, düşük ayırt edici durum (ayırt edicilik parametresi  $a \sim U(0.4,0.8)$ ), orta ayırt edici durum (tipik bir testi yansıtan durum) ve yüksek ayırt edici durum (ayırt edicilik parametresi  $a \sim U(1.6,2.0)$ ) olmak üzere üç tanılayıcı durum belirlemişlerdir. 2PL ve DINA model parametrelerinin karşılaştırılabilmesi için LST kullanarak, aynı ölçek üzerine yerleştirmişlerdir. Çalışmada, model veri uyumunun hesaplanmasında RMSD (root mean square deviation) kullanmışlardır. Düşük RMSD ve  $-2\log$ -likelihood değerleri ile yüksek tanılayıcılığı olan maddelerin çok az uyum gösterdiğini belirtmişlerdir. Madde ve birey kestirim tutarlılığını RMSE kullanarak hesaplanmıştır. Yüksek tanılayıcı durumda ise, yanlış sınıflama yüzdesinin daha az tutarlı olduğu bulunmuştur.

Cui, Gierl ve Chang (2012), yaptıkları simülasyon çalışmasında, bilişsel tanı değerlendirilmesinde tanı sonuçlarının sınıflama tutarlığının ve doğruluğunun nasıl olduğunu göstermeyi amaçlamışlardır. Bu amaçla, iki yeni sınıflama indeksini tanıtmışlardır: sınıflama tutarlığı indeksi ( $P_c$ ) ve sınıflama doğruluğu indeksi ( $P_a$ ). Bu indekslerin performansını ve dağılım özelliklerini, hem Tatsuoka'nın gerçek verisi üzerinde hem de simülasyon düzeneğinde test etmişlerdir. DINA modele dayalı olarak yaptıkları simülasyon düzeneğinde, madde sayısını sabit tutarak (20 madde), her bir maddenin yaklaşık olarak 1.5 özeliği ölçmesini ayarlamışlardır. Ayrıca, madde ayırt edicilik gücünü (yüksek ve düşük), örneklem büyüklüğünü (100,500 ve 1000), testte ölçülen özellik sayısını (3, 5 ve 8) ve özellikler arası korelasyonu (düşük, orta düzeyde korelasyon gösteren ve yüksek düzeyde korelasyon gösteren) manipüle etmişlerdir. Madde parametreleri daha önceden bilinen test için,  $P_c$  ve  $P_a$ 'nın örnekleme dağılımlarının asimptotik olarak normal olduğunu göstererek, simülasyon düzeneğinde bu durumunun nasıl olacağını araştırmışlardır. Simülasyon çalışması sonucunda, farklı ayırt edicilik, farklı örneklem büyüklüğü, farklı özellik sayısı ve farklı özellik bağlılığına karşı  $P_c$  ve  $P_a$ 'nın örnekleme dağılımlarının ortalama ve standart sapmasının, ilişkili evren parametre değerlerine yakın olduğu bulunmuştur.

Habenicht, Rupp ve Wilhelm (2012), log-linear model kullanarak, madde uyum istatistiklerini ve sınıflama doğruluğunu incelemişlerdir. Yaptıkları simülasyon düzeneğinde, testi alan birey sayısını (1000 ve 10.000), özellik sayısını (3 ve 5), madde sayısını (25 ve 50), özellikler arasındaki korelasyonu (.50 ve .80) marjinal özellik güçlüklerini (aynı ve farklı) manipüle etmişlerdir. Çalışmada, doğru tanımlanmış Q matrisinin ve iki farklı yanlış tanımlanmış Q matrisinin parametre kestirimine etkisini araştırılmıştır. Analizde yanlış tanımlanmış Q matrisi kullanıldığında, sınıflama



doğruluğunun görülür derecede düştüğü görülmüştür. Ayrıca, AIC ve BIC uyum indekslerinin de, Q matrisinin yanlış belirlenmesine karşı duyarlı olduğu görülmüştür.

### 1.3. Araştırmanın Amacı ve Önemi

Eğitimde ve psikolojide KTK ve TBMTK, ölçülmek istenilen yapının tek boyutlu olması durumunda kullanılmaktadır. KTK’de elde edilen gözlenen puanlar ve TBMTK’de elde edilen yetenek puanları bireylerin görel olarak sıralanmasında kullanılır. Ayrıca TBMTK’de süreçten çok maddeye doğru cevap verme olasılıkları üzerine odaklanılmaktadır, İlgilenilen yapı çok boyutlu olduğunda ise, tek boyutluluk sayılıtsı gerektirmeyen ÇBMTK geliştirilmiş olup, bu modelde birden fazla örtük özeliği ölçen maddelere ilişkin performansın gözlenebilmesine olanak tanınmaktadır.

Bireylerin ilgilenilen özellik açısından güçlü ya da zayıf yönlerinin ortaya çıkarılmasında, önceden belirlenmiş beceri ya da özelliklere sahip olup olmadığına ilişkin bilgiler elde edilmesinde ya da bireyler hakkında daha zengin, anlamlı, yönlendirici bilgiler sağlanmasında bu kuramların eksiklikleri bulunmaktadır. Özellikle hiyerarşinin olmadığı becerilerin yoklanmasında eksiklikler söz konusudur. Bu tür eksiklikler göz önünde bulundurularak Bilişsel Tanı Modelleri geliştirilmiştir. Bu modeller sayesinde, ailelere, öğretmenlere, eğitim yöneticilerine ve öğrencilere, öğrencilerin neyi öğrendiklerine, öğrenme eksikliklerinin neler olduğuna ya da istenilen becerilerden hangilerine sahip olup olmadıklarına ilişkin daha anlamlı ve zengin geri dönüt verilebilmektedir.

BTM uygulamalarında, birey sınıflamasının güvenilirliği ve model uyumunun değerlendirilmesi, yapılacak olan çıkarımlar açısından büyük önem taşımaktadır. Bu nedenle, bu çalışma kapsamında, Bilişsel Tanı Modelleri’nde parametre kestirimini ve sınıflama tutarlığını etkileyen faktörlerin, bazı sınırlılıklar çerçevesinde, neler olduğunun

belirlenmesi amaçlanmıştır. Bu amaçla, üretilen veriye ilişkin parametre kestirimlerinin hangi koşullarda daha yansız ve sınıflama tutarlılığının hangi koşullarda daha tutarlı sonuçlar verdiğine bakılmıştır. Ayrıca bu çalışmada, tamamlayıcı ve tamamlayıcı olmayan BTM'nin parametre kestirimi ve sınıflama tutarlılığı açısından benzeştiği veya ayrıştığı durumlar belirlenmeye çalışılmıştır.

İlgili literatür incelendiğinde, yurtiçinde BTM'nde parametre kestirimini ya da sınıflama tutarlılığını etkileyen faktörlerin araştırılmasına yönelik herhangi bir çalışmanın yapılmadığı görülmüştür. Yurt dışında ise, bu çalışma kapsamına benzer simülasyon çalışmalarının yapıldığı görülmüştür ancak, bu çalışmada, değişimlenen faktörler ve bu faktörlerin düzeyleri çeşitlendirilerek çalışmaya özgül değer katılmıştır. Bu çalışmanın, ülkemizde Bilişsel Tanı Modelleri'nin kullanılmasının yaygınlaşmasına ışık tutacağı düşünülmektedir.

#### **1.4. Problem Cümlesi**

Bilişsel Tanı Modellerinde, madde parametre kestirimini ve sınıflama tutarlılığını etkileyen faktörler nelerdir?

##### **1.4.1. Alt Problemler**

Tamamlayıcı modele (DINA) göre üretilen verinin, madde parametre kestirimini ve sınıflama tutarlılığını etkileyen faktörler nelerdir?

**1.4.1.1.** Çeşitli faktörlerin (örneklem büyüklüklerinin, özellikler arası korelasyonun, özellik sayılarının, madde sayılarının,  $s$  ve  $g$  parametre düzeylerinin ve DINA ve DINO analiz modellerinin),  $g$  parametre kestirimi için elde edilen,

**a.** Mutlak Ortalama Yanlılık (MOY) ortalamalarına temel etkileri nasıldır?

**b. MOY ortalamalarına ilişkin ortak etkileri nasıldır?**

**1.4.1.2.** Çeşitli faktörlerin (örneklem büyüklüklerinin, özellikler arası korelasyonun, özellik sayılarının, madde sayılarının, s ve g parametre düzeylerinin ve DINA ve DINO analiz modellerinin), *s parametre kestirimi* için elde edilen,

**a. MOY ortalamalarına temel etkileri nasıldır?**

**b. MOY ortalamalarına ilişkin ortak etkileri nasıldır?**

**1.4.1.3.** Çeşitli faktörlerin (örneklem büyüklüklerinin, özellikler arası korelasyonun, özellik sayılarının, madde sayılarının, s ve g parametre düzeylerinin ve DINA ve DINO analiz modellerinin), *madde uyumu* için elde edilen,

**a. RMSEA ortalamalarına ilişkin temel etkileri nasıldır?**

**b. RMSEA ortalamalarına ilişkin ortak etkileri nasıldır?**

**1.4.1.4.** Çeşitli faktörlerin (örneklem büyüklüklerinin, özellikler arası korelasyonun, özellik sayılarının, madde sayılarının, s ve g parametre düzeylerinin ve DINA ve DINO analiz modellerinin), *sınıflama tutarlılığı* için elde edilen,

**a. Doğru Sınıflama Oranları (DSO) ortalamalarına ilişkin temel etkileri nasıldır?**

**b. Doğru Sınıflama Oranları (DSO) ortalamalarına ilişkin ortak etkileri nasıldır?**

### **1.5. Sınırlılıklar**

- 1.** Araştırmanın veri üretimi aşamasında, tamamlayıcı olmayan modeller içerisinde yer alan DINA modeli kullanılmıştır.
- 2.** Araştırmanın veri analizi aşamasında, DINA ve DINO modelleri kullanılmıştır.
- 3.** Araştırma, simülasyon düzeneğinde yer alan faktörlerle (örneklem büyüklüğü, özellikler arası korelasyon, özellik sayısı, madde sayısı, s ve g parametreleri) ve bu faktörlerin çeşitli düzeyleriyle sınırlıdır.
- 4.** Araştırmada parametre kestiriminde “E-M yaklaşımı” ve sınıflama tutarlılığı hesaplanmasında “Ençok Olabilirlik Kestirimi” yöntemleri kullanılmıştır.

## **BÖLÜM II: YÖNTEM**

### **II. 1. Araştırmanın Türü**

Bu çalışmada, Bilişsel Tanı Modelleri'nde madde parametre kestirimini ve sınıflama tutarlılığını etkileyen faktörlerin neler olduğunun incelenmesi, hangi durumlarda daha yansız kestirimlerin ve daha doğru sınıflamaların elde edildiğinin belirlenmesi ve tamamlayıcı model (DINO) ile tamamlayıcı olmayan modelin (DINA) hangi durumlarda yanlılık ve sınıflama tutarlılığı açısından örtüştüğünün ya da ayrıştığıının araştırılması amaçlanmıştır. Bu nedenle, bu çalışma temel araştırma olarak değerlendirilebilir.

### **II. 2. Veri Üretim ve Veri Analiz Koşulları**

Veri üretim çalışmasında, örneklem büyüklüğü, özellikler arası korelasyon, özellik sayısı, madde sayısı, s ve g parametre düzeyleri değişimlenmiş olup, her bir durum için 100 yineleme (replikasyon) yapılmıştır.

Bu çalışma kapsamında, özelliklerin güçlük düzeyleri sabit tutulmuştur. Tüm özellikler için özellik güçlükleri aynı olarak belirlenmiş ve 3 özellik için ortalama vektörü  $\mu=(0.00, 0.00, 0.00)$ , 4 özellik için ortalama vektörü  $\mu=(0.00, 0.00, 0.00, 0.00)$  olarak ayarlanmıştır.

Veri üretimi, R 3.0 programında CDM paketi kullanılarak gerçekleştirilmiştir. Araştırma kapsamında kullanılan Q matrisleri EK 1 ve EK 2'de verilmiştir.

Araştırma kapsamında değişimlenen faktörler ve bu faktörlerin düzeylerine ilişkin değerler belirlenirken, ilgili literatürde yer alan benzer çalışmalarda kullanılan değerler ve bu çalışmalardan elde edilen bulgular dikkate alınmıştır. Değişimlenen faktörler ve bu faktörlere ilişkin düzeyler aşağıda belirtilmiştir.

**Örneklem Büyüklüğü:** İlgili literatür incelendiğinde, örneklem büyüklüğünün parametre kestirimini etkileyen önemli bir faktör olduğu görülmüştür. Örneğin; de la Torre, Hong ve Deng (2010), çalışmalarında örneklem büyüklüklerini 1000, 2000 ve 5000 olarak; Habenicht, Rupp ve Wilhelm (2012) ise, 1000 ve 10000 olarak belirlemişlerdir.

Bu çalışma kapsamında örneklem büyüklükleri, parametre kestiriminin ve sınıflama tutarlılığının daha düşük örneklem büyüklüklerinde de nasıl değişeceğini belirlemek ve diğer çalışmalarla karşılaştırma yapmak için 200, 500, 1000 ve 5000 olmak üzere dört düzey olarak değişimlenmiştir.

**Özellikler Arası Korelasyon:** Özellikler arası korelasyonlar, modelde yer alan özelliklerin birbirini tamamlaması ya da tamamlaması açısından önemli bir faktördür. Bu durum, yapılacak çalışmada analiz modellerinin örtüşüp ayrıştığı koşulların belirlenmesi açısından dikkat edilmesi gereken bir faktördür. Yapılan çalışmalar incelendiğinde, özellikler arası korelasyonların genellikle düşük, orta ve yüksek olarak değişimlenmiş olduğu görülmektedir. Örneğin; Henson ve diğerleri (2008), yaptıkları çalışmada tamamlayıcı olmayan modeli (R-RUM) kullanmış olup, özellikler arası korelasyon değerlerini .50, .75 ve .95 olarak belirlemişlerdir. Wang (2009) ise, yapmış olduğu çalışmada tamamlayıcı olmayan modeli (R-RUM) kullanmış olup, özellikler arası korelasyon değerlerini .20, .50 ve .90 olarak belirlemiştir.

Bu çalışma kapsamında üretilen veri hem tamamlayıcı hem de tamamlayıcı olmayan modele göre analiz edileceğinden, özellikler arası korelasyon düzeylerinin kapsayıcı olmasına dikkat edilmiştir. Bu nedenle, düşük korelasyon değeri için .20, orta korelasyon değeri için .50 ve yüksek korelasyon değeri için .80 olarak değişimleme yapılmıştır.

**Özelik Sayısı:** Yapılan çalışmalar incelendiğinde, Henson ve Douglas (2005), özellik sayısını 4 ve 8; Rupp ve Templin (2008), 4 olarak belirlemişlerdir. Habenicht, Rupp ve Wilhelm (2012), yaptıkları çalışmada özellik sayısını 3 ve 5 olarak belirlemişler ve özellik sayısının sınıflama tutarlılığı açısından önemli bir faktör olduğunu belirtmişlerdir.

Bu çalışma kapsamında özellik sayısı, madde sayısı da göz önünde bulundurularak 3 ve 4 olarak değişimlenmiştir.

**Madde Sayısı:** Değişimlenen bu faktör için yapılan çalışmalar incelendiğinde, Tatsuoka'nın (1990), 20 madde ve 8 özellik, Henson ve Templin'in (2009), 40 madde ve 7 özellik, Templin ve diğerlerinin (2009), 20 madde ve 4 özellik, Choi ve diğerlerinin (2010), 40 madde ve 4 özellik üzerinde çalışmalarını yürüttükleri görülmektedir.

Bu çalışmada ise, özellik sayısı da göz önünde bulundurularak madde sayısı, 15, 30 ve 45 olarak değişimlenmiştir.

**s ve g Parametre Düzeyleri:** Araştırmalar incelendiğinde, parametre kestirim sürecini etkileyebilecek diğer bir faktörün s ve g parametre düzeyleri olduğu görülmüştür. Yapılan çalışmalar incelendiğinde, Henson ve Douglas (2005), s ve g  $\approx U(.05 - .40)$ ; Rupp ve Templin (2008), s  $\approx U(.0 - .25)$  ve g  $\approx U(.0 - .15)$  olarak belirlemişlerdir.

Bu çalışma kapsamında ise, s ve g parametre düzeyleri düşük ve yüksek olarak değişimlenmiştir. Düşük düzey için, s ve g  $\approx U(.05 - .10)$  ve yüksek düzey için, s ve g  $\approx U(.20 - .30)$  olarak belirlenmiştir.

**Analiz Modeli:** Bu çalışmada belirlenen amaç doğrultusunda, üretilen veri, hem tamamlayıcı model (DINA) hem de tamamlayıcı olmayan modele (DINO) göre analiz

edilmiştir. İlgili literatür incelendiğinde, üretilen verinin hem tamamlayıcı hem de tamamlayıcı olmayan modele göre analiz edilmesini içeren bir çalışmaya rastlanmamıştır.

Bu çalışma kapsamında,  $4 \times 3 \times 2 \times 3 \times 4 \times 2 = 576$  tane farklı deneysel yapı ve her biri için 100 replikasyon yapılmıştır. Yapılan değişimlemelere ilişkin düzenek Tablo 7'de gösterilmektedir.

**Tablo 7:** Yapılan Değişimlemelere İlişkin Düzenek

Faktör	Düzenek Sayısı	Düzenek Değerleri
Örneklem Büyüklüğü ( $N$ )	4	200 ( $N_1$ )
		500 ( $N_2$ )
		1000 ( $N_3$ )
		5000 ( $N_4$ )
Özellikler Arası Korelasyon ( $c$ )	3	0.2 ( $c_1$ )
		0.5 ( $c_2$ )
		0.8 ( $c_3$ )
Özellik Sayısı ( $a$ )	2	3 ( $a_3$ )
		4 ( $a_4$ )
Madde Sayısı ( $MS$ )	3	15 ( $MS_1$ )
		30 ( $MS_2$ )
		45 ( $MS_3$ )
s ve g düzeyleri	4	s ve g düşük ( $s_d g_d$ ) s düşük - g yüksek ( $s_d g_y$ ) s yüksek - g düşük ( $s_y g_d$ ) s ve g yüksek ( $s_y g_y$ )
Analiz Modeli	2	DINA ve DINO
Replikasyon sayısı	100	



### II. 3. İşlem

Veri, Tamamlayıcı Olmayan Modele (DINA) göre, belirtilen koşulların çaprazlanması sonucu oluşan her duruma uygun olarak üretilmiştir. Üretilen veri hem DINA hem de DINO modele göre analiz edilmiştir.

Veri üretimi ve verinin modellere göre analizi R 3.0 programında CDM paketi kullanılarak gerçekleştirilmiştir.

Parametre kestirimi (MOY), madde uyumu (RMSEA) ve sınıflama tutarlılığı (DSO) için elde edilen 576 tane çıktı dosyası, değişimleme ölçütlerine göre hem temel etkiler hem de ortak etkiler bazında düzenlenmiştir.

Analiz sonuçlarından elde edilen bulguların organize edilmesi ise, araştırmacı tarafından R 3.0 programında kod yazılarak gerçekleştirilmiştir.

### II. 4. Verilerin Analizi

Parametre kestirimleri için gerçek değerler ile kestirilen değerler arasındaki farktan elde edilen “yanlılık değerleri”, parametre kestirim sürecinin sağlıklı işleyip işlemediğinin değerlendirilmesinde bir iyilik ölçütü olarak kullanılabilir (de la Torre, Hong ve Deng, 2010). Bu açıdan bu çalışma kapsamında, parametre kestiriminde, gerçek ile kestirilen değerler arasında tutarlı sonuçların elde edilip edilmediğinin belirlenmesi için “mutlak ortalama yanlılık (absolute mean bias)” hesaplaması yapılmış ve parametre kestiriminde E-M yaklaşımı kullanılmıştır.

Yanlılık hesaplamasında ilk olarak, satırlarında maddeler, sütunlarında replikasyon sayıları yer alan ve çeşitli değişimleme ölçütlerine göre düzenlenen matris oluşturulmuştur. Bu matrisin elemanları, kestirilen parametre değerlerinden oluşmaktadır. İkinci aşamada,

kestirilen parametre değerleri, veri üretim kodunda girdi olarak kullanılan gerçek parametre değerlerinden çıkartılarak yanlılık matrisi oluşturulmuştur. Bu matriste yer alan elemanların mutlak değerleri alınmıştır. Son aşamada ise, yanlılık matrisinin ortalama değeri alınmıştır.

