



**BİLİŞSEL TANI MODELLERİNDE Q-MATRİSİN FARKLI
YAKLAŞIMLARLA BELİRLENMESİNİN FARKLI YETENEK
DÜZEY VE DAĞILIM KOŞULLARI ALTINDA İNCELENMESİ**

Tuba Gündüz

DOKTORA TEZİ

EĞİTİM BİLİMLERİ ANABİLİM DALI

EĞİTİMDE ÖLÇME VE DEĞERLENDİRME BİLİM DALI

GAZİ ÜNİVERSİTESİ

EĞİTİM BİLİMLERİ ENSTİTÜSÜ

Temmuz, 2021

TELİF HAKKI VE TEZ FOTOKOPİ İZİN FORMU

Bu tezin tüm hakları saklıdır. Kaynak göstermek koşuluyla tezin teslim tarihinden itibaren 24 (yirmi dört) ay sonra tezden fotokopi çekilebilir.

YAZARIN

Adı : Tuba
Soyadı : Gündüz
Bölümü : Eğitimde Ölçme ve Değerlendirme
İmza :
Teslim Tarihi :

TEZİN

Türkçe Adı : Bilişsel Tanı Modellerinde Q-Matrisin Farklı Yaklaşımlarla Belirlenmesinin Farklı Yetenek Düzey ve Dağılım Koşulları Altında İncelenmesi

İngilizce Adı : Examination of Different Determination of Q-Matrix in Cognitive Diagnosis Models under Different Ability Levels and Distribution Conditions

ETİK İLKELERE UYGUNLUK BEYANI

Tez yazma sürecinde bilimsel ve etik ilkelere uyduğumu, yararlandığım tüm kaynakları kaynak gösterme ilkelerine uygun olarak kaynakçada belirttiğimi ve bu bölümler dışındaki tüm ifadelerin şahsıma ait olduğunu beyan ederim.

Yazar Adı Soyadı : Tuba Gündüz

İmza :

JÜRİ ONAY SAYFASI

Tuba GÜNDÜZ tarafından hazırlanan “Bilişsel Tanı Modellerinde Q-Matrisin Farklı Yaklaşımlarla Belirlenmesinin Farklı Yetenek Düzey ve Dağılım Koşulları Altında İncelenmesi” adlı tez çalışması aşağıdaki jüri tarafından oy birliği ile Gazi Üniversitesi Eğitim Bilimleri Anabilim Dalı’nda Doktora tezi olarak kabul edilmiştir.

Danışman: Prof. Dr. Mehtap ÇAKAN

Eğitimde Ölçme ve Değerlendirme, Gazi Üniversitesi

Başkan: Doç. Dr. Burcu ATAR

Eğitimde Ölçme ve Değerlendirme, Hacettepe Üniversitesi

Üye: Prof. Dr. Şeref TAN

Eğitimde Ölçme ve Değerlendirme, Gazi Üniversitesi

Üye: Prof. Dr. Nuri DOĞAN

Eğitimde Ölçme ve Değerlendirme, Hacettepe Üniversitesi

Üye: Doç. Dr. Dilara BAKAN KALAYCIOĞLU

Eğitimde Ölçme ve Değerlendirme, Gazi Üniversitesi

Tez Savunma Tarihi: 21/06/2021

Bu tezin Eğitim Bilimleri Anabilim Dalı’nda Doktora tezi olması için şartları yerine getirdiğini onaylıyorum.

Prof. Dr. Yücel GELİŞLİ

Eğitim Bilimleri Enstitüsü Müdürü



Oğlum Ali'ye...

TEŞEKKÜR

Lisansüstü eğitimim boyunca ihtiyaç duyduğum her an yardımını ve desteğini benden esirmeyen, kıymetli tecrübeleriyle beni hep en doğru olana yönlendiren ve varlığına daima ihtiyaç duyacağım çok değerli danışman hocam Sayın Prof. Dr. Mehtap ÇAKAN'a teşekkürlerimi sunarım. Tüm eğitim hayatım boyunca aldığım dersler arasında katılmaktan en çok keyif aldığım dersleri veren kıymetli hocam Sayın Prof. Dr. Şeref TAN'a içtenlikle teşekkür ederim. Jürimde bulunan engin bilgisi ve son derece mütevazı yaklaşımıyla çalışmama ışık tutan hocam Sayın Prof. Dr. Nuri DOĞAN'a; pozitif enerjisiyle çalışmama önemli katkılar sağlayan hocam Sayın Doç. Dr. Dilara BAKAN KALAYCIOĞLU'na ve sıcak kanlı tavırlarıyla verdiği önerileriyle çalışmama değerli katkılar sunan hocam Sayın Doç. Dr. Burcu ATAR'a teşekkürü borç bilirim. Çalışmamda kullandığım verileri sağlayan kıymetli hocam Sayın Doç. Dr. Tahsin Oğuz BAŞOKÇU'ya ve yardımlarıyla çalışmama değer katan hocam Sayın Doç. Dr. Kübra ATALAY KABASAKAL'a teşekkürlerimi sunarım.

Süreçte daima yanımda olduğunu hissettiğim kardeşlerim Fazilet Gül İNCE ARACI ve Yıldız YILDIRIM GÖRGÜLÜ'ye, birlikte ilerlemekten mutluluk duyduğum yol arkadaşım Serpil ÇELİKTEN DEMİREL'e, can dostlarım Sebahat GÖREN ve Sibel AYDOĞAN'a, yeri doldurulamaz arkadaşlarım Ceren MUTLUER ve Elif SEZER'e, çok kıymetli arkadaşım Esra OYAR'a ve ismini yazamadığım diğer arkadaşlarıma teşekkür ederim.

Her konuda bana yardımcı olan ve sabrını benden hiçbir zaman esirgemeyen, hep yanımda olan biricik eşim Fahrettin GÜNDÜZ'e, tüm hayatım boyunca bana inanan, güvenen ve benim bugünlere gelmemi sağlayan canım annem Gülseren KARACAN'a ve babam Murat KARACAN'a; her yönüyle örnek aldığım desteğini daima hissettiren abim Mustafa KARACAN'a sonsuz teşekkürler...

**BİLİŞSEL TANI MODELLERİNDE Q-MATRİSİN FARKLI
YAKLAŞIMLARLA BELİRLENMESİNİN FARKLI YETENEK
DÜZEY VE DAĞILIM KOŞULLARI ALTINDA İNCELENMESİ**
(Doktora Tezi)

Tuba Gündüz
GAZİ ÜNİVERSİTESİ
EĞİTİM BİLİMLERİ ENSTİTÜSÜ
Temmuz, 2021

ÖZ

Bu araştırma ile G-DINA Modeli altında Q-matrisin farklı belirlenmesinin değişen koşullar altında karşılaştırılması amaçlanmaktadır. Bu amaç doğrultusunda ilk olarak uzman kanısına ve açımlayıcı faktör analitik yöntemle dayalı olarak belirlenmiş Q-matrisleri ve bu Q-matrislere geçerleme sürecinin uygulanmasıyla elde edilen Q-matrisleri ile evren veri seti üzerinde yapılan sınıflandırmalar karşılaştırılmıştır. Ardından, bu Q-matrisler için önerilen geçerleme süreçleri kullanılarak alt ve üst yetenek gruplarında nitelik seti farklı belirlenen Q-matrisleri ile yapılan sınıflamalar incelenmiştir. Son olarak normal ve normal dağılımdan farklılaşan dağılım sağlayan gruplar (Çarpıklık katsayısı 0,5, 0,75, 1, 1,25, 1,5 ve 2) üzerinde yapılan sınıflamalar karşılaştırılmıştır. Yapılan sınıflandırmalar model uyum indeksleri, madde parametre kestirimleri (tahmin ve kaydırma parametreleri) ve sınıflama doğrulukları açısından karşılaştırılmıştır. Bu araştırmanın evrenini “Uluslararası Geniş Ölçekli Sınavlarda Türkiye'nin Matematik Başarısını Arttırabilmek İçin Bir Model Önerisi: Bilişsel Tanıya Dayalı İzleme Modelinin Etkililiği” başlıklı ve 115K531 No'lu TÜBİTAK Projesinde son test uygulamasına katılan 4292 altıncı sınıf öğrencisi oluşturmaktadır. Bu öğrencilerden kasıtlı örnekleme yoluyla çekilen 500'er kişilik dokuz grup ise çalışmanın

örneklemini oluşturmaktadır. Bu örneklemeler araştırma kapsamında ele alınan dokuz koşula uygun olarak elde edilmiştir. Evren üzerinde yapılan sınıflamalar için uzman kanısına dayalı belirlenen Q-matrisi ele alındığında test düzeyinde en yüksek sınıflama doğruluğu ve en uygun parametre kestirimleri, geçerleme yönteminin önerdiği modifikasyonlardan Mesa plot incelemelerine ek olarak tekrar uzman görüşlerine başvurulmasıyla uygun görülenlerin kabul edilmesi sonucunda belirlenen Q-matrisi ile elde edilmiştir. Faktör analizi ile belirlenen Q-matrisi ele alındığında ise geçerleme yönteminin önerdiği modifikasyon sayısının oldukça az olduğu ve dolayısıyla geçerleme yönteminin yapılmasına gerek olmadığı görülmüştür. Alt ve üst yetenek gruplarında nitelik seti farklı belirlenen Q-matrislerinin farklı doğrulukta sınıflandırma yaptıkları görülmüş ve benzer şekilde model veri uyumu ile parametre kestirimlerinin de farklılaştığı gözlemlenmiştir. Genel olarak incelendiğinde, rutin olmayan problem çözme becerisi ile okuduğunu anlama becerileri Q-matrislerine nitelik olarak eklendiğinde alt grup ile üst grup üzerinde sınıflamaları farklı yönde etkilediği gözlemlenmiştir. Bununla birlikte çarpıklık katsayısı arttığında, genel anlamda, elde edilen bulgular sınıflama doğruluğu, model uyumu ve parametre kestirimleri açısından olumsuz etkilendiği ve özellikle çarpıklık katsayısı 1,25'in üzerinde olduğu durumlarda oldukça farklı düzeyde sınıflama sağladığı görülmüştür. Son olarak bu araştırmadan elde edilen bulgular ışığında bilişsel tanı modelleri uygulamalarında karşılaşılabilecek durumlar için uygun Q-matrisi belirlemeye yönelik öneriler sunulmuştur.

Anahtar Kelimeler : Bilişsel Tanı Modelleri, G-DINA, Q-Matrisi Belirleme
Sayfa Adedi : xvii + 131
Danışman : Prof. Dr. Mehtap ÇAKAN

**EXAMINATION OF DIFFERENT DETERMINATION OF Q-MATRIX
IN COGNITIVE DIAGNOSIS MODELS UNDER DIFFERENT
ABILITY LEVELS AND DISTRIBUTION CONDITIONS**

(Ph.D Thesis)

Tuba Gündüz

GAZI UNIVERSITY

GRADUATE SCHOOL OF EDUCATIONAL SCIENCES

July, 2021

ABSTRACT

With this research, it is aimed to compare the different determination of the Q-matrix under the G-DINA Model under varying conditions. For this purpose, firstly, Q-matrices determined based on expert opinion and exploratory factor analytical method were compared with the classifications made on the population data set by applying validation process to these Q-matrices. Then, by using validation processes proposed for these Q-matrices, classifications made with Q-matrices with different set of attributes in lower and higher ability groups were examined. Finally, the classifications made on the groups providing distribution that differ from normal and non-normal distribution (coefficient of skewness 0.5, 0.75, 1, 1.25, 1.5 and 2) were compared. The classifications made were compared with model fit indices, item parameter estimates (guess and slip parameters) and classification accuracies. The population of this research consists of 4292 sixth grade students participating in the post-test application in the TUBITAK Project No 115K531, titled "A Recommended Model to Increase Success Level of Turkey in Mathematics in International Wide Scale Exams: Effectiveness of the Cognitive Diagnosis Based Tracking Model". Nine groups of 500 student, who were drawn from population is the samples of the study. These samples were obtained in accordance with the nine conditions considered within the scope of the research. Considering the Q-matrix determined based on expert opinion in the classifications

made on the population, the highest classification accuracy and the most appropriate parameter estimation at the test level were obtained with the Q-matrix determined as a result of the acceptance of the modifications suggested by the validation method, in addition to the Mesa plot examinations, and the acceptance of the appropriate ones. When the Q-matrix determined by factor analysis was considered, it was seen that the number of modifications suggested by the validation method was quite low and therefore the validation method was not required. It has been observed that Q-matrices whose attribute sets are determined differently in lower and upper skill groups make classifications with different accuracy, and similarly, it has been observed that model data fit and parameter estimates also differ. In general, when non-routine problem solving skills and reading comprehension skills were added to Q-matrices as attributes, it was observed that the classifications on the lower and the upper group were affected differently. However, when the coefficient of skewness increases, it has been observed that the findings obtained are negatively affected in terms of classification accuracy, model fit and parameter estimation, especially when the coefficient of skewness is above 1.25, it provides an unacceptable classification. In the light of the findings obtained from this study, suggestions for determining the appropriate Q-matrix for situations that may be encountered in Cognitive Diagnosis Model applications are presented.

Key Words : Cognitive Diagnosis Model, G-DINA, Determination of Q-matrix

Page Number : xvii + 131

Supervisor : Prof. Dr. Mehtap ÇAKAN

İÇİNDEKİLER

TELİF HAKKI VE TEZ FOTOKOPİ İZİN FORMU	i
ETİK İLKELERE UYGUNLUK BEYANI.....	ii
JÜRİ ONAY SAYFASI.....	iii
TEŞEKKÜR.....	v
ÖZ	vi
ABSTRACT	viii
İÇİNDEKİLER.....	x
TABLolar LİSTESİ.....	xiii
ŞEKİLLER LİSTESİ.....	xvi
SİMGE VE KISALTMALAR LİSTESİ	xvii
BÖLÜM I	1
GİRİŞ.....	1
Problem Durumu	1
Araştırmanın Amacı	5
Araştırmanın Önemi.....	6
Problem İfadesi	7
Araştırma Soruları.....	7
Sınırlılıklar.....	8

BÖLÜM II.....	9
KURAMSAL ÇERÇEVE VE İLGİLİ ARAŞTIRMALAR.....	9
Bilişsel Tanı Modellerinin Kuramsal Temeli	9
Bilişsel Tanı Modelleri.....	9
Bilişsel Tanı Modellerinde Nitelik Kavramı ve Tanımlanması	16
Q-Matrisi	18
Q-Matrisi Belirleme ve Geçerleme Yöntemleri.....	20
İlgili Araştırmalar	26
BÖLÜM III	36
YÖNTEM.....	36
Araştırmanın Modeli	36
Evren ve Örneklem	36
Veri Toplama Aracı	38
Verilerin Analizi.....	42
Dağılım Koşullarının Oluşturulması.....	42
Q-Matrislerinin Oluşturulması.....	43
Değerlendirme Kriterleri	51
BÖLÜM IV	53
BULGULAR	53
Birinci Araştırma Sorusuna İlişkin Bulgular	53
İkinci Araştırma Sorusuna İlişkin Bulgular	66
Üçüncü Araştırma Sorusuna İlişkin Bulgular	78
BÖLÜM V	84
SONUÇ VE TARTIŞMA.....	84
Sonuçlar	84

Birinci Araştırma Sorusuna İlişkin Sonuç ve Tartışma	84
İkinci Araştırma Sorusuna İlişkin Sonuç ve Tartışma.....	88
Üçüncü Araştırma Sorusuna İlişkin Sonuç ve Tartışma.....	92
Öneriler	94
Uygulayıcılara Yönelik Öneriler	94
Araştırmacılara Yönelik Öneriler	95
KAYNAKLAR.....	97
EKLER.....	106
EK 1: İstenen özellikteki örneklemin çekilmesinde kullanılan fonksiyon	107
EK 2a: Proje kapsamında ele alınan katılımcılara ait betimsel istatistikler	110
EK 2b: Proje kapsamında hesaplanan madde istatistikleri.....	110
EK 3: Normalliğe ilişkin grafiksel incelemeler	111
EK 4: Dağılım koşullarını elde etmede kullanılan örnek kodlar.....	113
EK 5: PVAf için kesme puan hesaplama	119
EK 6: Uzman Görüşü Formu.....	120
EK 7: Modifikasyon önerisi verilen maddelere ait Mesa Plotlar	122
EK 8: Yapılan ilk AFA sonucu	126
EK 9: GDINA paketi kullanıcı ara yüzü	128
EK 10: Q-matrisi için G-DINA modele göre kestirilen öğrencilerin gizil sınıflarda yer alma oranları.....	131

TABLÖLAR LİSTESİ

Tablo 1. <i>Bilişsel Tanı Modellerinin Sınıflandırılması</i>	12
Tablo 2. <i>K = 4 ve J 30 için Q-Matrisi Örneği</i>	19
Tablo 3. <i>Çalışma Grubunun Özellikleri</i>	37
Tablo 4. <i>Evren ve Örneklem Gruplarının Cinsiyete Göre Dağılımı Özellikleri</i>	38
Tablo 5. <i>Testten Elde Edilen Ölçümlere Ait Betimsel İstatistikler</i>	40
Tablo 6. <i>Son Test Uygulamasına Ait Madde Ayırıcılık ve Madde Güçlük Değerleri</i>	41
Tablo 7. <i>Uzman Görüşlerine Dayalı, Uzman Görüşleri ve PVAF Geçerleme Modifikasyonlarına Dayalı ile Uzman Görüşleri PVAF Geçerleme ve tekrar uzman görüşlerine ilişkin Modifikasyonlarına Dayalı Q-Matrisleri</i>	45
Tablo 8. <i>AFA'ya ilişkin Açıklanan Varyans Değerleri (s6470_A, s9342, s6370, s1119 ve s6323_1 Analiz Dışı)</i>	48
Tablo 9. <i>AFA Sonucunda Elde Edilen Yük Değerleri (s6470_A, s9342, s6370, s1119 ve s6323_1 analiz dışı)</i>	49
Tablo 10. <i>Faktör Analizi Sonuçlarına Dayalı, Faktör Analizi ve PVAF Geçerleme Modifikasyonlarına Dayalı Q-Matrisleri</i>	50
Tablo 11. <i>Uzman Kanısına Dayalı Oluşturulan Q-Matrisleri ile Yapılan Sınıflama Analizlerine Ait Test ve Nitelik Düzeyinde Sınıflama Doğrulukları</i>	54
Tablo 12. <i>Uzman kanısına dayalı oluşturulan Q-matrisleri ile yapılan sınıflama analizlerine ait gizil sınıf düzeyinde sınıflama doğrulukları</i>	55
Tablo 13. <i>Uzman Kanısına Dayalı Oluşturulan Q-Matrisleri ile Yapılan Sınıflama Analizlerine ait İlişkin Mutlak Model Uyumu İndeksleri</i>	56

Tablo 14. <i>Uzman Kanısına Dayalı Oluşturulan Q-Matrisleri ile Yapılan Sınıflama Analizlerine ait İlişkin Bağıl Model Uyumu İndeksleri</i>	57
Tablo 15. <i>Uzman Kanısına Dayalı Oluşturulan Q-Matrisleri ile Yapılan Sınıflama Analizlerine ait İlişkin Parametre Kestirimleri</i>	58
Tablo 16. <i>Faktör Analizi Sonuçlarına Dayalı Oluşturulan Q-Matrisleri ile Yapılan Sınıflama Analizlerine ait Test ve Nitelik Düzeyinde Sınıflama Doğrulukları</i>	61
Tablo 17. <i>Faktör Analizi Sonuçlarına Dayalı Oluşturulan Q-Matrisleri ile Yapılan Sınıflama Analizlerine Gizil Sınıf Düzeyinde Sınıflama Doğrulukları</i>	62
Tablo 18. <i>Faktör Analizi Sonuçlarına Dayalı Oluşturulan Q-Matrisleri ile Yapılan Sınıflama Analizlerine İlişkin Mutlak Model Uyumu İndeksleri</i>	63
Tablo 19. <i>Faktör Analizi Sonuçlarına Dayalı Oluşturulan Q-Matrisleri ile Yapılan Sınıflama Analizlerine İlişkin Bağıl Model Uyumu İndeksleri</i>	63
Tablo 20. <i>Faktör Analizi Sonuçlarına Dayalı Oluşturulan Q-Matrisleri ile Yapılan Sınıflama Analizlerine İlişkin Parametre Kestirimleri</i>	65
Tablo 21. <i>Alt ve Üst Grup için Farklı Belirlenen Q-Matrisleri ile Yapılan Sınıflama Analizlerine İlişkin Test ve Nitelik Düzeyinde Sınıflama Doğrulukları</i>	67
Tablo 22. <i>Alt ve Üst Gruplarda Yapılan Sınıflama Analizlerine İlişkin Mutlak Model Uyumu İndeksleri</i>	69
Tablo 23. <i>Uzman Kanısına ve Faktör Analizi Sonuçlarına Dayalı Oluşturulan Q-Matrisleri ile Yapılan Sınıflama Analizlerine İlişkin Bağıl Model Uyumu İndeksleri</i>	70
Tablo 24. <i>Alt Yetenek Grubunda Q-Matrisleri ile Yapılan Sınıflama Analizlerine ait İlişkin Parametre Kestirimleri</i>	72
Tablo 25. <i>Üst Yetenek Grubunda Q-Matrisleri ile Yapılan Sınıflama Analizlerine ait İlişkin Parametre Kestirimleri</i>	75
Tablo 26. <i>Çarpıklık Katsayıları 0, 0,5, 0,75, 1, 1,25, 1,5 ve 2 Olan Gruplar Üzerinde Yapılan Sınıflama Analizlerine Ait Test ve Nitelik Düzeyinde Sınıflama Doğrulukları</i>	78
Tablo 27. <i>Çarpıklık Katsayıları 0, 0,5, 0,75, 1, 1,25, 1,5 ve 2 Olan Gruplarda Yapılan Sınıflama Analizlerine ait Mutlak Model Uyumu İndeksleri</i>	80

Tablo 28. <i>Çarpıklık Katsayıları 0, 0,5, 0,75, 1, 1,25, 1,5 ve 2 Olan Gruplarda Yapılan Sınıflama Analizlerine ait Bağıl Model Uyumu İndeksleri</i>	81
Tablo 29. <i>Çarpıklık Katsayıları 0, 0,5, 0,75, 1, 1,25, 1,5 ve 2 Olan Gruplar Üzerinde Yapılan Sınıflama Analizlerine Ait Ortalama Paramerte Kestirimleri</i>	82



ŞEKİLLER LİSTESİ

<i>Şekil 1.</i> Bilişsel tanı modellerinin uygulamasında adımlar	10
<i>Şekil 2.</i> Altı nitelik kullanılarak dört farklı hiyerarşik yapının gösterimi.	17
<i>Şekil 3.</i> Altı nitelik ve 30 madde için farklı nitelik yapılarına ait Q-matrisi gösterimleri ...	18
<i>Şekil 4.</i> PVAF yöntemi kullanılarak Q-matris geçerlemesi için kullanılan mesa plot grafiği örneği	23
<i>Şekil 5.</i> AFA için özdeğer grafiği	47
<i>Şekil 6.</i> Uzman kanısına dayalı oluşturulan Q-matrisleri ile yapılan sınıflama analizlerine ait tahmin parametreleri	59
<i>Şekil 7.</i> Uzman kanısına dayalı oluşturulan Q-matrisleri ile yapılan sınıflama analizlerine ait kaydırma parametreleri	60
<i>Şekil 8.</i> Alt grupta nitelik boyutu farklı belirlenen Q-matrisleri ile yapılan sınıflama analizlerine ait tahmin parametreleri	73
<i>Şekil 9.</i> Alt grupta nitelik boyutu farklı belirlenen Q-matrisleri ile yapılan sınıflama analizlerine ait kaydırma parametreleri	74
<i>Şekil 10.</i> Üst grupta nitelik boyutu farklı belirlenen Q-matrisleri ile yapılan sınıflama analizlerine ait tahmin parametreleri	76
<i>Şekil 11.</i> Üst grupta nitelik boyutu farklı belirlenen Q-matrisleri ile yapılan sınıflama analizlerine ait kaydırma parametreleri	77

SİMGE VE KISALTMALAR LİSTESİ

BTM	Bilişsel Tanı Modelleri
KTK	Klasik Test Kuramı
MTK	Madde Tepki Kuramı
SRMSR	Standardized Root Mean Square of the Residuals
RMSEA	Root Mean Square Error of Approximation
TLI	Tucker Levis Index
AIC	Akaike Information Criterion
BIC	Bayesian Information Criterion
CAIC	Consistent Akaike Information Criterion
DINA	Deterministic Inputs, Noisy “and” Gate
DINO	Deterministic Inputs, Noisy “or” Gate
ÇK	Çarpıklık Katsayısı
BK	Basıklık Katsayısı
PVAF	Proportion of Variance Accounted for

BÖLÜM I

GİRİŞ

Bu bölümde, araştırmanın problem durumuna, amacına, önemine, problem ifadesine, araştırma sorularına ve sınırlılıklarına yer verilmiştir.