Çalışma kapsamında, s ve g parametreleri için yanlılık hesaplaması ayrı ayrı yapılmıştır.

Mutlak ortalama yanlılık (MOY) hesaplanmasında 21 no'lu eşitlik kullanılmış olup aşağıda belirtilmiştir.

$$MOY = \frac{\sum_{j=1}^N |(\pi_{jk} - \hat{\pi}_{jk})|}{N} \quad (21)$$

Madde-model uyumunun bir göstergesi olarak “*madde uyum RMSEA*” değerleri hesaplanmıştır. Bu hesaplama için ilk olarak, satırında ortalama madde uyum RMSEA değerleri ve sütunlarında replikasyon sayıları yer alan vektör (tek satırlı ve 100 sütunlu) oluşturulmuştur. İkinci aşama olarak ise, bu vektörün ortalama değeri hesaplanmıştır.

Madde uyum RMSEA hesaplanmasında 22 no'lu eşitlik kullanılmış olup aşağıda belirtilmiştir.

$$RMSEA_j = \sqrt{\sum_k \sum_c \pi(\theta_c) (P_j(\theta_c) - \frac{n_{jkc}}{N_{jc}})^2} \quad (22)$$

c,  $\theta$  özellik vektör sınıflarını; k, madde kategorilerini;  $\pi(\theta_c)$ , kestirilen  $\theta_c$  sınıf olasılıklarını;  $P_j$ , kestirilen madde tepki fonksiyonunu;  $n_{jkc}$ , k kategorisi j maddesi ve  $\theta_c$

özelliğindeki beklenen öğrenci sayısını;  $N_{jc}$ , j maddesi ve  $\theta_c$  özelliğindeki beklenen öğrenci sayısını belirtmektedir.

von Davier (2005) tarafından “*mdltn*” içerisinde uygulanan fonksiyon, bilişsel tanı modellerinde madde uyumunun ölçülmesine dayalı olarak hesaplanan Ki-Kare kestirimi yapmaktadır.

Bireylerin doğru sınıflanıp sınıflanmadığını belirlemek üzere “*Doğru Sınıflama Oranları*” hesaplanmıştır. Burada ilk olarak, üretilen veriye ilişkin olarak elde edilen bireylere ait özellik örüntüleri ile Ençok Olabilirlik Kestirimi yaklaşımı kullanılarak kestirilen bireylerin özellik örüntüleri arasındaki doğru sınıflama oranları hesaplanmıştır. Sonraki aşamada, satırlarında Doğru Sınıflama Oranları değerleri ve sütunlarında replikasyon sayıları yer alan vektör oluşturulmuştur. Son olarak, bu vektörün ortalama değeri hesaplanmıştır.

g ve s parametre kestirimleri için elde edilen MOY, madde uyumu için elde edilen RMSEA ve sınıflama tutarlılığı için elde edilen DSO değerlerine ilişkin olarak, değişimlenen tüm faktörlerin temel etkileri hesaplanmıştır. Temel etkiler, her bir faktörün her bir düzeyi için elde edilen değerlerin ortalamaları alınarak hesaplanmıştır.

Çeşitli koşullarda yer alan temel etkiler için elde edilen ortalamalar arasında istatistiksel açıdan anlamlı bir farklılık olup olmadığının test edilmesinde ANOVA kullanılmıştır. Ortalamalar arası farkların hangi koşullar arasında olduğunu bulmak amacıyla Post Hoc testi yapılmıştır. Her düzeyde yer alan gözlem sayıları eşit olması nedeniyle Tukey testi tercih edilmiştir.

Elde edilen bulguların ortak etkiler açısından yorumlanabilmesi için çok deęişkenli grafiksel yöntemlerden yararlanılmıştır. Grafik çizimleri, R 3.0 programı kullanılarak gerçekleştirilmiştir.

### **BÖLÜM III: BULGULAR**

Bu bölümde, alt problemlere ilişkin bulgulara yer verilmiştir. Çeşitli faktörlerin temel etkilerinin ve temel etki değerlerine ilişkin ortalamalar arası farkın gösteriminde tablolardan, ortak etkilerin gösteriminde ise, çok boyutlu veri grafiklerinden yararlanılmıştır. Grafikler arası standardın korunabilmesi için, parametre kestiriminden elde edilen bulguların grafikleri minimum 0.0, maksimum 0.3; sınıflama tutarlılığından elde edilen bulguların grafikleri ise, minimum 0.0, maksimumu 1.0 olacak şekilde ölçeklenmiştir.

**III.1.1. Çeşitli faktörlerin (örneklem büyüklüklerinin, özellikler arası korelasyonun, özellik sayılarının, madde sayılarının, s ve g parametre düzeylerinin ve DINA ve DINO analiz modellerinin), g parametre kestirimleri için elde edilen MOY ortalamalarına temel etkileri nasıldır?**

a) Çeşitli faktörlerin (örneklem büyüklüklerinin, özellikler arası korelasyonun, özellik sayılarının, madde sayılarının, s ve g parametre düzeylerinin ve DINA analiz modelinin), g parametre kestirimleri için elde edilen MOY ortalamalarına temel etki sonuçları Tablo 8’de gösterilmektedir.

**Tablo 8:** g Parametre Kestiriminde DINA Analiz Modeli Kullanıldığında Elde Edilen MOY Değerlerine İlişkin Faktörlerin Temel Etki Değerleri

		DINA Analiz Modeli
		Yanlılık Değerleri
Örneklem Büyüklüğü	200	0.028
	500	0.018
	1000	0.012
	5000	0.006
Özellikler Arası Korelasyon	0.2	0.015
	0.5	0.016
	0.8	0.016
Özellik Sayısı	3	0.015
	4	0.016
Madde Sayısı	15	0.018
	30	0.015
	45	0.015
s ve g	s ve g düşük	0.011
	s düşük - g yüksek	0.019
	s yüksek - g düşük	0.012
	s ve g yüksek	0.021

DINA analiz modeli kullanılarak g parametre kestirimleri için elde edilen MOY ortalamaları arasında istatistiksel açıdan anlamlı bir fark olup olmadığının test edilmesinde ANOVA ve ortalamalar arası farkların hangi koşullar arasında olduğunu bulmak amacıyla Tukey testi yapılmıştır. ANOVA sonuçlarına ilişkin bulgular Tablo 9’da gösterilmektedir.

**Tablo 9:** g Parametre Kestiriminde DINA Analiz Modeli Kullanıldığında Faktörlerin Temel Etkilerine İlişkin ANOVA Tablosu

Faktör	Varyansın Kaynağı	Kareler Toplamı	Serbestlik Derecesi	Kareler Ortalaması	F	p	Anlamlı Fark
<b>Örneklem Büyüklüğü</b>	Gruplararası	0.019	3	0.006			N2-N1 , N3-N2
	Grupiçi	0.008	284	0.000	229.1	0.000	N3-N1 , N4-N2
	Toplam	0.027	287				N4-N1 , N4-N3
<b>Özellikler Arası Korelasyon</b>	Gruplararası	0.000	2	0.000			
	Grupiçi	0.027	285	0.000	0.26	0.771	-
	Toplam	0.027	287				
<b>Özellik Sayısı</b>	Gruplararası	0.000	1	0.000			
	Grupiçi	0.027	286	0.000	0.562	0.454	-
	Toplam	0.027	287				
<b>Madde Sayısı</b>	Gruplararası	0.000	2	0.000			MS2-MS1
	Grupiçi	0.026	285	0.000	3.494	0.032	MS3-MS1
	Toplam	0.026	287				
<b>s ve g Parametre Düzeyleri</b>	Gruplararası	0.005	3	0.002	22.72	0.000	sdgd-sdgy
	Grupiçi	0.022	284	0.000			sdgd-sygy
	Toplam	0.027	287				sygd- sdgy
							sygd- sygy

Çeşitli örneklem büyüklükleri açısından Tablo 8 incelendiğinde, DINA analiz modelinde g parametresi kestirimlerinden elde edilen MOY ortalama değerlerinin 0.006 ile 0.028 arasında değiştiği görülmektedir. DINA analiz modeli kullanılarak g parametresi kestirildiğinde, örneklem büyüklüğü arttıkça MOY ortalama değerlerinin azaldığı görülmektedir. Tablo 9 incelendiğinde, MOY ortalamalarının örneklem büyüklüklerine göre anlamlı bir şekilde farklılaştığı görülmektedir [ $F_{3-284}=229.1$ ,  $p<0.05$ ]. Tukey testi sonuçlarına göre,  $N_4$  örneklem büyüklüğünden elde edilen yanlılık değerinin  $N_3$ ,  $N_2$  ve  $N_1$  örneklem büyüklüklerinden elde edilen yanlılık değerlerinden daha düşük olduğu

görülmektedir. Elde edilen sonuçlara göre, yanlılık değerlerinin örneklem büyüklüklerine göre anlamlı bir şekilde ve daha büyük örneklem lehine farklılaştığı görülmektedir. Bu bulgulara göre, DINA analiz modeli kullanıldığında, örneklem büyüklüğü arttıkça g parametrelerinin daha yansız kestirildiği söylenebilir.

Tablo 8'e göre özellikler arasındaki korelasyon düzeyleri değişimlendiğinde, DINA analiz modelinden elde edilen MOY ortalama değerlerinin minimum ve maksimum değerleri arasındaki değişikliğin yok denecek kadar az olduğunu söylemek mümkündür. Tablo 9 incelendiğinde, g parametre kestirimi için elde edilen MOY ortalamalarının özellikler arası korelasyon düzeylerine göre anlamlı bir şekilde farklılaşmadığı görülmektedir [ $F_{2-285}=0.26$ ,  $p>0.05$ ]. Başka bir ifadeyle, DINA analiz modeli kullanılarak g parametreleri kestirimi için elde edilen MOY ortalamalarının, özellikler arası korelasyon düzeylerinin değişimlenmesiyle birlikte çok fazla değişmediği görülmektedir.

Özellik sayıları açısından Tablo 8 incelendiğinde, DINA analiz modelinden elde edilen MOY ortalama değerleri fazla bir değişkenlik göstermemektedir. Tablo 9 incelendiğinde, g parametre kestirimi için elde edilen MOY ortalamalarının özellik sayılarına göre anlamlı bir şekilde farklılaşmadığı görülmektedir [ $F_{1-286}=0.562$ ,  $p>0.05$ ]. Bu bulgulara göre, DINA analiz modeli kullanılarak g parametre kestiriminden elde edilen MOY ortalamalarının, özellik sayısının artışıyla birlikte çok fazla değişmediği görülmektedir.

Tablo 8'e göre madde sayıları değişimlendiğinde, elde edilen MOY ortalama değerlerinin çok fazla değişmediği söylenebilir. Ancak Tablo 9 incelendiğinde, MOY ortalamalarının madde sayılarına göre anlamlı bir şekilde farklılaştığı görülmektedir [ $F_{2-285}=3.494$ ,  $p<0.05$ ]. Bu farklılığın  $MS_1$  ile diğer madde sayıları arasında ve diğer



madde sayıları lehine olduğu görülmektedir. Başka bir ifadeyle,  $MS_2(\bar{X} = 0.015)$  ve  $MS_3(\bar{X} = 0.015)$  madde sayılarından elde edilen yanlılığın  $MS_1(\bar{X} = 0.018)$  madde sayısından elde edilen yanlılıktan daha düşük olduğu görülmektedir.  $MS_2$  ve  $MS_3$  arasında anlamlı bir farklılık görülmemektedir. Bu bulgulara göre, DINA analiz modelinde madde sayısının artırılmasıyla, g parametrelerinin daha yansız kestirilebileceği söylenebilir.

s ve g parametre düzeyleri açılarından Tablo 8 incelendiğinde, düşük s ve g parametre düzeylerinde g parametre kestirimlerinden elde edilen MOY ortalama değerlerinin daha düşük olduğu görülmektedir. Tablo 9 incelendiğinde, MOY ortalamalarının s ve g parametre düzeylerine göre anlamlı bir şekilde farklılaştığı görülmektedir [ $F_{3-284}=22.72, p<0.05$ ]. Tukey testi sonuçlarına göre,  $s_d g_d(\bar{X} = 0.011)$  ile  $s_d g_y(\bar{X} = 0.019)$  ve  $s_y g_y(\bar{X} = 0.021)$  arasında anlamlı bir farkın olduğu ve bunun da  $s_d g_d$  lehine olduğu görülmektedir. Ayrıca,  $s_y g_d(\bar{X} = 0.012)$  ile  $s_d g_y(\bar{X} = 0.019)$  ve  $s_y g_y(\bar{X} = 0.021)$  arasındaki anlamlı farklılığın  $s_y g_d$  lehine olduğu görülmektedir. Bu bulgulara göre, DINA analiz modelinde, düşük s ve g parametrelerinin düzeylerinde, g parametresinin daha yansız kestirildiği söylenebilir.

b) Çeşitli faktörlerin (örneklem büyüklüklerinin, özellikler arası korelasyonun, özellik sayılarının, madde sayılarının, s ve g parametre düzeylerinin ve DINO analiz modelinin), g parametre kestirimleri için elde edilen MOY ortalamalarına temel etki sonuçları Tablo 10'da gösterilmektedir.

**Tablo 10:** g Parametre Kestiriminde DINO Analiz Modeli Kullanıldığında Elde Edilen MOY Değerlerine İlişkin Faktörlerin Temel Etki Değerleri

		DINO Analiz Modeli Yanlılık Değerleri
Örnekleme Büyüklüğü	200	0.087
	500	0.084
	1000	0.082
	5000	0.080
Özellikler Arası Korelasyon	0.2	0.081
	0.5	0.092
	0.8	0.076
Özellik Sayısı	3	0.073
	4	0.093
Madde Sayısı	15	0.095
	30	0.080
	45	0.074
s ve g	s ve g düşük	0.093
	s düşük - g yüksek	0.097
	s yüksek - g düşük	0.074
	s ve g yüksek	0.068

DINO analiz modeli kullanılarak g parametre kestirimleri için elde edilen MOY ortalamaları arasında istatistiksel açıdan anlamlı bir fark olup olmadığının test edilmesinde ise ANOVA ve ortalamalar arası farkların hangi koşullar arasında olduğunu bulmak amacıyla Tukey testi yapılmıştır. ANOVA sonuçlarına ilişkin bulgular Tablo 11’de gösterilmektedir.

**Tablo 11:** g Parametresi Kestiriminde DINO Analiz Modeli Kullanıldığında Faktörlerin Temel Etkilerine İlişkin ANOVA Tablosu

Faktör	Varyansın Kaynağı	Kareler Toplamı	Serbestlik Derecesi	Kareler Ortalaması	F	p	Anlamlı Fark
<b>Örneklem Büyüklüğü</b>	Gruplararası	0.002	3	0.001			
	Grupiçi	0.172	284	0.000	1.226	0.3	-
	Toplam	0.174	287				
<b>Özellikler Arası Korelasyon</b>	Gruplararası	0.013	2	0.006			c2-c1
	Grupiçi	0.162	285	0.001	11.08	0.000	c3-c2
	Toplam	0.175	287				
<b>Özellik Sayısı</b>	Gruplararası	0.027	1	0.028			
	Grupiçi	0.146	286	0.001	53.84	0.000	a3-a4
	Toplam	0.173	287				
<b>Madde Sayısı</b>	Gruplararası	0.022	2	0.011			MS2-MS1
	Grupiçi	0.152	285	0.000	21.04	0.000	MS3-MS1
	Toplam	0.174	287				
<b>s ve g Parametre Düzeyleri</b>	Gruplararası	0.043	3	0.014			s dgd-sygd
	Grupiçi	0.131	284	0.000	31.8	0.000	s dgd-sygy
	Toplam	0.174	287				s dgy-sygd sdgy- s ygy

Tablo 10'a göre örneklem büyüklükleri değişimlendiğinde, g parametresi kestirimlerinden elde edilen ortalama MOY değerlerinin 0.080 ile 0.087 arasında değiştiği görülmektedir. Ayrıca Tablo 11'deki bulgulara göre, MOY ortalamalarının örneklem büyüklüklerine göre anlamlı bir şekilde farklılaşmadığı görülmektedir [ $F_{3-284} = 1.226, p > 0.05$ ]. Bu sonuçlar ışığında, DINO analiz modeli kullanılarak g parametresi kestirildiğinde, örneklem büyüklüğünün artışıyla birlikte elde edilen MOY ortalamalarının çok fazla değişmediği söylenebilir.

Özellikler arası korelasyon düzeyleri değişimlendiğinde, DINO analiz modelinden elde edilen MOY ortalama değerlerinin, 0.076 ile 0.092 arasında değiştiği ancak, bu değişimin monotonik olmadığı görülmektedir. Tablo 11 incelendiğinde, g parametre kestirimi için elde edilen MOY ortalamaların özellikler arası korelasyon düzeylerine göre anlamlı bir şekilde farklılaştığı görülmektedir [ $F_{2-285}=11.08$ ,  $p<0.05$ ]. Bu farklılığın,  $c_2$  ( $\bar{X} = 0.092$ ) ile  $c_1$  ( $\bar{X} = 0.081$ ) arasında  $c_1$  lehine ve  $c_3$  ( $\bar{X} = 0.076$ ) ile  $c_2$  ( $\bar{X} = 0.092$ ) arasında  $c_3$  lehine olduğu görülmektedir. Bu bulgulara göre, özellikler arası korelasyon düzeyi maksimum olduğunda en yansız kestirimlerin yapıldığı görülmektedir. Bu sonuçlar ışığında, DINO modelin özelliklerin birbirini tamamlaması üzerine kurulu olmasının, bu sonucun gözlenmesine neden olduğu söylenebilir.

Tablo 10 incelendiğinde, DINO analiz modelinde özellik sayısı düşüktüçe MOY ortalama değerlerinin belirgin bir şekilde düştüğü görülmektedir. Tablo 11 incelendiğinde, g parametre kestirimi için elde edilen MOY ortalamaların özellik sayılarına göre anlamlı bir şekilde farklılaştığı görülmektedir [ $F_{1-286}=53.84$ ,  $p<0.05$ ]. Oluşan farklılığın özellik sayısının 3 olduğu durum lehine olduğu görülmektedir. DINO analiz modeli kullanılarak g parametre kestiriminde, özellik sayısı azaldığında daha yansız kestirimlerin yapıldığı görülmektedir.

Tablo 10'a göre madde sayısı değişimlendiğinde elde edilen MOY ortalama değerlerinin 0.074 ile 0.095 arasında değiştiği görülmektedir. Tablo 11 incelendiğinde, MOY ortalamalarının madde sayılarına göre anlamlı bir şekilde farklılaştığı görülmektedir [ $F_{2-285}=21.04$ ,  $p<0.05$ ]. Tukey testi sonuçlarına göre,  $MS_2$  ve  $MS_3$  madde sayılarından elde edilen yanlılığın  $MS_1$  madde sayısından elde edilen yanlılıktan daha düşük olduğu

görülmektedir. Bu bulguya dayanarak, DINO analiz modelinde madde sayısı arttıkça g parametresinin daha yansız kestirildiği söylenebilir.

Tablo 10 incelendiğinde, DINO analiz modeli için MOY ortalama değerlerinin yüksek s ve g parametre düzeylerinde azaldığı görülmektedir. Tablo 11 s ve g parametre düzeyleri açısından incelendiğinde ise, elde edilen MOY ortalamalarının s ve g parametre düzeylerine göre anlamlı bir şekilde farklılaştığı görülmektedir [ $F_{3-284}=31.8$ ,  $p<0.05$ ]. Tukey testi sonuçlarına göre,  $s_d g_d (\bar{X} = 0.093)$  ile  $s_y g_y (\bar{X} = 0.068)$  ve  $s_y g_d (\bar{X} = 0.074)$  arasında anlamlı bir farkın olduğu ve bunun da  $s_y g_y$  ve  $s_y g_d$  lehine olduğu görülmektedir. Ayrıca,  $s_d g_y (\bar{X} = 0.097)$  ile  $s_y g_y (\bar{X} = 0.068)$  ve  $s_y g_d (\bar{X} = 0.074)$  arasındaki anlamlı farklılığın  $s_y g_y$  ve  $s_y g_d$  lehine olduğu görülmektedir. Bu sonuçlar ışığında, DINO analiz modeli kullanılarak g parametreleri kestirildiğinde, s ve g parametrelerinin yüksek düzeyde olmasının daha yansız kestirimlerin elde edilmesi açısından önemli olduğu söylenebilir.

c) DINA ve DINO analiz modelinde g parametresi için elde edilen MOY ortalamaları arasında istatistiksel açıdan anlamlı bir fark olup olmadığının test edilmesine ilişkin yapılan ANOVA sonuçlarının karşılaştırmaları Tablo 12’de gösterilmektedir.