Problem Durumu

Öğretim etkinliklerinin verimli bir şekilde yürütülmesi için öğretmenin öğretilmekte olan konunun doğasını bilmesi ve konuyu öğrencilerin öğrenmesine uygun küçük adımlara bölmesi gereklidir. Bu yaklaşım birçok öğrenme kuramının temelinde yer almaktadır. Bir konunun sistematik analizi ve öğretim birimlerinin nicel parametreler aracılığıyla tanımlanması ve ilgili temel işlemlerin bir fonksiyonu olarak her bir öğrenme biriminin modellenerek test edilmesi uygun bir yöntem olacaktır. Böyle bir yöntemin katkısı, madde güçlüğü'nün istatistiksel olarak tanımlanmasının çok ötesinde bir problemi çözmede hangi adımların (işlemlerin) birim olarak görülmesi gerektiğine dair incelemelere olanak sunmasıdır (Fischer, 1973).

Bir testin amacı, sınava giren kişinin genel yeteneğini doğru bir şekilde ölçmekse, bir testin bu yeteneği ne kadar güvenilir bir şekilde ölçtüğüne dair bir gösterge sağlayan indeksler oluşturabilmelidir. Bununla birlikte, beceri tanımlamaları için modern yöntemler, genel yeteneği değerlendirmek yerine belirli sayıda özellikle ilgili uzmanlığı belirlemekle ilgilenmektedir. Örneğin, bir bireyin bir soruyu doğru cevaplayabilmesi için genellikle başarıyla tamamlanması gereken bir dizi gerekli adım vardır. Sınava giren kişi bu adımlar için gerekli tüm niteliklere hâkim olmuşsa, soru büyük olasılıkla doğru yanıtlanacaktır (Henson, Roussos, Douglas & He, 2008).

Eđitim arařtırmalarında, durum belirleme amacıyla tasarlanmıř sınavların niteliklerinin bir setinde her birine sahip olma ya da olmamayı sınıflandırmaya y6nelik biliřsel tanı i6in 6zelleřtirilmiř gizil sınıf modelleri geliřtirilmiřtir. Tanılayıcı modellerin uygulanmasının temel amacı, bireyleri nitelik profilleri ile tanımlanan farklı kategorilerden birine sınıflandırmaktır. Nitelikler uygulamaya bađlı olarak bir6ok farklı formda alınabilir, fakat genellikle bir sınavda yer alan maddelerde ya da diđer psikolojik deđerlendirmelerdeki 6zel becerileri bire bir karřılaması gerekmektedir. Enformasyon durumları hakkındaki spesifik bilgiler gerekli olduđuunda detaylı becerilere g6re sınıflandırılması istenilmektedir ve b6yle bir durumda 6nemli bir beklenti, yapılan sınıflandırmanın daha etkili iyileřtirmeler sađlamasıdır (Chiu, 2008).

Performanslarından memnun olmayan bireylere kendilerini geliřtirmeleri i6in g66l6 ve zayıf y6nlerinin bildirilmesi 6nemlidir. Bu sayede, bireyler yapılan deđerlendirme sonucunda aldıkları detaylı d6n6tler sayesinde kendi durumlarının farkına varır. Yapılan deđerlendirmelerde bireylerin bařarılı olması i6in hangi konuları 6alıřmaları ve hangi becerilerini geliřtirmeleri konusunda bilgi verilmesi, bireylerin yapılan deđerlendirme alanındaki geliřimine katkı sađlar (Ardı6, 2020). Eđitimde, kavramsal anlamda yer alan psikolojik s6re6leri haritalayan ve 6l6en deđerlendirmeleri geliřtirmeye olan ilgi artmaktadır. Genel olarak tanılayıcı deđerlendirme ile alanın ortaya 6ıkan bu talebini karřılayabileceđi d6ř6n6lmektedir (MacDonald, 2013). Geleneksel olarak, bir test genel bir toplam puan veya birka6 toplam alt test puanı sunar. Diđer yandan, tanılayıcı deđerlendirme, 6đrencilerin hangi kavram ve becerilerde ustalařtıđını ve hangi alanlarda iyileřtirici eđitime ihtiya6 duyulduđunu belirleyen her bir adaya 6zg6 profil sunar. Bu nedenle tanılayıcı deđerlendirme kapsamında kullanılan bir biliřsel tanı testi, yalnızca deđerlendirme ama6larına hizmet etmekle kalmaz, aynı zamanda sınava giren her bireyin eđitim ihtiya6larına iliřkin deđerli bilgiler sunar (Cheng, 2010).

Sınıftaki eđitim ve 6đretimi geliřtirme potansiyelinden dolayı, Biliřsel Tanı Modelleri (BTM) arařtırmacılar ve eđitimde 6l6me ve deđerlendirme alanındaki uygulayıcılar arasında ilgi g6rmekte ve dikkat 6ekmektedir. BTM biliřsel becerileri ve belirli bir alandaki problemleri 66zmek i6in gerekli olan nitelikler hakkında belirli bilgiyi oluřturmak i6in geliřtirilen 6ok sayıda ayrı gizil deđiřkenleri i6eren psikometrik modellerdir. Ayrıca, BTM ilgilenilen alanda 6đrencilerin g66l6 ve zayıf oldukları y6nleri tanımlamak i6in kullanılabilir. Bu nedenle, uygun řekilde oluřturulmuř durum belirlemelerinden ayrıntılı bilgiler kullanılarak t6retilmiř BTM tanılama amacıyla daha kullanıřlı ve 6đretimsel d6zenlemeler

ile ilgilidir. Buna karşılık, yaygın olarak kullanılan Klasik Test Kuramı (KTK) ve Madde Tepki Kuramı (MTK) gibi psikometrik çerçeveler sürekli bir ölçek (continuum) üzerinde öğrencinin durumunu gösteren tek bir genel toplam puana dayalıdır (de la Torre & Lee, 2013). Gizil değişkenlerin sürekli ölçeklerde olduğu geleneksel Çok Boyutlu Madde Tepki Kuramı'nın (ÇBMTK) aksine, BTM birden çok kategorik gizil değişkeni veya nitelikleri modeller ve katılımcıların nitelik örüntülerinin sınıflandırılmasına olanak tanır. Bu nitelik örüntüleri çeşitli gizil sınıflardaki üyeliği belirtir. Her bir katılımcının nitelik örüntüsü niteliğin gerektirdiği becerilere sahip ise 1, değil ise 0 ile gösteren ikili bir vektör ile gösterilir. Bu tür yeterlilik profilleri genellikle öğretmenlerin hedeflenen iyileştirici öğretimi tasarımlarına yardımcı olmayı amaçlamaktadır (Feng, 2013).

BTM sınava giren bireyleri doğrusal olarak sıralamaktan ya da kısmen sıralamaktan daha karmaşık olan amaçlar ile ilgilenir. BTM bunlar yerine birey tarafından gerçekleştirilen performansın daha ayrıntılı kanıtlarına dayanarak, sınava giren kişinin sahip olabileceği veya olmayabileceği becerilerin ya da diğer bilişsel özelliklerin bir listesini üretir. Bununla birlikte, bu modellerin daha bilinen MTK modelleriyle pek çok ortak noktası vardır ancak MTK ve benzer modellerin yorumlanabilirliği, model parçaları arasındaki basit, tek yönlü ilişkilerle artırılır. Ayrıca tek boyutlu MTK modellemesinde uyum iyi olsa bile testin amacı bilişsel değerlendirme veya teşhis ise öğrenci profilleri bağlamında BTM kadar ayrıntılı sonuçlar vermeyecektir. Birbiri ile bağlantılı iki Bilişsel Tanı Modeli olan DINA (Deterministic inputs, noisy “and” gate) ve NIDA (Noisy inputs, deterministic ‘and’ gate.) modellerinin, standart MTK varsayımlarının çok boyutlu genellemelerini karşıladığı dikkate alındığında ÇBMTK modellerinin davranışı ve yorumlanması hakkındaki sezgiler bu iki modelle de karşılanır (Junker & Sijtsma, 2001).

Bilişsel tanı değerlendirme alanındaki en temel soru “Nasıl tutarlı ve doğru tanılayıcı sonuçlar elde ederiz?” şeklindedir. Bu soru doğrudan bilişsel tanı değerlendirmesinin gelecek başarısı ile ilgilidir. Tutarsız ve doğru olmayan beceri tanımlaması öğrencilerin beceri profillerinin yanlış yorumlanmasına neden olur ve bu durum öğrenci ile ilgili verilecek iyileştirme kararlarının hatalı olmasına yol açabilir. Bu durum sadece öğrencilerin ve öğretmenlerin zaman ve çaba kaybına neden olmaz, aynı zamanda öğrencilerin eğitimini ve geleceğe yönelik iş fırsatlarını olumsuz şekilde etkiler (Cui, Gierl & Chang, 2012). Etkili bilişsel tanı uygulamaları madde nitelik bağlantısını sağlayan ikili matris olan Q-matrisinin doğru bir şekilde belirlenmesine dayanır (Feng, 2013).

Q-matrisi, değerlendirme aracının tasarımını yansıtır ve bu ölçme aracı için tanılayıcı geribildirim kalitesini belirleyen temel unsurdur (Rupp & Templin, 2008a). Bilişsel Tanı Modellerini eğitimsel test verilerine uyarlamak ve sınava girenlerin yeterlilik sınıflarına atamasını yapmak için kullanılan çoğu yöntem, bir testteki her bir maddeyi doğru yanıtlamak için gereken bilişsel becerilerle (niteliklerle) ilişkilendirilen Q-matrisinin oluşturulmasını gerektirir. Q-matrisi genellikle eğitim alanındaki uzmanların yargılarına dayalı olarak oluşturulmaktadır. Uzman görüşüne dayalı olarak hazırlanan bir Q-matrisinde uzmanların görüşleri yanıltıcı olabilir. Q-matrisinin hatalı bir şekilde tanımlanması ise model parametre kestirimlerini olumsuz etkileyecektir ve bu durumun da sınava girenlerin yanlış sınıflandırılmasına neden olabileceği yaygın olarak kabul edilmektedir (Chi, 2013).

BTM'nin tanınal gücü, teorik olarak uygun ve deneysel olarak desteklenen bir Q-matrisin oluşturulmasında yatmaktadır. Diğer bir deyişle, belirli bir değerlendirmeden elde edilen tanınal çıkarımların kalitesi, Q-matrisi, teorik olarak zorlayıcı, deneysel olarak sağlam ve test kullanımıyla ilgili nitelikleri temsil etme derecesinden büyük ölçüde etkilenir. Hedef nitelikler, puan raporlama kategorileri geliştirmek ve kullanıcıları puanlamak için sağlanan performans geri bildiriminin doğasını belirlemek için de temel görevi görebilir (Lee & Sawaki, 2009).

Bir sınava girmenin içerdiği bilişsel süreçlerin tam olarak anlaşılmaması nedeniyle, gerçek Q-matrisi bilinmemektedir (DeCarlo, 2012; Lei & Li, 2016). Ancak BTM'nin tipik uygulamalarında maddelerin gösterdiği becerilere göre teoriyi yansıtan Q-matrisin bilindiği varsayılır. Bununla birlikte, Q-matrisi genellikle uzman değerlendirmesi ile belirlenir ve bu nedenle bazı unsurları hakkında belirsizlik olabilir (DeCarlo, 2012). Bilişsel tanındaki model uyum analizlerinin çoğu bir Q-matrisinin uygunluğunu, geçerleme yapmadan, Q-matrisi oluşturulduktan sonra doğru olduğunu varsayar. Ancak Q-matrisinin doğruluğu model uyumunu da etkilemektedir ve Q-matris için doğrulama (geçerleme) yapılması model uyumunu iyileştirir. Eksiksiz bir Q-matris geçerleme süreci hem istatistiksel bilgiden hem de alan uzmanlığından yararlanmayı gerektirir (de la Torre, 2008). Q-matrisinin düzeltilmesine ilişkin karar sadece deneysel olarak gerçekleştirilmiş bir Q-matris doğrulama sürecine dayandırılmamalı, Q-matrisindeki herhangi bir değişiklik ile ilgili bir karar alan uzmanları ve psikometristler tarafından dikkatlice düşünülerek yapılması görüşü önerilmektedir (Collares, 2021; Ma & de la Torre, 2020; de la Torre & Akbay, 2019; Wang, Cai & Tu, 2020). Ancak yapılan çalışmalar incelendiğinde, bu önerilen geçerleme süreci adımlarının test edildiği bir çalışmaya rastlanılmamıştır.

Q-matrisi uzman kanısına dayalı olmadan, birey yanıtlarına dayalı olarak yapılan istatistiksel çıkarımlarla da belirlenebilmektedir. Ancak Q-matrisin istatistiksel çıkarımı, bilişsel değerlendirme literatüründe büyük ölçüde keşfedilmemiş bir alan olmuştur (Chen, Liu, Xu & Ying, 2012). Faktör analitik yöntemlerle Q-matrisin belirlendiği çalışmalar olmasına rağmen (Ardıç, 2020; Chui, 2013; Close, Davison, & Davenport, 2012; Henson & Templin, 2007) uzman kanısı ile belirlenen Q-matrislerine dayalı sınıflamalar ile karşılaştırıldığı bir çalışmaya da rastlanılmamıştır.

Bir Bilişsel Tanı Modeli'nin uygulanması için Q-matrisinin dışında gereken diğer bir girdi (unsur) katılımcıların test maddelerine verdikleri yanıt örüntüleridir. Bireylerin yanıt örüntülerine bağlı olarak boyutluluk farklı yetenek düzeylerinde farklılaşabilmektedir. Bununla birlikte farklı yetenek düzeyindeki bireylerin maddeyi doğru cevaplama süreçlerinin birbirinden farklılaşabileceği görülmüştür (Carboni, 2001; Pöhler, George, Prediger & Weinert 2017). BTM'nin aynı test üzerinde farklı niteliklerin değişen yetenek düzeylerinde nasıl sınıflama sağlayacağına ilişkin alanda bir boşluk olduğu düşünülmektedir. Belirlenen Q-matrislerin farklı yetenek düzeyleri ve dağılımlar üzerinde nasıl sınıflama yapıldığına dayalı az sayıda çalışmaya (de la Torre & Lee, 2010; Im & Park, 2010; MacDonald, 2013; Şen & Arıcan, 2016) rastlanılmasıyla beraber daha çok çalışmaya ihtiyaç olduğu düşünülmektedir.

Araştırmanın Amacı

Bu araştırmada G-DINA Modeli altında Q-matrisin farklı belirlenmesinin değişen koşullar altında incelenmesi amaçlanmaktadır. Bu ana amaç doğrultusunda ilk olarak hem uzman kanısına hem de faktör analizine dayalı Q-matrisinin geçerleme sürecinin uygulanmasına ilişkin sonuçlarının karşılaştırılması hedeflenmektedir. Ardından önerilen geçerleme süreçleri göz önüne alınarak farklı belirlenen Q-matrisleri ile alt ve üst yetenek grupları üzerinde sonuçların incelenmesi amaçlanmaktadır. Son olarak normal dağılım ve normal dağılımdan farklılaşan çarpıklıktaki dağılımlar üzerinde uzman kanısına ve faktör analizine dayalı Q-matrisleri ile elde edilen sonuçların karşılaştırılması hedeflenmektedir. En nihayetinde bu araştırmanın amacı farklı belirlenen Q-matrislerinin test ve nitelik düzeyinde sınıflama doğruluğu, model veri uyumu ile tahmin ve kaydırma parametrelerine etkisini ortaya koymaktır.

Araştırmanın Önemi

Mevcut bir Q-matrisinin belirlenmesinin doğruluğunu deneysel verilerden yararlanarak belirlemek için geçerleme yöntemlerinin kullanılması, BTM'nin başarılı bir şekilde uygulanması için önemlidir (Feng, 2013). Başarılı bir şekilde uygulanan bilişsel değerlendirmeler ise hem eğitimciler hem de sınava giren bireylere doğru tanılayıcı geribildirim verilmesi açısından önemlidir. Q-matrisinin doğru bir şekilde belirlenmesinin bilişsel tanı uygulamasından elde edilen geri bildirimlerin doğru bir şekilde verilmesini etkileyeceği de göz önüne alındığında, Q-matrisi geçerleme çalışmalarının kilit bir role sahip olduğu ortaya çıkmaktadır. Bu araştırma özellikle uzman görüşlerine dayalı Q-matrisi belirlenmesinin ampirik olarak geçerleme süreci ile iyileştirilmesine yönelik incelemeleri ortaya koyması yönüyle önemli görülmektedir.

Pratikte, BTM'lerin kullanıldığı ilk dönemlerden bu yana, Q-matrisi genellikle konu uzmanları tarafından, subjektif olarak tanımlanmaktadır. Ancak son zamanlarda bilgisayar uyarlamalı test uygulamaları ile birleştirilmesi gibi durumlarda madde havuzunun oluşturulması, güncellenmesi gibi madde sayısının fazla olması, uzman görüşü almak zaman alıcı ve maliyetli olduğundan kullanışlı ve hatasız olmamaktadır (Wang vd., 2020). Bu çalışma ile uzman kanısına dayalı olmadan faktör analizi sonuçlarına dayalı olarak belirlenen Q-matrisinin ele alınan hangi durumda kullanılmasına yönelik bilgi sağlayacağından önemli görülmektedir.

Herhangi bir yetenek tanılama yaklaşımının, uygulanan bir sistemin parçası hâline gelmeden önce gerçek veri analizleri ile kapsamlı bir biçimde değerlendirilmesi gerekmektedir (Kalkan, 2016). Alanyazında yapılan araştırmalarda kullanılan koşullar çoğunlukla veri simülasyonu (MacDonald, 2013; Ömür Sünbül, 2013; Uyumaz, 2016) ile elde edilmiş olsa da bu çalışma kapsamında ele alınan koşullar gerçek veriden elde edilmiştir. Çalışmanın, araştırma kapsamında ele alınan tüm koşullar için gerçek veriden yararlanılmış olması yönüyle önemli olduğu düşünülmektedir.

Bu çalışmadan elde edilen bulgular, ele alınan benzer test durumları bağlamında sınırlı kalmakla birlikte, Bilişsel Tanı Modeli kullanmayı planlayan eğitimciler ve uygulayıcılara bulunan koşullar altında daha doğru sınıflandırmaları elde edebilmek için yapmaları gerekenler konusunda yol göstereceği düşünülmektedir. Dolayısıyla, araştırmacıların BTM'leri daha geniş bir kullanım alanında uygulayabilmesine yönelik olarak

araştırmacıların ve uygulayıcıların sıklıkla karşılaşılabilecek koşullar altında ele alınarak karşılaştırılması önemli görülmektedir.

Problem İfadesi

Bilişsel tanı modellerine göre geliştirilen bir testten elde edilen verilere dayalı G-DINA Modeli altında Q-matrisin geçerleme ve nitelik seti bakımından farklı belirlenmesi, farklı yetenek düzeyleri ve farklı yetenek dağılımları koşulları altında model uyum indeksleri, madde parametre kestirimleri ile sınıflama doğruluğunu nasıl etkilemektedir?

Araştırma Soruları

1. Tüm gruba yapılan bilişsel tanı değerlendirmesinde, G-DINA Modeli altında;
 - 1.1. Uzman kanısına dayalı olarak belirlenen Q-matrisinin, PVAf yöntemine ait geçerleme modifikasyonlarına ilişkin farklı belirlenmesi
 - a. Test, nitelik ve gizil sınıf düzeyinde sınıflama doğruluklarını nasıl etkilemektedir?
 - b. Model veri uyumunu nasıl etkilemektedir?
 - c. Tahmin ve kaydırma parametre kestirimlerini nasıl etkilemektedir?
 - 1.2. Faktör analizi sonuçlarına dayalı olarak belirlenen Q-matrisinin PVAf yönteme ait geçerleme modifikasyonları dikkate alınarak belirlenmesi
 - a. Test, nitelik ve gizil sınıf düzeyinde sınıflama doğruluklarını nasıl etkilemektedir?
 - b. Model veri uyumunu nasıl etkilemektedir?
 - c. Tahmin ve kaydırma parametre kestirimlerini nasıl etkilemektedir?
2. Alt ve üst yetenek gruplarına yapılan bilişsel tanı değerlendirmelerinde, G-DINA Modeli altında uzman kanısı ile faktör analizi sonuçlarına dayalı oluşturulan Q-matrislerinin nitelik boyutunun farklı belirlenmesi
 - a. Test ve nitelik düzeyinde sınıflama doğruluklarını nasıl etkilemektedir?
 - b. Model veri uyumunu nasıl etkilemektedir?
 - c. Tahmin ve kaydırma parametre kestirimlerini nasıl etkilemektedir?

3. Bilişsel tanı değerlendirmelerinde, G-DINA Modeli altında farklı dağılım koşulları (Çarpıklık katsayıları 0, 0,5, 0,75, 1, 1,25, 1,5 ve 2)
- a. Test ve nitelik düzeyinde sınıflama doğruluklarını nasıl etkilemektedir?
 - b. Model veri uyumunu nasıl etkilemektedir?
 - c. Tahmin ve kaydırma parametre kestirimlerini nasıl etkilemektedir?

Sınırlılıklar

Bu çalışma;

1. “Uluslararası Geniş Ölçekli Sınavlarda Türkiye'nin Matematik Başarısını Arttırabilmek İçin Bir Model Önerisi: Bilişsel Tanıya Dayalı İzleme Modelinin Etkililiği” adlı proje kapsamındaki 6. sınıf düzeyindeki öğrenciler ve bu öğrencilerden elde edilen veriler ile sınırlıdır.
2. Bilişsel tanı modellerinden yalnızca G-DINA modeli ile sınırlıdır.
3. Yetenek düzeylerinin belirlenmesinde KTK'dan yararlanılmıştır. Yetenek düzeyleri alt ve üst yetenek grubu olarak iki ile sınırlı kalmıştır.
4. Yetenek dağılımlarının belirlenmesinde yalnızca çarpıklık katsayılarından yararlanılmış ve basıklık katsayısı dikkate alınmamıştır. Çarpıklık katsayıları 0, 0,5, 0,75, 1, 1,25, 1,5 ve 2 olan dağılımlar incelenmiştir.

BÖLÜM II


KURAMSAL ÇERÇEVE VE İLGİLİ ARAŞTIRMALAR

Bu bölümde Bilişsel Tanı Modelinin kuramsal temeli ve alan yazında yapılmış olan ilgili araştırmalara yer verilmiştir.

Bilişsel Tanı Modellerinin Kuramsal Temeli

Bilişsel Tanı Modelleri

BTM, gözlemlenebilir verilerin bir dizi kategorik gizil değişkenle ilişkisini tanımlayan gizil sınıf modellerinin özel durumlarıdır (Templin & Henson, 2006). BTM ilk olarak, öğrencilerin belirlenmiş niteliklere sahip olduğu ya da olmadığını tanımlamak amacıyla geliştirilmiştir. Bu modeller, belirli bir nitelikte öğrencilerin güçlü ve zayıf yönlerinin belirlenmesine izin verir. BTM'den türetilen bilgilerin özgünlüğü sınıf öğretimi ve öğrenci öğrenmelerine bilgi sağlamak amacıyla kullanılabilir (de la Torre, 2008). BTM'nin uygulanmasındaki adımlar Şekil 1'de gösterilmiştir (Sorrel, Olea, Abad, de la Torre, Aguado ve Lievens, 2016).



řekil 1. Biliřsel tanı modellerinin uygulamasında adımlar. Sorrel, M. A., Olea, J., Abad, F. J., de la Torre, J., Aguado, D., & Lievens, F. (2016). Validity and reliability of situational judgement test scores: A new approach based on cognitive diagnosis models. *Organizational Research Methods*, 19(3), 506-532.

Verilere uyum saęlayan birkaç model olduęunda, en uygun modelin seřimi nemli bir konuyu oluřturmaktadır. Model seřim sreci test ya da madde dzeyinde ve birey dzeyinde incelenen ok ynl bir aba olan model veri uyumunun kontrol edilmesini ierir. En uygun modeli belirleme sreci geerleme srecidir. Bu nedenle, bilimsel arařtırmalarda geerlemeye ynelik iřlemlerde olduęu gibi, model seřimi genellikle teoriye dayalı tahminler ve gerek gzlemler karřılařtırılarak gerekleřtirilir. Psikometrik baęlamda, teori verileri analiz etmek iin kullanılan psikometrik modelin spesifik formu olarak dar bir řekilde yorumlanabilir. Bu nedenle, psikometrik modelde ifade edilen temelde yatan sre, gzlemlenen veriler iin makul bir aıklama saęlar (de la Torre & Lee, 2013).

BTM'lerde sınıflama gizil yordayıcı deęiřken ve gzlenen tepki deęiřkenlerinin iki kategorili ya da ok kategorili olmalarına gre yapılabilir. Ayrıca BTM'de telafisel (tamamlayıcı) model ya da telafisel olmayan (tamamlayıcı olmayan) model olarak iki model tr bulunmaktadır. Telafisel ve telafisel olmayan modeller arasındaki fark, gizil yordayıcı

değişkenlerin, gözlenen cevabı vermek için farklı nitelikler arasında nasıl bir araya getirildiğini yansıtmasıyla ilgilidir. Telafisel modellerde, bir nitelikteki eksiklik diğer kalan nitelikler tarafından giderilebilirken; telafisel olmayan modellerde, her bir nitelik, doğru cevabın verilmesi için gereklidir. Yani telafisel modellerde eksik olan nitelik, yetkin olunan nitelik tarafından tamamlanabilirken, telafisel olmayan modellerde, eksik olan niteliğin başka herhangi bir nitelik tarafından telafi edilememesi durumu söz konusudur. Tablo 1’de bilişsel tanı modellerine ait sınıflama yer almaktadır (Rupp &Templin, 2008b).



Tablo 1

Bilişsel Tanı Modellerinin Sınıflandırılması

Gözlenen Tepki Değişken	Gizil Yordayıcı Değişken		Model Türü
	İki Kategorili	Çok Kategorili	
İki Kategorili	RSM AHM DINA HO-DINA MS-DINA NIDA BIN MCLCM NC-RUM RERU	BIN MCLCM NC-RUM RERU	Telafisel Olmayan Model
	DINO NIDO BIN MCLCM C-RUM GDM LCDM	BIN MCLCM C-RUM GDM LCDM	Telafisel Model
Çok Kategorili	RSM AHM BIN MCLCM NC-RUM	BIN MCLCM NC-RUM	Telafisel Olmayan Model
	BIN MCLCM C-RUM GDM LCDM	BIN MCLCM C-RUM GDM LCDM	Telafisel Model

Not: RSM = Rule-space method. AHM = Skill hierarchy method. BIN = Bayesian inference network. DINA = Deterministic inputs, noisy 'and' gate. HO-DINA = Higher- order DINA. MS-DINA = Multi-strategy DINA. LCDM = Loglinear Cognitive Diagnosis Model. DINO = Deterministic inputs, noisy 'or' gate. NIDA=Noisy inputs, deterministic 'and' gate. NIDO = Noisy inputs, deterministic 'or' gate. RUM = Reparametrized unified model / Fusion model. C-RUM = Compensatory RUM. NC-RUM = Non-compensatory RUM. GDM = General Diagnosis Model. LCDM = Loglinear Cognitive Diagnosis Model. MCLCM = Multiple Classification Latent Class Model.

Rupp, A. A., & Templin, J. (2008b). Unique characteristics of diagnostic classification models: A comprehensive review of the current state-of-the-art. *Measurement: Interdisciplinary Research and Perspectives*, 6(4), 219-262. <http://dx.doi.org/10.1080/15366360802490866>

Aşağıda BTM içinde literatürde sıklıkla kullanılan DINA, DINO ve G-DINA modeline ilişkin bilgilere yer verilmektedir.

DINA Model

Haertel (1989) tarafından temeli atılan DINA (The deterministic-input, noisy-and-gate) modeli Junker & Sijtsma (2001) tarafından geliştirilmiş ve adlandırılmıştır. DINA model bilişsel tanı modellerinin en kolay yorumlanana ve esnek olmayan (parsimonious) modelidir (de la Torre, 2008). Bağlayıcı (conjunctive) ve telafisel olmayan bir model olarak, sınava giren bir kişinin maddeye atfedilen tüm niteliklere sahip olmasını gerektirir. Bir madde eşit derecede önemli birkaç niteliğin birleşimini gerektirdiğinde ve sınava giren bireyin bu madde için gerekli olan bir niteliğe sahip olmaması, gerekli tüm niteliklerin eksikliğiyle aynıdır (de la Torre ve Douglas, 2004). DINA modelinde, bir madde gizil yanıt η_{ij} ile iki sınıf için farklı nitelik vektörleriyle ($\alpha_i = \alpha_{i1}, \alpha_{i2}, \dots, \alpha_{iK}$) bireyleri ayırır.

$$\eta_{ij} = \prod_{k=1}^K \alpha_{ik}^{q_{jk}}$$

Bir sınıf gerekli niteliklerin hepsine sahip olanlar ($\eta_{ij}=1$) ve niteliklerden en az birine sahip olmayanların oluşturduğu ($\eta_{ij}=0$) iki grup içerir. Dolayısıyla η_{ij} ideal puan olarak adlandırılır. Yukarıdaki formüldeki η_{ij} DINA'nın bağlayıcı özelliğini gösterir. Ayrıca nitelik vektörleri ve Q-matrisi verildiğinde, η_{ij} rastgele değildir (deterministic). Tahmin parametresi g_j ve kaydırma parametresi s_j verildiğinde, DINA modelin madde yanıt fonksiyonu η_{ij} ile belirlenen iki sınıf için madde j 'yi destekleyen olasılıkları tanımlar (Li, 2016).

$$P(X_{ij} = 1 | \eta_{ij}) = (1 - s_j)^{\eta_{ij} g_j^{1-\eta_{ij}}}$$

burada

$$s_j = P(X_{ij} = 0 | \eta_{ij} = 1)$$

$$g_j = P(X_{ij} = 1 | \eta_{ij} = 0)$$

Madde yanıt fonksiyonu gizil yanıt değişkeni η_{ij} nin gürültülü (noisy) bir gözlemi X_{ij} ile modellenir (Junker & Sijtsma, 2001). Kaydırma parametresi s_j sınava giren birey tüm özelliklere sahip olduğunda hata yapma olasılığını ve tahmin parametresi g_j sınava giren

bireyler tüm özelliklere sahip olmadığında bireyin bir maddeyi doğru yanıtlama olasılığını gösterir. Gizil yanıt madde j için i . birey için 1 ise, maddenin doğru yanıtlanma olasılığı $1 - s_j$ dir. Benzer olarak, gizil yanıt bu birey için 0 ise, maddenin doğru yanıtlanma olasılığı g_j dir. Sınava girenlerin yanıtlarının, ideal yanıtlarına (η) bağlı olarak birbirinden bağımsız olduğunu varsayarsak, olasılık fonksiyonu aşağıdaki gibidir (Li, 2016):

$$P(X_{ij} = x_{ij}, \forall i, j | \eta, s, g) = \prod_{i=1}^N \prod_{j=1}^J [(1 - s_j)^{x_{ij} s_j^{1-x_{ij}}}]^{\eta_{ij}} [g_j^{x_{ij}} (1 - g_j)^{1-x_{ij}}]^{1-\eta_{ij}}$$

Gerekli niteliklerin sayısı maddeden maddeye farklılık gösterse de, DINA model her bir madde için yalnızca iki parametre gerektirir. Bunun temel nedeni, DINA modelinin güçlü bir varsayımı olan maddeye ait niteliklerden birine dahi sahip olmanın maddenin doğru cevaplanması için gerekli durumun sağlanmasıdır. Bu modelde sınava giren kişi daha az niteliğe sahip olarak maddeyi doğru cevap verdiyse tahmin etme ile doğru cevap verdiğini varsaymak daha mantıklı bir kabul olabilir. Ancak, DINA modelde tahmin ve kaydırma parametreleri birey düzeyinin yerine madde düzeyindedir (Li, 2016). Madde parametrelerinden g parametresi maddeyi doğru cevaplamak için gerekli olan en az bir niteliğe sahip olunmadığı durumda, tahmin edilerek doğru cevaplanmasıyla ilgilidir. Madde parametrelerinden s parametresi ise maddeyi doğru cevaplamak için gerekli olan tüm niteliklere sahip olduğu durumda maddenin yanlış cevaplanmasıyla ilgilidir. Her iki parametrenin düşük değerler alması maddenin orta güçlükte olduğu anlamına gelebilmektedir. Başokçu (2012) yüksek g parametre değerinin, Q-matris tarafından tanımlanamamış bir özelliği kullanarak maddeyi doğru cevaplamak anlamına da gelebileceğini belirtmiştir. Dolayısıyla Q-matriste belirlenen niteliklere başka niteliklerin de eklenmesi gerektiğinin göstergesi olabileceği düşünülmektedir.

DINO Model

DINO model (The deterministic input, noisy “or” gate model) (Templin & Henson, 2006) ayırık (disjunctive) ve telafi edici bir modeldir. DINO modelde bir madde j , sınava giren bireyleri gizil yanıt değişkeni ω ya göre iki grup içinde farklı gizil sınıfların içinde ayırır.

$$\omega_{ij} = 1 - \prod_{k=1}^K (1 - \alpha_{ik})^{q_{jk}}$$

$\omega_{ij} = 1$ ile bulunan grup madde j için gerekli niteliklerden en az birine sahip tüm sınava giren bireyleri içerir ve $\omega_{ij} = 0$ ile bulunan grup madde j için gerekli niteliklerin hiçbirine sahip olmayan sınava giren bireyleri içerir (Templin & Henson, 2006). DINO modelin verilen bu özelliği, psikolojik araştırmalardan elde edilen yanıtların analizin genellikle uygulanır. Kaydırma parametresi $\omega_{ij} = 1$ grubunda verilen bir yanlış cevabın olasılığı olarak ve tahmin parametresi $\omega_{ij} = 0$ grubunda verilen bir doğru cevabın olasılığı olarak tanımlanır. Buna göre, DINO modelin madde yanıt fonksiyonu tahmin parametresi g_j ve kaydırma parametresi s_j ile belirlenen gizil yanıt değişkeni ω için uygun bulunan madde j 'nin olasılığını hesaplar (Li, 2016).

$$P(X_{ij} = 1 | \omega_{ij}) = (1 - s_j)^{\omega_{ij} g_j^{1 - \omega_{ij}}}$$

burada

$$s_j = P(X_{ij} = 0 | \omega_{ij} = 1)$$

$$g_j = P(X_{ij} = 1 | \omega_{ij} = 0)$$

DINA model ile karşılaştırıldığında, DINO modelin temel farkı gizil yanıt değişkeninin hesaplanma şeklidir. DINO model altında, gerekli niteliğin herhangi birinde uzmanlaşmak doğru yanıt vermek için yeterlidir (Li, 2016).

G-DINA

Genelleştirilmiş DINA model, de la Torre (2011) tarafından DINA modelin bir genelleştirilmesi olarak sunulmuştur. Bu model, DINA modelin varsayımı olan $\eta_{ij} = 0$ grubundaki nitelik sınıflarının tamamından başarılı olmanın eşit olasılığa sahip olduğu kabulünde daha esnektir (de la Torre, 2011). DINA modeldeki gizil yanıt değişkeninin (η) iki grup içinde bireyleri sınıflaması ve her bir grup içinde maddelerin nitelik vektörleri arasındaki farklılıklara bakmaksızın uygun bulunan maddelerde bireylerin özdeş olasılığa sahip olması varsayımı çok güçlüdür ve uygulamada bu varsayımın bir testin tüm maddeleri için sağlanması zordur. G-DINA model $2^{K_j^*}$ (K_j^* madde j için gerekli olan nitelik sayısı) gizil sınıf içinde bireyleri sınıflandırır. α_{ij}^* madde j için gerekli olan bileşenlerin indirgenmiş nitelik vektörü olsun ve her α_{ij}^* , $2^{K_j^*}$ gizil gruptan biri ile temsil edilsin. Özdeşlik bağlantısı kullanılarak, G-DINA model için madde yanıt fonksiyonu her bir gizil grup için bir doğru yanıtın olasılığını tanımlar (de la Torre, 2011).

$$P(X_{lj} = 1|\alpha_{lj}^*) = \delta_{j0} + \sum_{k=1}^{K_j^*} \delta_{jk} \alpha_{lk} + \sum_{k'=k+1}^{K_j^*} \sum_{k=1}^{K_j^*-1} \delta_{jkk'} \alpha_{lk} \alpha_{lk'} \cdots + \delta_{j12 \dots K_j^*} \prod_{k=1}^{K_j^*} \alpha_{lk}$$

burada

δ_{j0} madde j için kesim noktası (intercept)

δ_{jk} α_k dan gelen ana etki


$\delta_{jkk'}$ α_k ve $\alpha_{k'}$ den gelen etkileşim etkisi

$\delta_{j12 \dots K_j^*}$ $\alpha_1, \alpha_2, \dots, \alpha_{K_j^*}$ den gelen etkileşim etkisi

Bu parametreler şu şekilde tanımlanabilir: δ_0 temel olasılığı temsil eder (örneğin, gerekli niteliklerden hiçbirini temsil edilmediği zaman bir doğru yanıtın olasılığı); δ_k tek bir nitelikte (örneğin α_k) uzmanlaşmanın bir sonucu olarak bir doğru yanıtın olasılığını temsil eder; $\delta_{jkk'}$ birinci düzey etkileşim etkisi, aynı iki özelliğe uzmanlaşmanın toplamsal etkisinin üzerinde ve ötesinde hem α_k hem de $\alpha_{k'}$ niteliklerindeki uzmanlaşmadan dolayı bir doğru yanıtın olasılığını temsil eder ve $\delta_{j12 \dots K_j^*}$ ana ve daha düşük etkileşim etkilerinin toplamsal etkisinin üzerinde ve ötesinde gerekli niteliklerin hepsinde uzmanlaşmanın getirdiği bir doğru yanıtın olasılığını temsil eder. Kesim noktası hiçbir zaman negatif olamaz, ana etkiler tipik olarak negatif olamaz fakat etkileşim etkileri herhangi bir değeri alabilir (de la Torre, 2011).


Bilişsel Tanı Modellerinde Nitelik Kavramı ve Tanımlanması

Nitelik, belirli bir alanda bir görevi gerçekleştirmek için gereken işlemsel veya bildirimsel bilginin bir açıklamasıdır. Bu nitelikler, test maddelerini çözmek için gerekli bilişsel beceri arasındaki sıralamayı özetleyen bir hiyerarşi oluşturur. Bu nedenle nitelik hiyerarşisi açık bir bilişsel model olarak hizmet eder. Nitelik hiyerarşisi ayrıca, hem maddelerin geliştirilmesine hem de sınava girenlerin puanlarının yorumlanmasına rehberlik edecek yorumlayıcı bir çerçeve sağlar. Böylece test performansı, sınava girenlerin bilgi ve becerileri hakkında belirli bilişsel çıkarımlarla ilişkilendirilebilir (Gierl, Alves & Majeau, 2010). Şekil 2’de nitelik yapılarına ilişkin yapılandırılmış ile yapılandırılmamış arasında bir dizi hiyerarşi sunulmuştur (Leighton, Gierl & Hunka, 2004).



Şekil 2. Altı nitelik kullanılarak dört farklı hiyerarşik yapının gösterimi. Leighton, J. P., Gierl, M. J., & Hunka, S. M. (2004). The Attribute Hierarchy Method for Cognitive Assessment: A Variation on Tatsuoka's Rule-Space Approach. *Journal of Educational Measurement*, 41(3), 205–237. <https://doi.org/10.1111/j.1745-3984.2004.tb01163.x>

Şekil 2’de, nitelik 1 (şekilde 1 olarak gösterilmekte) diğer nitelikler için ön koşul olan bir başlangıç bilgisi ya da becerisi olarak düşünülebilir. Şekil 2A’da nitelik 1 ikinci nitelik için, nitelik 1 ve 2 üçüncü nitelik için, nitelik 1, 2 ve 3 dördüncü nitelik için, nitelik 1, 2, 3 ve 4 beşinci nitelik için, nitelik 1, 2, 3, 4 ve 5 altıncı nitelik için ön koşuldur. Nitelik 1’in ikinci niteliğin ön koşulu olması, sınava giren kişinin birinci nitelikteki bilgi ya da beceri sahip olmadan ikinci niteliği sahip olamayacağını beklenmesi anlamına gelir. Sonuç olarak doğrusal bir hiyerarşide ilk niteliğe sahip olmayan bir kişinin takip eden niteliklere de sahip olamayacağıdır. Şekil 2D ise hiyerarşik yapının diğer bir ucu olan yapılandırılmamış (yayılmış) hiyerarşiyi temsil etmektedir. Bu yapıda nitelik bir diğer beş nitelik için ön koşuldur ancak Şekil 2A’dakinin aksine burada diğer nitelikler arasında bir sıralama yoktur. Şekil 2B nitelik 1’den nitelik 6’ya kadar iki farklı yolun izlenebildiği yakınsak (convergent) dallı bir hiyerarşiyi temsil ederken, Şekil 2C iraksak (divergent) dallı bir hiyerarşiyi temsil etmektedir (Leighton, Gierl & Hunka, 2004). Bu yapıların temsil edilmesine yönelik olarak Zhan, Ma, Jiao & Ding’in (2020) çalışmasında kullanılan, örnek Q-matrisi gösterimleri Şekil 3’te sunulmuştur.



Şekil 3. Altı nitelik ve 30 madde için farklı nitelik yapılarına ait Q-matrisi gösterimleri (Gri hücreler 1 ve Beyaz hücreler 0 anlamındadır) Zhan, P., Ma, W., Jiao, H., & Ding, S. (2020). A sequential higher order latent structural model for hierarchical attributes in cognitive diagnostic assessments. *Applied Psychological Measurement*, 44(1), 65-83.

Şekil 3, Q-matrislerde ortaya çıkan örüntünün nitelik yapılarına bağlı olarak nasıl değiştiğini temsil eden bir örnek olarak gösterilebilir.

Q-Matrisi

Bir bilişsel testin J iki düzeyli (dichotomous) madde ile K iki düzeyli niteliğin bir setini ölçtüğü varsayılır. Q-matrisi her bir maddeyi ölçen niteliklerin gösterildiği matrise verilen isimdir ve aşağıdaki şekildeki gibi gösterilir (Cui, Gierl ve Chang; 2012):

$$Q_{J \times K} = \begin{bmatrix} q_{11} & q_{12} & \cdots & q_{1k} & \cdots & q_{1K} \\ q_{21} & q_{22} & \cdots & q_{2k} & \cdots & q_{2K} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ q_{j1} & q_{j2} & \cdots & q_{jk} & \cdots & q_{jK} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ q_{J1} & q_{J2} & \cdots & q_{Jk} & \cdots & q_{JK} \end{bmatrix}$$

Bu matris gösteriminde q_{jk} , k niteliğinin j maddesinde ölçülüp ölçülmemeye durumu olup 1 ya da 0 ile ifade edilir. Tanılayıcı test öğrencilerin madde yanıt vektörüne $X = (X_1, X_2, \dots, X_k)$ dayalı olarak her bir öğrencinin nitelik örüntüsünü $\alpha = (\alpha_1, \alpha_2, \dots, \alpha_k)$ tanılamayı amaçlar. Burada α_k öğrencinin nitelik k ya sahip olup olmama durumuna göre 1 ya da 0 ve X_k öğrencinin j maddesini doğru cevaplayıp cevaplamama durumuna göre 1 ya da 0 ile ifade edilir (Cui, Gierl & Chang, 2012). Diğer bir anlatımla bu matriste her madde ayrı bir satırda listelenir, her nitelik ise ayrı bir sütunda listelenir ve her hücreye söz konusu maddenin değerlendirilen özelliği gerektirip gerektirmediğine göre "0" veya "1" yazılır. Böylece Q-matrisi ölçme aracının tasarımını yansıtır ve bu durum ölçme aracının tanılayıcı geribildirim kalitesini belirten temel unsurdur (Rupp & Templin, 2008a). Feng (2013) tarafından 4 nitelik ve 30 madde için oluşturulmuş bir Q-matrisi örneği Tablo 2’de sunulmuştur.

Tablo 2

K = 4 ve J 30 için Q-Matrisi Örneği

Madde	Nitelik				Madde	Nitelik			
	1	2	3	4		1	2	3	4
1	1	0	1	1	16	1	0	0	1
2	0	1	1	0	17	1	1	1	1
3	1	0	0	0	18	0	0	1	0
4	1	1	0	1	19	1	0	0	1
5	0	0	1	1	20	0	1	1	0
6	1	0	1	1	21	1	1	0	1
7	1	1	1	1	22	1	1	0	0
8	1	0	1	1	23	0	1	0	0
9	0	1	0	1	24	1	0	1	1
10	0	1	0	0	25	0	1	1	0
11	1	0	1	0	26	1	0	0	1
12	1	0	0	1	27	1	1	1	0
13	0	1	0	1	28	1	1	1	0
14	0	0	0	1	29	0	1	1	1
15	0	1	0	0	30	0	1	1	0

Tablo 2’de görüldüğü gibi 17 madde birinci nitelikte, 17 madde ikinci nitelikte, 16 madde üçüncü nitelikte ve 17 madde dördüncü nitelikte ilişkilendirilmiştir. Ayrıca 6 madde sadece bir niteliğe, 13 madde iki niteliğe, 9 madde üç niteliğe ve 4 madde dört niteliğe yönelik beceriler ile bağdaştırılmıştır. Örneğin, birinci madde bir, üç ve dördüncü nitelikteki beceriler ile ilişkilirken, ikinci madde ikinci ve üçüncü niteliğe ait beceriler ve üçüncü madde sadece birinci niteliğe ait beceri ile ilişkilidir. Templin ve Henson’ın (2006) belirttiği gibi Q-matrisinin yapısı, analizin tanısal sonuçlarının geçerliliğinin merkezinde yer

almaktadır. BTM, Q-matrisi tarafından tanımlanan nitelikler aracılığıyla gizil sınıfların sayısını tanımlar (Templin & Henson, 2006). Her bir niteliğe sahip olup olmama kombinasyonları birlikte ele alındığında bilişsel tanı modellerinde gizil sınıfların toplam sayısı, tabanı 2 ve kuvveti nitelik sayısı olan üstel fonksiyonuna (2^k) eşittir.

Q-Matrisi Belirleme ve Geçerleme Yöntemleri

Q-matrisinin doğru bir şekilde belirlenmesi yapılan değerlendirme sonucunda doğru sınıflandırmalar yapmak için önemlidir. BTM'nin tanısal gücü, teoriye uygun ve ampirik olarak desteklenen niteliklere sahip bir Q-matrisinin belirlenmesine dayanmaktadır (Lee & Sawaki, 2009). Alanyazında Q-matrisinin belirlenmesinde yaygın olarak uzman kanısı kullanılmasına karşın Q-matris belirlenmesinde ampirik yöntemlerin kullanılmasının daha doğru bir Q-matrisi elde etmede önemli olduğuna yönelik çalışmalar da (Chiu, 2013; Close, Davison, & Davenport, 2012; de la Torre, 2008; de la Torre & Lee, 2013; Koyuncu, 2020) bulunmaktadır. Q-matrisi bazı durumlarda niteliklerin az ya da fazla tanımlanması, niteliklerin eksik tanımlanması gibi durumlarda yanlış belirlenebilir. Bu nedenle Q-matrisinin doğruluğuna ilişkin geçerleme çalışmaları (DeCarlo, 2011; DeCarlo, 2012; de la Torre, 2008; de la Torre & Chiu, 2016; Feng, 2013; Ma, 2017; MacDonald, 2013; Koyuncu, 2020; Rupp & Templin, 2008a; Uyumaz, 2016) yürütülmektedir. Bu bölümde Q-matrisi belirleme ve geçerleme yöntemleri ile ilgili açıklayıcı bilgiler sunulmuştur.

Q-matris Belirleme Yöntemleri

Uzman Kanısına Dayalı

Bilişsel değerlendirme alanındaki test geliştiriciler gerekli işlemleri oluşturma çabası içindedirler ve tanılayıcı amaçla yazılan maddelerin bir seti için Q-matrisi oluşturmada bilişsel teorideki alan uzmanlarına başvururlar (Close, Davison & Davenport, 2012). Uzman kanısına dayalı olarak bir Q-matrisini belirlemek için, belirli bir değerlendirmedeki belirli maddelere yanıt verirken, sınava girenlerin hangi psikolojik birimlerin veya bilişsel bileşenlerin (niteliklerin) gerekli olduğunu teori ve deneyimlerine dayanarak belirleyen bir grup alan uzmanı toplanır. Alan uzmanları grubu, değerlendirmede yer alan bilişsel bileşenler üzerinde anlaştıktan sonra, değerlendirmedeki her bir maddenin cevaplanması için

gerekli olan nitelikleri bağımsız olarak belirtmeleri istenir. Bir maddeyi çözmek için bir niteliğin gerekli olması durumunda ağırlığı 1 ve gerekli olmaması durumunda ağırlığı 0'dır. Alan uzmanları kendi ağırlık matrislerini bağımsız olarak oluşturduktan sonra, sonuçları karşılaştırmak ve ulaşmak için tüm grup toplanır ve son ağırlıklı matris üzerinde fikir birliği oluşturur. Elde edilen madde nitelik ağırlıklı matrisi Q-matrisi olarak belirlenir (MacDonald, 2013).

Faktör analizine dayalı yöntemler

Temel bileşenler analizi Q-matrisini üretmede kullanılan bütünsel bir yaklaşımdır (Close, Davison & Davenport, 2012). Temel bileşenler analizi yöntemi, beceri setleri birden fazla madde ile ölçüldüğünde bir Q-matrisi oluşturmada uygulanabilir ve yararlı bir adım olarak ele alınabilir. Maddeler içerik uzmanları tarafından geliştirildikten sonra, bu maddeler pilot uygulama yapılarak test edilir ve maddeler işlevsel olarak kullanılmadan önce Q-matrisine son şeklini vermek için temel bileşenler analizi kullanılır. Bu yöntemde, maddeler her bir nitelik setini ölçen maddelerin yeterli bir sayısı ile dar içeriğin alanlarını kaplayan belirli becerilerin tanımlanabilmesi için tasarlanmalıdır. Bu tür durumlarda, temel bileşen analizi yöntemi Q-matrisinin oluşturulmasını teoriyi güçlendirmek için güçlü bir araç olarak kullanılabilir. Temel bileşenler analizi ile her bir bileşene yüklenene maddeler, aynı beceri setine sahip madde bloklarını belirlemek için incelenir. Bileşenlerin çözümü her bir bileşene yüklenen maddeler tarafından ölçülen beceri setlerinin tutarlılığı açısından mantıklı ise Q-matrisi oluşturulur. Oluşturulan Q-matrisi bileşen çözümünde tanımlanan her beceri için bir boyuta sahiptir. (Close, Davison & Davenport, 2012).