Tablo 12 incelendiğinde, hem DINA hem de DINO analiz modellerinden elde edilen MOY ortalama değerlerinin, madde sayılarına ve s ve g parametre düzeylerine göre anlamlı bir şekilde farklılaştığı görülmektedir. DINA analiz modelinden elde edilen MOY ortalama değerlerinin örneklem büyüklüklerine göre anlamlı bir şekilde farklılaştığı ancak, DINO analiz modelinden elde edilen MOY ortalama değerlerinin örneklem büyüklüklerine göre anlamlı bir şekilde farklılaşmadığı görülmektedir. Ayrıca, özellikler arası korelasyon

düzeylerine ve özellik sayılarına göre DINO analiz modelinden elde edilen MOY ortalama değerlerinin farklılaştığı ancak, DINA analiz modelinden elde edilen MOY ortalama değerlerinin anlamlı bir şekilde farklılaşmadığı görülmektedir.

**Tablo 12:** g Parametresine İlişkin DINA ve DINO Analiz Modeli Karşılaştırılması

<b>Faktör</b>	<b>DINA</b>	<b>DINO</b>
<b>Örneklem Büyüklüğü</b>	+	-
<b>Özellikler Arası Korelasyon</b>	-	+
<b>Özellik Sayısı</b>	-	+
<b>Madde Sayısı</b>	+	+
<b>s ve g Parametre Düzeyleri</b>	+	+

g parametre kestirimi için DINA ve DINO analiz modellerinden elde edilen MOY ortalamaları genel olarak incelendiğinde ise, her koşul düzeyi için, DINA analiz modelinden elde edilen MOY ortalama değerleri, DINO analiz modelinden elde edilen MOY ortalama değerlerinden daha düşük bulunmuştur. Ayrıca faktörlerin temel etkileri açısından, DINA ve DINO analiz modellerinde herhangi bir örtüşmenin olmadığı görülmüştür.

**III.1.2. Çeşitli faktörlerin (örneklem büyüklüklerinin, özellikler arası korelasyonun, özellik sayılarının, madde sayılarının, s ve g parametre düzeylerinin), g parametre kestirimleri için elde edilen MOY ortalamalarına ortak etkileri nasıldır?**

a) DINA analiz modeli kullanılarak çeşitli s ve g parametre düzeylerinde, g parametre kestirimleri için ortalama MOY değerleri elde edilmiştir. Çeşitli faktörlerin (örneklem büyüklüklerinin, özellik sayılarının, madde sayılarının ve özellikler arasındaki çeşitli korelasyon düzeylerinin) ortak etkileşimlerine ilişkin saçılım Grafik 1, 2, 3 ve 4'te sunulmuştur.


Grafiklerde yer alan koşulların ortak etkileri açısından ortalama MOY dağılımları incelendiğinde, anlamlı yapılanmaların olduğu göze çarpmaktadır. Özellikle örneklem büyüklüğü arttıkça ortalama MOY değerlerinin azaldığı ve bunun kısmen de olsa madde sayısı ile ilişkili olduğu görülmektedir. Madde sayısı arttıkça ortalama MOY değerlerinin çok az da olsa azaldığı görülmektedir.

Dikkat edilmesi gereken bir nokta ise, dört grafikte de özellikler arasındaki korelasyon düzeylerinin ve özellik sayılarının g parametre kestirimindeki önemsizliğidir. Bütün özellikler arası korelasyon düzeylerinde ve özellik sayılarında yaklaşık aynı sonuçlar elde edilmiştir.


Grafik 1 ve Grafik 2, ortak etkiler açısından incelendiğinde, genel olarak Grafik 1'den elde edilen sonuçların (düşük s ve g düzeyi), Grafik 2'den elde edilen sonuçlara (yüksek s ve g düzeyi) göre daha düşük olduğu görülmektedir. Bu durumda, g parametre kestirimi için MOY ortalamaları elde edildiğinde, s ve g parametre düzeylerinin etkili bir faktör olduğu söylenebilir.

Grafik 3 ve Grafik 4 ortak etkiler açısından incelendiğinde, faktörlerin tüm düzeylerinde, Grafik 4'ten (g parametresi düşük düzeyde) elde edilen MOY ortalamalarının, Grafik 3'ten (g parametresi yüksek düzeyde) elde edilen MOY ortalamalarına göre daha düşük olduğu görülmektedir. Bu durum






**Grafik 1:** DINA Analiz Modeli ve Düşük s ve g Parametre Düzeyleri Kullanıldığında, g Parametre Kestiriminden Elde Edilen Ortalama MOY Değerleri




**Grafik 2:** DINA Analiz Modeli ve Yüksek s ve g Düzeyleri Kullanıldığında, g Parametre Kestiriminden Elde Edilen Ortalama MOY Değerleri



**Grafik 3:** DINA Analiz Modeli ve Düşük s ve Yüksek g Parametre Düzeyleri

Kullanıldığında, g Parametre Kestiriminden Elde Edilen Ortalama MOY Değerleri



**Grafik 4:** DINA Analiz Modeli ve Yüksek s ve Düşük g Parametre Düzeyleri

Kullanıldığında, g Parametre Kestiriminden Elde Edilen Ortalama MOY Değerleri


b) DINO analiz modeli kullanılarak çeşitli s ve g parametre düzeylerinde, g parametre kestirimleri için ortalama MOY değerleri elde edilmiştir. Çeşitli faktörlerin (örneklem büyüklüklerinin, özellik sayılarının, madde sayılarının ve özellikler arasındaki çeşitli korelasyon düzeylerinin) ortak etkileşimlerine ilişkin saçılım Grafik 5, 6, 7 ve 8’de sunulmuştur.

Grafiklerde yer alan koşulların ortak etkileri açısından ortalama MOY dağılımları incelendiğinde, farklı yapılanmaların oluştuğu göze çarpmaktadır. Grafik 5 ve Grafik 6, ortak etkiler açısından incelendiğinde, genel olarak Grafik 5’ten elde edilen sonuçların (düşük s ve düzeyi), Grafik 6’dan elde edilen sonuçlara (yüksek s ve g düzeyi) göre daha yüksek olduğu görülmektedir. Dikkat edilmesi gereken bir nokta ise, DINA analiz modelinde, bu durumun tam tersinin görülmesidir. g parametre kestirimi için MOY ortalamalarının elde edilmesinde, s ve g parametrelerinin düzeylerinin etkili bir faktör olduğu, DINO analiz modeli için de söylenebilir.


Grafik 5 incelendiğinde, özellikle özellik sayısı düşük olduğunda, ortalama MOY değerlerinin azaldığı ve bunun madde sayısı ve özellikler arası korelasyon düzeyleriyle ilişkili olduğu görülmektedir. Madde sayısı arttıkça ortalama MOY değerlerinin azaldığı görülmektedir. Ayrıca, özellikler arası korelasyon düzeyi ve özellik sayısı düşük, madde sayısının yüksek olduğu durumlarda, örneklem büyüklüğü arttıkça, g parametrelerin daha yansız kestirildiği söylenebilir.

Grafik 6 incelendiğinde ise, s ve g parametre düzeyi yüksek olduğunda, MOY ortalamalarının elde edilmesinde, özellik sayısının, madde sayısının ve örneklem büyüklüğünün etkisinin çok çok az olduğu göze çarpmaktadır. Ancak, özellikler arası korelasyon düzeyinin düşük ve madde sayısının yüksek olduğu durumlarda, özellik sayısı azaldıkça g parametrelerinin daha yansız kestirildiği söylenebilir.


Grafik 7 ve Grafik 8 ortak etkiler açısından incelendiğinde, g parametre kestirimi için MOY ortalamaları elde edildiğinde yaklaşık aynı sonuçların elde edildiği görülmektedir.



**Grafik 5:** DINO Analiz Modeli ve Düşük s ve g Parametre Düzeyleri Kullanıldığında, g Parametre Kestiriminden Elde Edilen Ortalama MOY Değerleri

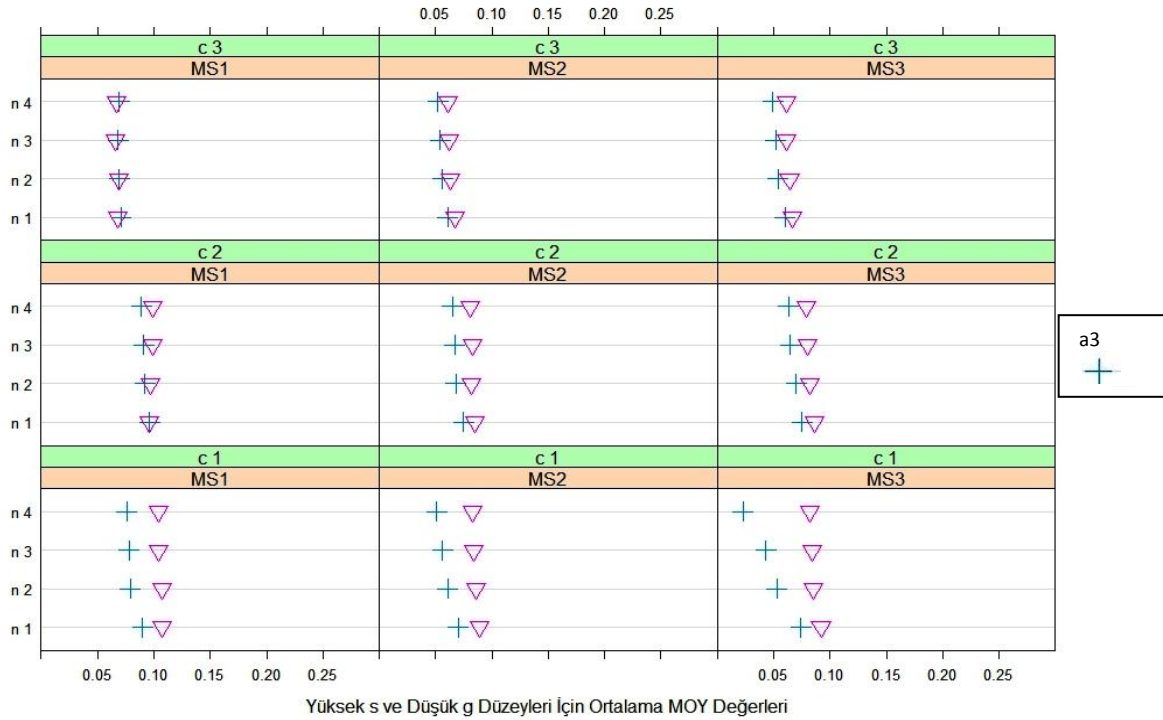


**Grafik 6:** DINO Analiz Modeli ve Yüksek s ve g Parametre Düzeyleri Kullanıldığında, g Parametre Kestiriminden Elde Edilen Ortalama MOY Değerleri



**Grafik 7:** DINO Analiz Modeli ve Düşük s ve Yüksek g Parametre Düzeyleri

Kullanıldığında, g Parametre Kestiriminden Elde Edilen Ortalama MOY Değerleri




**Grafik 8:** DINO Analiz Modeli ve Düşük s ve Yüksek g Parametre Düzeyleri

Kullanıldığında, g Parametre Kestiriminden Elde Edilen Ortalama MOY Değerleri

c) Hem DINA hem de DINO analiz modelleri kullanılarak, g parametre kestirimleri için ortalama MOY deęerleri elde edilmiřtir. eřitli faktörlerin (örneklem büyüklüklerinin, madde sayılarının, özellik sayılarının, özellikler arasındaki çeřitli korelasyon düzeylerinin ve s ve g parametre düzeylerinin) ortak etkileřimlerine iliřkin saılım Grafik 9’da sunulmuřtur.

Grafik 9 incelendięinde, tüm faktörlerin her kořul düzeylerinde DINA analiz modelinden elde edilen ortalama MOY deęerlerinin, DINO analiz modelinden elde edilen ortalama MOY deęerlerinden düşük bulunduęu görölmektedir. Ayrıca Grafik 9 incelendięinde, örneklem büyüklüęünün 5000, madde sayısının 45, özellik sayısının 3, özellikler arası korelasyonun 0.20 ve s ve g parametrelerinin düşük olduęu düzeyde DINA ve DINO analiz modellerinden elde edilen sonuçların örtüřtüęü, bu kořulların dıřındaki tüm faktörlerin tüm kořul düzeylerinde elde edilen sonuçlarda herhangi bir örtüřmenin olmadıęı görölmektedir.

### DINA ve DINO Analiz Modeli g Parametre Kestirimi



**Grafik 9:** DINA ve DINO Analiz Modelleri Kullanıldığında, g Parametre Kestiriminden Elde Edilen Ortalama MOY Değerleri

**III.2.1. Çeşitli faktörlerin (örneklem büyüklüklerinin, özellikler arası korelasyonun, özellik sayılarının, madde sayılarının, s ve g parametre düzeylerinin ve DINA ve DINO analiz modellerinin), s parametre kestirimleri için elde edilen MOY ortalamalarına temel etkileri nasıldır?**

a) Çeşitli faktörlerin (örneklem büyüklüklerinin, özellikler arası korelasyonun, özellik sayılarının, madde sayılarının, s ve g parametre düzeylerinin ve DINA analiz modelinin), s parametre kestirimleri için elde edilen MOY ortalamalarına temel etki sonuçları Tablo 13'te gösterilmektedir.

**Tablo 13:** s Parametre Kestiriminde DINA Analiz Modeli Kullanıldığında Elde Edilen MOY Değerlerine İlişkin Faktörlerin Temel Etki Değerleri

		DINA Analiz Modeli Yanlılık Değerleri
Örneklem Büyüklüğü	200	0.036
	500	0.023
	1000	0.016
	5000	0.007
Özellikler Arası Korelasyon	0.2	0.023
	0.5	0.020
	0.8	0.018
Özellik Sayısı	3	0.019
	4	0.022
Madde Sayısı	15	0.022
	30	0.020
	45	0.019
s ve g	s ve g düşük	0.015
	s düşük - g yüksek	0.015
	s yüksek - g düşük	0.024
	s ve g yüksek	0.027



DINA analiz modeli kullanılarak  $s$  parametre kestirimleri için elde edilen MOY ortalamaları arasında istatistiksel açıdan anlamlı bir fark olup olmadığının test edilmesinde ise ANOVA ve ortalamalar arası farkların hangi koşullar arasında olduğunu bulmak amacıyla Tukey testi yapılmıştır. ANOVA sonuçlarına ilişkin bulgular Tablo 14’te gösterilmektedir.

**Tablo 14:**  $s$  Parametresi Kestiriminde DINA Analiz Modeli Kullanıldığında Faktörlerin Temel Etkilerine İlişkin ANOVA Tablosu

Faktör	Varyansın Kaynağı	Kareler Toplamı	Serbestlik Derecesi	Kareler Ortalaması	F	p	Anlamlı Fark
<b>Örneklem Büyüklüğü</b>	Gruplararası	0.032	3	0.011			N2-N1 , N3-N2
	Grupiçi	0.014	284	0.000	208.9	0.000	N3-N1 , N4-N2
	Toplam	0.046	287				N4-N1 , N4-N3
<b>Özellikler Arası Korelasyon</b>	Gruplararası	0.001	2	0.001			
	Grupiçi	0.046	285	0.000	3.229	0.041	c3-c1
	Toplam	0.047	287				
<b>Özellik Sayısı</b>	Gruplararası	0.000	1	0.001			
	Grupiçi	0.046	286	0.000	3.216	0.074	-
	Toplam	0.046	287				
<b>Madde Sayısı</b>	Gruplararası	0.000	2	0.000			
	Grupiçi	0.046	285	0.000	1.156	0.316	-
	Toplam	0.046	287				
<b><math>s</math> ve <math>g</math> Parametre Düzeyleri</b>	Gruplararası	0.009	3	0.003			$s$ dgd-sygd
	Grupiçi	0.038	284	0.000	21.4	0.000	$s$ dgd-sygy
	Toplam	0.047	287				$s$ dgy-sygd
							$s$ dgy-sygy

Tablo 13’e göre örneklem büyüklükleri değişimlendiğinde,  $s$  parametresi kestirimlerinden elde edilen ortalama MOY değerlerinin 0.007 ile 0.036 arasında değiştiği görülmektedir. DINA analiz modeli kullanılarak  $s$  parametresi kestirildiğinde, örneklem

büyüklüğü arttıkça MOY ortalama değerlerinin azaldığı görülmektedir. Tablo 14 incelendiğinde, MOY ortalamalarının çeşitli örneklem büyüklüklerine göre anlamlı bir şekilde farklılaştığı görülmektedir [ $F_{3-284}=208.9$ ,  $p<0.05$ ]. Tukey testi sonuçlarına göre,  $N_4$  örneklem büyüklüğünden elde edilen yanlılık değerinin  $N_3$ ,  $N_2$  ve  $N_1$  örneklem büyüklüklerinden elde edilen yanlılık değerlerinden daha düşük olduğu görülmektedir. Elde edilen sonuçlara göre, yanlılık değerlerinin örneklem büyüklüklerine göre anlamlı bir şekilde ve daha büyük örneklem lehine farklılaştığı görülmektedir. Bu bulgulara göre, DINA analiz modeli kullanıldığında, örneklem büyüklüğü arttıkça s parametrelerinin daha yansız kestirildiği söylenebilir.

Özellikler arasındaki korelasyon düzeyleri değişimlendiğinde, DINA analiz modelinden elde edilen MOY ortalamalarının minimum ve maksimum değerleri arasındaki değişikliğin yok denecek kadar az olduğunu söylemek mümkündür. Tablo 14 incelendiğinde, MOY ortalamalarının özellikler arası korelasyon düzeylerine göre anlamlı bir şekilde farklılaştığı görülmektedir. [ $F_{2-285}=3.229$ ,  $p<0.05$ ]. Bu farklılığın,  $c_3(\bar{X} = 0.018)$  ile  $c_1(\bar{X} = 0.023)$  arasında olduğu ve  $c_3$  lehine olduğu görülmektedir. Ayrıca, diğer korelasyon düzeyleri arasında anlamlı bir farklılık görülmemektedir. Bu bulgulara göre, DINA analiz modelinde özellikler arası korelasyon düzeylerinden elde edilen MOY ortalama değerleri birbirine yakın olmasına rağmen, özellikler arasındaki korelasyon düzeyi yüksek olduğunda s parametrelerinin daha yansız kestirildiği söylenebilir.

Özellik ve madde sayıları açısından Tablo 13 incelendiğinde, DINA analiz modelinden elde edilen ortalama MOY değerleri fazla bir değişkenlik göstermemektedir. Tablo 14 incelendiğinde, s parametre kestirimi için elde edilen MOY ortalamaların özellik

sayılarına göre anlamlı bir şekilde farklılaşmadığı görülmektedir [ $F_{1-286}=3.216$ ,  $p>0.05$ ]. Ayrıca, çeşitli madde sayılarından elde edilen MOY ortalamaları arasında da anlamlı bir farklılığın olmadığı görülmektedir [ $F_{2-285}=1.156$ ,  $p<0.05$ ]. Bu sonuçlar ışığında, DINA analiz modelinde özellik sayısının ve madde sayısının artışıyla birlikte MOY ortalamalarının çok fazla değişmediği görülmektedir.

Tablo 13 s ve g parametre düzeyleri açısından incelendiğinde, DINA analiz modelinden elde edilen MOY ortalama değerlerinin, 0.015 ile 0.027 arasında değiştiği görülmektedir. Tablo 14 incelendiğinde ise, MOY ortalamalarının s ve g parametre düzeylerine göre anlamlı bir şekilde farklılaştığı görülmektedir [ $F_{3-284}=21.4$ ,  $p<0.05$ ]. Tukey testi sonuçlarına göre,  $s_d g_d (\bar{X} = 0.015)$  ile  $s_d g_y (\bar{X} = 0.015)$  ve  $s_y g_y (\bar{X} = 0.027)$  arasında anlamlı bir farkın olduğu ve bunun da  $s_d g_d$  lehine olduğu görülmektedir. Ayrıca,  $s_d g_y (\bar{X} = 0.015)$  ile  $s_y g_d (\bar{X} = 0.024)$  ve  $s_y g_y (\bar{X} = 0.027)$  arasındaki anlamlı farklılığın  $s_d g_y$  lehine olduğu görülmektedir. Bu bulgulara göre, DINA analiz modeli kullanılarak s parametreleri kestirildiğinde, özellikle s ve g parametrelerinin düşük düzeyde olmasının daha yansız kestirimlerin elde edilmesi açısından önemli olduğu söylenebilir..

b) Çeşitli faktörlerin (örneklem büyüklüklerinin, özellikler arası korelasyonun, özellik sayılarının, madde sayılarının, s ve g parametre düzeylerinin ve DINO analiz modelinin), s parametre kestirimleri için elde edilen MOY ortalamalarına temel etki sonuçları Tablo 15'te gösterilmektedir.