Q-matris Geçerleme (Doğrulama) Yöntemleri

Q-matrislerinin uzman görüşlerine dayalı olarak oluşturulmasından sonra genellikle doğru olduğu varsayılır. Bu varsayımın bir getirisi olarak, uygun olmayan Q-matrisinden kaynaklanan model uyumsuzluğu tespit edilemez veya düzeltilemez (de la Torre & Chiu; 2016). Bu hususta Q-matris geçerlemenin önemi büyüktür.

Sıralı EM Tabanlı Delta Yöntemi

de la Torre (2008) tarafından önerilen sıralı EM (Expectation–Maximization) tabanlı δ yöntemi, Q-matrisi hakkında istatistiksel bilgi sağlayan bir araçtır. K gizil niteliğin araştırılan alanla ilgili olduğunu varsayalım. α_l , K nitelikte tanımlanan 2^K niteliği ifade etsin ($l = 0, 1, \dots, 2^K - 1$ ve α_0 yokluk (null) vektörü $(0, 0, \dots, 0)$ karşılığı olarak alalım). DINA modelde, α_l ile ilgili olarak madde j için q-vektörü gerekli niteliklere sahip olan ve olmayan bireyler arasındaki doğru yanıt olasılıklarının farkını maksimize ederek doğru bir şekilde elde edilebilir. Bu şekilde, doğru q-vektörü olan q_j aşağıdaki şekilde belirlenebilir (de la Torre, 2008).

$$q_j = \arg \max_{\alpha_l} [P(X_j = 1 | \eta_{ll'} = 1) - P(X_j = 1 | \eta_{ll'} = 0)] = \arg \max_{\alpha_l} [\delta_{jl}]$$

$l, l' = 0, 1, \dots, 2^K - 1$. $\eta_{ll'} = \prod_{k=1}^K \alpha_{l'k}^{\alpha_{lk}}$. Çünkü $P(X_j = 1 | \eta_{ll'} = 1) = 1 - s_j$ ve $P(X_j = 1 | \eta_{ll'} = 0) = g_j$. Yukarıdaki denklemde farkı maksimize etmek, veride verilen madde j nin kaydırma (s_j) ve tahmin (g_j) parametrelerindeki toplamını en aza indirmeye eşdeğerdir. Bu nedenle, kaydırma ve tahmin parametrelerinin büyüklükleri kullanılabilir. Bununla birlikte, kaydırma ve tahmin parametre değerlerinin küçük elde edilmesinin yeterli olduğu, ancak model-veri uyumu oluşturmak için gerekli bir koşul olmadığı göz önünde bulundurulmalıdır. Bazı durumlarda, belirli bir nitelik seti verildiğinde maddeler yüksek tahmin veya kaydırma parametrelerine sahip olabilir, ancak farklı bir nitelik seti kullanılmadıkça ek model-veri uyumu iyileştirmesi beklenmez. Sonuç olarak, $\eta_j = 1$ ve $\eta_j = 0$ gruplarındaki bireyler arasındaki doğru yanıtlama olasılıklarındaki fark olarak tanımlan δ_j madde j nin ayırt edicilik indeksi olarak kabul edilebilir. Ancak δ_j maddenin doğal bir özelliği değil, madde q-vektörü değiştikçe değişebilir bir özelliğidir (de la Torre, 2008).

PVAF Yöntemi


Deneyssel Q-matrisi geçerlemenin genel bir yöntemi olarak PVAF (the proportion of variance accounted for) de la Torre ve Chiu (2016) tarafından önerilmiştir. Bu yöntem G-DINA modeli ile birlikte kullanılan ayırt edicilik indeksine (ς^2) dayanır. Genel ayırt edicilik indeksi aşağıdaki gibi tanımlanır.

$$\varsigma_j^2 = \sum_{c=1}^{2^{K_j^*}} w(\alpha_{cj}^*) [P(\alpha_{cj}^*) - \bar{P}_j]^2$$

burada $w(\alpha_{cj}^*)$ indirgenmiş nitelik örüntülerinin (α_{cj}^*) olasılığıdır, $P(\alpha_{cj}^*)$ indirgenmiş nitelik örüntülerinin (α_{cj}^*) başarıma olasılığıdır ve $\bar{P}_j = \sum_{c=1}^{K_j^*} w(\alpha_{cj}^*)P(\alpha_{cj}^*)$ ortalama başarı olasılığıdır. Bu ayırt edicilik indeksi bir maddenin indirgenmiş nitelik vektörlerinin başarıma olasılıklarına dayalı olarak farklı indirgenmiş nitelik vektörleri arasında ayırım yapabildiğini ölçer ve $P(\alpha_{1j}^*) = P(\alpha_{2j}^*) = \dots = P(\alpha_{2^{K_j^*}j}^*) = \bar{P}$ olduğunda minimumdur (yani sıfır). Madde j için ζ^2 nin maksimum değeri (ζ_{jmax}^2) bütün nitelikler ayrıntılı bir şekilde belirtildiğinde elde edilir. PVAf bu maksimum değere göre belirli bir q vektörü ile aşağıdaki şekilde tanımlanır (de la Torre & Chiu, 2016).

$$PVAf = \frac{\zeta^2}{\zeta_{jmax}^2}$$

Q-matris geçerlemesi için en popüler yöntemlerden biri olan PVAf için genel kural açılımlayıcı faktör analizi ve temel bileşenler analizinde üretilen yamaç birikinti grafiğine benzer bir şekilde mesa plot grafiğini yorumlanmasına dayanır. Mesa plot grafiğinin eşik değerindeki q vektöründen gelen gizil sınıf Q-matris geçerlemesindeki becerilerin önerilen bir seti olma eğilimindedir. Şekil 4’te bir mesa plot grafiği sunulmuştur (Collares, 2021).



Şekil 4. PVAf yöntemi kullanılarak Q-matris geçerlemesi için kullanılan mesa plot grafiği örneği Collares, C. F. (2021, February 3). A primer on cognitive diagnostic modelling for the healthcare professions education. <https://psyarxiv.com/jr4m6/>

Şekil 4’te görüldüğü gibi mesa plot grafiği farklı gizil sınıflara, yani farklı beceri setlerine atfedilebilen varyans yüzdesini görselleştirilmektedir. Q-matrisinde tanımlanan bilişsel becerilerin orijinal seti ile varyansın yaklaşık olarak %80’ni karşılanmaktadır. Grafikten %95’den daha fazla varyans açıklamak için belirlenen q vektör setine ek bir niteliğin eklenmesinin yeterli olduğu görülmektedir (Collares, 2021).

Aşamalı (Stepwise) Wald Testi

İki veya daha fazla nitelik içeren bir q vektöründe gerekli olduğu varsayılan niteliğin istatistiksel olarak gerekli olup olmadığını belirlemek için Ma (2017) tarafından aşamalı Wald testi önerilmiştir. Bu yöntem, spesifik olarak bir q vektörünün bir bileşeni sıfıra dönüştürüldüğünde daha kötü bir model veri uyumuna yol açmıyor ise bu niteliğin istatistiksel olarak gereksiz olduğu fikrine dayanır. Bu yöntem, model karşılaştırma perspektifi açısından Q-matrisi geçerlemesi yapılmasına izin verir. Madde j de aşama h için bir q vektöründe bir bileşenin sıfıra dönüşüp dönüşmediğini test etmek istediğimizi farz edelim, $\tilde{q}_{jh} = \{ \tilde{q}_{jhk} \}$ ve $\tilde{K}_{jh}^* = \sum_{k=1}^K \tilde{q}_{jhk}$. Burada , $\tilde{q}_{jh}$ niteliklerin en az ikisine sahiptir (yani $\tilde{K}_{jh}^* \geq 2$) ve q_{jh} ile aynı olması gerekmemektedir. Bir $2^{\tilde{K}_{jh}^*-1} \times 2^{\tilde{K}_{jh}^*}$ kısıtlama (restriction) matrisi R , $R \times \tilde{s}_{jh} = 0$ sıfır hipotezi altında Wald testi için gereklidir. Sıfır hipotezindeki $\tilde{s}_{jh} = \{ \tilde{S}_j(h | \alpha_{l_{jh}}^*, \tilde{q}_{jh}) \}$, $\tilde{q}_{jh}$ kullanıldığında madde j nin kategori h için işlem fonksiyonudur. Örneğin, $\tilde{K}_{jh}^* = 3$ ve $\tilde{q}_{jh} = (1,1,1, \dots)$ varsayalım. Nitelik 1’in istatistiksel olarak gerekli olup olmadığını test etmek için, sıfır hipotezi aşağıdaki gibidir (Ma, 2017).

$$\begin{bmatrix} 1 & -1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & -1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & -1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & -1 & 1 \end{bmatrix} \times \begin{bmatrix} \tilde{S}_j(h|000, \tilde{q}_{jh}) \\ \tilde{S}_j(h|100, \tilde{q}_{jh}) \\ \tilde{S}_j(h|010, \tilde{q}_{jh}) \\ \tilde{S}_j(h|001, \tilde{q}_{jh}) \\ \tilde{S}_j(h|110, \tilde{q}_{jh}) \\ \tilde{S}_j(h|101, \tilde{q}_{jh}) \\ \tilde{S}_j(h|011, \tilde{q}_{jh}) \\ \tilde{S}_j(h|111, \tilde{q}_{jh}) \end{bmatrix}$$

Nitelik 2 ve 3’ün gerekliliğini test etmek için kısıtlama matrisi sırasıyla şu şekildedir (Ma, 2017):

Nitelik 2 için;

$$\begin{bmatrix} 1 & 0 & -1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & -1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 & -1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 & -1 \end{bmatrix}$$

Nitelik 3 için;

$$\begin{bmatrix} 1 & 0 & 0 & -1 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & -1 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 & -1 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 & 0 & -1 \end{bmatrix}$$

Wald testi aşağıdaki gibi tanımlanır:

$$W = [R \times \tilde{s}_{jh}]' [R \times V_{jh} \times R']^{-1} [R \times \tilde{s}_{jh}]$$

burada V_{jh} , boyutu $2^{\tilde{K}_{jh}^*} \times 2^{\tilde{K}_{jh}^*}$ olan $\tilde{s}_{jh}$ nin varyans-kovaryans matrisidir. Wald istatistiği W $2^{\tilde{K}_{jh}^* - 1}$ serbestlik derecesi ile dağılan asimptotik χ^2 dir (Ma, 2017).

Q-Matrisi İyileştirme Yöntemi

Chi (2013) tarafından önerilen Q-matris iyileştirme yöntemi parametrik olmayan sınıflama yöntemine dayalıdır ve gözlenen ve ideal madde yanıtlarından hesaplanan artık (residual) kareler toplamının (RSS - Residual sum of Squares) karşılaştırılmasını içerir. Y_{ij} ve η_{ij} sırasıyla sınava giren i. kişinin j. maddeye verdiği gözlenen ve ideal yanıtlar olsun. i. kişi için j maddesine ait RSS aşağıdaki gibi tanımlanır.

$$RSS_{ij} = (Y_{ij} - \eta_{ij})^2$$

Sınava giren tüm bireylere ait j. maddesinin RSS değeri aşağıdaki gibi hesaplanır:

$$RSS_{ij} = \sum_{i=1}^N (Y_{ij} - \eta_{ij})^2 = \sum_{m=1}^{2^K} \sum_{i \in C_m} (Y_{ij} - \eta_{jm})^2$$

Yukarıdaki formülde C_m m gizil yeterlilik-sınıfıdır ve N sınava giren kişi sayısıdır. Madde j için ideal yanıt indeksine dikkat edilirse “ij” den “jm” ye değişmektedir; çünkü ideal madde sınıfa özgüdür. Böylece aynı sınıftaki her birey bir madde için aynı ideal yanıtı sahiptir. Yanlış belirlenmiş bir q-vektörü için tanımlanan bir kayıp (loss) fonksiyonu olarak RSS kullanımını doğru q vektörünün RSS'sinin, sınava girenlerin doğru bir sınıflandırması verildiğinde, tüm olası q vektörlerinin en düşük RSS'si olması beklendiği görüşüne dayanır. Her bir maddenin RSS değeri diğer tüm maddelerin RSS değerinden bağımsız olduğundan, yanlış belirlenen q-vektörü düzeltildiğinde testin toplam RSS değeri minimize edilmiş olacaktır (Chi, 2013).

İlgili Araştırmalar

Araştırmanın bu bölümünde zaman sıralaması dikkate alınarak alanyazındaki ilgili çalışmalara yer verilmiştir.

Rupp & Templin (2008a) DINA model için Q-matrisinin yanlış belirlenmesinin parametre kestirimleri ve yanlış sınıflandırma oranları üzerinde etkisini incelemiştir. Çalışmada dört bağımsız niteliğe dayalı tüm 15 olası nitelik örüntüsünü eşleştiren bir değerlendirme için her bir madde için “0” veya “1” değerleri değiştirilerek yanlış belirlenmeler oluşturulmuştur. Q-matrisindeki bu değişimler belirli nitelik kombinasyonlarının tamamen silinmesiyle yapılmış ve nitelikler arasında belirli yanlış bağımlılık ilişkileri tanımlanmıştır. Sonuç olarak, nitelikler Q-matrisinden silindiğinde kaydırma parametresinin maddeye özgü aşırı kestirimleri elde edilmiştir. Nitelikler Q-matrisine eklendiğinde ise tahmin parametresinin maddeye özgü aşırı kestirimleri tespit edilmiştir. Ayrıca Q-matrisinden silinen nitelik kombinasyonlarını içeren nitelik sınıfları için yüksek yanlış sınıflandırma oranları elde edilmiştir.

Chiu (2008) madde-özellik gerektiren bir yaklaşım olarak kümeleme analizi ve hiyerarşik algomeratif (agglomerative) kümeleme analizi yöntemlerini incelemiştir. Araştırmada sınıflandırma doğruluğu sonuçları, test uzunluğu ve kümeleme yönteminin etkilerini karşılaştıran simülasyonlarla birlikte verilmiştir. Ayrıca yöntemlerin pratikte nasıl kullanılacağına yönelik olarak bir dil sınavı üzerinde analizler yapılmıştır. Sonuçlardan yola çıkarak, bilişsel tanımlama amacıyla kümeleme analizi yöntemlerinin kullanımı kısıtlanmış gizil sınıf modellerinin bir alternatifi olarak önerilmiştir. Aynı zamanda, kümelemenin dayandığı istatistik her bir nitelik çifti için daha iyi ayrım yapan beklenen değerlere dayalı olduğunda daha doğru sınıflama yapacağı gösterilmiştir. K-ortalama kümeleme analizi ve hiyerarşik algomeratif kümeleme analizi yöntemlerinin bilişsel tanı modellerinden DINA modelleri ile benzer ya da daha iyi performans gösterdiği belirlenmiştir.

de la Torre (2008) bir Q-matrisinin uygunluğunu geçerlemede DINA modeli ile birlikte kullanılan bir Q-matrisini doğrulamak için deneysel temelli bir yöntem önermiştir. Q-matrisini geçerlemenin deneysel temelli bir yöntemi olan sıralı EM tabanlı δ -yöntemiyle optimal bir q vektörü seçilerek model-veri uyumunun geliştirilmesi amaçlanır. Sıralı EM tabanlı δ -yöntemi Q-matrisinin yeniden değerlendirilmesinde kullanışlı olan bilgiler sağlar. İlgili çalışma ile q vektörü yanlış belirlenmesinin bir çeşiti ve derecesinin sunulduğu simülasyon çalışmasıyla önerilen yöntemin potansiyel olarak uygulanabilirliği

gösterilmiştir. Önerilen yöntem sayesinde uygun olmayan q vektörlerini belirleyip doğru bir şekilde değiştirebilmekte ve aynı zamanda doğru bir şekilde belirlenen q vektörleri ise korunabilmektedir. Araştırma kapsamında belirlenen simülasyon koşulları altında incelenen yöntemin birinci ve ikinci tip hataları sıfırdır.

Henson, Roussos, Douglas & He (2008) bilişsel tanı modelinde bir madde için nitelik düzeyi ayırt edicilik indekslerini genelleştirmeyi amaçlamışlardır. Üç farklı nitelik düzeyi ayırt edicilik indeksi tanımlanmış ve bu indekslerin doğru sınıflama oranları ile ilişkisini belirlemek için Monte Carlo simülasyon yöntemi kullanılmıştır. Sonuç olarak tanımlanan ayırt edicilik indeksleri ile doğru sınıflama oranları arasında güçlü ilişkiler olduğu tespit edilmiştir. Çalışmada sunulan ayırt edicilik indekslerinin nitelik düzeyi doğru sınıflama oranları ile yakın ilişkilerinden dolayı, bu ayırt edicilik indekslerin önemli potansiyel uygulaması maddelerin kalibre edildiği bir bilişsel tanı modelinde test edilir.

Cheng (2010) bilişsel tanı bilgisayar uyarlamalı testler için yeni bir madde seçim yöntemi olan maksimum küresel ayırt edicilik indeksini önermektedir. Araştırma kapsamında önerilen bu yöntem maddeyi iki farklı yönden değerlendiriyor. Bunlardan biri her niteliğin yeterli bir şekilde kapsanmasına yönelik katkı miktarıdır. Madde seçiminde dikkate aldığı diğer bir yaklaşım ise gizil bilişsel profilin iyileştirilmesine yapabileceği katkı miktarıdır. Çalışma sonucunda, bilişsel tanı bilgisayar uyarlamalı testlerde madde seçim için önerilen maksimum küresel ayırt edicilik indeksi yöntemi orijinal küresel ayırt edicilik indeksi yöntemleri ile karşılaştırıldığında her bir nitelik iyileşme oranının ve tüm bilişsel profilin gelişimini sağladığı belirtilmiştir.

de la Torre & Lee (2010) DINA bilişsel tanı modellerinden olan DINA modele ve bu modelin parametre değişmezliğine odaklanmıştır. Simülasyon yardımı ile elde edilen farklı yetenek dağılımları içeren veri setleri üzerinden analizler gerçekleştirilmiştir. Sonuç olarak DINA modelin mükemmel bir şekilde veriye uyum sağladığı durumda, model parametrelerinde mutlak bir değişmezlik olduğu tespit edilmiştir. Farklı yetenek gruplarını içeren ek örnekte ise gerçek verideki gürültünün (noise) bu parametrelerin değişmezliğinin olmamasına nasıl neden olduğu gösterilmiştir.

DeCarlo (2011) DINA modeli altında Q-matrix yanlış belirlenmelerinin gizli sınıf büyüklükleri üzerindeki etkisini incelemiştir. Birleşmeye yakın bir veya daha fazla beceri için gizli sınıf büyüklüğü tahminleri yapılacaksa, Q-matrisinin yanlış tanımlanmış olma olasılığının dikkate alınması gerektiği belirlenmiştir. Ayrıca gizli sınıf büyüklüklerinin elde

edilen geniş kestirimlerinin ilgisiz becerilerin Q-matrisine dahil edilmesi gibi Q-matrisi yanlış belirlemeleri gösterebileceği belirlenmiştir. Analitik olarak ve simülasyonlar ile problemlerin büyük ölçüde Q-matrisinin yapısı ile ilgili olduğu belirlenmiştir.

Lee, Park ve Taylan (2011) çalışmasında TIMSS 2007 dördüncü sınıf matematik testinde DINA modelini kullanmıştır. Çalışma grupları ise 564 öğrenci ABD ülke örnekleme, 132 öğrenci Minnesota eyaleti örnekleme ve 127 öğrenci Massachusetts eyaleti örnekleme oluşturmaktadır. Araştırmacılar, çalışmadan elde edilen ana bulgunun DINA modelinin doğrudan sınıf öğretimine uygulanabilecek zengin ve tanılayıcı bilgileri sağladığını vurgulamıştır. İlgili çalışmada MTK Modellerinden 1 parametrelili lojistik model, 2 parametrelili lojistik model ve 3 parametrelili lojistik model altında yapılan kestirimler ile BTM'lerinden DINA Model altında yapılan kestirimlerin birbirleriyle kıyaslamasına gidilmiştir. Sonuç olarak, bir maddeyi çözmek için gereken doğru yanıtlama ve ustalaşma becerileri oranları arasında önemli bir farklılık olduğu belirtilmiştir.

Kunina-Habenicht, Rupp ve Wilhelm (2012), bir simülasyon çalışması ile, log-lineer modelleme çerçevesinde doğru ve yanlış belirlenmiş bilişsel tanı modelleri için sınıflandırma doğruluğu ve iki madde uyum istatistiğinin performansını farklı koşullar altında araştırmışlardır. Araştırma kapsamındaki test edilen faktörler; örneklem büyüklüğü (1.000 ve 10.000), nitelik sayısı (3 ve 5) ve madde sayısı (25 ve 50) ile nitelik korelasyonları (.50 ve .80) ve marjinal nitelik zorlukları (eşit ve farklı)'dır. Çalışmanın bulgularına göre nitelik sayısı daha az olduğunda doğru sınıflama oranlarının marjinal ortalaması daha fazla çıkmaktadır. Ancak örneklem büyüklükleri dikkate alındığında doğru sınıflama oranlarının marjinal ortalaması üzerinde farklılık olsa da anlamlı bir etkinin olmadığı görülmektedir.

Close, Davison, & Davenport (2012) DINA modeline uygun bir veri setinde açıklayıcı bir teknik olarak temel bileşenler analizinin bilişsel tanı testlerinde Q-matrisinin belirlenmesinde kullanılabilirliğini incelemiştir. DINA model kullanılarak simüle edilen veri seti üzerinde analizler gerçekleştirilmiştir. Q-matrisinin üç niteliği içeren 21 madden olduğu tasarlanmıştır. Çalışmada Q-matris geliştirme için temel bileşenler analizi yöntemi nitelik setleri birden fazla madde ile ölçüldüğünde Q-matris oluşturmada uygulanabilir ve yararlı bir adım olarak ele alınmıştır. Uzmanlar tarafında geliştirilen maddelerin pilot olarak test edilmesi ve maddeler operasyonel olarak kullanılmadan önce Q-matrisine son şeklini vermeden temel bileşenler analizi ile değerlendirilmesi önerilmektedir. Sonuç olarak, temel

bileşenler analizi Q-matrisinin geliştirilmesinde teoriyi güçlendirmek için güçlü bir araç olarak kullanılabilir olduğu vurgulanmıştır.

DeCarlo (2012) Q-matrisi genellikle uzman değerlendirmesi ile belirlenmesi ve bu nedenle bazı unsurları hakkında ortaya çıkan belirsizliğin modelinin Bayesian bir uzantısı yoluyla tanınabileceği ve araştırılabileceğini göstermiştir. Kullanılan yaklaşımda Q-matrisinin bazı öğeleri sabit olmaktan ziyade rastgele olarak belirlenir, sonsal (posterior) dağılımlar daha sonra Q matrix'e dahil edilmesi şüpheli olan unsurlar hakkında bilgi elde etmek için kullanılır. Araştırma kapsamında Q-matrisindeki öğelerin yanlış belirlendiği veya belirsiz bırakıldığı koşullar oluşturulmuştur. Yapılan simülasyonlar, Q-matrisinin bazı unsurları hakkında belirsizlik olduğunda bu yaklaşımın gerçek Q-matrisini düzeltmeye yardımcı olduğunu göstermiştir. Sonuç olarak, Bayesian yaklaşımının Q-matrisi ve nitelik sayısı en azından genel olarak doğru bir şekilde belirlendiğinde, maddelerin hangi niteliklere yüklenmesi gerektiğini tespit etmek için yararlı bir yöntem olarak bulunmuştur.

Cui, Gierl & Chang (2012) sınıflama tutarlılığının ve doğrulunun incelenmesindeki boşluğu doldurmak için iki yeni sınıflama indeksini inceledikleri çalışmada simülasyon yardımı ile geliştirdikleri indekslerin performanslarını incelemişlerdir. Sınıflama tutarlığı indeksi ve sınıflama doğrulu indeksi olarak isimlendirdikleri iki indeksin performansını DINA modele dayalı olarak incelemişler, ancak madde tepki fonksiyonu açık bir şekilde tanımlandığından diğer bilişsel tanı modellerinde de uygulanabilir olduğunu ifade etmişlerdir. Bu iki indeksin daha ayırt edici maddelerde, niteliklerin sayısı daha az olduğunda ve nitelikler arasındaki bağımlılık daha fazla olduğunda beklentiler ile tutarlı olarak daha yüksek değerler ürettikleri belirlenmiştir.

de la Torre ve Lee (2013) kapsadığı azaltılmış modellerin uyumlarına göre doymuş (saturated) bilişsel tanı modellerin madde-düzey uyumu değerlendirmek için Wald testi kullanmıştır. G-DINA model kapsamında Wald testin birinci tip hata ve gücünü incelemek için bir simülasyon araştırması gerçekleştirmişlerdir. Wald test performansı ayrıca gerçek veri seti üzerinden de gerçekleştirilmiştir. Sonuç olarak, örneklem büyüklüğü küçüldüğünde ve daha fazla nitelik sayısı gerektiğinde, DINA ve DINO modeller için Wald testinin birinci tip hata oranı nominal anlamlılık düzeylerinden daha yüksek ancak eklemeli BTM'in birinci tip hata oranı nominal anlamlılık düzeyine daha olduğu belirlenmiştir.