**Tablo 15:** s Parametre Kestiriminde DINA Analiz Modeli Kullanıldığında Elde Edilen MOY Değerlerine İlişkin Faktörlerin Temel Etki Değerleri

		DINO Analiz Modeli Yanlılık Değerleri
Örnekleme Büyüklüğü	200	0.116
	500	0.104
	1000	0.100
	5000	0.098
Özellikler Arası Korelasyon	0.2	0.180
	0.5	0.091
	0.8	0.041
Özellik Sayısı	3	0.116
	4	0.093
Madde Sayısı	15	0.088
	30	0.109
	45	0.116
s ve g	s ve g düşük	0.136
	s düşük - g yüksek	0.076
	s yüksek - g düşük	0.125
	s ve g yüksek	0.080

DINO analiz modeli kullanılarak s parametre kestirimleri için elde edilen MOY ortalamaları arasında istatistiksel açıdan anlamlı bir fark olup olmadığının test edilmesinde ise ANOVA ve ortalamalar arası farkların hangi koşullar arasında olduğunu bulmak amacıyla Tukey testi yapılmıştır. ANOVA sonuçlarına ilişkin bulgular Tablo 16'da gösterilmektedir.

**Tablo 16:** s Parametresi Kestiriminde DINO Analiz Modeli Kullanıldığında Faktörlerin Temel Etkilerine İlişkin ANOVA Tablosu

Faktör	Varyansın Kaynağı	Kareler Toplamı	Serbestlik Derecesi	Kareler Ortalaması	F	p	Anlamlı Fark
<b>Örnekleme Büyüklüğü</b>	Gruplararası	0.014	3	0.004	0.882	0.451	-
	Grupiçi	1.448	284	0.005			
	Toplam	1.462	287				
<b>Özellikler Arası Korelasyon</b>	Gruplararası	0.950	2	0.475	264.1	0.000	c2-c1
	Grupiçi	0.512	285	0.001			c3-c1
	Toplam	1.462	287				c3-c2
<b>Özellik Sayısı</b>	Gruplararası	0.036	1	0.036	7.308	0.007	a3-a4
	Grupiçi	1.424	286	0.004			
	Toplam	1.460	287				
<b>Madde Sayısı</b>	Gruplararası	0.043	2	0.022	4.346	0.013	MS1-MS3
	Grupiçi	1.418	285	0.004			
	Toplam	1.461	287				
<b>s ve g Parametre Düzeyleri</b>	Gruplararası	0.206	3	0.001	15.56	0.000	s dgd-sdgy
	Grupiçi	1.254	284	0.000			sdgd-sygy
	Toplam	1.460	287				s dgy-sygd
							sygd-sygy

Tablo 15 incelendiğinde, örneklem büyüklüklerine göre DINO analiz modelinden elde edilen ortalama MOY değerlerinin 0.098 ile 0.116 arasında değiştiği görülmektedir. Tablo 16 incelendiğinde, MOY ortalamalarının örneklem büyüklüklerine göre anlamlı bir şekilde farklılaşmadığı görülmektedir [ $F_{3-284}=0.882$ ,  $p>0.05$ ]. Bu sonuçlar ışığında, DINO analiz modeli s parametresi kestirimi için MOY ortalamalarının örneklem artışıyla birlikte çok fazla değişmediği söylenebilir.

Özellikler arası korelasyon düzeyleri açısından Tablo 15 incelendiğinde, DINO analiz modelinden elde edilen MOY ortalama değerlerinin, 0.041 ile 0.180 arasında değiştiği görülmektedir. DINO analiz modeli kullanılarak s parametresi kestirildiğinde, özellikler arasındaki korelasyon değeri arttıkça ortalama MOY değerlerinin azaldığı görülmektedir. Tablo 16 incelendiğinde, MOY ortalamalarının özellikler arası korelasyon düzeylerine göre anlamlı bir şekilde farklılaştığı görülmektedir [ $F_{2-285}=264.1$ ,  $p<0.05$ ]. Bu farklılığın,  $c_1$  ile  $c_2$  arasında  $c_2$  lehine,  $c_3$  ile  $c_2$  ve  $c_1$  arasında  $c_3$  lehine olduğu görülmektedir. Bu bulgulara göre, özellikler arasındaki korelasyon düzeyi arttıkça s parametrelerinin daha yansız kestirildiği görülmektedir. DINO modelinde özelliklerin birbirini tamamlaması söz konusu olduğundan, bu durumun gözlemlendiği söylenebilir.

Özellik sayıları açısından Tablo 15 incelendiğinde, DINO analiz modelinden elde edilen ortalama MOY değerlerinin 0.093 ile 0.116 arasında değiştiği görülmektedir. Ayrıca Tablo 16'dan elde edilen bulgulara göre, MOY ortalamalarının özellik sayılarına göre anlamlı bir şekilde farklılaştığı [ $F_{1-286}=7.308$ ,  $p<0.05$ ] ve bu farklılığın özellik sayısının 4 olduğu durum lehine olduğu görülmektedir. Bu bulgulara göre, özellik sayısının artmasıyla, DINO analiz modeli s parametrelerinin daha yansız kestirildiği söylenebilir.

Tablo 15 madde sayıları açısından incelendiğinde, DINO analiz modelinden elde edilen ortalama MOY değerlerinin 0.088 ile 0.116 arasında değiştiği görülmektedir. Tablo 16 incelendiğinde, MOY ortalamalarının madde sayılarına göre anlamlı bir şekilde farklılaştığı görülmektedir [ $F_{2-285}=4.346$ ,  $p<0.05$ ]. Bu farklılığın  $MS_1$  ile  $MS_3$  arasında ve  $MS_1$  madde sayısı lehine olduğu görülmektedir. Bu bulgulara dayanarak, madde sayısı azaltıldığında, s parametrelerinin daha yansız kestirildiği söylenebilir.

s ve g parametre düzeyleri açısından Tablo 15 incelendiğinde, DINO analiz modelinden elde edilen MOY ortalama değerlerinin 0.080 ile 0.136 arasında değiştiği görülmektedir. Tablo 16 incelendiğinde MOY ortalamalarının s ve g parametre düzeylerine göre anlamlı bir şekilde farklılaştığı görülmektedir [ $F_{3-284}=15.56$ ,  $p<0.05$ ]. Tukey testi sonuçlarına göre,  $s_d g_d$  ile  $s_y g_y$  ve  $s_d g_y$  arasında anlamlı bir farkın olduğu ve bunun da  $s_y g_y$  ve  $s_d g_y$  lehine olduğu görülmektedir. Ayrıca,  $s_y g_d$  ile  $s_y g_y$  ve  $s_y g_d$  arasındaki anlamlı farklılığın  $s_y g_y$  ve  $s_y g_d$  lehine olduğu görülmektedir. Bu bulgulara göre, DINO analiz modeli kullanılarak g parametreleri kestirildiğinde, s ve g parametrelerinin yüksek düzeyde olması daha yansız kestirimlerin elde edilmesi açısından önemli olduğu görülmektedir.

c) s parametre kestirimleri için elde edilen MOY ortalamaları arasında istatistiksel açıdan anlamlı bir fark olup olmadığının test edilmesine ilişkin yapılan ANOVA sonuçlarına ait DINA ve DINO analiz modeli karşılaştırmaları Tablo 17’de gösterilmektedir.

Tablo 17 incelendiğinde, hem DINA hem de DINO analiz modelleri kullanıldığında, elde edilen MOY ortalamalarının özellikler arası korelasyon düzeylerine ve s ve g parametre düzeylerine göre anlamlı bir şekilde farklılaştığı görülmektedir. DINA analiz modelinde elde edilen MOY ortalamalarının örneklem büyüklüklerine göre anlamlı bir şekilde farklılaştığı ancak, DINO analiz modelinde herhangi bir farklılaşmanın olmadığı görülmektedir. DINO analiz modelinde elde edilen MOY ortalamalarının, madde sayılarına ve özellik sayılarına göre anlamlı bir şekilde farklılaştığı, ancak DINA analiz modelinde anlamlı bir farklılaşmanın olmadığı görülmektedir.

**Tablo 17:** s Parametresine İlişkin DINA ve DINO Analiz Modeli Karşılaştırılması

<b>Faktör</b>	<b>DINA</b>	<b>DINO</b>
<b>Örneklem Büyüklüğü</b>	+	-
<b>Özellikler Arası Korelasyon</b>	+	+
<b>Özellik Sayısı</b>	-	+
<b>Madde Sayısı</b>	-	+
<b>s ve g Parametre Düzeyleri</b>	+	+

s parametre kestirimi için DINA ve DINO analiz modellerinden elde edilen MOY ortalamaları genel olarak incelendiğinde ise, her koşul düzeyi için, DINA analiz modelinden elde edilen MOY ortalama değerleri, DINO analiz modelinden elde edilen MOY ortalama değerlerinden daha düşük bulunmuştur. Faktörlerin temel etkileri açısından, DINA ve DINO analiz modellerinde herhangi bir örtüşme görülmemiştir.

### **III.2.2. Çeşitli faktörlerin (örneklem büyüklüklerinin, özellikler arası korelasyonun, özellik sayılarının, madde sayılarının, s ve g parametre düzeylerinin), s parametre kestirimleri için elde edilen MOY ortalamalarına ortak etkileri nasıldır?**

a) DINA analiz modeli kullanılarak çeşitli s ve g parametre düzeylerinde, s parametre kestirimleri için ortalama MOY değerleri elde edilmiştir. Çeşitli faktörlerin (örneklem büyüklüklerinin, özellik sayılarının, madde sayılarının ve özellikler arasındaki

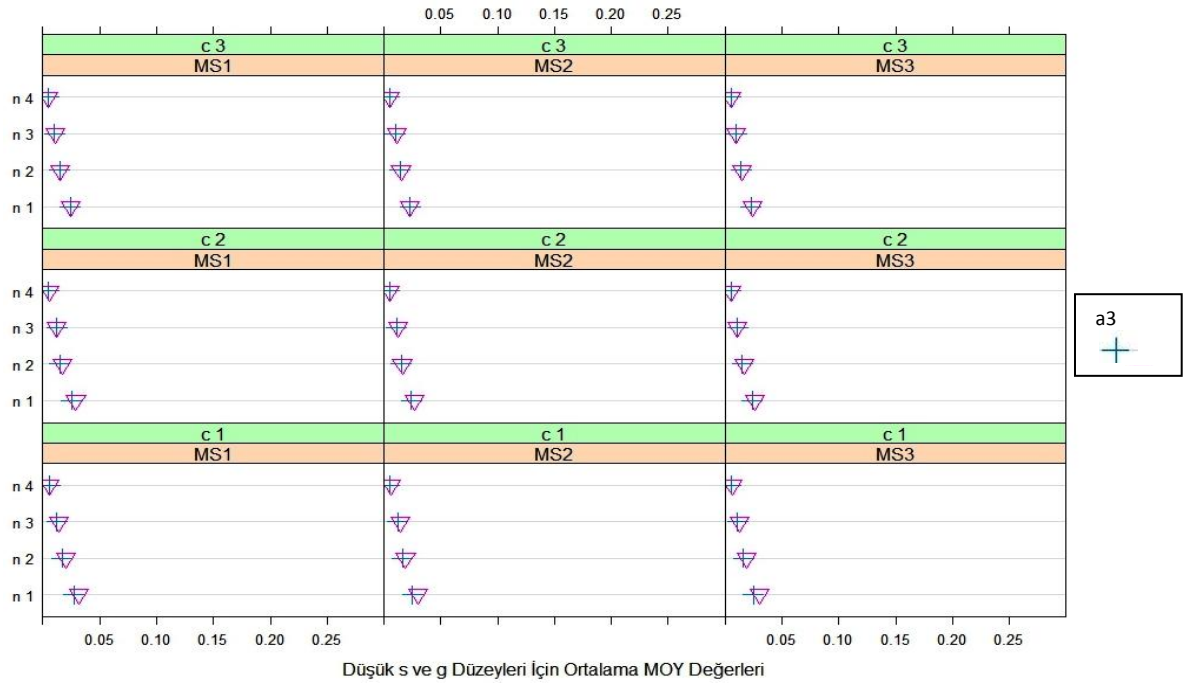


çeşitli korelasyon düzeylerinin) ortak etkileşimlerine ilişkin saçılım Grafik 10, 11, 12 ve 13'te sunulmuştur.


Grafiklerde yer alan koşulların ortak etkileri açısından ortalama MOY dağılımları incelendiğinde, anlamlı yapılanmaların olduğu göze çarpmaktadır. Özellikle örneklem büyüklüğü arttıkça ortalama MOY değerlerinin azaldığı görülmektedir. Başka bir ifadeyle, diğer faktörlerin her düzeyi için örneklem büyüklüğü arttıkça yanlılığın azaldığı görülmektedir. Buradan hareketle, s parametre kestirimi için MOY ortalamalarının elde edilmesinde örneklem büyüklüğünün etkili bir faktör olduğu görülmektedir.

Grafik 10 ve Grafik 11, ortak etkiler açısından incelendiğinde, genel olarak Grafik 10'dan elde edilen sonuçların, Grafik 11'den elde edilen sonuçlara göre daha düşük olduğu görülmektedir. Ayrıca, Grafik 12 ve Grafik 13 ortak etkiler açısından incelendiğinde, s parametresinin daha düşük olduğu düzeylerden elde edilen MOY ortalamalarının, s parametresini daha yüksek olduğu düzeylerden elde edilen MOY ortalamalarına göre daha düşük olduğu görülmektedir. Bu durumda, s parametre kestirimi için MOY ortalamalarının elde edilmesinde, s ve g parametrelerinin düzeylerinin etkili olduğu söylenebilir.


Dört grafik ayrı ayrı incelendiğinde, madde sayılarının ve özellik sayılarının s parametre kestirimi için MOY ortalamalarının elde edilmesinde önemsiz olduğu söylenebilir. Bütün madde ve özellik sayıları koşullarında yaklaşık aynı sonuçların elde edildiği görülmektedir.



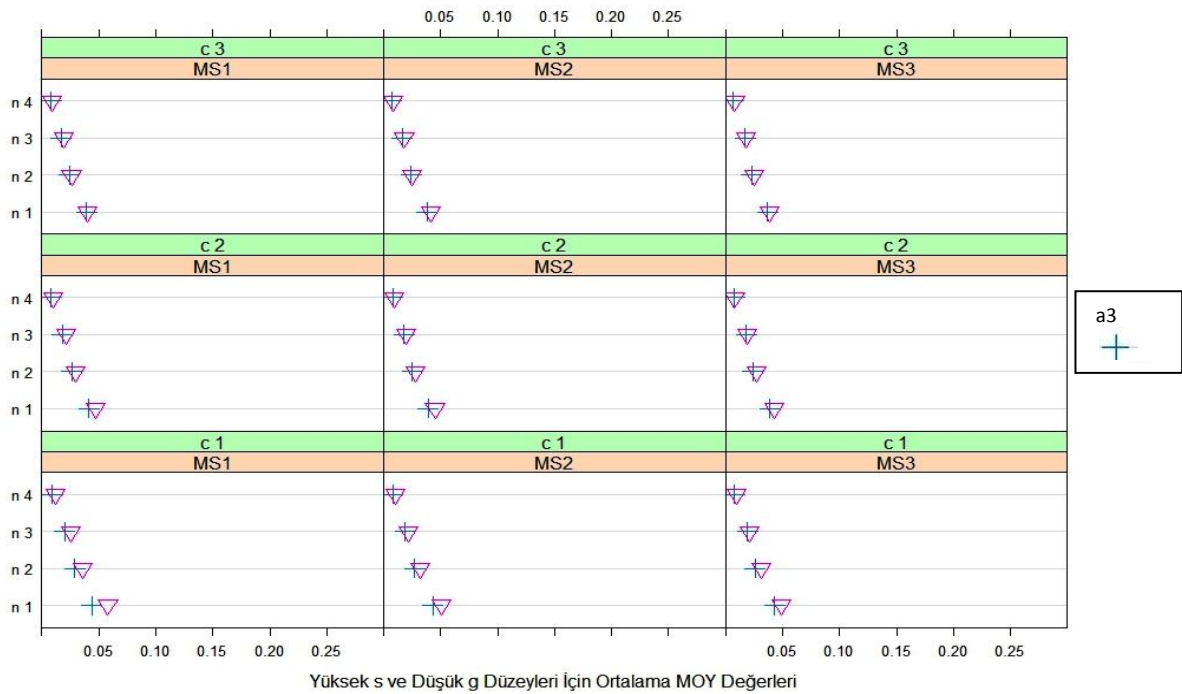
**Grafik 10:** DINA Analiz Modelinde ve Düşük s ve g Parametre Düzeylerinde, s Parametre Kestiriminden Elde Edilen Ortalama MOY Değerleri



**Grafik 11:** DINA Analiz Modelinde, Yüksek s ve g Düzeylerinde s Parametre Kestiriminden Elde Edilen Ortalama MOY Değerleri



**Grafik 12:** DINA Analiz Modelinde, Düşük s ve Yüksek g Parametre Düzeylerinde, s Parametre Kestiriminden Elde Edilen Ortalama MOY Değerleri



**Grafik 13:** DINA Analiz Modelinde ve Yüksek s ve Düşük g Parametre Düzeylerinde, s Parametre Kestiriminden Elde Edilen Ortalama MOY Değerleri

b) DINO analiz modeli kullanılarak çeşitli  $s$  ve  $g$  parametre düzeylerinde,  $s$  parametre kestirimleri için ortalama MOY değerleri elde edilmiştir. Çeşitli faktörlerin (örneklem büyüklüklerinin, özellik sayılarının, madde sayılarının ve özellikler arasındaki çeşitli korelasyon düzeylerinin) ortak etkileşimlerine ilişkin saçılım Grafik 14, 15, 16 ve 17'de sunulmuştur.

Grafiklerde yer alan koşulların ortak etkileri açısından ortalama MOY dağılımları incelendiğinde, farklı yapılanmaların oluştuğu göze çarpmaktadır. Grafik 14 incelendiğinde, diğer faktörlerin her düzeyi için özellik sayısının MOY ortalamalarının elde edilmesinde önemli olduğu, özellik sayısı 4 iken daha yansız kestirimler yapıldığı söylenebilir. Ayrıca, madde sayısı azaldıkça ve özellikler arası korelasyon düzeyi arttıkça ortalama MOY değerlerinin azaldığı görülmektedir. Özellikler arası korelasyon düzeyinin yüksek ve özellik sayısının 4 olduğu durumlarda örneklem büyüklüğü arttıkça,  $s$  parametrelerin daha yansız kestirildiği söylenebilir.


Grafik 15 incelendiğinde ise, özellik sayısının 4 olduğu durumlarda ortalama MOY değerlerinin azaldığı görülmektedir. Özellikle dikkat edilmesi gereken nokta ise, korelasyon düzeyi en yüksek, madde sayısı en düşük olduğunda bu durumun tam tersinin görülmesidir.

Grafik 14 ve Grafik 15, ortak etkiler açısından incelendiğinde, genel olarak Grafik 15'ten elde edilen sonuçların, Grafik 14'ten elde edilen sonuçlara göre daha düşük olduğu görülmektedir. Dikkat edilmesi gereken bir nokta ise, DINA analiz modelinde, bu durumun tam tersinin görülmesidir.  $s$  parametre kestirimi için MOY ortalamalarının elde edilmesinde,  $s$  ve  $g$  parametrelerinin düzeylerinin etkili olduğu, DINO analiz modeli için de söylenebilir.


Grafik 16 incelendiğinde, özellikler arası korelasyon düzeyi yüksek olduğunda, özellik sayısı ne olursa olsun yaklaşık aynı sonuçların elde edildiği görülmektedir. Özellikler arası korelasyon düzeyi düşük ve özellik sayısı 4 olduğunda ise, daha düşük ortalama MOY değerlerinin elde edildiği görülmektedir.

Grafik 17 incelendiğinde, özellikler arası korelasyon düzeyi en yüksek madde sayısının en düşük olduğu durum haricindeki tüm durumlarda, özellik sayısı 4 olduğunda s parametre kestiriminden elde edilen ortalama MOY değerlerinin daha düşük olduğu görülmektedir.


Grafik 16 ve 17 birlikte ele alındığında ise, s parametre düzeyinin düşük olduğu durumlarda elde edilen MOY değerlerinin daha düşük olduğu görülmektedir. Bu durum, s parametre kestirimi için MOY ortalamasının elde edilmesinde, s ve g parametre düzeyinin etkili olduğunu bir kere daha göstermektedir.




**Grafik 14:** DINO Analiz Modelinde ve Düşük s ve g Parametre Düzeylerinde, s Parametre Kestiriminden Elde Edilen Ortalama MOY Değerleri



**Grafik 15:** DINO Analiz Modelinde, Yüksek s ve g Düzeylerinde s Parametre Kestiriminden Elde Edilen Ortalama MOY Değerleri



**Grafik 16:** DINO Analiz Modelinde, Düşük s ve Yüksek g Parametre Düzeylerinde, s Parametre Kestiriminden Elde Edilen Ortalama MOY Değerleri



**Grafik 17:** DINO Analiz Modelinde, Yüksek s ve Düşük g Parametre Düzeylerinde, s Parametre Kestiriminden Elde Edilen Ortalama MOY Değerleri


c) Hem DINA hem de DINO analiz modelleri kullanılarak, s parametre kestirimleri için ortalama MOY deęerleri elde edilmiřtir. eřitli faktörlerin (örneklem büyüklüklerinin, madde sayılarının, özellik sayılarının, özellikler arasındaki çeřitli korelasyon düzeylerinin ve s ve g parametre düzeylerinin) ortak etkileřimlerine iliřkin saılım Grafik 18’de sunulmuřtur.

Grafik 18 incelendięinde, tüm faktörlerin her kořul düzeylerinde DINA analiz modelinden elde edilen ortalama MOY deęerlerinin, DINO analiz modelinden elde edilen ortalama MOY deęerlerinden düşük bulunduęu görölmektedir.

Grafik 18 incelendięinde, düşük s ve g düzeyinde, özellik sayısı 4, madde sayısı 30, özellikler arası korelasyon 0.90 ve örneklem büyüklüęü 2000 ve 5000 olduęunda DINA ve DINO analiz modellerinden elde edilen sonuçların örtüřtüęü görölmektedir. Bununla beraber, düşük s ve yüksek g düzeyinde, özellikler arası korelasyonun 0.90 olduęu tüm madde sayılarında, özellik sayılarında ve örneklem büyüklüklerinde DINA ve DINO analiz modellerinden elde edilen sonuçların örtüřtüęü görölmektedir.



### DINA ve DINO Analiz Modeli s Parametre Kestirimi



**Grafik 18:** DINA ve DINO Analiz Modelleri Kullanıldığında, s Parametre Kestiriminden Elde Edilen Ortalama MOY Değerleri

**III.1.3.1. Çeşitli faktörlerin (örneklem büyüklüklerinin, özellikler arası korelasyonun, özellik sayılarının, madde sayılarının, s ve g parametre düzeylerinin ve DINA ve DINO analiz modellerinin), madde uyumu için elde edilen RMSEA ortalamalarına temel etkileri nasıldır?**

a) Çeşitli faktörlerin (örneklem büyüklüklerinin, özellikler arası korelasyonun, özellik sayılarının, madde sayılarının, s ve g parametre düzeylerinin ve DINA analiz modelinin), madde uyumu için elde edilen RMSEA ortalamalarına ilişkin temel etki sonuçları Tablo 18’de gösterilmektedir.

**Tablo 18:** DINA Analiz Modeli Kullanıldığında Faktörlerin RMSEA Ortalamalarına İlişkin Temel Etki Değerleri

		DINA Analiz Modeli RMSEA değerleri
Örneklem Büyüklüğü	200	0.084
	500	0.053
	1000	0.038
	5000	0.017
Özellikler Arası Korelasyon	0.2	0.049
	0.5	0.048
	0.8	0.047
Özellik Sayısı	3	0.041
	4	0.055
Madde Sayısı	15	0.039
	30	0.050
	45	0.054
s ve g	s ve g düşük	0.041
	s düşük - g yüksek	0.056
	s yüksek - g düşük	0.046
	s ve g yüksek	0.049

DINA analiz modeli kullanılarak elde edilen RMSEA ortalamaları arasında istatistiksel açıdan anlamlı bir fark olup olmadığının test edilmesinde ise ANOVA ve ortalamalar arası farkların hangi koşullar arasında olduğunu bulmak amacıyla Tukey testi yapılmıştır. ANOVA sonuçlarına ilişkin bulgular Tablo 19'da gösterilmektedir.

**Tablo 19:** DINA Analiz Modeli Kullanılarak RMSEA Ortalamalarının Elde Edilmesinde Faktörlerin Temel Etkilerine İlişkin ANOVA Tablosu

Faktör	Varyansın	Kareler	Serbestlik	Kareler	F	p	Anlamlı Fark
	Kaynağı	Toplamı	Derecesi	Ortalaması			
<b>Örneklem Büyüklüğü</b>	Gruplararası	0.172	3	0.057			N2-N1 , N3-N2
	Grupiçi	0.048	284	0.000	336.1	0.000	N3-N1 , N4-N2
	Toplam	0.220	287				N4-N1 , N4-N3
<b>Özellikler Arası Korelasyon</b>	Gruplararası	0.000	2	0.000			-
	Grupiçi	0.220	285	0.000	0.1	0.905	
	Toplam	0.220	287				
<b>Özellik Sayısı</b>	Gruplararası	0.015	1	0.015			a3-a4
	Grupiçi	0.206	286	0.000	20.97	0.000	
	Toplam	0.221	287				
<b>Madde Sayısı</b>	Gruplararası	0.011	2	0.006			MS1-MS2
	Grupiçi	0.209	285	0.001	7.64	0.000	MS1-MS3
	Toplam	0.220	287				
<b>s ve g Parametre Düzeyleri</b>	Gruplararası	0.008	3	0.003			s dgd-sygy
	Grupiçi	0.213	284	0.000	3.551	0.015	
	Toplam	0.221	287				

Tablo 18 çeşitli örneklem büyüklükleri açısından incelendiğinde, DINA analiz modelinden elde edilen RMSEA ortalama değerlerinin 0.017 ile 0.084 arasında değiştiği görülmektedir. DINA analiz modeli madde uyumunda, örneklem büyüklüğü arttıkça RMSEA ortalama değerlerinin azaldığı görülmektedir. Başka bir ifadeyle, örneklem büyüklüğü arttıkça maddelerin daha fazla uyum gösterdiği söylenebilir. Tablo 19

incelendiğinde, RMSEA ortalamalarının örneklem büyüklüklerine göre anlamlı bir şekilde farklılaştığı görülmektedir [ $F_{3-284}=336.1, p<0.05$ ]. Tukey testi sonuçlarına göre,  $N_4$  ( $\bar{X} = 0.017$ ) örneklem büyüklüğü ortalaması ile  $N_3$  ( $\bar{X} = 0.038$ ),  $N_2$  ( $\bar{X} = 0.053$ ) ve  $N_1$  ( $\bar{X} = 0.084$ ) örneklem büyüklükleri ortalamaları arasında anlamlı bir farklılığın bulunduğu ve bunun da  $N_4$  örneklem büyüklüğü lehine olduğu görülmektedir. Ayrıca,  $N_3$  örneklem büyüklüğünden elde edilen RMSEA değerinin  $N_2$  ve  $N_1$  örneklem büyüklüklerinden elde edilen RMSEA değerlerinden;  $N_2$  örneklem büyüklüğünden elde edilen RMSEA değerinin  $N_1$  örneklem büyüklüğünden elde edilen RMSEA değerinden daha düşük olduğu görülmektedir. Bu bulgulara göre, DINA analiz modeli kullanıldığında, örneklem büyüklüğü arttıkça madde uyumunun daha fazla olduğu görülmektedir.

Özellikler arasındaki çeşitli korelasyon düzeyleri açısından Tablo 18 incelendiğinde, DINA analiz modelinde bu değerlerinin minimum ve maksimum değerleri arasındaki değişikliğin yok denecek kadar az olduğunu söylemek mümkündür. Tablo 19 incelendiğinde, elde edilen RMSEA ortalamalarının özellikler arası korelasyon düzeyine göre anlamlı bir şekilde farklılaşmadığı görülmektedir [ $F_{2-285}=0.1, p>0.05$ ]. Başka bir ifadeyle, DINA analiz modeli kullanıldığında, RMSEA ortalama değerlerinin özellikler arası korelasyon düzeylerinin değişimlenmesiyle birlikte çok fazla değişmediği görülmektedir.

Özelik sayıları açısından Tablo 18 incelendiğinde, elde edilen RMSEA ortalama değerleri DINA analiz modelinde fazla bir değişkenlik göstermemektedir. Ancak, özellik sayıları açısından Tablo 19 incelendiğinde, elde edilen RMSEA ortalamalarının özellik sayılarına göre anlamlı bir şekilde farklılaştığı [ $F_{1-286}=20.97$ ,  $p>0.05$ ], bu farklılığın da özellik sayısının 3 olduğu durum lehine olduğu görülmektedir

Tablo 18 madde sayıları açısından incelendiğinde, DINA analiz modelinde RMSEA ortalama değerlerinin 0.039 ile 0.054 arasında değiştiği görülmektedir. Tablo 19 incelendiğinde, elde edilen RMSEA ortalamalarının madde sayılarına göre anlamlı bir şekilde farklılaştığı görülmektedir [ $F_{2-285}=7.64$ ,  $p<0.05$ ]. Bu farklılığın  $MS_1$  ile diğer madde sayıları arasında ve  $MS_1$  lehine olduğu görülmektedir. DINA analiz modeli kullanılarak madde uyumları incelendiğinde, madde sayısının düşük olmasının madde uyumu açısından önemli olduğu görülmektedir. Başka bir ifadeyle, DINA analiz modelinde madde sayısı azaldıkça maddelerin daha fazla uyum gösterdiği söylenebilir.

Tablo 18 s ve g parametre düzeyleri açısından incelendiğinde, RMSEA ortalama değerlerin 0.041 ile 0.056 arasında değiştiği görülmektedir. Tablo 19 incelendiğinde ise, RMSEA ortalamalarının s ve g parametre düzeylerine göre anlamlı bir şekilde farklılaştığı görülmektedir [ $F_{3-284}=3.551$ ,  $p<0.05$ ]. Tukey testi sonuçlarına göre,  $s_d g_d$  ile  $s_y g_y$  arasında anlamlı bir farkın olduğu ve bunun da  $s_d g_d$  lehine olduğu görülmektedir. Bu sonuçlar ışığında, DINA analiz modeli kullanılarak madde uyumu incelendiğinde, s ve g parametrelerinin düşük düzeyde olmasının madde uyumu açısından önemli olduğu görülmektedir.

b) Çeşitli faktörlerin (örneklem büyüklüklerinin, özellikler arası korelasyonun, özellik sayılarının, madde sayılarının, s ve g parametre düzeylerinin ve DINO analiz modelinin), madde uyumu için elde edilen RMSEA ortalamalarına ilişkin temel etki sonuçları Tablo 20’de gösterilmektedir.

**Tablo 20:** DINO Analiz Modeli Kullanıldığında Faktörlerin RMSEA Ortalamalarına İlişkin Temel Etki Değerleri

		DINO Analiz Modeli RMSEA Değerleri
Örneklem Büyüklüğü	200	0.108
	500	0.094
	1000	0.088
	5000	0.082
Özellikler Arası Korelasyon	0.2	0.123
	0.5	0.096
	0.8	0.061
Özellik Sayısı	3	0.111
	4	0.075
Madde Sayısı	15	0.056
	30	0.101
	45	0.123
s ve g	s ve g düşük	0.142
	s düşük - g yüksek	0.071
	s yüksek - g düşük	0.107
	s ve g yüksek	0.053

DINO analiz modeli kullanılarak elde edilen RMSEA ortalamaları arasında istatistiksel açıdan anlamlı bir fark olup olmadığının test edilmesinde ise ANOVA ve ortalamalar arası farkların hangi koşullar arasında olduğunu bulmak amacıyla Tukey testi yapılmıştır. ANOVA sonuçlarına ilişkin bulgular Tablo 21’de gösterilmektedir.

**Tablo 21:** DINO Analiz Modeli Kullanılarak RMSEA Ortalamalarının Elde Edilmesinde Faktörlerin Temel Etkilerine İlişkin ANOVA Tablosu

Faktör	Varyansın Kaynağı	Kareler Toplamı	Serbestlik Derecesi	Kareler Ortalaması	F	p	Anlamlı Fark
<b>Örneklem Büyüklüğü</b>	Gruplararası	0.027	3	0.009	2.444	0.064	-
	Grupiçi	1.044	284	0.004			
	Toplam	1.071	287				
<b>Özellikler Arası Korelasyon</b>	Gruplararası	0.181	2	0.090	29.09	0.000	c1-c2
	Grupiçi	0.890	285	0.003			c1-c3
	Toplam	1.071	287				c2-c3
<b>Özellik Sayısı</b>	Gruplararası	0.093	1	0.093	27.27	0.000	a3-a4
	Grupiçi	0.977	286	0.003			
	Toplam	1.060	287				
<b>Madde Sayısı</b>	Gruplararası	0.226	2	0.113	38.09	0.000	MS1-MS2
	Grupiçi	0.844	285	0.002			MS1-MS3
	Toplam	1.070	287				MS2-MS3
<b>s ve g Parametre Düzeyleri</b>	Gruplararası	0.343	3	0.114	44.59	0.000	s dgd-sygy
	Grupiçi	0.728	284	0.002			s dgd-sdgy
	Toplam	1.071	287				s dgd-sygd
							sdgy-sygd
							sygd-sygy

Tablo 20 incelendiğinde, DINO analiz modelinde çeşitli örneklem büyüklüklerinden elde edilen RMSEA ortalamalarının DINO analiz modelinde madde uyumu için elde edilen RMSEA ortalama değerlerinin ise, 0.082 ile 0.108 arasında değiştiği görülmektedir. Tablo 21 incelendiğinde ise, elde edilen RMSEA ortalamalarının örneklem büyüklüklerine göre anlamlı bir şekilde farklılaşmadığı görülmektedir [  $F_{3-284}=2.444, p>0.05$ ]. Bu bulgulara göre, DINA analiz modelinden elde edilen RMSEA ortalamalarının, örneklem büyüklüklerinin değişimlenmesiyle birlikte çok fazla değişmediği görülmektedir.

Tablo 20 incelendiğinde, DINO analiz modelinde özellikler arası korelasyon düzeylerinden elde edilen RMSEA ortalamalarının 0.061 ile 0.123 arasında değiştiği görülmektedir. Tablo 21 incelendiğinde, RMSEA ortalamalarının özellikler arası korelasyon düzeylerine göre anlamlı bir şekilde farklılaştığı görülmektedir [ $F_{2-285}=29.09$ ,  $p<0.05$ ]. Bu farklılığın  $c_3$  ile  $c_1$  ve  $c_2$  arasında  $c_3$  lehine,  $c_2$  ve  $c_1$  arasında  $c_2$  lehine olduğu görülmektedir. Bu sonuçlar ışığında, DINO analiz modelinde, özellikler arasındaki korelasyon düzeyi artıkça madde uyumlarının daha fazla olduğu söylenebilir. DINO analiz modelinde özelliklerin birbirini tamamlaması söz konusu olduğundan, bu durumun gözlemlendiği söylenebilir.

Tablo 20'ye göre özellik sayıları değişimlendiğinde, RMSEA ortalama değerlerinin 0.075 ve 0.111 olduğu görülmektedir. Tablo 21 incelendiğinde ise, RMSEA ortalamalarının özellik sayılarına göre anlamlı bir şekilde farklılaştığı [ $F_{1-286}=27.27$ ,  $p<0.05$ ] ve bu farklılığın özellik sayısının 4 olduğu durum lehine olduğu görülmektedir. Bu bulgulara göre, DINO analiz modelinde, özellik sayısının yüksek olmasının madde uyumunu arttırdığı söylenebilir.

Madde sayıları açısından Tablo 20 incelendiğinde, elde edilen RMSEA ortalama değerlerinin 0.056 ile 0.123 arasında değiştiği görülmektedir. Tablo 21 incelendiğinde, elde edilen RMSEA ortalamalarının madde sayılarına göre anlamlı bir şekilde farklılaştığı görülmektedir [ $F_{2-285}=38.09$ ,  $p>0.05$ ]. Bu farklılığın  $MS_1$  ile  $MS_2$  ve  $MS_3$  arasında ve  $MS_1$  madde sayısı lehine olduğu görülmektedir. Bu bulgulara göre, DINO analiz modelinde madde sayısı düşük olduğunda, maddelerin daha fazla uyum gösterdiği söylenebilir.

Tablo 20'ye göre  $s$  ve  $g$  parametre düzeylerinden elde edilen RMSEA ortalamalarının 0.053 ile 0.142 arasında değiştiği görülmektedir. Tablo 21 incelendiğinde,



elde edilen RMSEA ortalamalarının s ve g parametre düzeylerine göre anlamlı bir şekilde farklılaştığı görülmektedir [ $F_{3-284}=44.59$ ,  $p<0.05$ ]. Tukey testi sonuçlarına göre,  $s_d g_d$  ( $\bar{X} = 0.142$ ) ile diğer tüm s ve g düzeyleri ( $s_d g_y$  ( $\bar{X} = 0.071$ ),  $s_y g_d$  ( $\bar{X} = 0.107$ ),  $s_y g_y$  ( $\bar{X} = 0.053$ )) arasında anlamlı farklılığın ve bunun diğer s ve g düzeyleri lehine olduğu görülmektedir. Ayrıca,  $s_d g_y$  ile  $s_y g_d$  arasındaki anlamlı farklılığın  $s_d g_y$  lehine;  $s_y g_y$  ve  $s_y g_d$  arasındaki anlamlı farklılığın  $s_y g_y$  lehine olduğu görülmektedir. Bu sonuçlar ışığında, DINO analiz modelinde, s ve g parametre düzeyleri yüksek olduğunda madde uyumunun daha fazla olduğu görülmektedir.

c) Madde uyumu için elde edilen RMSEA ortalamaları arasında istatistiksel açıdan anlamlı bir fark olup olmadığının test edilmesine ilişkin yapılan ANOVA sonuçlarına ait DINA ve DINO analiz modeli karşılaştırmaları Tablo 22’de gösterilmektedir.

**Tablo 22:** Madde Uyumuna İlişkin DINA ve DINO Analiz Modeli Karşılaştırılması

Faktör	DINA	DINO
Örneklem Büyüklüğü	+	-
Özellikler Arası Korelasyon	-	+
Özellik Sayısı	+	+
Madde Sayısı	+	+
s ve g Parametre Düzeyleri	+	+

Tablo 22 incelendiğinde, hem DINA hem de DINO analiz modellerinden elde edilen RMSEA ortalamalarının özellik sayılarına, madde sayılarına ve s ve g parametre düzeylerine göre anlamlı bir şekilde farklılaştığı görülmektedir. DINA analiz modeli kullanıldığında elde edilen RMSEA ortalamalarının örneklem büyüklüklerine göre anlamlı bir şekilde farklılaştığı ancak, DINO analiz modeli kullanıldığında herhangi bir farklılaşmanın olmadığı görülmektedir. DINO analiz modeli kullanıldığında, elde edilen RMSEA ortalamalarının özellikler arası korelasyon düzeylerine göre anlamlı bir şekilde farklılaştığı ancak, DINA analiz modeli kullanıldığında herhangi bir farklılaşmanın olmadığı görülmektedir.

Madde uyumu için DINA ve DINO analiz modellerinden elde edilen RMSEA ortalamaları genel olarak incelendiğinde ise, her koşul düzeyi için, DINA analiz modelinden elde edilen RMSEA ortalama değerleri, DINO analiz modelinden elde edilen RMSEA ortalama değerlerinden daha düşük bulunmuştur. Faktörlerin temel etkileri açısından, DINA ve DINO analiz modellerinde herhangi bir örtüşme görülmemiştir.

### **III.3.2. Çeşitli faktörlerin (örneklem büyüklüklerinin, özellikler arası korelasyonun, özellik sayılarının, madde sayılarının, s ve g parametre düzeylerinin), madde uyumu için elde edilen ortalama RMSEA ortalamalarına ortak etkileri nasıldır?**

a) DINA analiz modeli kullanılarak çeşitli s ve g parametre düzeylerinde, madde uyumu için ortalama RMSEA ortalama değerleri elde edilmiştir. Çeşitli faktörlerin (örneklem büyüklüklerinin, özellik sayılarının, madde sayılarının ve özellikler arasındaki çeşitli korelasyon düzeylerinin) ortak etkileşimlerine ilişkin saçılım Grafik 19, 20, 21 ve 22’de sunulmuştur.