Chiu (2013) Q-matrisinin uygunluğunu geçerlemede parametrik olmayan sınıflama yöntemine dayalı bir yöntem önermiştir. Gözlenen ve ideal madde yanıtlar dikkate alınarak

hesaplanan artık (residual) kareler toplamının karşılaştırılmasını içeren bu yöntem Q-matris iyileştirme yöntemi olarak adlandırılmıştır. Araştırma kapsamında yapılan üç simülasyon çalışması ve bir gerçek veri seti uygulamasından elde edilen sonuçlara göre önerilen yöntemin yanlış tanımlanmış bir Q-matrisinin geçerlemesi sonucunda doğru Q-matrisi elde etme etmede etkili ve verimli bir yöntem olduğu gösterilmiştir. Yanlış tanımlanmış q girişleri ve q vektörlerinin sayısı ve türü Q-matrisi iyileştirme yönteminin performansı çok az etkiye sahip olduğu tespit edilmiştir. DINA modeli ya da genelleştirilmiş NIDA modeline uyan gözlenen madde yanıtları için önerilen yöntem bu yanıtların hata bozulmasının (perturbation) önemli bir derecesini tolere edebileceğini ortaya koymuştur. Ancak Q-matrisi iyileştirme yönteminin niteliklerin toplam sayısının yanlış belirlenmesi gibi Q-matrisindeki yanlış belirlemelerin diğer türleri ile başa çıkmada sınırlı olabileceği belirtilmiştir.

Feng (2013) alan yazındaki Q-matrisi geçerleme yöntemlerinin bilişsel tanı modellerinden DINA modeli için incelendiği sınırlılığından yola çıkarak daha esnek bilişsel tanı modelleri olan indirgenmiş RUM ve DINO modelleri için Q-matrisi geçerleme işlemlerinin geliştirilmesine odaklanmıştır. Sıralı araştırmaya dayalı δ -yöntemi ile Bayesian modelleri fikrini birleştiren iki aşamalı yöntem ile simülasyon veride yapılan incelemelerde her iki model için de Q-matris geçerlemesinin iyi performans sergilediği belirlenmiştir. Ayrıca R-RUM modelinde bu geçerleme yönteminin performansı gerçek veri seti üzerinden de incelenmiştir. Çalışmada yapılan kestirim yöntemi incelemelerinde ise EM algoritmasının R-RUM için madde parametre tahmininde önemli zaman tasarrufu ile iyi performans gösterdiği tespit edilmiştir.

de la Torre ve Chiu (2016) Q-matrisinin oluşturulmasının büyük bir ölçüde öznel süreçlere dayanması ve bu sürecin Q-matrisinde yanlış belirlemelere neden olmasından yola çıkarak Q-matrisindeki yanlış belirlemelerin tanımlanması ve iyileştirilmesi için bilişsel tanı modellerinin birçoğunda kullanılabilecek bir ayırt edicilik indeksi önermeyi amaçlamıştır. Bu amaca yönelik olarak G-DINA modelinde kullanılabilen bir ayırt edicilik indeksi yardımı ile Q-matrisindeki yanlış belirlemelerin tanımlanması ve düzeltilmesi Q-matris özelliklerinin deneysel olarak geçerlemesini incelemiştir. Araştırmada önerilen indeksin matematiksel alt yapısı açıklanmış ve önerilen yöntemin uygulanabilirliği çeşitli koşullara göre üretilen veri setleri üzerinden test edilmiştir. Tüm nitelikler belirlendiğinde ulaşılan maksimum ayırt edicilik indeksine göre belirli bir q vektörüyle hesaplanan varyans oranına (PVAf) dayalı bir kriter kullanılmıştır. Çalışmaların sonuçları, yöntemin, özellikle yüksek kaliteli maddeler söz konusu olduğunda, doğru girişleri değiştirmeden yanlış belirlenmiş q

girişlerini doğru bir şekilde tanımlayıp düzeltebileceğini göstermiştir. Ayrıca gerçek veri seti üzerinde de önerilen yöntemin uygulaması yapılmıştır. Araştırma sonucunda önerilen yöntemin Q-matrisindeki doğru tanımlanan girişleri değiştirmeden yanlış belirlenmiş Q-matrisi girişlerini tanımlayıp düzelttiği belirlenmiştir. Diğer bir ifadeyle önerilen yöntemin muhtemelen yanlış tanımlanmış q-vektörlerini belirleyebileceğini gösterilmiştir.

Sünbül (2013), BTM’lerde madde parametre kestirimini, madde uyumunu ve sınıflama tutarlılığını etkileyen faktörlerin neler olduğunu incelemek için. DINA Model ile örneklem büyüklüğü, özellikler arası korelasyon, özellik sayısı, madde sayısı, s ve g parametre düzeyleri koşulları altında simülasyon çalışması yapmıştır. Veri analizi için R 3.0 yazılımı ve CDM paketi kullanılmıştır. Parametre kestirimlerinde; g parametre kestirimi için elde edilen “Mutlak Ortalama Yanlılık (MOY)” ortalamalarına, örneklem büyüklüğünün, madde sayısının ve parametre düzeylerinin anlamlı bir etkisinin olduğu bulunmuşken, s parametre kestiriminden elde edilen MOY ortalamalarına ise, örneklem büyüklüğünün, özellikler arası korelasyon düzeyinin ve parametre düzeylerinin anlamlı bir etkisinin olduğu gözlenmiştir. Madde uyumu için elde edilen RMSEA ortalama değerlerine göre ise, örneklem büyüklüğünün, özellik sayısının, madde sayısının ve parametre düzeylerinin anlamlı bir etkisinin olduğu gözlenmiştir. Sınıflama tutarlılığı için elde edilen “Doğru Sınıflama Oranları (DSO)” sonuçları incelendiğinde ise, özellik sayısının, madde sayısının ve parametre düzeylerinin anlamlı bir etkisinin olduğu gözlenmiştir.

Zhao (2013), çalışmasında BTM kapsamındaki telafi edici olmayan dört modelin (AHM, DINA, Fusion, and Bayesian Networks) performansını karşılaştırmış ve bu dört modeli parametre kestirim sonuçları ile model uyumları açısından betimlemiştir. Bu çalışmada Tatsuoaka’nın (1984) Kesirlerde Çıkarma veri seti, TIMSS 4. Sınıf Matematik Değerlendirmesi veri seti ve FCSA (The Foundational Concepts of Slope Assessment) veri seti kullanılmıştır. AHM’nin madde parametre kestirim aşamasında ve sınıflandırma aşamasında sırasıyla OpenBUGS ve FORTRAN; Hem DINA hem de Bayesian Network modeli için OpenBUGS; Fusion Modeli içinse Arpeggio 3.1 (DiBello & Stout, 2010) kullanılarak analiz edilmiştir. Bu çalışmanın sonuçları şu şekildedir: (1) AHM, nitelik bağımlılıkları ile ilgili teorik kestirimler önsel olarak belirlendiğinde, öğrencileri sınıflandırmada daha iyidir. (2) DINA modeli basit bir BTM olarak düşünülse de, belirli veri seti için öğrenci sınıflandırması hakkında daha fazla bilgi sağlayabilir. (3) Fusion Modeli, Kesir ve TIMSS veri setinde daha iyi uyum sağlayabilir ve hesaplama maliyeti beklenenden daha azdır. (4) Bayesian Networks yaklaşımı esnek bir teknik oluştururken, bu çalışmadaki

Slope veri seti ile Kesir veri setinde uyum ve model yorumu bakımından üstünlük sağlamıştır.

MacDonald (2013) maddeler ve nitelikler arasındaki ilişkilerin yanlış belirlendiği durumlarda doğrusal lojistik test modelinin (LLTM) performansını incelemek amacıyla bir simülasyon çalışması yürütmüştür. LLTM performansı Q-matrisinin hatalı belirlenme oranı, Q-matrisinin yanlış belirlenme şekli, örneklem büyüklüğü, Q-matrisi yoğunluğu, madde sayısı ve kişi yetenek dağılımının çarpıklığına göre incelenmiştir. Çalışmada tasarlanan bu faktörlerin madde gücü ve birey yetenek kestirimleri üzerindeki etkisi yorumlanmıştır. Sonuç olarak, parametre kestirimlerinin yanlış belirlemeye karşı hassas olduğu, yetersiz belirlenmiş Q-matrisinin aşırı belirlenmiş Q-matrisine tercih edilebileceği, örneklem büyüklüğü 80'den büyük olduğunda nitelik parametre kestirimlerinin doğru bir şekilde belirlenmesinin tolere edilebilir hataya sahip olduğu belirlenmiştir. Ayrıca LLTM yönteminin madde sayısı 40 ve daha fazla olduğunda daha iyi çalıştığı ve yetenek dağılımındaki hafif çarpıklıklara karşı güçlü olduğu belirlenmiştir.

Sorrel, Olea, Abad, de la Torre, Aguado & Lievens (2016) test puanlarının geçerliğini ve güvenilirliğini değerlendirmede geleneksel yöntemlerin yerine bilişsel tanı modellerinin kullanımını göstermiştir ve geleneksel yöntemlerin bu konuda sınırlılıklarının bilişsel tanı modelleme kullanılarak üzerinden gelindiğini ifade etmiştir. Yirmi üç maddelik durumsal kaygı testi üzerinden analizleri gerçekleştirmişlerdir. Q-matris belirlenmesi analizi, model uyumu ve model parametre tahminleri geleneksel test puanlarının geçerliliğini belirleme yöntemlerine göre daha fazla bilgi sağlamaktadır.

Uyumaz (2016) Q-matrisinin farklı biçimlerde hatalı belirlenmesinin (düzen, oran, madde blokları, bağımlılık ilişkisi), farklı örneklem büyüklüklerinde madde parametrelerine ve bireylerin sınıflandırılmalarına etkisini incelemiştir. DINA modele uygun simülatif olarak oluşturulan veri setleri üzerinden analizler gerçekleştirilmiştir. Q-matrisinin eksik belirlendiği koşullarda, eksik belirleme yapılan maddelere ait kaydırma parametreleri ve fazla belirleme yapılan koşullarda ise fazla belirleme yapılan maddelere ilişkin tahmin parametreleri yüksek değerde kestirildiği belirlenmiştir. Araştırma kapsamında incelenen tüm koşullarda, parametre kestirimleri Q-matrisinin hatalı belirlenmesinden etkilenirken bireylerin hatalı Q-matrisi kullanılarak olası farklı gizil sınıflara yerleştirilmelerindeki oranları ile hatasız Q-matrisi ile elde edilen sınıflama oranların farklılaşmadığı tespit edilmiştir.

Ma (2017) çoklu puanlanan maddelerin özel bir türü için genel bir bilişsel tanı modeli önermektedir. Kullanılan madde türünde, madde kategorileri sıralı bir şekilde elde edilir ve açıkça bazı nitelikler ile ilişkilendirilir. Önerilen model ve işlemlerin performansı hem Monte Carlo simülasyon çalışması kullanılarak elde edilen veriler hem de gerçek veri seti üzerinden incelenmiştir. Araştırılan çoğu koşul altında, çalışılan yöntemlerin benzer güç oranlarına sahip olduğu ve tüm koşullar altında iyi olan tek bir yöntemin olmadığı sonucuna ulaşılmıştır.

Yakar (2017) ortak noktaları bulunan bilişsel tanı modelleri ile çok boyutlu madde tepki kuramı modellerinin birbiri yerine kullanım durumlarını incelemeyi amaçlamıştır. Araştırma kapsamında iki parametrelili çok boyutlu madde tepki kuramı modeli ile tam eklenir olan bilişsel tanı modeli kullanılmıştır. Madde ayır edicilik indeksi, test maddelerinin yapılarına göre oranı, test uzunluğu ve yetenekler arası korelasyon değerlerinin farklı koşulları altında telafisel ve telafisel olmayan veri setine dayalı olarak üretilen veri setleri üzerinden analizler yürütülmüştür. Tüm koşullarda çok boyutlu madde tepki kuramı ve bilişsel tanı modeli sonuçlarının benzer olduğu sonucuna ulaşılmıştır. Ayrıca birey parametre doğruluğunun artışı etkileyen en önemli koşulun test uzunluğu olduğu ortaya konulmuştur.

Baykal Yetimler (2019) bilişsel tanı modellemede Q-matrisinin hata profilleri üzerine uyarlamasını içeren bir çalışma yürütmüştür. Çalışma kapsamında öğrenci cevapları için ters kodlanmış veri kullanılarak hata matrisi ile birlikte analizi gerçekleştirilmiştir. DINA modeline dayalı olarak gerçekleştirilen analizler sonucunda araştırma kapsamında hata profillerine dayalı oluşturulan Q-matrisinin bilişsel profiller, kazanım profilleri ve test toplam puanları ile uyumlu olduğu tespit edilmiştir.

Ceylan (2019) bilişsel tanı modellerinde veri ve Q-matrisi genişletme yönteminin gizil sınıf dağılımları üzerindeki etkisini incelemeyi amaçlamıştır. Araştırmacı bu doğrultuda karma maddelerden oluşan test yapılarından kısmi puanlamanın bilişsel tanı modellerine göre gizil sınıf değişmezliği etkisini araştırmış, veri ve Q-matrisi genişletme yöntemlerinin gizil sınıf değişmezliğine etkisini incelemiştir. Altıncı sınıf düzeyinde üst düzey düşünme becerilerini ölçecek biçimde oluşturulan maddeler içeren matematik testi ile toplanan veri seti üzerinden analizler yapılmıştır. Sonuç olarak, kısmi puanlama yapılması durumunda Q-matrisi ve veri genişletildiğinde öğrencilere ilişkin elde edilen bilgilerin daha detaylı olduğu ve öğrencilere daha açık geri bildirim verebilme şansı elde edildiği belirlenmiştir.

Koyuncu (2020) yapısal eşitlik modellemesine dayalı Q-matrisi modifikasyon önerisinin nasıl yapılacağına yönelik incelemeler yapmış ve bu yöntem ile elde edilen sonuçların PVAF, Stepwise Wald testi Q-matris modifikasyon yöntemleriyle ve uzman kanısına dayalı Q-matrisi ile karşılaştırarak incelemiştir. Gerçek veri seti üzerinden yapılan analizlerde G-DINA modeli altında elde edilen model veri uyumu, madde parametreleri ve sınıflama doğrulukları incelenmiştir. Sonuç olarak, yapısal eşitlik modellemesine dayalı Q-matrisi geçerleme yönteminden elde edilen sonuçlar ile PVAF ve Stepwise Wald yöntemlerinden elde edilen sonuçların uyumlu olduğu belirlenmiştir. G-DINA modeline göre üç yöntemin model veri uyumu incelendiğinde ise en model veri uyumunun Q-matrisinin PVAF yöntemi ile geçerlemesi ile olduğu, yapısal eşitlik modellemesine dayalı Q-matrisi geçerlemesinin ise Stepwise Wald testine göre daha model veri uyumu gösterdiği belirlenmiştir. Uzman görüşüne dayalı Q-matrisinin G-DINA modele göre model veri uyumu ise yapısal eşitlik modellemesine göre belirlenen Q-matrisi belirlemesine göre daha düşüktür. Sınıflama doğruluğu açısından değerlendirildiğinde ise yapısal eşitlik modellemesine dayalı geçerleme yönteminin sınıflama doğruluğu oranının PVAF ve Stepwise Wald yöntemleriyle elde edilen sınıflama doğruluğu oranlarına benzer olduğu belirlenmiştir.

Ardıç (2020) üç parametrelili çok boyutlu madde tepki kuramı ile bilişsel tanı modelleriyle kestirilen birey parametrelerinin sınıflama doğruluğunu incelemiştir. Bu kapsamda analizlerini hem simülasyona dayalı hem de gerçek veri üzerinden gerçekleştirmiştir. Araştırmanın sonucunda tüm test koşullarında üç parametrelili çok boyutlu madde tepki kuramının en düşük hata ve yanlışlık değerine sahip olduğu, test uzunluğu ve nitelikler arası korelasyonun artması ile hatanın azaldığı tespit edilmiştir. Ayrıca yanlışlık değerlerinin düşmesinde en etkili koşulun ise madde sayısı olduğu belirlenmiştir. Nitelik ve nitelik profillerinin eşit sayıda ölçüldüğü durumlarda ise Q-matrisinin kullanılmasının daha yüksek oranda doğru sınıflama yapılmasını sağladığı ortaya konulmuştur.

Nájera, Sorrel, de la Torre, & Abad (2020) bilişsel tanı modellerinde sınıflandırma doğruluğuna etki eden Q-matrisinin bazı hatalı belirlemelerini düzeltmeye yönelik olarak geliştirilen genel ayırt edicilik indeksi ve Wald testi gibi Q-matris doğrulama yöntemlerinin yetersiz olabileceği noktaları göz önüne alarak bu yöntemlerin sınırlılığını gidermek için Q-matrisi geçerlemede Hull yöntemini önermişlerdir. Önerilen yöntem uyum ve tutuculuk (parsimony) arasındaki optimal dengeyi bulmayı amaçlar madde ayırıcılık (hesaplanan varyans oranı-PVAF) ya da belirleme katsayısı ile kullanılabilecek kadar esnektir. Simülasyona dayalı üretilen veri seti üzerinden incelemeler yapılmıştır. Sonuç olarak, Hull

yönteminin, özellikle PVAF kullanıldığında, tutarlı bir şekilde en iyi performansı gösterdiği belirlenmiştir.

Alanyazında birçok çalışma, yanlış tanımlanmış bir Q-matrisin parametre kestirimlerini olumsuz etkileyebileceğini ve bireylerin yanlış sınıflandırılmasına yol açabileceğini göstermiştir (Chiu ve Douglas, 2013; de la Torre, 2009; Im ve Corter, 2011; Kunina-Habenicht, Rupp ve Wilhelm, 2012; Rupp ve Templin, 2008a, Uyumaz, 2016).



BÖLÜM III

YÖNTEM

Bu bölümde araştırmanın modeline, evren ve örnekleme, veri toplama aracına, veri analizine ve değerlendirme kriterlerine yer verilmiştir.

Araştırmanın Modeli

Bu araştırmada farklı belirlenmiş Q-matrislerinin değişen dağılım koşullarında elde edilen sınıflamalara dayalı olarak sınıflama doğruluğu, model veri uyumları ile tahmin ve kaydırma parametreleri karşılaştırmalı olarak incelenmektedir. Bu çalışma, ele alınan değerlendirme kriterlerine göre belirli koşullar altında en uygun sınıflama sağlayan Q-matrisini sunması yönüyle ve Q-matrisinin belirlenmesine yönelik çalışmaların gelişmesine katkı sağlayacağı düşüncesiyle temel araştırma niteliğindedir (Wiersma & Jurs, 2005). Bununla birlikte araştırma kapsamındaki öğrencilerin BTM'ye dayalı olarak yapılan sınıflamaya ilişkin bulguları incelenmektedir. Bununla birlikte gerçek veri setinden elde edilen bulgulara dayalı olarak mevcut durumun ne olduğunun belirlenmesi yönüyle ise betimsel araştırma özelliğini taşımaktadır (Gall, Gall & Borg; 2007-s301).

Evren ve Örneklem

Bu araştırmanın evrenini “Uluslararası Geniş Ölçekli Sınavlarda Türkiye'nin Matematik Başarısını Arttırabilmek İçin Bir Model Önerisi: Bilişsel Tanıya Dayalı İzleme Modelinin Etkililiği” başlıklı ve 115K531 No'lu TÜBİTAK Projesinde son test uygulamasına katılan 4292 altıncı sınıf öğrencisi oluşturmaktadır. Bu öğrencilerden kasıtlı örnekleme yoluyla çekilen 500'er kişilik dokuz grup ise çalışmanın örneklemini oluşturmaktadır. Bu

örneklemeler araştırma kapsamında ele alınan dokuz koşula uygun olarak elde edilmiştir. Örneklemi oluşturan bu grupların çekilmesi araştırma kapsamında R Studio ortamında geliştirilen bir fonksiyon yardımıyla gerçekleştirilmiştir (Ek 1). Geliştirilen bu fonksiyon ile yeniden örnekleme yapılmadan evren veri setinden belirlenen bir örneklem büyüklüğünde, istenen merkezi eğilim ve dağılım ölçüleri ile normallikten sapma ölçülerine sahip (çarpıklık ve basıklık) örneklemeler elde edilebilmektedir. Bu fonksiyon yardımıyla evrenden araştırma kapsamında ele alınan koşullara en yakın özellikteki dağılımı sağlayabilecek örneklemeler elde edilmeye çalışılmıştır. Daha sonra Excel’de “=DÜŞEYARA” fonksiyonundan yararlanarak tüm veri setinden çekilen istendik dağılım özelliklerine sahip örneklemde bulunan bireylere ait 1-0 cevap örüntüleri ile demografik bilgileri elde edilmiştir. Tablo 3’te araştırma kapsamında ele alınan dağılım koşulları ve bu koşulları karşılayabilecek dağılım özelliklerini sergileyen ve ilgili fonksiyonlar yardımıyla elde edilen örneklemelere ilişkin bazı betimsel istatistiklere yer verilmiştir.

Tablo 3

Çalışma Grubununa İlişkin Dağılım Özellikleri

	Kişi Sayısı (N)	Ortalama ($\bar{X}$)	Standart Sapma (ss)	Çarpıklık Katsayısı (çk)	Basıklık Katsayısı (bk)
Tüm Veri	4292	9,709	5,770	0,939	0,597
Alt Grup	500	8,974	5,593	0,390	0,432
Üst Grup	500	14,314	4,457	0,035	-0,169
ÇK:0	500	11,788	4,421	0,051	-0,221
ÇK:0,50	500	10,726	6,147	0,498	0,095
ÇK:0,75	500	9,438	5,436	0,723	0,120
ÇK:1,00	500	8,590	4,871	1,082	1,180
ÇK:1,25	500	7,580	4,599	1,215	1,885
ÇK:1,50	500	5,494	4,359	1,488	2,581
ÇK:2,00	500	4,576	3,358	2,124	5,196

Tablo 3 incelendiğinde, çalışma kapsamında istenen dağılım koşulları ile örneklemelerden elde edilen istatistiklerin birbirleriyle uyumlu olduğu söylenebilir. Öyle ki çarpıklık katsayılarına göre istenen ve elde edilen değer arasındaki fark en az 0,002 (ÇK:0,50 koşulunda) iken en fazla 0,124 (ÇK:2 koşulunda)’dır.

Evren ile örneklemelere seçilen bireylerin cinsiyet dağılımına ilişkin frekans ve yüzde istatistiğine Tablo 4’te yer verilmiştir.

Tablo 4

Evren ve Örneklem Gruplarının Cinsiyete Göre Dağılımı Özellikleri

	N	Kız (%)	Erkek (%)
Tüm Veri	4292	2097(48,9)	2195(51,1)
Alt Grup	500	243(48,6)	257(51,4)
Üst Grup	500	266(53,2)	234(46,8)
ÇK:0	500	268(53,6)	232(46,4)
ÇK:0,50	500	255(51,0)	245(49,0)
ÇK:0,75	500	235(47,0)	265(53,0)
ÇK:1,00	500	233(46,6)	267(53,4)
ÇK:1,25	500	247(49,4)	253(50,6)
ÇK:1,50	500	227(45,4)	273(54,6)
ÇK:2,00	500	225(45,1)	275(54,9)

Tablo 4’ te görüldüğü üzere evren dağılımında (tüm veri) kız ve erkek öğrenci oranı birbirine oldukça yakinken alt grup ve ÇK:0,75, ÇK:1,00, ÇK:1,25, ÇK:1,50 ve ÇK:2,00 koşullarını sağlayan örneklemelerde erkek öğrencilerin kız öğrencilerine oranla daha fazla oldukları gözlemlenmiştir. Bu durumu tamamlayıcı olarak üst grup ve ÇK:0 ve ÇK:0,50 koşullarını sağlayan örneklemelerde ise erkek öğrencilerin kız öğrencilerine oranla daha az oldukları gözlemlenmiştir. Bunun olası sebepleri incelenmiş ve evren veri setinde yer alan kız ve erkek öğrencilerin test puanı ortalamalarının sırasıyla 10,01 ve 9,41 olduğu görülmüştür. Araştırma kapsamında ele alınan çarpık dağılımlar pozitif kayışlı olduğundan (sağa çarpık) düşük ortalamaya sahip erkek öğrencilerin çarpık dağılımlarda daha fazla yer almasının bir sonucu olabileceği düşünülmüştür. Ancak bu durum evren ile en büyük farkı sağlayan örneklem ile istatistiksel olarak test edilmiş ve tüm veri ve ÇK:2,00 koşuluna ait örneklem arasında cinsiyet dağılımı açısından anlamlı bir fark bulunmamıştır ($\chi^2 = 2,669$, $p > 0,05$). Dolayısıyla ele alınan tüm koşullarda kullanılan örneklemeler ile evren arasında cinsiyet dağılımları birbirine benzerdir.

Veri Toplama Aracı

Veri toplama aracı olarak “Uluslararası Geniş Ölçekli Sınavlarda Türkiye'nin Matematik Başarısını Arttırabilmek İçin Bir Model Önerisi: Bilişsel Tanıya Dayalı İzleme Modelinin

Etkililiği” başlıklı ve 115K531 No’lu TÜBİTAK Projesi kapsamında geliştirilen son test uygulamasındaki iki oturum halinde uygulanan ölçme aracı kullanılmıştır. Son test uygulamasına ait bu ölçme aracında; ilk oturumda dokuz, ikinci oturumda sekiz çoktan seçmeli madde içeren 15’er maddelik karma test türünde toplam 30 madde yer almaktadır. Proje kapsamında kullanılan testlerin geliştirilmesinden önce gönüllü öğretmenlere üst düzey düşünme becerileri ile ilgili madde yazma eğitimlerinin verilmesi sağlanmıştır. Madde havuzunun oluşturulmasının ardından, içlerinde alan uzmanlarının da bulunduğu hakemlerce puanlanarak deneme formları oluşturulmuştur. Pilot uygulamalar sonrasında testin nihai formu oluşturulmuş ve ana uygulamalar yapılmıştır. Projede geliştirilen maddelerin PISA (The Program for International Student Assessment) ve TIMSS (Trends in International Mathematics and Science Study) çalışmalarındaki maddeler ile eşdeğer olduğu ve kapsam açısından da uyumlu olduğu vurgulanmıştır (Başokçu, 2018).

Testin Psikometrik Özellikleri

Proje kapsamında son test uygulamasına katılan öğrencilerden ön test uygulamasına girmeyenler proje bulgularına dâhil edilmemiş ve böylelikle son test analizleri 3705 öğrenci üzerinden gerçekleştirilmiştir. Proje kapsamında ele alınan bu katılımcıların toplam puanlarına ait betimsel istatistikler Ek 2a’da sunulmuştur. Ancak bu araştırma kapsamında son test uygulama verilerinden (N=4298) iki oturumdan yalnızca birine katılan altı öğrenci çıkarılmış ve bu veriler üzerinden elde edilen toplam puana ilişkin betimsel istatistikler Tablo 5’te sunulmuştur.

Tablo 5

Testten Elde Edilen Ölçümlere Ait Betimsel İstatistikler

Kişi Sayısı (N)	4292
Soru Sayısı (K)	30
Ortalama ($\bar{X}$)	9,709
Mod	6
Medyan	9
Minumum	0
Maksimum	30
Standart Sapma (ss)	5,77
Varyans	33,294
Çarpıklık Katsayısı (ÇK)	0,939 (0,037*)
Basıklık Katsayısı (BK)	0,597 (0,075*)
KR-21	0,830

(*: momente ait standart hata)

Tablo 5 incelendiğinde, araştırmanın evrenini oluşturan çalışma grubundaki 4292 öğrencinin 30 maddelik testte soruların tamamını yanlış yanıtlayan ve tamamına doğru cevap verenlerin olduğu görülmektedir. Öğrencilerin testten elde ettikleri puanların ortalaması 9,71; tepe değeri 6 ve ortanca değeri ise 9'dur. Dağılımın standart sapması 5,77 iken varyansı 33,29 olarak hesaplanmıştır. Çarpıklık katsayısının evren kestirimleri için ∓ 1 sınırları içinde kalması puanların normalden aşırı bir sapma göstermediği şeklinde yorumlanabilirken, basıklık ve çarpıklık katsayısının 0'dan büyük olması dağılımın normal dağılıma göre daha sivri ve sağa çarpık olduğunun bir göstergesidir (Morgan, Leech, Gloeckner & Barrett; 2004). Ancak çarpıklık ve basıklık momentleri ile standart hatalarının oranına bakılınca her bir değer 1,96'dan oldukça büyük çıkmaktadır. Buradan 0,05 manidarlık düzeyi ile dağılımın normal olmadığı kanısına varılır. Bununla birlikte dağılımın normal dağılımdan farklılaşıp farklılaşmadığının incelenmesi için Kolmogorov-Smirnov testi incelenmiş ve dağılımın normal dağılımdan farklı bir dağılım sergilediği sonucuna varılmıştır ($p < 0,05$). Bu sonuç grafiksel incelemeler ile de desteklenmektedir (Ek 3). Hesaplanan KR-21 güvenirlik katsayısı ise 0,83 olup elde edilen ölçümlerin güvenirlik düzeyinin yüksek olduğu gözlemlenmiştir.

Proje kapsamında son test uygulamasında yer alan maddelerin psikometrik özellikleri Ek 2b'de sunulmuştur. Bu maddelerin araştırma kapsamında yer alan öğrenci yanıtlarına dayalı olarak hesaplanan madde istatistiklerine ise Tablo 6'da yer verilmektedir.

Tablo 6

Son Test Uygulamasına Ait Madde Ayırıcılık ve Madde Güçlük Değerleri

Madde	Düzeltilmiş Madde -Toplam Korelasyonu (Madde ayırt ediciliği)	Madde Ortalaması (Madde güçlüğü)	Madde	Düzeltilmiş Madde - Toplam Korelasyonu (Madde ayırt ediciliği)	Madde Ortalaması (Madde güçlüğü)
s0203	0,34	0,49	s5050_A1	0,46	0,39
s0204	0,28	0,46	s6963_B	0,30	0,35
s6471	0,40	0,54	s6370	0,26	0,36
s9074	0,53	0,48	s3281	0,39	0,27
s0504	0,39	0,35	s8867	0,57	0,21
s6470_A	0,22	0,27	s6323_1	0,22	0,21
s9342	0,22	0,28	s7305_A	0,43	0,05
s0501	0,46	0,20	s0205	0,27	0,39
s9270	0,26	0,16	s0206	0,30	0,27
s3159	0,41	0,10	s6251	0,33	0,23
s0505	0,52	0,14	s1119	0,26	0,30
s9739	0,31	0,19	s5752_3	0,54	0,19
s4427	0,37	0,34	s0507	0,49	0,37
s6188	0,34	0,40	s0503	0,39	0,61
s0201	0,33	0,61	s0502_2	0,50	0,48
Ortalama				0,37	0,32

Tablo 6 incelendiğinde, son test uygulamasında yer alan maddeler için madde ayırt edicilik değerinin 0,22 ile 0,54 arasında; madde güçlüğü ise 0,05 ile 0,61 arasında değiştiği görülmektedir. Sekiz maddenin ayırt edicilik değerinin 0,30'dan küçük olduğu görülmektedir. Test maddelerinin ayırt ediciliklerinin ortalaması 0,37 olup testin genel olarak yeterli düzeyde ayırt ediciliğe sahip olduğu görülmüştür. Test maddelerinin madde güçlük değerlerinin ortalaması ile elde edilen testin ortalama güçlüğü ise 0,32 olup testin genel olarak orta güçlükten daha zor bir düzeyde olduğu görülmüştür. Madde güçlüklerinin farklı olduğu gözlemlendiğinden güvenilirlik kanıtı için KR-20 katsayısı da hesaplanmış ve 0,849 olarak bulunmuştur. Bu değer testin yeterli derecede güvenilir ölçümler sağladığının bir göstergesi olarak görülebilir.

Verilerin Analizi

Verilerin analizine geçilmeden önce veri seti için ön incelemelerde bulunulmuştur. Evren veri seti üzerinde boş bırakılan maddeler için madde puanlaması sıfır olarak düzenlenmiştir. Daha sonra öğrenci cevap örüntüleri soru kitapçığında yer alan madde sıralamaları ile eşleştirilmiştir. Kullanılan test karma test türünde olmasına rağmen madde türünden kaynaklanabilecek format etkisi dikkate alınmamıştır. Yapılan çalışmalar göstermiştir ki matematik ve fen bilimleri gibi derslerde farklı madde türlerinden eş değer sonuçlar elde edilmektedir (Lissitz, Hou & Slater, 2012; Rodriguez, 2003). Toplam puanlar elde edildikten sonra evrenden istenen özellikte örneklem çekilme aşamasına geçilmiş ve ardından Q-Matrisleri oluşturulmuştur. Bu iki ana aşama aşağıda sunulmuştur.

Dağılım Koşullarının Oluşturulması

Bu çalışma kapsamında üç araştırma sorusundan ilki için evren dağılımı üzerinde analizler yürütülmüştür. Evren dağılımı üzerinde son test uygulamasının her iki oturumuna birden katılan öğrencilerin tamamı araştırmaya dâhil edilmiştir.

İkinci araştırma sorusu için farklı yetenek düzeylerine ilişkin dağılımlar oluşturulmuştur. Bu iki örneklemin elde edilmesinde grupların bağımsız ölçümler içermesi sağlanmıştır. Bir başka deyişle bir öğrenci her iki grubun içinde yer almamaktadır. Yetenek gruplarının oluşturulmasında evren ortalamasının altında bir ortalamaya sahip bir örneklemin elde edilmesinin ardından kalan öğrenciler arasından evren ortalamasının üstünde bir ortalamaya sahip örneklem elde edilmiştir. Bu iki örnekleme ait test puanları arasındaki fark, parametrik test varsayımları karşılanmadığından Mann Whitney U testi ile sınanmış ve anlamlı farklılık bulunmuştur ($U=53542$, $z=-15,672$, $p<0,05$, $r=0,70$). Diğer bir deyişle grupların başarı düzeyleri arasında büyük etki büyüklüğünde anlamlı farklılık vardır. Burada aritmetik ortalama dışındaki diğer momentler sabit tutulmaya çalışılmıştır. Tablo 3'te görüldüğü gibi sırasıyla üst ve alt yetenek gruplarının standart sapmaları 5,60 ve 4,48; çarpıklık katsayıları 0,39 ve 0,04; basıklık değerleri 0,43 ve -0,17'dir. Çarpıklık ve basıklık değerleri 0'a oldukça yakın olan bu iki dağılımın şekilleri görsel olarak incelenmiş ve birbirine benzer olduğu kanısına varılmıştır.

Üçüncü araştırma sorusu için ise normal dağılımın yanında farklı derecelerde normallikten sapma göstermiş (çarpık) dağılımlar oluşturulmuştur. Çarpık dağılımların elde edilmesinde çarpıklık katsayısı 0,5'ten başlayarak 0,25 ve 0,50'lik değerinde artacak şekilde dağılımların

elde edilmesi sağlanmış ve böylelikle olabildiğince hassas bir değerlendirme yapılması amaçlanmıştır. Bu amaç doğrultusunda normalikten sapma gösteren çarpıklık katsayıları yaklaşık olarak 0,50, 0,75, 1,00, 1,50 ve 2,00 olacak şekilde dağılım gösteren örneklemelerde BTM kullanarak belirlenen değerlendirme kriterleri açısından incelenmiştir. Burada çarpıklık katsayısı dışındaki diğer momentler sabit tutulmaya çalışılsa da bu mümkün olmamıştır. Örneğin, elde edilen dağılımların aritmetik ortalaması olabildiğince evren ortalamasına yakın tutulmasına çalışılsa da sağa çarpık bir dağılımın doğası gereği çarpıklık değeri arttıkça örneklemelerin ortalaması da azalma göstermiştir. Bunun yanında bu dağılımların basıklık değerleri de birbirlerine yakın tutulması arzu edilse de çarpık dağılımların doğası gereği çarpıklık değeri arttıkça dağılımın sivrileşmesine ilişkin olarak basıklık değeri de artmıştır (Fleishman, 1987).

İkinci ve üçüncü araştırma sorusu için dağılımların oluşturulmasında kullanılan fonksiyona ilişkin örnek kodlar ve çıktı dosyaları Ek 4'te sunulmuştur.

BTM'de doğru kestirimlerin gerçekleşebilmesi için örneklem büyüklüğü her bir profil sınıfına ait en az 30 kişinin olmasını, yani örneklem büyüklüğünün 30×2^K olmasını gerektirdiği Xu (2013) tarafından belirtilmiştir. Buna göre nitelik sayısının dört olması durumunda gerekli örneklem büyüklüğü 480 olmaktadır. Bununla birlikte tekrar örneklemeye gidilmeden istenen dağılım koşullarının elde edilmesi durumu da dikkate alınarak bu çalışma kapsamında örneklem büyüklüğü 500 olarak belirlenmiştir.

Q-Matrislerinin Oluşturulması

Q-matrislerinin oluşturulmasında iki farklı yaklaşım ele alınmıştır. Bunlardan ilki nitelik boyutunun öğrenci cevaplarından bağımsız olarak uzman kanısına dayalı olarak belirlenmesi iken ikincisi herhangi bir uzman kanısına başvurmada ve yalnızca öğrenci cevaplarından yararlanarak faktör analitik yöntemle dayalı olarak belirlenmesidir.

Q-Matrisin Uzman Kanısına Dayalı Olarak Belirlenmesi

İlk olarak Q-matrisleri uzman kanısına dayalı olarak belirlenmiş, ardından bu matrise dayalı yapılan geçerleme sonucunda tüm modifikasyon önerileri dikkate alınmış ve son olarak geçerleme sonucundaki modifikasyon önerilerinden gerekli olanlar dikkate alınmıştır. Araştırma kapsamında geçerleme yöntemi PVAF olarak ele alınmıştır.

de la Torre ve Chiu (2016) Q-matris geerlemeye iliřkin olarak PVAF iin kesme deęerini %95 olarak belirlemiřtir. Terzi (2017) ise %95 kesme deęerinin %90 olmasıyla daha iyi sonular elde edildięini gstermiřtir. Nájera, Sorrel & Abad (2019) simlasyon alıřmalarının bulgularına dayalı olarak, rneklem byklę kk olduęunda (N= 500), madde ayırıcılık indekslerinin orta ve yksek olmasına baęlı olarak optimum EPS (ϵ -Epsilon / PVAF kesme deęeri) deęerinin sırasıyla 0,85 ve 0,90 olarak seilmesini nermiřlerdir. Bu arařtırma kapsamında evren verisi zerinde konu alanı ile uzman grřne dayalı oluřturulan Q-matris iin optimum kesme puanı hesaplanmış ve %95'in altında bulunmuřtur (0,925) (Ek 5). Yapılan kesme puan hesaplaması ve ilgili alıřmalar ıřıęında bu alıřmada kesme deęeri %90 olarak belirlenmiřtir.

Arařtırma kapsamında hazırlanan uzman grř formu ile  alan uzmanından, her bir maddenin doęru zmnde iliřkili olabilecek ęrenme alanı ve beceriler hakkındaki grřleri Ek 6'daki formla elde edilmiřtir (İlgili ekte arařtırma kapsamında kullanılan testte yer alan maddeler, verilerin elde edildięi proje paydařlarının isteęi doęrultusunda gizlilik sebebiyle paylařılmamıřtır.) Geerleme sonucundaki modifikasyon nerilerinin dikkate alınıp alınmamasına ynelik olarak yalnızca modifikasyon nerileri olan maddeler iin ikinci kez uzman grř toplanmıřtır. Bu arařtırmada uzmanların hem fikir oldukları grřler doęrudan dikkate alınırken ortak grř saęlanamadıęı durumda, oęunluk saęlanan Q-matris girdileri kabul edilmiřtir. Ma ve de la Torre (2020) Q-matris doęrulama yntemleri eldeki verilere dayandıęına ve nerilen deęiřikliklerin dahil edilip edilmeyeceęinin alan uzmanlarının kararına tabi olması gerektięini vurgulamıřtır. de la Torre ve Ma (2018) Mesa Plotların nitelięin bařarı olasılıklarındaki deęiřkenlięi aıklayabildięinden modifikasyon nerisinin kabul edilmesinde incelenmesini nermiřlerdir. de la Torre ve Akbay (2019) geerleme yntemi bir q-vektrn nermiř olsa da, Q-matrisini dzeltmeye iliřkin nihai karar, ilgili maddeye ait q-vektr ve test tarafından llen nitelikler dikkatlice deęerlendirildikten sonra uzman kararına dayandırılması gereklilięini vurgulamıřtır. Bu alıřma kapsamında ise modifikasyon nerisi sunulan maddelere iliřkin mesa plotlar (Ek 7) arařtırmacı tarafından incelenmiř ve nceden bahsedildięi gibi uzman kanısına tekrar bařvurulmuřtur. Tablo 7'de uzman grřlerine dayalı, uzman grřleri ve PVAF geerleme modifikasyonlarına dayalı ile uzman grřleri PVAF geerleme ve tekrar uzman grřlerine iliřkin modifikasyonlarına dayalı belirlenen ve sırasıyla QMatris_KA(3u), QMatris_KA(3u+PVAF) ve QMatris_KA(3u+PVAF+3u) olarak adlandırılmıř Q-Matrisleri yer almaktadır.

Tablo 7

Uzman Görüşlerine Dayalı, Uzman Görüşleri ve PVAF Geçerleme Modifikasyonlarına Dayalı ile Uzman Görüşleri PVAF Geçerleme ve tekrar uzman görüşlerine ilişkin Modifikasyonlarına Dayalı Q-Matrisleri

Maddeler	QMatris_KA(3u)				QMatris_KA(3u+PVAF)				QMatris_KA(3u+PVAF+3u)			
	α_S	α_C	α_G	α_V	α_S	α_C	α_G	α_V	α_S	α_C	α_G	α_V
s0203	0	0	0	1	0	0	0	1	0	0	0	1
s0204	0	0	0	1	0	0	0	1	0	0	0	1
s6471	0	1	0	0	0	1	0	0	0	1	0	0
s9074	1	1	0	0	1	1	0	0	1	1	0	0
s0504	0	1	1	0	0	1	1	0	0	1	1	0
s6470_A	1	0	0	0	1	0	0	1*	1	0	0	0
s9342	1	0	0	1	1	0	0	1	1	0	0	1
s0501	0	0	1	1	0	0	1	1	0	0	1	1
s9270	1	1	0	0	1	1	0	0	1	1	0	0
s3159	1	1	0	0	1	1	0	0	1	1	0	0
s0505	1	0	0	1	1	0	0	1	1	0	0	1
s9739	1	0	1	0	1	0	1	0	1	0	1	0
s4427	1	1	0	0	1	1	0	0	1	1	0	0
s6188	1	0	0	0	1	1*	0	0	1	1*	0	0
s0201	1	0	0	1	1	0	0	1	1	0	0	1
s5050_A1	0	0	1	0	0	0	1	0	0	0	1	0
s6963_B	0	1	0	0	1*	1	0	0	1*	1	0	0
s6370	0	0	1	0	0	0	1	0	0	0	1	0
s3281	0	0	0	1	1*	0	0	1	0	0	0	1
s8867	0	1	0	0	1*	1	0	0	1*	1	0	0
s6323_1	1	0	0	1	1	0	0	1	1	0	0	1
s7305_A	1	0	0	1	1	0	0	1	1	0	0	1
s0205	0	1	0	0	1*	1	0	0	0	1	0	0
s0206	1	1	0	0	1	1	0	0	1	1	0	0
s6251	0	1	0	0	1*	1	0	0	1*	1	0	0
s1119	1	0	0	0	1	0	0	1*	1	0	0	0
s5752_3	1	0	0	1	1	0	0	1	1	0	0	1
s0507	0	0	0	1	0	0	0	1	0	0	0	1
s0503	0	0	0	1	0	0	0	1	0	0	0	1
s0502_2	0	1	0	0	0	1	0	0	0	1	0	0

α_S : Sayılar ve İşlemler, α_C : Cebir, α_G : Geometri, α_V : Veri İşleme

*: Modifiye edilmiş

Tablo 7’de sunulduğu üzere, uzman grubundaki üç uzmandan iki uzmanın görüşleri doğrultusunda s6188, s6963_B, s8867, s6251 maddelerine ait modifikasyon önerileri dikkate alınırken s6470_A, s3281, s0205 ve s1119 ve maddelerine ait modifikasyon önerileri reddedilmiştir.


Q-matrisinin belirlenmesinde farklı alanlara ait nitelikler birlikte veya kombinasyonları birçok araştırmada kullanılmıştır. Doğan (2006) dokuz süreç becerisi ve altı içerik alanı özelliğini birlikte kullanarak on beş nitelikten oluşan bir Q-matrisi üzerinde çalışmasını yürütmüştür. George ve Robitzsch (2014) ise, dört işlem becerisi ile dört içerik alanına özgü niteliğin kombinasyonlarından oluşan 16 nitelikten oluşan bir Q-matrisi üzerinde çalışmıştır. Alanyazında farklı türde nitelik setlerinin kullanımına başka çalışmalarda da raslanılmıştır (George ve Robitzsch, 2015; Gündüz ve Çakan 2020). Bu çalışma kapsamında da konu alanına (Sayılar ve İşlemler, Cebir, Geometri, Veri İşleme) ek olarak maddeyi doğru cevaplayabilmede ilişkili olabilecek rutin olmayan problem çözme becerisi ve okuduğunu anlama becerisi birer nitelik olarak ele alınmış ve Q-matrisleri belirlenmiştir. Bu Q-matrisleri konu alanına ek rutin olmayan problem çözme becerisi ile birlikte yapılandırıldığında, okuduğunu anlama becerisi ile birlikte yapılandırıldığında ve her ikisiyle birlikte yapılandırılarak sırasıyla QMatris_KA_RP, QMatris_KA_OA ve QMatris_KA_RP_OA olarak adlandırılmış Q-Matrisleri belirlenmiştir.

Q-Matrisin Faktör Analitik Yönteme Dayalı Olarak Belirlenmesi

Nitelik boyutunun faktör analitik yönteme dayalı olarak belirlenmesinde evren ve örneklem verilerine Açıklayıcı Faktör Analizi (AFA) yapılmış ve kurulan modeldeki faktörler birer nitelik olarak ele alınmıştır. Faktör analizi sonucunda ortaya çıkan faktör deseni kullanılarak madde ve nitelikler arasındaki ilişkiler belirlenmiştir. Faktör yük değeri kriteri 0,30 olarak ele alınmıştır. Böylelikle maddenin bulunduğu faktördeki yük değeri 0,30 ve üstü ise Q-matrisi girdisi “1” olarak temsil edilirken, 0,30’un altında ise “0” olarak temsil edilmiştir.

Evren ve örneklem verilerine AFA, tetrakorik korelasyon matrisine dayalı olarak temel eksenler yöntemi (principal axis factoring) ile yapılmıştır. Faktör analizi yapılmadan önce örneklem büyüklüğünün yeterli olup olmadığının test edilmesinde ve maddeler arası çoklu korelasyonların anlamlılığı sırasıyla Kaiser-Meyer-Olkin (KMO) testi ve Barlett Küresellik testinin sonuçları incelenmiştir. Evren veri seti için KMO değerinin 0,939 olduğu bulunmuştur. Bu değer 0,60’dan yüksek olduğu için örneklem büyüklüğünün AFA için uygun olduğu söylenebilir. Barlett testinin de istatistiksel olarak anlamlı çıkmış olması açıklayıcı faktör analizine devam edilebileceğini göstermektedir (Bartlett küresellik testi sonucu : $\chi^2 = 19705,108$, $sd=435$ ve $p < .05$).

İlgili yapıyı açıklayan faktör sayısına karar vermede Kaiser-Harris kriteri, Cattell yamaç-birikinti grafiği ve Horn'un paralel analiz yöntemi incelenmiştir. Bu incelemelere ilişkin yamaç birikinti grafiği Şekil 5'te verilmiştir.



Şekil 5. AFA için özdeğer grafiği

Şekil 5 incelendiğinde, faktör çıkarma yöntemlerinden Cattell'in yamaç birikinti grafiği esas alındığında 4 faktörlü bir yapısal model tercih edilmiştir. Faktör sayısına karar vermede paralel analizin önerdiği 5 faktörlü yapı denenmiş ancak bazı boyutlara 3 maddeden daha az madde düştüğü için bu öneri dikkate alınmamıştır. Yapılan ilk AFA sonucunda elde edilen açıklanan varyans tablosu ve maddelerin hangi faktöre ne kadar yük verdiğine ilişkin bilgiler Ek 8'de sunulmuştur. Buna göre ölçülen özelliğe ilişkin dört boyutta açıklanan varyans oranı %39 olarak tespit edilmiştir. Buna göre, 30 maddeli bu test ölçmeyi amaçlandığı özellikteki varyansın %39'unu açıklamaktadır. Faktör 1'in katkısı toplam varyansın %11'sini Faktör 2

%12'sini, Faktör 3 %10'unu ve Faktör4 ise %6'sını açıklamaktadır Dört faktörün birlikte açıkladıkları varyansa katkılarının ise sırasıyla %28, %29, %26 ve %16 olarak bulunmuştur. Faktör yük değerleri incelendiğinde, açıkladığı varyansı düşük olan s6470_A, s9342, s6370, s1119 ve s6323_1 maddeleri analiz dışında bırakılarak analizler tekrarlanmıştır. Bunun sonucunda elde edilen öz değerler ve açıklanan varyanslar Tablo 8'de sunulmuştur.

Tablo 8

AFA'ya ilişkin Açıklanan Varyans Değerleri (s6470_A, s9342, s6370, s1119 ve s6323_1 Analiz Dışı)

	Faktör1	Faktör2	Faktör3	Faktör4
Açıklanan Varyans	0.16	0.13	0.09	0.07
Kümülatif Açıklanan Varyans	0.16	0.29	0.37	0.44
Açıklama Oranları	0.35	0.29	0.20	0.16
Kümülatif Açıklama Oranları	0.35	0.64	0.84	1.00

Tablo 8'de görüldüğü üzere ölçülen özelliğine ilişkin dört boyutta açıklanan varyans oranının %44'e çıktığı tespit edilmiştir. Toplam açıklanan varyansta faktör yük değeri 0,30'dan düşük olan maddelerin çıkarılmasıyla %5'lik bir artış bulunmuştur. Faktör 1'in katkısı dört faktörün birlikte açıkladığı toplam varyansın %35'ini Faktör 2 %29'unu, Faktör 3, %20'sini ve Faktör 4 %16'sını açıklamaktadır.