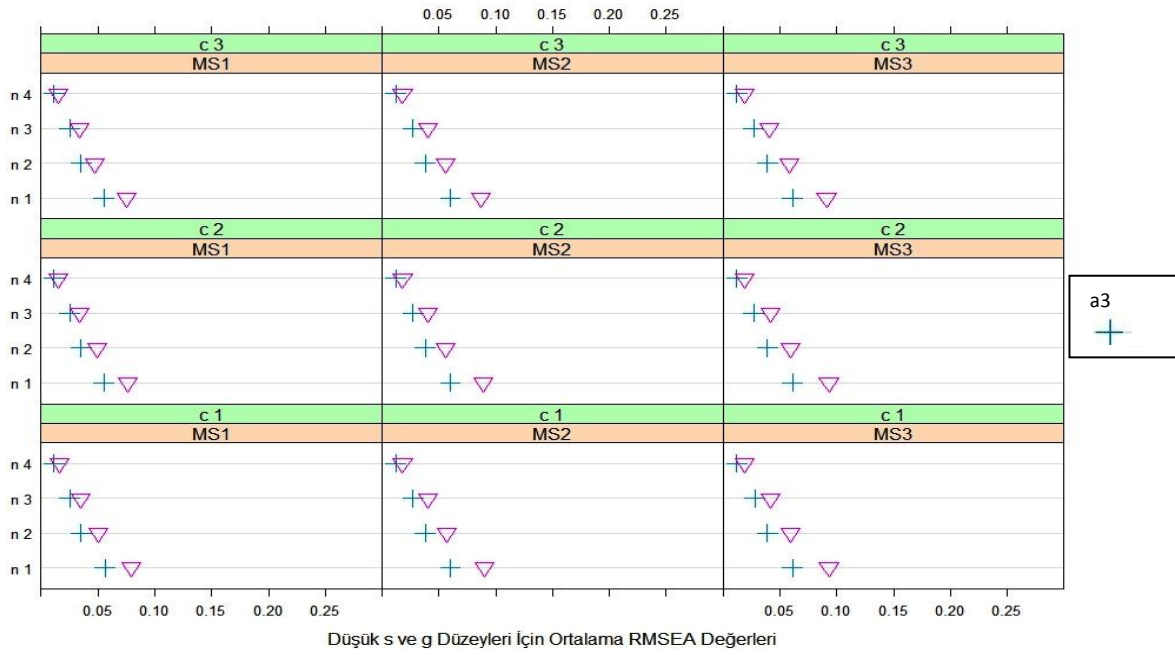
Grafiklerde yer alan koşulların ortak etkileri açısından RMSEA ortalama dağılımları incelendiğinde, anlamlı bir yapılanmanın olduğu gözle çarpılmaktadır. Özellikle örneklem büyüklüğü arttıkça RMSEA ortalama değerlerinin azaldığı ve bunun madde sayısı ile ilişkili olduğu görülmektedir. Madde sayısı arttıkça, ortalama RMSEA ortalama değerlerinin de arttığı görülmektedir.

Dört grafik ayrı ayrı incelendiğinde, özellik sayısının 3 olduğu durumdan elde edilen RMSEA ortalama değerlerinin daha düşük olduğu görülmektedir. Başka bir ifadeyle, özellik sayısı 3 olduğunda madde uyumunun daha fazla olduğu gözle çarpılmaktadır.


Özellik sayısı ve madde sayısının arttığı durumlarda, RMSEA ortalamalarının arttığı görülmektedir. Bu durumun modelin kompleksleşmesinden kaynaklandığı söylenebilir.

Ayrıca özellikler arası korelasyon düzeylerinin, madde uyumu için hesaplanan RMSEA ortalama değerleri için önemsiz olduğu söylenebilir. Bütün özellikler arası korelasyon düzeylerinde yaklaşık aynı sonuçlar elde edildiği görülmektedir.


Grafik 19 ve Grafik 20 ortak etkiler açısından incelendiğinde, genel olarak Grafik 19'dan elde edilen sonuçların (düşük s ve g düzeyi), Grafik 20'den elde edilen sonuçlara (yüksek s ve g düzeyi) göre daha düşük olduğu görülmektedir. Bu durumda, madde uyumu için elde edilen RMSEA ortalama değerleri için, s ve g parametre düzeylerinin etkili bir faktör olduğu söylenebilir.




**Grafik 19:** DINA Analiz Modelinde ve Düşük s ve g Parametre Düzeylerinde, Madde Uyumu İçin Elde Edilen RMSEA Ortalama Değerleri



**Grafik 20:** DINA Analiz Modelinde, Yüksek s ve g Düzeylerinde Madde Uyumu İçin Elde Edilen RMSEA Ortalama Değerleri



**Grafik 21:** DINA Analiz Modelinde, Düşük s ve Yüksek g Parametre Düzeylerinde, Madde Uyumu İçin Elde Edilen RMSEA Ortalama Değerleri



**Grafik 22:** DINA Analiz Modelinde ve Yüksek s ve Düşük g Parametre Düzeylerinde, Madde Uyumu İçin Elde Edilen RMSEA Ortalama Değerleri

b) DINO analiz modeli kullanılarak çeşitli s ve g parametre düzeylerinde, madde uyumu için RMSEA ortalama değerleri elde edilmiştir. Çeşitli faktörlerin (örneklem büyüklüklerinin, özellik sayılarının, madde sayılarının ve özellikler arasındaki çeşitli korelasyon düzeylerinin) ortak etkileşimlerine ilişkin saçılım Grafik 23, 24, 25 ve 26’da sunulmuştur.


Grafiklerde yer alan koşulların ortak etkileri açısından RMSEA ortalama dağılımları incelendiğinde, farklı yapılanmaların oluştuğu göze çarpmaktadır. Grafik 23 incelendiğinde, özellikle özellik sayısı 4 olduğunda, ortalama RMSEA değerlerinin azaldığı ve bunun madde sayısı ve özellikler arası korelasyon düzeyleriyle ilişkili olduğu görülmektedir. Madde sayısı azaldıkça ve özellikler arası korelasyon düzeyi arttıkça ortalama RMSEA değerlerinin azaldığı görülmektedir. Ayrıca, özellikler arası korelasyon düzeyinin yüksek, madde sayısının az olduğu durumda, özellik sayısı ne olursa olsun yaklaşık aynı sonuçların elde edildiği görülmektedir. Özellik sayısının 4 ve özellikler arası korelasyon düzeyinin yüksek olduğu durumlarda örneklem büyüklüğü arttıkça, madde uyumunun arttığı söylenebilir.

Grafik 24 incelendiğinde ise, özellik sayısının 4 ve madde sayısının düşük olduğu durumlarda RMSEA ortalama değerlerinin azaldığı görülmektedir.


Grafik 23 ve Grafik 24, ortak etkiler açısından incelendiğinde, genel olarak Grafik 24’ten elde edilen sonuçların (yüksek s ve g düzeyi), Grafik 23’ten elde edilen sonuçlara (düşük s ve g düzeyi) göre daha düşük olduğu görülmektedir. Dikkat edilmesi gereken bir nokta ise, DINA analiz modelinde, bu durumun tam tersinin görülmesidir.

Grafik 25 ve 26 incelendiğinde, özellik sayısı 4 ve madde sayısının düşük olduğu durumlarda RMSEA ortalama değerlerinin azaldığı görülmektedir. Sonuç olarak, madde


uyumu için elde edilen RMSEA ortalama değerleri için, s ve g parametre düzeylerinin etkili bir faktör olduğu söylenebilir.



**Grafik 23:** DINO Analiz Modelinde ve Düşük s ve g Parametre Düzeylerinde, Madde Uyumu İçin Elde Edilen RMSEA Ortalama Değerleri




**Grafik 24:** DINO Analiz Modelinde, Yüksek s ve g Düzeylerinde Madde Uyumu İçin Elde Edilen RMSEA Ortalama Değerleri



Düşük s ve Yüksek g Düzeyleri İçin Ortalama RMSEA Değerleri

**Grafik 25:** DINO Analiz Modelinde, Düşük s ve Yüksek g Parametre Düzeylerinde,

Madde Uyumu İçin Elde Edilen RMSEA Ortalama Değerleri



Yüksek s ve Düşük g Düzeyleri İçin Ortalama RMSEA Değerleri

**Grafik 26:** DINO Analiz Modelinde ve Yüksek s ve Düşük g Parametre Düzeylerinde,

Madde Uyumu İçin Elde Edilen RMSEA Ortalama Değerleri

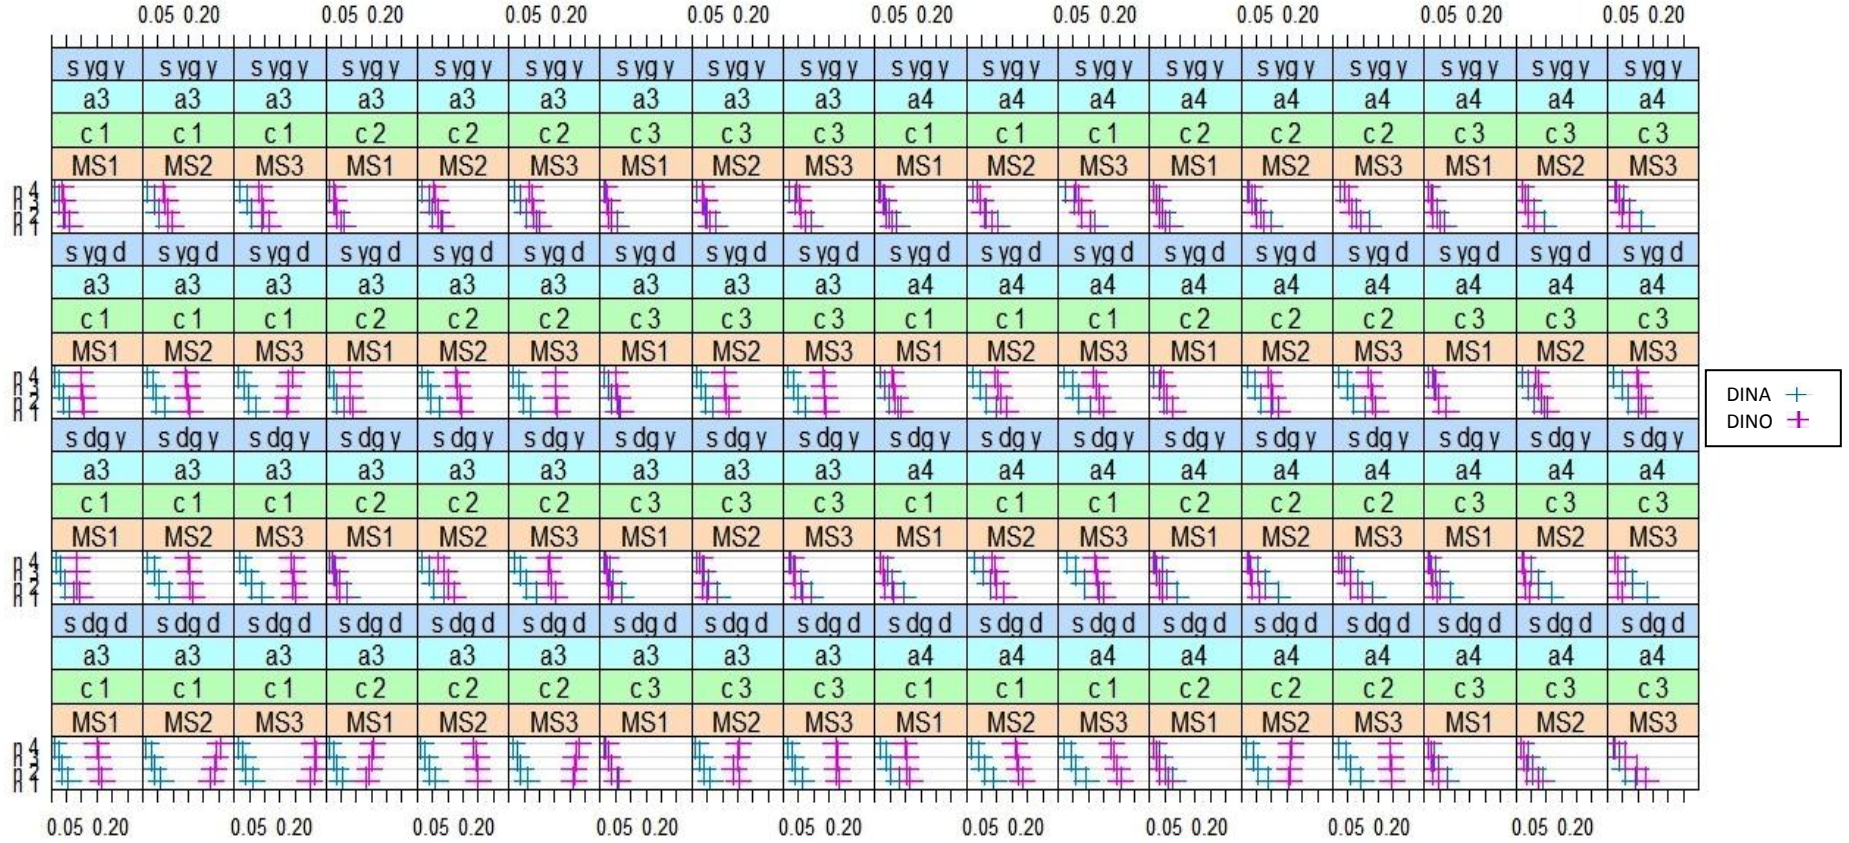


c) Hem DINA hem de DINO analiz modelleri kullanılarak ortalama RMSEA deęerleri elde edilmiřtir. eřitli faktörlerin (örneklem büyüklüklerinin, madde sayılarının, özellik sayılarının, özellikler arasındaki çeřitli korelasyon düzeylerinin ve s ve g parametre düzeylerinin) ortak etkileřimlerine iliřkin saçılım Grafik 27’de sunulmuřtur.

Grafik 27 incelendięinde, tüm faktörlerin her kořul düzeylerinde DINA analiz modelinden elde edilen ortalama RMSEA deęerlerinin, DINO analiz modelinden elde edilen ortalama RMSEA deęerlerinden düşük bulunduęu görölmektedir.

Grafik 27 incelendięinde, s ve g’nin düşük, özellik sayısının 3, madde sayısının 15 olduęu tüm örneklem büyüklüklerinde, DINA ve DINO analiz modellerinden elde edilen sonuçların örtüřtüęü görölmektedir.

### DINA ve DINO Analiz Modeli RMSEA Ortalama Değerleri



**Grafik 27:** DINA ve DINO Analiz Modelleri Kullanıldığında, Elde Edilen RMSEA Ortalama Değerleri

**III.4.1. Çeşitli faktörlerin (örneklem büyüklüklerinin, özellikler arası korelasyonun, özellik sayılarının, madde sayılarının, s ve g parametre düzeylerinin ve DINA ve DINO analiz modellerinin), Doğru Sınıflama Oranları (DSO) ortalamalarına temel etkileri nasıldır?**

a) Çeşitli faktörlerin (örneklem büyüklüklerinin, özellikler arası korelasyonun, özellik sayılarının, madde sayılarının, s ve g parametre düzeylerinin ve DINA analiz modelinin), sınıflama tutarlılığı için elde edilen Doğru Sınıflama Oranları (DSO) ortalamalarına ilişkin temel etki sonuçları Tablo 23'te gösterilmektedir.

**Tablo 23:** DINA Analiz Modeli Kullanıldığında Faktörlerin Doğru Sınıflama Oranları Ortalamalarına İlişkin Temel Etki Değerleri

		DINA Analiz Modeli
		DSO Değerleri
Örneklem Büyüklüğü	200	0.851
	500	0.852
	1000	0.853
	5000	0.853
Özellikler Arası Korelasyon	0.2	0.854
	0.5	0.853
	0.8	0.851
Özellik Sayısı	3	0.911
	4	0.794
Madde Sayısı	15	0.764
	30	0.869
	45	0.925
s ve g	s ve g düşük	0.948
	s düşük - g yüksek	0.872
	s yüksek - g düşük	0.884
	s ve g yüksek	0.706

DINA analiz modelinde elde edilen DSO ortalamaları arasında istatistiksel açıdan anlamlı bir fark olup olmadığının test edilmesinde ise ANOVA ve ortalamalar arası farkların hangi koşullar arasında olduğunu bulmak amacıyla Tukey testi yapılmıştır. ANOVA sonuçlarına ilişkin bulgular Tablo 24’te gösterilmektedir.

**Tablo 24:** Sınıflama Tutarlılığı İçin DINA Analiz Modeli Kullanıldığında Faktörlerin Temel Etkilerine İlişkin ANOVA Tablosu

Faktör	Varyansın	Kareler	Serbestlik	Kareler	F	p	Anlamlı Fark
	Kaynağı	Toplamı	Derecesi	Ortalaması			
<b>Örnekleme Büyüklüğü</b>	Gruplararası	0.000	3	0.000	0.003	0.97	-
	Grupiçi	4.998	284	0.017			
	Toplam	4.998	287				
<b>Özellikler Arası Korelasyon</b>	Gruplararası	0.000	2	0.000	0.01	0.098	-
	Grupiçi	4.997	285	0.017			
	Toplam	4.997	287				
<b>Özellik Sayısı</b>	Gruplararası	0.998	1	0.998	71.4	0.000	a3-a4
	Grupiçi	3.999	286	0.014			
	Toplam	4.997	287				
<b>Madde Sayısı</b>	Gruplararası	1.287	2	0.644	49.45	0.000	MS1-MS2
	Grupiçi	3.710	285	0.013			
	Toplam	4.997	287				
<b>s ve g Parametre Düzeyleri</b>	Gruplararası	2.305	3	0.768	81.01	0.000	s dgd-sdgy
	Grupiçi	2.693	284	0.009			
	Toplam	4.998	287				
							s dgd-sygy
							s dgy-sygy
							s ygd-sygy

Örnekleme büyüklükleri açısından Tablo 23 incelendiğinde, elde edilen DSO ortalama değerlerinin 0.851 ile 0.853 arasında değiştiği görülmektedir. Tablo 24 incelendiğinde ise, elde edilen DSO ortalamalarının örnekleme büyüklüklerine göre anlamlı

bir şekilde farklılaşmadığı görülmektedir [ $F_{3-284}=0.003$ ,  $p<0.05$ ]. Bu sonuçlar ışığında, DINA analiz modelinde DSO ortalamalarının, örneklem büyüklüğünün artışıyla birlikte çok fazla değişmediği görülmektedir.

Tablo 23 özellikler arasındaki çeşitli korelasyon düzeyleri açısından incelendiğinde, DSO ortalamaları arasındaki değişikliğin yok denecek kadar az olduğunu söylemek mümkündür. Ayrıca Tablo 24 incelendiğinde, elde edilen DSO ortalamaların özellikler arası korelasyon düzeylerine göre anlamlı bir şekilde farklılaşmadığı görülmektedir [ $F_{2-285}=0.01$ ,  $p>0.05$ ]. Başka bir ifadeyle, DINA analiz modeli kullanılarak DSO incelendiğinde, özellikler arası korelasyon düzeylerinin anlamlı bir etkisinin olmadığı görülmektedir.

Özelik sayıları açısından Tablo 23 incelendiğinde, DINA analiz modelinde elde edilen DSO ortalama değerlerinin 0.794 ve 0.911 olduğu görülmektedir. DINA analiz modelinde, özellik sayısı arttıkça DSO ortalama değerlerinin azaldığı görülmektedir. Özellik sayıları açısından Tablo 24 incelendiğinde, DSO ortalamaları arasında istatistiksel açıdan anlamlı bir farklılık olduğu [ $F_{1-286}=71.4$ ,  $p>0.05$ ], bu farklılığın da özellik sayısının 3 olduğu durum lehine olduğu görülmektedir. Bu bulgulara göre, özellik sayısı arttıkça doğru sınıflamanın daha az yapıldığı söylenebilir.