Maddelerin hangi faktörlere ne kadar yük verdiğine ilişkin bilgilere Tablo 9'da yer verilmiştir. Çalışma kapsamında yapılan tüm faktör analizlerinde faktör yük değeri 0,30'un üstünde olan değerler raporlanarak faktör desenleri sunulmuştur.

Tablo 9

AFA Sonucunda Elde Edilen Yük Değerleri (s6470_A, s9342, s6370, s1119 ve s6323_1 analiz dışı)

	Faktör1	Faktör2	Faktör3	Faktör4
s0203				0,619
s0204				0,533
s6471		0,377		
s9074		0,511		0,300
s0504			0,369	
s0501				0,497
s9270			0,371	
s3159			0,589	
s0505			0,555	
s9739	0,319			
s4427		0,360	0,309	
s6188		0,397		
s0201		0,552		
s5050_A1	0,512			
s6963_B	0,349			
s3281	0,552			
s8867	0,788			
s7305_A	0,734		0,342	
s0205	0,363			
s0206	0,377			
s6251	0,418			
s5752_3	0,553	0,360		
s0507		0,590		
s0503		0,560		
s0502_2		0,662		

Tablo 9 incelendiğinde, Faktör1'e on madde (s5050_A1, s6963_B, s9739, s3281, s8867, s7305_A, s0205, s0206, s5752_3 ve s6251), Faktör 2'ye dokuz madde (s5752_3, s0507, s0503, s0502_2, s4427, s6188, s0201, s6471 ve s9074), Faktör 3'e altı madde (s0504, s7305_A, s4427, s9270, s3159 ve s0505), Faktör 4'e dört maddenin (s0203, s0204, s9074 ve s0501) nin yük verdiği görülmektedir. Faktör 1'deki yük değerleri 0,319 ile 0,788 arasında, Faktör 2'deki yük değerleri 0,360 ile 0,662 arasında, Faktör 3'teki yük değerleri 0,309 ile 0,589 arasında ve Faktör 4'teki yük değerleri 0,300 ile 0,619 arasında değişmektedir.

Evren verisi ile kurulan bu modelde Tucker Lewis Index (TLI) değeri 0,912 bulunmuştur. Bu bulgu kurulan modelin yapı güvenilirliğinin yüksek olduğunun göstergesidir. RMSEA ve root mean square of the residuals (RMSR) değerleri incelendiğinde, hata terimleri açısından model veri uyumunun iyi olduğu yorumu yapılabilir (RMSEA= 0,057 (%90 güven

aralığında 0,055-0,059) ve RMSR= 0,02). Kurulan modelde boyutların isimlendirilmesi yapılmamıştır.

AFA sonuçlarına göre elde edilen faktör yapısı kullanılarak, madde ve nitelikler arasındaki ilişkiler belirlenmiş (Q-matrisi oluşturulmuştur). Maddenin ölçülen boyutta faktör yükü 0,30 ve üstünde ise ilgili boyutun (niteliğin) madde ile ölçüldüğünü belirtmek üzere Q-matrisi girdisi olarak 1, faktör yükü 0,30'un altında ise 0 ile temsil edilmiştir. PVAf için kesme değer uzman kanısına dayalı Q-matrisi geçerleme sürecinde olduğu gibi 0,90 alınmıştır. Tablo 10'da faktör analizi sonuçlarına dayalı Q-matrisi ile faktör analizi ve PVAf geçerleme modifikasyonlarına dayalı belirlenen (sırasıyla QMatris_FA ve QMatris_FA(PVAf)) Q-matrisleri yer almaktadır.

Tablo 10

Faktör Analizi Sonuçlarına Dayalı, Faktör Analizi ve PVAf Geçerleme Modifikasyonlarına Dayalı Q-Matrisleri

	QMatris_FA				QMatris_FA(PVAf)			
	α_1	α_2	α_3	α_4	α_1	α_2	α_3	α_4
s0203	0	0	0	1	0	0	0	1
s0204	0	0	0	1	0	0	0	1
s6471	0	1	0	0	0	1	0	0
s9074	0	1	0	1	0	1	0	1
s0504	0	0	1	0	0	1*	1	0
s0501	0	0	0	1	0	0	0	1
s9270	0	0	1	0	0	0	1	0
s3159	0	0	1	0	0	0	1	0
s0505	0	0	1	0	0	0	1	0
s9739	1	0	0	0	1	0	1*	0
s4427	0	1	1	0	0	1	1	0
s6188	0	1	0	0	0	1	0	0
s0201	0	1	0	0	0	1	0	0
s5050_A1	1	0	0	0	1	0	0	0
s6963_B	1	0	0	0	1	0	0	0
s3281	1	0	0	0	1	0	0	0
s8867	1	0	0	0	1	0	0	0
s7305_A	1	0	1	0	1	0	1	0
s0205	1	0	0	0	1	0	0	0
s0206	1	0	0	0	1	0	0	0
s6251	1	0	0	0	1	0	0	0
s5752_3	1	1	0	0	1	1	0	0
s0507	0	1	0	0	0	1	0	0
s0503	0	1	0	0	0	1	0	0
s0502_2	0	1	0	0	0	1	0	0

*: Modifiye edilmiş

Tablo 10 incelendiğinde, geçerleme yöntemi yalnızca iki girdi için modifikasyon önerisi sunmuştur. QMatris_FA ve QMatris_FA(PVAF) arasında %98’lik bir uyuşma söz konusudur.

Verilerin düzenlenmesinde ve analizinde SPSS 21 ve RStudio 5.4.1’den (R Core Team, 2019) yararlanılmıştır. RStudio ile istenilen özellikteki dağılım koşullarının oluşturulmasında yararlanılan fonksiyonun çalıştırılması için “dplyr” (Wickham, François, Henry & Müller, 2019), “psych” (Revelle, 2018), “SimMultiCorrData” (Fialkowski, 2018) ve “lattice” (Sarkar, 2008) paketleri kullanılmıştır. Faktör analizi için “psych” (Revelle, 2018) paketinde yer alan “fa()” fonksiyonu kullanılmıştır. BTM analizi için ise “GDINA” (Ma & de la Torre, 2020) paketi ile “startGDINA()” fonksiyonu çalıştırılarak kullanıcı arayüzü kullanılmıştır (Ek 9).

Değerlendirme Kriterleri

Özellikle öğretim ile ilgili alınacak kararlarda bilişsel tanılama yapılması için madde parametre kestirimleri (kaydırma ve tahmin parametre kestirimleri) ve sınıflama doğruluğu çok büyük bir öneme sahiptir, çünkü bunlar geçerli çıkarımların elde edilmesinde gerekli koşullardır (de la Torre, Hong & Deng, 2010). Bu çalışma kapsamında da araştırma sorularına yönelik olarak test ve nitelik düzeyinde sınıflama doğrulukları ve parametre kestirimlerine yönelik olarak incelemelerde bulunulmuştur. Öte yandan, farklı yöntemlerle belirlenen Q-matrislerini karşılaştırmak için her bir Q-matrisine dayalı çeşitli bağıl ve mutlak uyum istatistikleri kullanılabilmektedir (Wang vd., 2020). Bu sebeple sınıflama doğrulukları ve parametre kestirimlerine ek olarak model uyumlarına yönelik olarak değerlendirmelerde bulunulmuştur.

Sınıflama doğruluğu bireylerin maddelere verdikleri cevap örüntülerine göre ait olduğu sınıf ve gerçekte bulunduğu sınıf ile uyuşma derecesi olarak tanımlanmıştır (Ciu, Gierl & Chang, 2012). Bu araştırma kapsamında kestirilen sınıflama doğrulukları göreceli olarak karşılaştırılarak değerlendirilmiştir. Sınıflama doğruluğunun 1’e daha yakın olması istenen bir durum olarak değerlendirilmiştir.

Kestirilen madde parametreleri sınıflama doğrulukları gibi göreceli olarak karşılaştırılarak değerlendirilmiştir. Yüksek g ve s madde parametreleri, Q-matrisin yanlış belirlenmesinin ampirik bir kanıtı olabilir (Rupp & Templin, 2008a). Dolayısıyla parametre kestirimlerinin 0’a daha yakın olması istenen bir durum olarak değerlendirilmiştir. Beklenmedik bir şekilde

büyük kaydırma ve tahmin parametreleri değerleri, Q-Matris girdilerinin hatalı tanımlanmasına işaret edebilir (Rupp & Templin, 2008a)

Model veri uyumunun değerlendirilmesine yönelik olarak ise Kunina-Habenicht, Rupp ve Wilhelm'in (2009), RMSEA (Root Mean Square Error of Approximation) için kullandığı ölçüt ($<0,05$) bu çalışmada da kullanılmıştır. Lei ve Li'nin (2016) çalışmasında, veriler GDINA için üretildiğinde, RMSEA, orijinal Q-matrisi yerine aşırı belirlenmiş Q-matrisini destekleme eğilimindeyken, $N=500$ örneklem büyüklüğünde orijinal Q-matrisi yerine yetersiz tanımlanmış Q-matrisine dayalı yapılan sınıflamayı destekleme eğiliminde olduğu görülmüştür. Bu sebeple RMSEA'nın yanında SRMSR (Standardized Root Mean Squared Residual) indeksi de kullanılmıştır. Maydeu-Olivares & Joe (2014) ve SRMSR indeksi için kullandığı ölçüt ($<0,05$) bu çalışmada da yeterli uyumu belirtmek için kullanılmıştır. Yapılan sınıflamalar sonucunda mutlak uyum indekslerine göre veriye iyi uyum sergilendiği durumda göreceli uyum indeksleri ile en iyi uyum sağlanan durum daha kesin olarak belirlenebilir (Li, 2016). Bu çalışma kapsamında bağıl uyum indekslerinden AIC (Akaike information criterion), BIC (Bayesian information criterion), CAIC (Consistent Akaike information criterion) ve SABIC (Sample size adjusted Bayesian information criterion) değerleri raporlanmıştır. Lei ve Li'nin (2016) çalışmasında, G-DINA modeli altında yapılan analizlerde, uyum indekslerinin orijinal Q-matrisini örneklem büyüklüğüne bakılmaksızın yüksek yüzdelilerle (0,87) belirleyebildiğini göstermekmiştir. İlgili araştırmacılar BIC uyum indeksinin, örneklem büyük olduğu durumlarda AIC uyum indeksinin ise örneklem küçük olduğu durumlarda orijinal Q-matrisini seçme eğiliminde olduğunu belirtmiştir. Bu çalışmada raporlanan tüm bağıl indeksler bir arada değerlendirilmiştir. Koyuncu (2020) bağıl indeksler arasındaki uyumsuzluk durumunda BIC değerinin kullanılmasına ilişkin görüşü destekleyen birçok araştırma bulgusunu raporlamıştır. Bu çalışmada da kullanılan bağıl indeksler arasında çoğunluk olmadığı durumda BIC değeri yorumlamada öncü tutulmuştur.

BÖLÜM IV

BULGULAR

Bu bölümde çalışmanın araştırma problemleri doğrultusunda elde edilen bulgular sunulmuştur.

Birinci Araştırma Sorusuna İlişkin Bulgular

Çalışmanın ilk araştırma sorusu kapsamında analizler tüm grup üzerinde yapılmıştır. Bu araştırma sorusu iki ayrı düzeyde incelenmiştir. İlk düzeye yönelik kullanılan Q-matrisleri sırasıyla yalnızca uzman kanısına dayalı oluşturulan QMatris_KA(3u), uzman kanısına dayalı oluşturulan ve PVAF yöntemiyle geçerleme modifikasyonlarının tamamının uygulanmasıyla oluşturulan QMatris_KA(3u+PVAF) ve bu modifikasyonların tekrar uzman görüşü alınmasıyla oluşturulan QMatris_KA(3u+PVAF+3u)'dir. İkinci düzeye yönelik kullanılan Q-matrisleri sırasıyla faktör analizine dayalı oluşturulan QMatris_FA ve PVAF yöntemiyle geçerleme modifikasyonlarının tamamının uygulanmasıyla oluşturulan QMatris_FA(PVAF)'dir.

Araştırma Sorusu 1.1.a: Tüm gruba yapılan bilişsel tanı değerlendirmesinde, G-DINA Modeli altında; uzman kanısına dayalı olarak belirlenen Q-matrisinin, PVAF yöntemine ait geçerleme modifikasyonlarına ilişkin farklı belirlenmesi test ve nitelik düzeyinde sınıflama doğruluklarını nasıl etkilemektedir?

Bu araştırma sorusuna yanıt aramak amacıyla uzman kanısına dayalı oluşturulan Q-matrisleri ile yapılan sınıflama analizlerin test ve nitelik düzeyinde sınıflama doğrulukları

incelenmiştir. Tablo 11’de QMatris(KA-3u), QMatris(KA-3u+PVAF) ve QMatris(KA-3u+PVAF+3u)’in G-DINA modele göre kestirilen test düzeyinde sınıflama doğrulukları (test level accuracy) ve nitelik düzeyinde sınıflama doğrulukları (attribute level accuracy) yer almaktadır.

Tablo 11

Uzman Kanısına Dayalı Oluşturulan Q-Matrisleri ile Yapılan Sınıflama Analizlerine Ait Test ve Nitelik Düzeyinde Sınıflama Doğrulukları

	Test düzeyinde Sınıflama Doğruluğu	Nitelik Düzeyinde Sınıflama Doğruluğu			
		α_S	α_C	α_G	α_V
QMatris(KA-3u)	0,8405	0,9478	0,9420	0,9280	0,9331
QMatris(KA-3u+PVAF)	0,8202	0,9191	0,9305	0,9167	0,9265
QMatris(KA-3u+PVAF+3u)	0,8407	0,9782	0,9390	0,9211	0,9357

α_S : Sayılar ve İşlemler, α_C : Cebir, α_G : Geometri, α_V : Veri İşleme

Tablo 11 incelendiğinde, test düzeyinde sınıflama doğrulukları ele alındığında en yüksek sınıflama doğruluğuna QMatris(KA-3u+PVAF+3u) ile yapılan analiz sonucunda ulaşılmıştır. QMatris(KA-3u+PVAF+3u) ve QMatris(KA-3u) ile elde edilen test düzeyinde sınıflama doğruluklarının birbirine oldukça yakın olduğu görülmektedir. En az sınıflama doğruluğu QMatris(KA-3u+PVAF)’nin kullanılmasıyla elde edilmiştir. Nitelik düzeyinde sınıflama doğrulukları ele alındığında her bir nitelik için tüm Q-matrisleri ile yüksek düzeyde sınıflama doğrulukları elde edilmiştir. α_S ve α_V niteliğine ilişkin sınıflama doğrulukları en yüksek QMatris(KA-3u+PVAF+3u) ile elde edilmişken α_C ve α_G niteliğine ilişkin sınıflama doğrulukları en yüksek QMatris(KA-3u) ile elde edilmiştir. Nitelik düzeyindeki sınıflama doğrulukları kendi içinde değerlendirildiğinde en büyük farkın α_S niteliğine ait olduğu görülmektedir. Bu durum Q-matris geçerleme yönteminin önerdiği modifikasyonların en fazla α_S niteliği üzerinde olması ile açıklanabilir.

Tablo 12’de QMatris(KA-3u), QMatris(KA-3u+PVAF) ve QMatris(KA-3u+PVAF+3u)’in G-DINA modele göre kestirilen gizil sınıf düzeyinde sınıflama doğrulukları (pattern level accuracy) yer almaktadır.

Tablo 12

Uzman kanısına dayalı oluşturulan Q-matrisleri ile yapılan sınıflama analizlerine ait gizil sınıf düzeyinde sınıflama doğrulukları

	QMatris(KA-3u)	QMatris(KA-3u+PVAF)	QMatris(KA-3u+PVAF+3u)
0000	0,9704	0,9635	0,9653
1000	0,3828	0,2728	0,9369
0100	0,0000	0,4332	0,2083
0010	0,0000	0,2331	0,0000
0001	0,2541	0,0000	0,1868
1100	0,3297	0,0000	0,0000
1010	0,4133	0,0000	0,0000
1001	0,0000	0,6021	0,0000
0110	0,0949	0,3135	0,1625
0101	0,4994	0,7178	0,6526
0011	0,1085	0,4149	0,0000
1110	0,0000	0,0000	0,0000
1101	0,0000	0,0000	0,0000
1011	0,0000	0,0000	0,6022
0111	0,7625	0,6245	0,7605
1111	0,8907	0,9275	0,8941

Tablo 12 incelendiğinde, yapılan sınıflamada QMatris(KA-3u) ile kestirilen gizil sınıf düzeyinde sıfırdan büyük olan sınıflama doğrulukları 0,1085 ile 0,9704 arasında değişmekte iken QMatris(KA-3u+PVAF) ile 0,2331 ile 0,9635 arasında, QMatris(KA-3u+PVAF+3u) ile 0,1625 ile 0,9635 arasında değişmektedir. Tablo 12'ye göre "0000" ve "1111" gizil sınıflarına ait sınıflama doğruluklarının her bir Q-matrisleri için birbirine yakın ve oldukça yüksek olduğu görülmektedir. Gizil sınıflardan "1110" ve "1101" e ait sınıflama doğruluklarının, ele alınan tüm Q-matrisleri için, sıfır olduğu görülmektedir. Bununla birlikte QMatris(KA-3u) ile elde edilen sınıflamada "1100", "1010", "1001" ve "1011" gizil sınıflarına ait sınıflama doğrulukları; QMatris(KA-3u+PVAF) ile elde edilen sınıflamada "1011", "0001", "1100" ve "1010" gizil sınıflarına ait sınıflama doğrulukları ve QMatris(KA-3u+PVAF+3u) ile elde edilen sınıflamada "0010", "0011", "1100", "1010" ve "1001" sınıflama doğrulukları sıfır değerine sahiptir. Sınıflama doğruluğunun sıfır olduğu bu gizil sınıflarda hiç öğrenci bulunmamaktadır (Ek 10). İlgili üç Q-matrisi ile yapılan sınıflamalarda gizil sınıflarda yer alan öğrenci yüzdeleri incelendiğinde, "0000" ve "1111" gizil sınıflarında bulunan kişi sayısı toplam öğrenci sayının yarısından fazladır. Bu durumda, dört niteliğin yüksek oranda ilişkili olduğu yorumu yapılabilir. Yani bir öğrenci bir niteliğe hakim olamadığında, aynı öğrenci tüm niteliklere birden hakim olamama eğilimindedir.

Araştırma Sorusu 1.1.b: Tüm gruba yapılan bilişsel tanı değerlendirmesinde, G-DINA Modeli altında uzman kanısına dayalı olarak belirlenen Q-matrisinin, PVAF yöntemine ait geçerleme modifikasyonlarına ilişkin farklı belirlenmesi model veri uyumunu nasıl etkilemektedir?

Bu araştırma sorusuna yanıt aramak amacıyla uzman kanısına dayalı oluşturulan Q-matrisleri ile yapılan sınıflama analizlerine ilişkin mutlak ve bağıl model veri uyumları incelenmiştir. Tablo 13'te QMatris(KA-3u), QMatris(KA-3u+PVAF) ve QMatris(KA-3u+PVAF+3u)'in G-DINA modeline göre mutlak model veri uyum indeksleri yer almaktadır.

Tablo 13

Uzman Kanısına Dayalı Oluşturulan Q-Matrisleri ile Yapılan Sınıflama Analizlerine İlişkin Mutlak Model Uyumu İndeksleri

	RMSEA (%90 Güven aralığı)	SRMSR
QMatris(KA-3u)	0.0324 [0.031-0.0338]	0.0530
QMatris(KA-3u+PVAF)	0.0266 [0.0251-0.0281]	0.0372
QMatris(KA-3u+PVAF+3u)	0.0309 [0.0295-0.0323]	0.0461

Tablo 13 incelendiğinde, her üç matrise göre G-DINA modelde kestirilen RMSEA uyum indeksine göre uyum sağlandığı görülmektedir. Ancak QMatris(KA-3u+PVAF) ile QMatris(KA-3u+PVAF+3u) ele alındığında SRMSR uyum indeksine göre uyum sağlanmasına rağmen QMatris(KA-3u) ile yeteri düzeyde uyum sağlanamamıştır. Bununla birlikte ele alınan tüm mutlak uyum indekslerine göre QMatris(KA-3u+PVAF)'i ile yapılan sınıflamanın en iyi düzeyde uyum sağladığı görülmüştür. Ayrıca QMatris(KA-3u+PVAF+3u) ile yapılan sınıflama QMatris(KA-3u) ile yapılan sınıflamadan daha iyi uyum sergilemiştir. Yani PVAF yöntemine dayalı olarak belirlenen Q-matrislerine dayalı yapılan sınıflamalar daha iyi düzeyde uyum göstermiştir. Başka bir ifadeyle ele alınan mutlak uyum indekslerine göre, geçerleme yönteminin verdiği modifikasyonlarının dikkate alınması dikkate alınmaması durumuna göre daha iyi uyum göstermesini sağlamaktadır. Lei ve Li'nin (2016) çalışmasında mutlak uyum endekslerinin $n=500$ olduğu durumda, yetersiz tanımlanmış Q-matrisini destekleme eğiliminde olduğunu bulmuştur. İlgili araştırma göz önüne alındığında, geçerleme yönteminin sunduğu modifikasyon önerilerinin tamamının

aşırı belirlemeye yönelik olduğu varsayıldığında, nispeten yetersiz tanımlandığı varsayılan ve geçerleme yapılmayan Q-matrisinde daha yüksek çıkması beklenirken, geçerleme yapılan Q-matrislerde daha iyi uyum sağlaması, geçerleme yönteminin verdiği modifikasyon önerilerinin uygun olduğunun bir göstergesi kabul edilebilir. Uzman kanısına dayalı oluşturulan bu Q-matrisleri ile yapılan sınıflama analizlerin bağıl model veri uyumu Tablo 14'te verilmiştir.

Tablo 14

Uzman Kanısına Dayalı Oluşturulan Q-Matrisleri ile Yapılan Sınıflama Analizlerine ait İlişkin Bağıl Model Uyumu İndeksleri

	Loglikeli hood	Deviance	AIC	BIC	CAIC	SABIC
QMatris(KA-3u)	-67985,66	135971,3	136177,3	136832,9	136935,9	136505,6
QMatris(KA-3u+PVAF)	-67421,67	134843,3	135081,3	135838,7	135957,7	135460,6
QMatris(KA-3u+PVAF+3u)	-67662,83	135325,7	135547,7	136254,1	136365,1	135901,4

Tablo 14 incelendiğinde, G-DINA modelde kestirilen bağıl test uyum indekslerinin tamamında QMatris(KA-3u+PVAF) en iyi uyumu göstermiştir. Bununla birlikte QMatris(KA-3u+PVAF) ile QMatris(KA-3u+PVAF+3u) kullanılarak yapılan sınıflamada QMatris(KA-3u) kullanılarak yapılan sınıflamaya göre daha iyi uyum sağladığı görülmüştür. Kestirilen bağıl uyum indeksleri ile mutlak uyum indeksleri kendi içlerinde tutarlılık sağlayarak tamamı her bir Q-matris için aynı sıralamayı sunmuştur. Bu bulgulara göre Q-matris geçerliği yapılmayan QMatris(KA-3u), PVAF yöntemine ait geçerleme modifikasyonlarına ilişkin farklı belirlenen QMatris(KA-3u+PVAF) ve QMatris(KA-3u+PVAF+3u) ile yapılan sınıflama göre daha az model veri uyumunu sağladığı söylenebilir.

Araştırma Sorusu 1.1.c: Tüm gruba yapılan bilişsel tanı değerlendirmesinde, G-DINA Modeli altında uzman kanısına dayalı olarak belirlenen Q-matrisinin, PVAF yöntemine ait geçerleme modifikasyonlarına ilişkin farklı belirlenmesi tahmin ve kaydırma parametre kestirimlerini nasıl etkilemektedir?

Bu araştırma sorusuna yanıt aramak amacıyla uzman kanısına dayalı oluşturulan Q-matrisleri ile yapılan sınıflamalarda madde parametrelerinden tahmin ve kaydırma parametrelerine incelenmiştir. Tablo 15'te QMatris(KA-3u), QMatris(KA-3u+PVAF) ve QMatris(KA-3u+PVAF+3u)'in G-DINA modeline göre maddelerin tahmin ve kaydırma parametreleri ile bu parametrelere ait standart hata değerleri yer almaktadır.