Tablo 23'teki DSO ortalama değerleri madde sayıları açısından incelendiğinde, DINA analiz modelinde elde edilen DSO ortalama değerlerinin 0.764 ile 0.925 arasında değiştiği görülmektedir. DINA analiz modelinde, madde sayısı arttıkça DSO ortalama değerlerinin arttığı görülmektedir. Tablo 24 incelendiğinde, DSO ortalamalarının madde sayılarına göre anlamlı bir şekilde farklılaştığı görülmektedir [ $F_{2-285}=49.45$ ,  $p<0.05$ ].  $MS_1$  ile diğer madde sayıları arasında anlamlı bir farklılığın olduğu ve bu farklılığın diğer

madde sayıları lehine olduğu görülmektedir. Ayrıca,  $MS_2$  ve  $MS_3$  ortalamaları arasındaki farklılığın  $MS_3$  lehine olduğu görülmektedir. Bu sonuçlar ışığında, DINA analiz modelinde madde sayısı artışıyla birlikte DSO ortalamalarının da arttığı görülmektedir.

s ve g parametre düzeyleri açısından Tablo 23 incelendiğinde, DINA analiz modelinde elde edilen DSO ortalama değerlerinin 0.706 ile 0.948 arasında değiştiği görülmektedir. Tablo 24 incelendiğinde ise, elde edilen DSO ortalamalarının s ve g parametre düzeylerine göre anlamlı bir şekilde farklılaştığı görülmektedir [ $F_{3-284} = 81.01, p < 0.05$ ]. Tukey testi sonuçlarına göre,  $s_d g_d (\bar{X} = 0.948)$  ile diğer s ve g parametre düzeyleri arasında ( $s_d g_y (\bar{X} = 0.872)$ ,  $s_y g_d (\bar{X} = 0.884)$ ,  $s_y g_y (\bar{X} = 0.706)$ ) anlamlı bir farklılığın ve bu farklılığın  $s_d g_d$  lehine olduğu görülmektedir.  $s_d g_y$  ile  $s_y g_y$  arasında anlamlı bir farkın olduğu ve bunun da  $s_d g_y$  lehine olduğu görülmektedir. Ayrıca,  $s_y g_d$  ile  $s_y g_y$  arasındaki anlamlı farklılığın  $s_y g_d$  lehine olduğu görülmektedir. Bu bulgulara göre, DINA analiz modelinde düşük s ve g parametre düzeyinde daha yüksek DSO ortalamalarının elde edildiği görülmektedir.

b) Çeşitli faktörlerin (örneklem büyüklüklerinin, özellikler arası korelasyonun, özellik sayılarının, madde sayılarının, s ve g parametre düzeylerinin ve DINA analiz modelinin), sınıflama tutarlılığı için elde edilen Doğru Sınıflama Oranları (DSO) ortalamalarına ilişkin temel etki sonuçları Tablo 25'te gösterilmektedir.

**Tablo 25:** DINO Analiz Modeli Kullanıldığında Faktörlerin Doğru Sınıflama Oranları Ortalamalarına İlişkin Temel Etki Değerleri

		DINO Analiz Modeli
		DSO Değerleri
Örnekleme Büyüklüğü	200	0.438
	500	0.441
	1000	0.445
	5000	0.445
Özellikler Arası Korelasyon	0.2	0.395
	0.5	0.400
	0.8	0.535
Özellik Sayısı	3	0.585
	4	0.301
Madde Sayısı	15	0.385
	30	0.454
	45	0.491
s ve g	s ve g düşük	0.507
	s düşük - g yüksek	0.454
	s yüksek - g düşük	0.441
	s ve g yüksek	0.370

DINO analiz modelinde elde edilen DSO ortalamaları arasında istatistiksel açıdan anlamlı bir fark olup olmadığının test edilmesinde ise ANOVA ve ortalamalar arası farkların hangi koşullar arasında olduğunu bulmak amacıyla Tukey testi yapılmıştır. ANOVA sonuçlarına ilişkin bulgular Tablo 26'da gösterilmektedir.

**Tablo 26:** Sınıflama Tutarlılığı İçin DINO Analiz Modeli Kullanıldığında Faktörlerin Temel Etkilerine İlişkin ANOVA Tablosu

Faktör	Varyansın	Kareler	Serbestlik	Kareler	F	p	Anlamlı Fark
	Kaynağı	Toplamı	Derecesi	Ortalaması			
<b>Örneklem Büyüklüğü</b>	Gruplararası	0.004	3	0.001			-
	Grupiçi	10.481	284	0.037	0.035	0.991	
	Toplam	10.481	287				
<b>Özellikler Arası Korelasyon</b>	Gruplararası	1.217	2	0.608			c3-c1
	Grupiçi	9.268	285	0.032	18.7	0.000	c3-c2
	Toplam	10.485	287				
<b>Özellik Sayısı</b>	Gruplararası	5.776	1	5.776			a3-a4
	Grupiçi	4.709	286	0.016	350.8	0.000	
	Toplam	10.485	287				
<b>Madde Sayısı</b>	Gruplararası	0.557	2	0.279			MS1-MS2
	Grupiçi	9.927	285	0.035	8.002	0.000	MS1-MS3
	Toplam	10.484	287				
<b>s ve g Parametre Düzeyleri</b>	Gruplararası	0.695	3	0.231			s dgd-sygy
	Grupiçi	9.790	284	0.034	6.72	0.000	s dgy-sygy
	Toplam	10.485	287				

Tablo 25 örneklem büyüklükleri açısından incelendiğinde, DINO analiz modelinden elde edilen DSO ortalama değerlerinin 0.438 ile 0.445 arasında değiştiği görülmektedir. Tablo 26 incelendiğinde ise, DSO ortalamalarının örneklem büyüklüklerine göre anlamlı bir şekilde farklılaşmadığı görülmektedir [ $F_{3-284}=0.035$ ,  $p<0.05$ ]. Bu sonuçlar ışığında, DINO analiz modelinde DSO ortalamalarının, örneklem büyüklüğünün artışıyla birlikte çok fazla değişmediği görülmektedir.

Özellikler arası korelasyon düzeyleri açısından Tablo 25 incelendiğinde, DINO analiz modelinde DSO ortalama değerlerinin 0.395 ile 0.535 arasında değiştiği



görülmektedir. Özellikler arası korelasyon düzeyi arttıkça, DSO ortalamalarının arttığı görülmektedir. Tablo 26 incelendiğinde, elde edilen DSO ortalamaların özellikler arası korelasyon düzeylerine göre anlamlı bir şekilde farklılaştığı görülmektedir [ $F_{2-285} = 18.7, p > 0.05$ ]. Tukey testi sonuçlarına göre c3 ile c1 ve c2 korelasyon düzeyleri arasında anlamlı farklılığın bulunduğu ve bu farklılığın da c3 lehine olduğu görülmektedir. Bu bulgulara göre, DINO analiz modelinde, özellikler arası korelasyon düzeyi arttıkça daha doğru sınıflamaların yapıldığı söylenebilir.

Tablo 25 incelendiğinde, özellik sayılarından elde edilen DSO ortalama değerlerinin 0.301 ve 0.585 olduğu görülmektedir. Özellik sayısı arttıkça elde edilen DSO ortalama değerlerinin azaldığı görülmektedir. Başka bir ifadeyle, özellik sayısı arttıkça doğru sınıflamanın daha az yapıldığı söylenebilir. Tablo 26 incelendiğinde, DSO ortalamaların özellik sayılarına göre anlamlı bir şekilde farklılaştığı [ $F_{1-286} = 350.8, p > 0.05$ ] ve bu farklılığın da özellik sayısının 3 olduğu durum lehine olduğu görülmektedir.

Tablo 25 madde sayıları açısından incelendiğinde, DINO analiz modelinde elde edilen DSO ortalama değerlerinin, 0.385 ile 0.491 arasında değiştiği görülmektedir. DINO analiz modelinde, madde sayısı arttıkça DSO ortalama değerlerinin arttığı görülmektedir. Tablo 26 incelendiğinde, elde edilen DSO ortalamalarının madde sayılarına göre anlamlı bir şekilde farklılaştığı görülmektedir [ $F_{2-285} = 8.002, p < 0.05$ ].  $MS_3$  ile  $MS_2$  ve  $MS_1$  madde ortalamaları arasında anlamlı bir farklılığın olduğu ve bu farklılığın  $MS_3$  lehine olduğu görülmektedir. bu sonuçlar ışığında, DINO analiz modelinde madde sayısı arttıkça daha fazla doğru sınıflamanın yapıldığı söylenebilir.

Tablo 25 s ve g parametre düzeyleri açısından incelendiğinde DINO analiz modelinden elde edilen DSO ortalama değerlerinin 0.370 ile 0.507 arasında değiştiği görülmektedir. Tablo 26 incelendiğinde ise, elde edilen DSO ortalamalarının s ve g parametre düzeylerine göre anlamlı bir şekilde farklılaştığı görülmektedir [ $F_{3-284} = 6.72, p < 0.05$ ]. Tukey testi sonuçlarına göre,  $s_y g_y$  ile  $s_d g_d$  ve  $s_d g_y$  arasında anlamlı bir farklılığın ve bu farklılığın  $s_d g_d$  ve  $s_d g_y$  lehine olduğu görülmektedir. Bu bulgulara göre, düşük s ve g parametrelerinin düzeylerinde, DSO değerlerini arttığı söylenebilir.

c) Sınıflama tutarlılığı için elde edilen DSO ortalamaları arasında istatistiksel açıdan anlamlı bir fark olup olmadığının test edilmesine ilişkin yapılan ANOVA sonuçlarına ait DINA ve DINO analiz modeli karşılaştırmaları Tablo 27’de gösterilmektedir.

**Tablo 27:** Sınıflama Tutarlılığına İlişkin DINA ve DINO Analiz Modeli Karşılaştırılması

<b>Faktör</b>	<b>DINA</b>	<b>DINO</b>
<b>Örneklem Büyüklüğü</b>	-	-
<b>Özellikler Arası Korelasyon</b>	-	+
<b>Özellik Sayısı</b>	+	+
<b>Madde Sayısı</b>	+	+
<b>s ve g Parametre Düzeyleri</b>	+	+

Tablo 27 incelendiğinde, hem DINA hem de DINO analiz modellerinde elde edilen DSO ortalamalarının, özellik sayılarına, madde sayılarına ve s ve g parametre düzeylerine göre anlamlı bir şekilde farklılaştığı; örneklem büyüklüklerine göre ise anlamlı bir farklılaşmanın olmadığı görülmektedir. Özellikler arası korelasyon düzeylerine göre elde edilen DSO ortalamalarının, DINO analiz modelinde anlamlı bir şekilde farklılaştığı, DINA analiz modelinde ise anlamlı bir şekilde farklılaşmadığı görülmektedir.


Sınıflama tutarlılığı için DINA ve DINO analiz modellerinden elde edilen DSO ortalamaları genel olarak incelendiğinde ise, her koşul düzeyi için, DINA analiz modelinden elde edilen DSO ortalama değerleri, DINO analiz modelinden elde edilen DSO ortalama değerlerinden daha düşük bulunmuştur. Faktörlerin temel etkileri açısından, DINA ve DINO analiz modellerinde herhangi bir örtüşme görülmemiştir.

#### **III.4.2. Çeşitli faktörlerin (örneklem büyüklüklerinin, özellikler arası korelasyonun, özellik sayılarının, madde sayılarının, s ve g parametre düzeylerinin), sınıflama tutarlılığı için elde edilen DSO ortalamalarına ortak etkileri nasıldır?**


a) DINA analiz modeli kullanılarak çeşitli özellikler arası korelasyon düzeylerinde, sınıflama tutarlılığı için DSO ortalama değerleri elde edilmiştir. Çeşitli faktörlerin (örneklem büyüklüklerinin, özellik sayılarının, madde sayılarının ve s ve g parametre düzeylerinin) ortak etkileşimlerine ilişkin saçılım Grafik 28, 29 ve 30'da sunulmuştur.

Grafik 28, 29 ve 30'da yer alan DSO ortalama dağılımları incelendiğinde, anlamlı bir yapılanmanın olduğu gözle çarpılmaktadır. Madde sayısı arttıkça, s ve g parametre düzeyleri ve özellik sayısı azaldıkça DSO değerlerinde artma görülmektedir. Başka bir ifadeyle, madde sayısının, s ve g düzeylerinin ve özellik sayısının, sınıflama tutarlılığı


açısından önemli olduğu söylenebilir. Ayrıca tüm grafikler ayrı ayrı incelendiğinde, örneklem büyüklüğünün ve özellikler arası korelasyon düzeylerinin sınıflama tutarlılığı açısından önemsiz olduğu göze çarpmaktadır.



**Grafik 28:** DINA Analiz Modelinde ve Özellikler Arası Korelasyonun Düşük Düzeyinde Elde Edilen DSO Ortalama Değerleri




**Grafik 29:** DINA Analiz Modelinde ve Özellikler Arası Korelasyonun Orta Düzeyinde, Elde Edilen DSO Ortalama Değerleri




**Grafik 30:** DINA Analiz Modelinde ve Özellikler Arası Korelasyonun Yüksek Düzeyinde, Elde Edilen DSO Ortalama Değerleri

b) DINO analiz modeli kullanılarak çeşitli özellikler arası korelasyon düzeylerinde, sınıflama tutarlılığı için DSO ortalama değerleri elde edilmiştir. Çeşitli faktörlerin (örneklem büyüklüklerinin, özellik sayılarının, madde sayılarının ve s ve g parametre düzeylerinin) ortak etkileşimlerine ilişkin saçılım Grafik 31, 32 ve 33’te sunulmuştur.


Grafik 31, 32 ve 33’te yer alan DSO ortalama dağılımları incelendiğinde, farklı yapılanmaların oluştuğu göze çarpmaktadır. Grafikler ayrı ayrı incelendiğinde, düşük özellik sayısında, madde sayısı arttıkça, s ve g parametre düzeyleri azaldıkça DSO değerlerinde artma görülmektedir. Daha yüksek özellik sayısında, madde sayısı ve s ve g parametre düzeyleri ne olursa olsun yaklaşık aynı sonuçların elde edildiği görülmektedir. Ancak genel olarak düşük özellik sayısında doğru sınıflama oranlarının daha yüksek olduğu görülmektedir. Ayrıca, özellikler arasındaki korelasyon düzeyinin DINO analiz modelinde etkili olduğu görülmektedir. Özellikle özellikler arasındaki korelasyon düzeyi yüksek olduğunda elde edilen DSO ortalamalarının daha yüksek olduğu görülmektedir.



**Grafik 31:** DINO Analiz Modelinde ve Özellikler Arası Korelasyonun Düşük Düzeyinde, Elde Edilen DSO Ortalama Değerleri



**Grafik 32:** DINO Analiz Modelinde ve Özellikler Arası Korelasyonun Orta Düzeyinde, Elde Edilen DSO Ortalama Değerleri




**Grafik 33:** DINO Analiz Modelinde ve Özellikler Arası Korelasyonun Yüksek Düzeyinde, Elde Edilen DSO Ortalama Değerleri

c) Hem DINA hem de DINO analiz modelleri kullanılarak DSO ortalama deęerleri elde edilmiřtir. eřitli faktörlerin (örneklem büyüklüklerinin, madde sayılarının, özellik sayılarının, özellikler arasındaki çeřitli korelasyon düzeylerinin ve s ve g parametre düzeylerinin) ortak etkileřimlerine iliřkin saçılım Grafik 34'te sunulmuřtur.

Grafik 34 incelendięinde, tüm faktörlerin her kořul düzeylerinde DINA analiz modelinden elde edilen ortalama RMSEA deęerlerinin, DINO analiz modelinden elde edilen ortalama RMSEA deęerlerinden düşük bulunduęu görölmektedir. Ayrıca, s ve g'nin düşük, özellik sayısının 3, özellikler arası korelasyonun 0.90, madde sayısının 45 ve örneklem büyüklüęünün 5000 olduęu durumlarda, DINA ve DINO analiz modellerinden elde edilen sonuçların örtüřtüęü görölmektedir.



### DINA ve DINO Analiz Modeli Ortalama DSO Değerleri



**Grafik 34:** DINA ve DINO Analiz Modelleri Kullanıldığında, Elde Edilen Ortalama DSO Değerleri

## **BÖLÜM IV: TARTIŞMA ve YORUM**

Bu bölümde elde edilen bulgular araştırma soruları çerçevesinde ele alınıp ilgili araştırmalarla tartışılıp yorumlanmıştır.

### **IV.1. g ve s Parametre Kestirimi İçin Elde Edilen MOY Sonuçlarının Değerlendirilmesi**

#### *a) Temel Etkiler Açısından*

Örneklem büyüklüğü arttıkça, DINA analiz modeli kullanılarak g ve s parametre kestirimi için elde edilen MOY ortalama değerlerin azaldığı görülmektedir. Başka bir ifadeyle, DINA analiz modelinde örneklem büyüklüğü arttıkça g ve s parametrelerin daha yansız kestirildiği söylenebilir. İlgili literatürde yapılan çalışmalar incelendiğinde, örneklem büyüklüğünün parametre kestiriminde önemli bir faktör olduğu ve elde edilen sonuçların, bu çalışmanın sonuçlarıyla örtüştüğü görülmektedir (de la Torre, Hong ve Deng, 2010; Choi ve diğerleri, 2010; Habenicht, Rupp ve Wilhelm, 2012). Bu çalışma kapsamında, diğer çalışmalardan farklı olarak daha düşük (200, 500) örneklem büyüklükleri de değişimlenmiştir. Bu örneklem büyüklükleri kullanıldığında, g ve s parametre kestirimi için elde edilen MOY değerlerinin arttığı, dolayısıyla daha yanlış kestirimlerin yapıldığı görülmektedir. DINO analiz modeli kullanılarak g ve s parametre kestirimi için elde edilen MOY değerlerinde, örneklem büyüklüğünün pek bir etkisinin olmadığı görülmektedir.

Özellikler arasındaki korelasyon düzeyleri değişimlendiğinde, DINA analiz modeli kullanılarak g ve s parametreleri kestiriminden elde edilen MOY değerlerinin çok az değiştiği görülmektedir. Bu bulgular, Kim'in (2011) yapmış olduğu çalışmanın bulgularıyla paralellik göstermektedir. DINO analiz modeli kullanıldığında ise, özellikler

arasındaki korelasyon değeri maksimum olduğunda,  $g$  ve  $s$  parametrelerinin en yansız kestirildiği görülmektedir. Bu duruma yol açan en önemli faktör, DINO modelin özelliklerin birbirini tamamlaması üzerine kurulu olmasıdır.

Özelik ve madde sayıları açısından bakıldığında ise, DINA analiz modelinde  $g$  ve  $s$  parametre kestiriminden elde edilen MOY değerlerinin çok az değiştiği görülmektedir. Ancak DINO analiz modelinde  $g$  parametre kestiriminde, özellik sayısı düşük, madde sayısı yüksek olduğunda;  $s$  parametre kestiriminde ise, özellik sayısı yüksek, madde sayısı düşük olduğunda daha yansız kestirimlerin yapıldığı görülmektedir.

DINA analiz modeli  $g$  ve  $s$  parametre kestirimlerinde,  $s$  ve  $g$  parametre düzeyleri düşük olduğunda daha yansız kestirimlerin yapıldığı görülmektedir. Bu sonuç, de la Torre, Hong ve Deng'in (2010), yaptıkları çalışmadan elde ettikleri bulgularla paralellik göstermektedir. DINO analiz modelinde ise,  $s$  ve  $g$  parametre düzeyleri yüksek olduğunda daha yansız kestirimlerin yapıldığı görülmektedir.

#### *b) Ortak Etkiler Açısından*

DINA analiz modeli kullanılarak  $g$  parametresi kestiriminde faktörlerin ortak etkileri incelendiğinde, örneklem büyüklüğü ve madde sayısı arttıkça,  $s$  ve  $g$  parametre düzeyleri azaldıkça,  $g$  parametrelerin daha yansız kestirildiği söylenebilir. Ayrıca, özellikler arasındaki korelasyon düzeylerinin ve özellik sayılarının, ortak etkiler açısından  $g$  parametre kestiriminde önemli bir etkisinin olmadığı yorumu yapılabilir.

DINA analiz modeli kullanılarak  $s$  parametresi kestiriminde ise, örneklem büyüklüğü arttıkça,  $s$  ve  $g$  parametre düzeyleri azaldıkça daha yansız kestirildiği söylenebilir. Ayrıca, madde sayılarının ve özellik sayılarının  $s$  parametre kestiriminde

önemsiz olduğu söylenebilir. Bütün madde ve özellik sayıları koşullarında yaklaşık aynı sonuçların elde edildiği görülmektedir.

DINO analiz modeli kullanılarak  $g$  ve  $s$  parametreleri kestiriminde faktörlerin ortak etkileri incelendiğinde farklı yapılanmaların olduğu göze çarpmaktadır. Ancak, en dikkat çekici durum, DINA analiz modelinden elde edilen sonuçların tam tersine, yüksek  $s$  ve  $g$  düzeyinde daha yansız kestirimlerin elde edilmesidir.

## **IV.2. Madde Uyumu İçin Elde Edilen RMSEA Sonuçlarının Değerlendirilmesi**

### *a) Temel Etkiler Açısından*

Hem DINA hem de DINO analiz modelleri kullanıldığında, örneklem büyüklüğü arttıkça ortalama RMSEA değerlerinin azaldığı görülmektedir. Başka bir ifadeyle, örneklem büyüklüğü arttıkça maddelerin daha fazla uyum gösterdiği görülmektedir.

Özellikler arasındaki çeşitli korelasyon düzeyleri açısından ortalama RMSEA değerleri incelendiğinde, DINA analiz modelinde bu faktörün önemsiz olduğu ancak, DINO analiz modeli için, özellikler arasındaki korelasyon değeri arttıkça maddelerin daha fazla uyum gösterdiği söylenebilir. DINO modelde özelliklerin birbirini tamamlaması söz konusu olduğundan, bu durumun gözlemlendiği söylenebilir.

Özellik sayıları açısından bakıldığında, DINA analiz modelinde parametre kestiriminden elde edilen ortalama RMSEA değerlerinde çok çok az bir değişikliğin meydana geldiği, ancak DINO analiz modelinde, bu durumun yüksek özellik sayısı lehine olduğu görülmektedir. DINO analiz modelinde özellik sayısı yüksek olduğunda maddelerin daha uyumlu olduğu görülmektedir.

Madde sayıları açısından bakıldığında, hem DINA hem de DINO analiz modelleri için, madde sayısı azaldıkça madde uyumunun daha fazla olduğu görülmektedir.

s ve g parametre düzeyleri açısından bakıldığında ise, DINA analiz modelinde, s ve g parametre düzeyleri azaldıkça, DINO analiz modelinde, s ve g parametre düzeyleri arttıkça madde uyumunun daha fazla olduğu görülmektedir.

*b) Ortak Etkiler Açısından*

DINA analiz modeli kullanılarak faktörlerin ortak etkileri incelendiğinde, örneklem büyüklüğü arttıkça, madde sayısı, özellik sayısı, s ve g parametre düzeyleri azaldıkça madde uyumunun daha fazla olduğu göze çarpmaktadır. Ayrıca, özellikler arasındaki korelasyon düzeylerinin madde uyumu açısından önemli bir etkisinin olmadığı yorumu yapılabilir.

DINO analiz modeli kullanılarak faktörlerin ortak etkileri incelendiğinde ise, farklı farklı yapılanmaların olduğu göze çarpmaktadır. Ancak, en dikkat çekici durum, DINA analiz modelinden elde edilen sonuçların tam tersine, yüksek s ve g düzeyinde madde uyumunun daha yüksek olmasıdır. Sonuç olarak, madde uyumu için, s ve g parametre düzeylerinin etkili bir faktör olduğu yorumu yapılabilir.

**IV.3. Sınıflama Tutarlılığı İçin Elde Edilen DSO Sonuçlarının Değerlendirilmesi**

*a) Temel Etkiler Açısından*

Çeşitli örneklem büyüklükleri açısından bakıldığında, hem DINA hem de DINO analiz modellerinde örneklem büyüklüğünün doğru sınıflama oranlarına pek bir etkisinin olmadığı görülmektedir. Bu bulgular, Habenicht, Rupp ve Wilhelm'in (2012) yapmış olduğu çalışmadan elde ettikleri bulgularla paralellik göstermektedir.

Özellikler arasındaki çeşitli korelasyon düzeyleri açısından bakıldığında, DINA analiz modelinde bu faktörün etkisinin yok denecek kadar az olduğunu söylemek

mümkündür. Bu bulgular, Kim'in (2011) ve Henson ve diğerlerinin (2008) yapmış oldukları çalışmaların bulgularıyla paralellik göstermektedir. Ancak DINO analiz modeli için, özellikler arasındaki korelasyon değeri maksimum olduğunda daha doğru sınıflamanın yapıldığı söylenebilir. DINO modelde özelliklerin birbirini tamamlaması söz konusu olduğundan, bu durumun gözlemlendiği söylenebilir.

Özellik sayıları açısından bakıldığında, hem DINA hem de DINO analiz modellerinde, özellik sayısı arttıkça DSO ortalama değerlerinin azaldığı görülmektedir. Habenicht, Rupp ve Wilhelm'in (2012), yapmış oldukları çalışmada özellik sayısı arttıkça DSO'nun azaldığı görülmektedir. Ayrıca, Henson ve Douglas'ın (2005) yapmış oldukları çalışmada da hem DINA hem de RUM modellerinde DSO değerlerinin, düşük özellik sayısında daha yüksek bulunduğu görülmektedir. Başka bir ifadeyle, özellik sayısı arttıkça daha az doğru sınıflamanın yapıldığı söylenebilir.

DINA ve DINO analiz modellerinde, madde sayısı arttıkça DSO ortalama değerlerinin arttığı görülmektedir. Başka bir ifadeyle, madde sayısı arttıkça daha fazla doğru sınıflamanın yapıldığı söylenebilir.

s ve g parametre düzeyleri açısından bakıldığında, s ve g parametre düzeyleri arttıkça DSO ortalama değerlerinin azaldığı görülmektedir. Başka bir ifadeyle, s ve g parametre düzeyleri arttıkça yapılan doğru sınıflamanın azaldığı söylenebilir.

#### *b) Ortak Etkiler Açısından*

DINA analiz modeli kullanılarak faktörlerin ortak etkileri incelendiğinde, madde sayısı arttıkça, s ve g parametre düzeyleri ve özellik sayısı azaldıkça sınıfla tutarlığının

arttığı görülmektedir. Ayrıca, örneklem büyüklüğünün ve özellikler arası korelasyon düzeylerinin sınıflama tutarlılığı açısından önemsiz olduğu göze çarpmaktadır.

DINO analiz modeli kullanılarak faktörlerin ortak etkileri incelendiğinde ise, özellik sayısı ve s ve g parametre düzeyleri azaldıkça, madde sayısı ve özellikler arası korelasyon düzeyi arttıkça DSO değerlerinde artma görülmektedir.

Genel sonuç olarak, hem g ve s parametre kestirimleri hem madde uyumu hem de sınıflama tutarlılığı hesaplamalarında, tüm faktörlerin her koşul düzeylerinde, DINA analiz modelinden elde edilen sonuçların, DINO analiz modelinden elde edilen sonuçlara göre daha düşük bulunmuştur. Bu durumunun kaynaklanmasının doğal nedeni olarak verinin DINA modele göre üretilmiş olması gösterilebilir.

## ÖNERİLER

1. Bu çalışmada, veri tamamlayıcı olmayan modele (DINA) göre üretilmiştir. Aynı çalışma, veri üretimi aşamasında tamamlayıcı olmayan diğer modeller ya da tamamlayıcı modeller kullanılarak yapılabilir.

2. Bu çalışmada, DINA ve DINO analiz modelleri kullanılmıştır. Aynı çalışma, analiz aşamasında başka BTM kullanılarak yapılabilir.

3. Bu çalışmada, parametre kestiriminde E-M algoritması kullanılmıştır. Aynı çalışma, parametre kestirimi aşamasında başka yaklaşımlar kullanılarak yapılabilir.

4. Bu çalışmada, sınıflama tutarlılığı hesaplamasında “Ençok Olabilirlik Kestirimi” yöntemi kullanılmıştır. Aynı çalışma, sınıflama tutarlılığı hesaplamasında başka yöntemler kullanılarak yapılabilir.

5. Benzer çalışma gerçek verilerle çalışılarak yapılabilir.

## KAYNAKÇA

- Ackerman, T. (1996). Graphical representation of multidimensional item response theory analyses. *Applied Psychological Measurement*, 20, 311-329.
- Baykul, Y. (2000). *Eğitimde ve psikolojide ölçme: Klasik test teorisi ve uygulaması*. Ankara: ÖSYM Yayınları.
- Crocker, L. ve Algina, J. (1986). *Introduction to classical and modern test theory*. USA: Rinehart and Winston Inc.
- Cui, Y., Gierl, M. J., ve Chang, W. W. (2012). Estimating classification consistency and accuracy for cognitive diagnostic assessment. *Journal of Educational Measurement*, 49, 19-38.
- de la Torre, J. (2008a). An empirically-based method of Q-matrix validation for the DINA model: Development and applications. *Journal of Educational Measurement*, 45, 343–362.
- de la Torre, J. (2009b). A cognitive diagnosis model for cognitively-based multiple-choice options. *Applied Psychological Measurement*, 33, 163–183.
- de la Torre, J., ve Douglas, J. A. (2004). Higher-order latent trait models for cognitive diagnosis. *Psychometrika*, 69, 333–353.
- de la Torre, J., ve Douglas, J. A. (2008). Model evaluation and multiple strategies in cognitive diagnosis: An analysis of fraction subtraction data. *Psychometrika*, 73(4), 595.



- de la Torre, J., ve Karelitz, T. M. (2009). Impact of diagnosticity on the adequacy of models for cognitive diagnosis under a linear attribute structure: A simulation study. *Journal of Educational Measurement*, 46(4), 45.
- de la Torre, J., ve Young-Sun, L. (2010). A note on the invariance of the DINA model parameters. *Journal of Educational Measurement*, 47(1), 115.
- de la Torre, J., Hong, Y. ve Deng, W. (2010). Factors affecting the item parameter estimation and classification accuracy of the DINA model. *Applied Psychological Measurement*, 47, 227-249.
- DiBello, L. V., Stout, W. F., & Roussos, L. A. (1995). *Unified cognitive/psychometric diagnostic assessment likelihood-based classification techniques*. In P.D. Nichols, S.
- Embretson, S. E. ve Reise, S. (2000). *Item response theory for psychologists*. New Jersey: Lawrence Erlbaum Associates.
- Gelbal, S. (1994). *p madde güçlük indeksi ile rasch modelinin b parametresi ve bunlara dayalı yetenek ölçüleri üzerine bir karşılaştırma*. Yayınlanmamış doktora tezi, Hacettepe Üniversitesi, Ankara.
- Gierl, M. J., Cui, Y., ve Zhou, J. (2009). Reliability of attribute-based scoring in cognitive diagnostic assessment. *Journal of Educational Measurement*, 46, 293-313.
- Gulliksen, H. (1950). *Theory of mental tests*. New York: Wiley.
- Hambleton, R. K. ve Swaminathan, H. (1985). *Item response theory: principles and applications*. Boston: Academic Publishers Group.

- Hambleton, R. K. ve Jones, R. W. (1993). Comparison of classical test theory and item response theory and their applications to test development. *Educational Measurement*, 12, 38-47.
- Haertel, E.H. (1984). An application of latent class models to assessment data. *Applied Psychological Measurement* 8, 333–346.
- Haertel, E. H. (1989). Using restricted latent class models to map the skill structure of achievement items. *Journal of Educational Measurement*, 26, 333-352.
- Haertel, E.H. (1990). Continuous and discrete latent structure models of item response data. *Psychometrika* 55, 477–494.
- Hartz, S. M. (2002). *A Bayesian framework for the unified model for assessing cognitive abilities: Blending theory with practicality*, Yayınlanmamış doktora tezi. University of Illinois at Urbana, Champaign.
- Henson, R. Ve Douglas, J. (2005) Test construction for cognitive diagnosis, *Applied Psychological Measurement*, 29(4): 262-277.
- Henson, R. A., Roussos, L., Douglas, J., ve He, X. (2008). Cognitive diagnostic attribute level discrimination indices. *Applied Psychological Measurement*, 32, 275-288.
- Henson, R. A., Templin, J. L., ve Willse, J. T. (2009). Defining a family of cognitive diagnosis models using log-linear models with latent variables. *Psychometrika*, 74, 191-210.
- Huebner, A. ve Wang, C. (2011). A note on comparing examinee classification methods for cognitive diagnosis models. *Educational and Psychological Measurement*, 71(2), 407-419.

- Huff, K., ve Goodman, D. P. (2007). The demand for cognitive diagnostic assessment. J. P. Leighton ve M. J. Gierl (Eds.), *Cognitive assessment for education: Theory and applications (19-60)*. New York: Cambridge University Press.
- Huyn, S. K. (2011). *Diagnosing examinees' attributes-mastery using the bayesian inference for binomial proportion: a new method for cognitive diagnostic assessment*. Yayınlanmamış doktora tezi, Georgia Institute of Technology.
- Junker, B. (1999). *Some statistical models and computational methods that may be useful for cognitively relevant assessment*. Prepared for the Committee on the Foundations of Assessment, National Research Council, November 30,1999.
- Junker, B. W. ve Sijtsma, K. (2001). Cognitive assessment models with few assumptions, and connections with nonparametric item response theory. *Applied Psychological Measurement*, 25(3), 258-272.
- Kato, K. (2009). *Improving efficiency of cognitive diagnosis by using diagnostic items and adaptive testing*, Yayınlanmamış doktora tezi, The University Of Minnesota.
- Kunina-Habenicht, O., Rupp, A. A., ve Wilhelm, O. (2012). The impact of model misspecification on parameter estimation and item-fit assessment in log-linear diagnostic classification models. *Journal of Educational Measurement*, 49, 59-81.
- Lazarsfeld P. F. ve Henry N. W. (1968). *Latent Structure Analysis*. Boston: Houghton Mifflin.
- Leighton, J. P., Gierl, M. J. ve Hunka, S. M. (2004). The attribute hierarchy method for cognitive assessment: A variation on Tatsuoka's rule-space approach. *Journal of Educational Measurement*, 41, 205-237.

- Liu, Y., Douglas, J. A., ve Henson, R. A. (2009). Testing person fit in cognitive diagnosis. *Applied Psychological Measurement*, 33(8), 579.
- Lord, F. M. ve Novick M. R. (1968). *Statistical theories of mental test scores*. New York: Addison- Wesley Publishing Company.
- Lord, F. M. (1980). *Applications of item response theory to practical testing problems*. Hillsdale, New Jersey: Lawrence Erlbaum Associates.
- Macready, G. B., ve Dayton, C. M. (1977). The use of probabilistic models in the assessment of mastery. *Journal of Educational Statistics*, 2, 99-120.
- McCutcheon, A. C. (1987). *Latent class analysis*. Beverly Hills: Sage Publications.
- Reckase, M. D. (2009). *Multidimensional item response theory*. New York: Springer Dordrecht Heidelberg.
- Rupp, A. ve Templin, J. (2008a). The effects of Q-matrix misspecification on parameter estimates and classification accuracy in the DINA model. *Education and Psychological Measurement*, 68, 78-96.
- Rupp, A. ve Templin, J. (2008b). Unique characteristics of diagnostic models: a review of the current state-of-the-art. *Measurement*, 6, 219-262.
- Rupp, A. A., Templin, J., ve Henson, R. J. (2010). *Diagnostic measurement: Theory, methods, and applications*. New York: Guilford Press.

- Sünbül, Ö. (2011). *Çeşitli boyutluluk özelliklerine sahip yapılarda, madde parametrelerinin değişmezliğinin klasik test teorisi, tek boyutlu madde tepki kuramı ve çok boyutlu madde tepki kuramı çerçevesinde incelenmesi*. Yayınlanmamış doktora tezi, Hacettepe Üniversitesi, Ankara.
- Tatsuoka, K. (1985). A probabilistic model for diagnosing misconceptions in the pattern classification approach. *Journal of Educational Statistics*, 12, 55–73.
- Templin, J., ve Henson, R. (2006). Measurement of psychological disorders using cognitive diagnosis models. *Psychological Methods*, 11 (3), 287-305.
- Vermunt, J. K. ve Madigson, J. (2004). Local Independence. In A. B. M.S. Lewis Beck, The Sage Encyclopedia of Social Sciences Research Methods (ss. 732-733). Thousand Oaks: Sage Publications.
- Wang, Y. C. (2009). *Factor Analytic Models and Cognitive Diagnostic Models: How Comparable Are They?-A Comparison of R-RUM and Compensatory MIRT Model with Respect to Cognitive Feedback*. Yayınlanmamış doktora tezi, The University of North Carolina, Greensboro.
- von Davier, M. (2005). *A general diagnostic model applied to language testing data*. ETS Araştırma Raporu: RR-05-16, Educational Testing Service, Princeton, NJ.

## **EKLER**

**EK 1: Özellik Sayısı 3, Madde Sayısı 15, 30, 45 Olduğu Durumlarda Kullanılan Q**

**Matrisleri**

Aşağıda belirtilen Q matrisi, 3 özellik için madde sayısı 45 olduğunda kullanılmıştır.

Madde sayısı 15 olduğunda, Q matrisinde yer alan ilk 15 madde ve madde sayısı 30 olduğunda Q matrisindeki ilk 30 madde kullanılmıştır.

<b>Madde No</b>	$a_1$	$a_2$	$a_3$	<b>Madde No</b>	$a_1$	$a_2$	$a_3$	<b>Madde No</b>	$a_1$	$a_2$	$a_3$
<b>1</b>	1	0	0	<b>16</b>	1	0	0	<b>31</b>	1	0	0
<b>2</b>	0	1	0	<b>17</b>	0	1	0	<b>32</b>	0	1	0
<b>3</b>	0	0	1	<b>18</b>	0	0	1	<b>33</b>	0	0	1
<b>4</b>	1	1	0	<b>19</b>	1	1	0	<b>34</b>	1	1	0
<b>5</b>	1	0	1	<b>20</b>	1	0	1	<b>35</b>	1	0	1
<b>6</b>	0	1	1	<b>21</b>	0	1	1	<b>36</b>	0	1	1
<b>7</b>	1	1	1	<b>22</b>	1	1	1	<b>37</b>	1	1	1
<b>8</b>	1	0	0	<b>23</b>	1	0	0	<b>38</b>	1	0	0
<b>9</b>	0	1	0	<b>24</b>	0	1	0	<b>39</b>	0	1	0
<b>10</b>	0	0	1	<b>25</b>	0	0	1	<b>40</b>	0	0	1
<b>11</b>	1	1	0	<b>26</b>	1	1	0	<b>41</b>	1	1	0
<b>12</b>	1	0	1	<b>27</b>	1	0	1	<b>42</b>	1	0	1
<b>13</b>	0	1	1	<b>28</b>	0	1	1	<b>43</b>	0	1	1
<b>14</b>	1	1	1	<b>29</b>	1	1	1	<b>44</b>	1	1	1
<b>15</b>	1	0	0	<b>30</b>	1	0	0	<b>45</b>	1	0	0

**EK 2: Özellik Sayısı 4, Madde Sayısı 15, 30, 45 Olduğu Durumlarda Kullanılan Q**

**Matrisleri**

Aşağıda belirtilen Q matrisi, 4 özellik için madde sayısı 45 olduğunda kullanılmıştır.

Madde sayısı 15 olduğunda, Q matrisinde yer alan ilk 15 madde ve madde sayısı 30 olduğunda Q matrisindeki ilk 30 madde kullanılmıştır.

<b>Madde No</b>	$a_1$	$a_2$	$a_3$	$a_4$	<b>Madde No</b>	$a_1$	$a_2$	$a_3$	$a_4$	<b>Madde No</b>	$a_1$	$a_2$	$a_3$	$a_4$
<b>1</b>	1	0	0	0	<b>16</b>	1	0	0	0	<b>31</b>	1	0	0	0
<b>2</b>	0	1	0	0	<b>17</b>	0	1	0	0	<b>32</b>	0	1	0	0
<b>3</b>	0	0	1	0	<b>18</b>	0	0	1	0	<b>33</b>	0	0	1	0
<b>4</b>	0	0	0	1	<b>19</b>	0	0	0	1	<b>34</b>	0	0	0	1
<b>5</b>	1	1	0	0	<b>20</b>	1	1	0	0	<b>35</b>	1	1	0	0
<b>6</b>	1	0	1	0	<b>21</b>	1	0	1	0	<b>36</b>	1	0	1	0
<b>7</b>	1	0	0	1	<b>22</b>	1	0	0	1	<b>37</b>	1	0	0	1
<b>8</b>	0	1	1	0	<b>23</b>	0	1	1	0	<b>38</b>	0	1	1	0
<b>9</b>	0	1	0	1	<b>24</b>	0	1	0	1	<b>39</b>	0	1	0	1
<b>10</b>	0	0	1	1	<b>25</b>	0	0	1	1	<b>40</b>	0	0	1	1
<b>11</b>	1	1	1	0	<b>26</b>	1	1	1	0	<b>41</b>	1	1	1	0
<b>12</b>	1	1	0	1	<b>27</b>	1	1	0	1	<b>42</b>	1	1	0	1
<b>13</b>	1	0	1	1	<b>28</b>	1	0	1	1	<b>43</b>	1	0	1	1
<b>14</b>	0	1	1	1	<b>29</b>	0	1	1	1	<b>44</b>	0	1	1	1
<b>15</b>	1	1	1	1	<b>30</b>	1	1	1	1	<b>45</b>	1	1	1	1