Tablo 15

Uzman Kanısına Dayalı Oluşturulan Q-Matrisleri ile Yapılan Sınıflama Analizlerine ait İlişkin Parametre Kestirimleri

	Qmatris_KA(3u)		Qmatris_KA(3u+PVAF)		Qmatris_KA(3u+PVAF+3u)	
	Tahmin(Sh)	Kaydırma(Sh)	Tahmin(Sh)	Kaydırma(Sh)	Tahmin(Sh)	Kaydırma(Sh)
s0203	0,3438(0,0099)	0,2734(0,0133)	0,3349(0,0102)	0,2827(0,0131)	0,3364(0,0103)	0,3121(0,0127)
s0204	0,3388(0,0098)	0,3434(0,0138)	0,3341(0,0101)	0,3551(0,0136)	0,3351(0,0103)	0,3787(0,0130)
s6471	0,3929(0,0101)	0,1831(0,0111)	0,3382(0,0107)	0,2016(0,0106)	0,3481(0,0106)	0,2062(0,0104)
s9074	0,2381(0,0098)	0,0663(0,0131)	0,6547(0,0719)	0,0743(0,0138)	0,2084(0,0097)	0,0664(0,0136)
s0504	0,2068(0,0088)	0,3636(0,0177)	0,1774(0,0091)	0,3507(0,0191)	0,1888(0,0095)	0,3598(0,0181)
s6470_A	0,2291(0,0074)	0,4983(0,0229)	0,2009(0,0347)	0,4489(0,0255)	0,2379(0,0071)	0,4416(0,0266)
s9342	0,2174(0,0088)	0,4724(0,0253)	0,2707(0,0380)	0,4492(0,0256)	0,2150(0,0089)	0,4483(0,0266)
s0501	0,0576(0,0054)	0,4858(0,0181)	0,0526(0,0054)	0,4657(0,0196)	0,0546(0,0056)	0,4859(0,0189)
s9270	0,1111(0,0066)	0,5685(0,0252)	0,2157(0,0584)	0,5528(0,0269)	0,1032(0,0068)	0,5454(0,0280)
s3159	0,0289(0,0036)	0,4935(0,0255)	0,0296(0,0334)	0,5014(0,0272)	0,0259(0,0035)	0,4776(0,0279)
s0505	0,0196(0,0032)	0,3216(0,0257)	0,0979(0,0251)	0,3359(0,0260)	0,0199(0,0032)	0,3098(0,0268)
s9739	0,1199(0,0065)	0,4417(0,0254)	0,1497(0,0168)	0,4238(0,0263)	0,1242(0,0065)	0,4145(0,0274)
s4427	0,1960(0,0085)	0,2121(0,0219)	0,0854(0,0587)	0,2376(0,0235)	0,1887(0,0086)	0,2270(0,0240)
s6188	0,3237(0,0084)	0,1861(0,0193)	0,3193(0,0719)	0,2286(0,0227)	0,2573(0,0096)	0,2096(0,0230)
s0201	0,4624(0,0108)	0,0827(0,0152)	0,8879(0,0326)	0,1036(0,0171)	0,4599(0,0109)	0,0959(0,0176)
s5050_A1	0,2278(0,0084)	0,1775(0,0156)	0,2177(0,0086)	0,129(0,01570)	0,2266(0,0086)	0,1356(0,0158)
s6963_B	0,2512(0,0087)	0,4648(0,0143)	0,4376(0,0743)	0,2584(0,0238)	0,2506(0,0094)	0,2448(0,0242)
s6370	0,2425(0,0084)	0,3334(0,0163)	0,2405(0,0086)	0,313(0,01720)	0,2436(0,0085)	0,3092(0,0171)
s3281	0,1416(0,0073)	0,519(0,01420)	0,3022(0,0392)	0,2761(0,0235)	0,1376(0,0076)	0,5567(0,0129)
s8867	0,0450(0,0046)	0,4812(0,0152)	0,6711(0,0858)	0,1316(0,0191)	0,0391(0,0046)	0,1465(0,0208)
s6323_1	0,1592(0,0077)	0,5221(0,0256)	0,1338(0,0289)	0,5049(0,0261)	0,1614(0,0078)	0,4974(0,0271)
s7305_A	0,0047(0,0016)	0,6454(0,0253)	0,0411(0,0143)	0,6116(0,0266)	0,0017(0,0012)	0,5979(0,0274)
s0205	0,2974(0,0092)	0,4462(0,0144)	0,4963(0,0802)	0,2429(0,0234)	0,2881(0,0098)	0,4827(0,0127)
s0206	0,1849(0,0081)	0,4051(0,0253)	0,3594(0,0747)	0,3553(0,0256)	0,1826(0,0084)	0,3575(0,0264)
s6251	0,1295(0,0068)	0,5894(0,0140)	0,3889(0,0732)	0,3937(0,0258)	0,1257(0,0073)	0,3916(0,0264)
s1119	0,2481(0,0076)	0,4336(0,0233)	0,3145(0,0384)	0,3801(0,0253)	0,2591(0,0073)	0,3731(0,0261)
s5752_3	0,0340(0,0045)	0,2565(0,0240)	0,2773(0,0356)	0,2147(0,0224)	0,0299(0,0043)	0,2112(0,0236)
s0507	0,1688(0,0085)	0,2829(0,0132)	0,146(0,0083)	0,2807(0,0132)	0,1390(0,0082)	0,3122(0,0124)
s0503	0,4531(0,0105)	0,1328(0,0098)	0,4358(0,0107)	0,1312(0,0098)	0,4227(0,0108)	0,1443(0,0094)
s0502_2	0,2790(0,0098)	0,1679(0,0114)	0,2096(0,0098)	0,1947(0,0111)	0,2222(0,0098)	0,2003(0,0108)
Ortalama	0,205(0,0076)	0,3617(0,0190)	0,2940(0,0359)	0,3143(0,0206)	0,1944(0,0078)	0,3313(0,02030)


Tablo 15 incelendiğinde, tahmin parametrelerinin ortalaması en düşük Qmatris_KA(3u+PVAf+3u) ile yapılan sınıflama sonucu (0,1944), en yüksek ise Qmatris_KA(3u+PVAf) ile yapılan sınıflama sonucu (0,2940) elde edildiği görülmüştür.

Kaydırma parametrelerinin ortalaması en düşük Qmatris_KA(3u+PVAf+3u) ile yapılan sınıflama sonucu (0,3313), en yüksek ise Qmatris_KA(3u) ile yapılan sınıflama sonucu (0,3617) elde edildiği görülmüştür. Şekil 6 ve Şekil 7’de uzman kanısına dayalı oluşturulan Q-matrisleri ile yapılan sınıflama analizlerine ait, sırasıyla, tahmin ve kaydırma parametrelerinin grafiksel gösterimi yer almaktadır.



Şekil 6. Uzman kanısına dayalı oluşturulan Q-matrisleri ile yapılan sınıflama analizlerine ait tahmin parametreleri

Şekil 6 incelendiğinde, G-DINA modele göre kestirilen tahmin parametrelerinin Qmatris_KA(3u) ile Qmatris_KA(3u+PVAf+3u) için çoğunlukla örtüştüğü görülmektedir. Ancak Qmatris_KA(3u+PVAf) ile bazı maddelere (s9074, s0201, s8867, s0205) ait kestirilen parametrelerin çok büyük olduğu görülmektedir. Bu bulgular ışığında kestirilen tahmin parametrelerine yönelik olarak geçişleme yapılan iki matristen Qmatris_KA(3u+PVAf+3u)’in Qmatris_KA(3u+PVAf)’e göre daha uygun sonuçlar verdiği söylenebilir.



Şekil 7. Uzman kanısına dayalı oluşturulan Q-matrisleri ile yapılan sınıflama analizlerine ait kaydırma parametreleri

Şekil 7 incelendiğinde, G-DINA modele göre kestirilen kaydırma parametrelerinin s3281 ve s0205 maddeleri dışında Qmatris_KA(3u+PVAF) ile Qmatris_KA(3u+PVAF+3u) için çoğunlukla örtüştüğü görülmektedir. Qmatris_KA(3u) ile bazı maddelere (s6963_B, s8867, s6251) ait kestirilen kaydırma parametrelerinin Qmatris_KA(3u+PVAF) ile Qmatris_KA(3u+PVAF+3u) ile kestirilmesine göre daha büyük olduğu görülmektedir. Bu maddelere yönelik olarak kestirilen kaydırma parametrelerine yönelik olarak geçerleme yapılan iki matrisin Qmatris_KA(3u)'e göre daha uygun sonuçlar verdiği söylenebilir.

Araştırma Sorusu 1.2.a: Tüm gruba yapılan bilişsel tanı değerlendirmesinde, G-DINA Modeli altında; faktör analizi sonuçlarına dayalı olarak belirlenen Q-matrisinin PVAF yönteme ait geçerleme modifikasyonları dikkate alınarak belirlenmesi test ve nitelik düzeyinde sınıflama doğruluklarını nasıl etkilemektedir?

Bu araştırma sorusuna yanıt aramak amacıyla faktör analizi sonuçlarına dayalı olarak belirlenen Q-matrisleri ile yapılan sınıflama analizlerin test ve nitelik düzeyinde sınıflama doğrulukları incelenmiştir. Tablo 15'te QMatris(FA) ve QMatris(FA+PVAF) ile G-DINA modele göre kestirilen test ve nitelik düzeyinde sınıflama doğrulukları yer almaktadır.

Tablo 16

Faktör Analizi Sonuçlarına Dayalı Oluşturulan Q-Matrisleri ile Yapılan Sınıflama Analizlerine ait Test ve Nitelik Düzeyinde Sınıflama Doğrulukları

	Test düzeyinde Sınıflama Doğruluğu	Nitelik Düzeyinde Sınıflama Doğruluğu			
		α_1	α_2	α_3	α_4
QMatris(FA)	0,7983	0,9567	0,9346	0,9467	0,9121
QMatris(FA+PVAf)	0,7988	0,9560	0,9347	0,9501	0,9127

α_1 : Birinci Faktör, α_2 : İkinci Faktör, α_3 : Üçüncü Faktör, α_4 : Dördüncü Faktör

Tablo 16 incelendiğinde, QMatris(FA) ve QMatris(FA+PVAf) ile yapılan analiz sonucunda test düzeyinde sınıflama doğrulukları arasındaki farkın çok az olduğu (0,0005) olduğu görülmektedir. Bu bulgu QMatris(FA) ve QMatris(FA+PVAf) ele alındığında her iki sınıflamanın birbirine çok yakın doğrulukta test düzeyinde sınıflama yaptığı yorumu yapılabilir. Nitelik düzeyinde sınıflama doğrulukları incelendiğinde, ise her bir nitelik için tüm Q-matrisleri ile 0,90'ın üzerinde yüksek düzeyde sınıflama doğrulukları elde edilmiştir. α_1 ve α_4 niteliğine ilişkin sınıflama doğrulukları QMatris(FA) ile daha yüksek elde edilmişken α_2 ve α_3 niteliğine ilişkin sınıflama doğrulukları QMatris(FA+PVAf) ile daha yüksek elde edilmiştir. Nitelik düzeyindeki sınıflama doğrulukları kendi aralarında değerlendirildiğinde en az sınıflama doğruluğunun α_4 niteliğine ait olduğu görülmektedir. Bunun sebebinin ilgili boyutta az madde ve açıkladıkları varyansın düşük olması ile ilgili olduğu düşünülmektedir.

Tablo 17' de QMatris(FA) ve QMatris(FA+PVAf) ile G-DINA modele göre kestirilen gizil sınıf düzeyinde sınıflama doğrulukları yer almaktadır.

Tablo 17

Faktör Analizi Sonuçlarına Dayalı Oluşturulan Q-Matrisleri ile Yapılan Sınıflama Analizlerine ait Gizil Sınıf Düzeyinde Sınıflama Doğrulukları

	QMatris(FA)	QMatris(FA+PVAF)
0000	0,9536	0,9529
1000	0,2020	0,2747
0100	0,6933	0,6925
0010	0,0000	0,0000
0001	0,3525	0,3659
1100	0,4366	0,4472
1010	0,0000	0,0000
1001	0,3684	0,4634
0110	0,5012	0,5268
0101	0,5586	0,5506
0011	0,3711	0,3544
1110	0,4143	0,3957
1101	0,6033	0,6580
1011	0,5860	0,5404
0111	0,3848	0,4303
1111	0,8684	0,8461

Tablo 17 incelendiğinde, QMatris(FA) ile kestirilen gizil sınıf düzeyinde sıfırdan büyük olan sınıflama doğrulukları 0,2020 ile 0,9536 arasında değişmekte iken QMatris(FA+PVAF)’e göre 0,2747 ile 0,9529 arasında değişmektedir. Tablo 17’de görüldüğü gibi “0000” ve “1111” gizil sınıflarına ait sınıflama doğruluklarının her bir Q-matrisleri için birbirine yakın ve yüksek olduğu görülmektedir. Gizil sınıflardan “0010” ve “1010” a ait sınıflama doğruluklarının, her iki Q-matrisi için, sıfır olduğu görülmektedir. Sınıflama doğruluğunun sıfır olduğu bu gizil sınıflarda hiç öğrenci bulunmamaktadır (Ek 10).

Araştırma Sorusu 1.2.b: Tüm gruba yapılan bilişsel tanı değerlendirmesinde, G-DINA Modeli altında; faktör analizi sonuçlarına dayalı olarak belirlenen Q-matrisinin PVAF yönteme ait geçerleme modifikasyonları dikkate alınarak belirlenmesi model veri uyumunu nasıl etkilemektedir?

Bu araştırma sorusuna yanıt aramak amacıyla faktör analizi sonuçlarına dayalı oluşturulan Q-matrisleri ile yapılan sınıflama analizlerine ilişkin mutlak ve bağıl model veri uyumları incelenmiştir. Tablo 18’de QMatris(FA) ve QMatris(FA+PVAF) ile G-DINA modeline göre mutlak model veri uyum indeksleri yer almaktadır.

Tablo 18

Faktör Analizi Sonuçlarına Dayalı Oluşturulan Q-Matrisleri ile Yapılan Sınıflama Analizlerine İlişkin Mutlak Model Uyumu İndeksleri

	RMSEA (%90 Güven aralığı)	SRMSR
QMatris(FA)	0,0274 [0,0257-0,0291]	0,0515
QMatris(FA+PVAf)	0,0267 [0,0250-0,0284]	0,0504

Tablo 18 incelendiğinde, her iki matrise göre G-DINA modelde kestirilen RMSEA mutlak uyum indeksine göre uyum sağlandığı ancak ve SRMSR değerine göre yeterli uyumu sağlamadığı görülmektedir. Bununla birlikte ele alınan mutlak uyum indekslerine göre QMatris(FA+PVAf) ile yapılan sınıflama ve QMatris(FA) ile yapılan sınıflamaya ait mutlak uyum indeksleri birbirine oldukça yakın olmakla beraber QMatris(FA+PVAf) ile yapılan sınıflama QMatris(FA) ile yapılan sınıflamadan daha iyi uyum sergilemiştir. Yani PVAf yöntemine dayalı olarak belirlenen Q-matrislerine dayalı yapılan sınıflama çok az bir farkla daha iyi düzeyde uyum göstermiştir. Ele alınan iki matrise göre yapılan analizde mutlak uyumun incelenmesinin ardından bağıl uyum indekslerinin incelenmesine geçilmiştir.

Faktör analizi sonuçlarına dayalı oluşturulan bu Q-matrisleri ile yapılan sınıflama analizlerin bağıl model veri uyumu Tablo 19'da verilmiştir.

Tablo 19

Faktör Analizi Sonuçlarına Dayalı Oluşturulan Q-Matrisleri ile Yapılan Sınıflama Analizlerine İlişkin Bağıl Model Uyumu İndeksleri

	Loglikeli hood	Deviance	AIC	BIC	CAIC	SABIC
QMatris(FA)	-55437,12	110874,2	111020,2	111484,9	111557,9	111252,9
QMatris(FA+PVAf)	-55395,14	110790,3	110940,3	111417,6	111492,6	111179,3

Tablo 19 incelendiğinde, G-DINA modelde kestirilen bağıl test uyum indekslerinin tamamında QMatris(FA+PVAf) kullanılarak yapılan sınıflamanın QMatris(FA) kullanılarak yapılan sınıflamaya göre daha iyi uyum sağladığı görülmüştür. Bu bulguya göre Q-matris geçerliği yapılmayan QMatris(FA), PVAf yöntemine ait geçerleme modifikasyonlarına ilişkin farklı belirlenen QMatris(FA+PVAf) ile yapılan sınıflamaya göre daha az model veri uyumunu sağlamıştır.

Araştırma Sorusu 1.2.c: Tüm gruba yapılan bilişsel tanı değerlendirmesinde, G-DINA Modeli altında; faktör analizi sonuçlarına dayalı olarak belirlenen Q-matrisinin PVAf yönteme ait geçerleme modifikasyonları dikkate alınarak belirlenmesi tahmin ve kaydırma parametre kestirimlerini nasıl etkilemektedir?

Bu araştırma sorusuna yanıt aramak amacıyla faktör analizi sonuçlarına dayalı oluşturulan Q-matrisleri ile yapılan sınıflamalarda madde parametrelerinden tahmin ve kaydırma parametrelerine incelenmiştir. Tablo 20'de QMatris(FA) ve QMatris(FA+PVAf) ile G-DINA modeline göre maddelerin tahmin ve kaydırma parametreleri ile bu parametrelere ait standart hata değerleri yer almaktadır.



Tablo 20

Faktör Analizi Sonuçlarına Dayalı Oluşturulan Q-Matrisleri ile Yapılan Sınıflama Analizlerine İlişkin Parametre Kestirimleri

	QMatris(FA)		QMatris(FA+PVAF)	
	Tahmin(Sh)	Kaydırma(Sh)	Tahmin(Sh)	Kaydırma(Sh)
s0203	0,3343(0,0097)	0,1735(0,0135)	0,3346(0,0097)	0,1735(0,0135)
s0204	0,3297(0,0096)	0,2577(0,0148)	0,3298(0,0096)	0,2573(0,0148)
s6471	0,3593(0,0108)	0,2187(0,0108)	0,3594(0,0108)	0,2191(0,0108)
s9074	0,1795(0,0102)	0,1194(0,0126)	0,1796(0,0102)	0,1198(0,0127)
s0504	0,2576(0,0082)	0,2299(0,0183)	0,2587(0,0082)	0,2364(0,0182)
s0501	0,0386(0,0050)	0,4396(0,0167)	0,0386(0,0049)	0,4387(0,0167)
s9270	0,1144(0,0058)	0,6221(0,0202)	0,1141(0,0058)	0,6217(0,0200)
s3159	0,0267(0,0032)	0,5629(0,0206)	0,0266(0,0031)	0,5637(0,0206)
s0505	0,0269(0,0035)	0,3891(0,0223)	0,0262(0,0035)	0,3878(0,0220)
s9739	0,1291(0,0061)	0,5842(0,0179)	0,1221(0,0063)	0,4753(0,0244)
s4427	0,1906(0,0088)	0,2945(0,0204)	0,1905(0,0088)	0,2953(0,0201)
s6188	0,2416(0,0094)	0,3921(0,0127)	0,2416(0,0094)	0,3924(0,0127)
s0201	0,4319(0,0108)	0,1703(0,0101)	0,4317(0,0108)	0,1703(0,0101)
s5050_A1	0,2607(0,0081)	0,1532(0,0137)	0,2592(0,0082)	0,1523(0,0138)
s6963_B	0,2711(0,0080)	0,3686(0,0176)	0,2705(0,008)	0,3689(0,0175)
s3281	0,1655(0,0068)	0,3833(0,0177)	0,1644(0,0069)	0,3829(0,0177)
s8867	0,0586(0,0048)	0,2541(0,0172)	0,0565(0,0048)	0,2519(0,0172)
s7305_A	0,0058(0,0016)	0,6649(0,0225)	0,0058(0,0016)	0,658(0,02290)
s0205	0,3138(0,0084)	0,3539(0,0177)	0,3137(0,0084)	0,3558(0,0177)
s0206	0,1975(0,0072)	0,4721(0,0182)	0,197(0,0072)	0,4726(0,0181)
s6251	0,151(0,00660)	0,5003(0,0180)	0,1501(0,0066)	0,5001(0,0180)
s5752_3	0,0291(0,0043)	0,3786(0,0191)	0,0282(0,0043)	0,3799(0,0191)
s0507	0,1216(0,0080)	0,3066(0,0121)	0,121(0,0079)	0,3063(0,0121)
s0503	0,4076(0,0109)	0,1383(0,0091)	0,4075(0,0109)	0,1383(0,0091)
s0502_2	0,1973(0,0095)	0,1661(0,0103)	0,1973(0,0095)	0,1665(0,0103)
Ortalama	0,1936(0,0074)	0,3438(0,0162)	0,1929(0,0074)	0,3394(0,0164)

Tablo 20 incelendiğinde, faktör analizi sonuçlarına dayalı oluşturulan Q-matrislerinden PVAF yönteme ait geçerleme modifikasyonları dikkate alınarak belirlenmesiyle elde edilen QMatris(FA+PVAF) ve hiçbir modifikasyon yapılmadan belirlenen QMatris(FA) ile yapılan sınıflamalarda maddelere ait tahmin ve kaydırma parametreleri arasında en fazla farklılık “s9739” maddesinde görülmüştür. Bu maddeye ait tahmin ve kaydırma parametreleri arasında

fark sırasıyla 0,0070 ve 0,1089'dur. "s9739" maddesine PVAF yönteme ait geçerleme modifikasyonları dikkate alınarak "0" olan bir niteliğe ait girdi "1" olarak değiştirilmiştir. Modifikasyona bağlı diğer değişikliğe gidilen "s0504" maddesine ait tahmin ve kaydırma parametreleri arasında fark ise sırasıyla 0,0011 ve 0,0065'tir. Modifikasyon yapılan iki madde dahil maddelerin parametre değerlerinin birbirine çok yakın oldukları görülmüştür.

Birinci araştırma sorusuna ilişkin bulgular şu şekilde özetlenebilir: Uzman görüşüne dayalı belirlenen Q-matrisleri arasında test düzeyinde sınıflama doğruluğu açısından QMatris(KA-3u+PVAF+3u) ile; model veri uyumu açısından QMatris(KA-3u+PVAF); tahmin parametresi açısından QMatris(KA-3u+PVAF+3u) ile; kaydırma parametresi açısından QMatris(KA-3u+PVAF) ile yapılan analizler sonucunda en uygun sınıflamalar elde edilmiştir. Faktör analizi ile belirlenen Q-matris için geçerleme yönteminin önerdiği modifikasyon sayısının oldukça az olduğu görülmüştür. Bu modifikasyon önerileri dikkate alınarak elde edilen Q-matris ile modifikasyon yapılmayan Q-matris karşılaştırıldığında, araştırma kapsamında ele alınan kriterler açısından oldukça benzer oldukları söylenebilir. Bu sebeple sonraki araştırma sorusunda faktör analizine dayalı Q-matrislerinin belirlenmesinde geçerleme sürecine gidilmemiştir. Bununla birlikte elde edilen şişkin g parametre değeri, Q-matriste belirlenen niteliklere başka niteliklerin de eklenmesi gerektiğinin göstergesi olabilir (de la Torre & Douglas 2008 ve Maris, 1999'dan aktaran Lee, Torre & Park; 2011). Bu bulgu ışığında ilgili durum sonraki araştırma sorusu ile incelenmeye çalışılmıştır.

İkinci Araştırma Sorusuna İlişkin Bulgular

Çalışmanın ikinci araştırma sorusu kapsamında analizler alt ve üst grup üzerinde yapılmıştır. Bu araştırma sorusuna yönelik kullanılan Q-matrisleri uzman görüşüne dayalı olarak belirlenen QMatris_KA, QMatris_KA_RP, QMatris_KA_OA ve QMatris_KA_RP_OA ile faktör analizi sonuçlarına dayalı olarak belirlenen QMatris_FA'dır.

Araştırma Sorusu 2.a: Alt ve üst yetenek gruplarına yapılan bilişsel tanı değerlendirmelerinde, G-DINA modeli altında uzman kanısı ile faktör analizi sonuçlarına dayalı oluşturulan Q-matrislerinin nitelik boyutunun farklı belirlenmesi test ve nitelik düzeyinde sınıflama doğruluklarını nasıl etkilemektedir?

Bu araştırma sorusuna yanıt aramak amacıyla alt grupta yer alan öğrenciler için hem uzman görüşüne hem de faktör analizi sonuçlarına dayalı olarak belirlenen Q-matrisleri ile yapılan

sınıflama analizlerin test ve nitelik düzeyinde sınıflama doğrulukları incelenmiştir. Tablo 21'de alt ve üst grup örneklemeleri için QMatris_KA, QMatris_KA_RP, QMatris_KA_OA, QMatris_KA_RP_OA ve QMatris_FA ile G-DINA modele göre kestirilen test ve nitelik düzeyinde sınıflama doğrulukları yer almaktadır.

Tablo 21

Alt ve Üst Grup için Farklı Belirlenen Q-Matrisleri ile Yapılan Sınıflama Analizlerine Ait Test ve Nitelik Düzeyinde Sınıflama Doğrulukları

		Test düzeyinde Sınıflama Doğruluğu	Nitelik Düzeyinde Sınıflama Doğruluğu					
			$\alpha_{S/1}$	$\alpha_{C/2}$	$\alpha_{G/3}$	$\alpha_{V/4}$	$\alpha_{R/5}$	α_O
Alt Grup	QMatris_KA	0,8241	0,9047	0,9590	0,9526	0,9509	-	-
	QMatris_KA_RP	0,8001	0,9255	0,9518	0,9650	0,9309	0,9502	-
	QMatris_KA_OA	0,8448	0,9149	0,9665	0,9549	0,9657	-	0,9263
	QMatris_KA_RP_OA	0,7945	0,9459	0,9537	0,9440	0,9289	0,9162	0,9662
	QMatris_FA	0,8298	0,9635	0,9729	0,9304	0,9327	0,9993	-
Üst grup	QMatris_KA	0,7511	0,9100	0,9237	0,8698	0,9115	-	-
	QMatris_KA_RP	0,7398	0,9290	0,9136	0,8982	0,8842	0,9415	-
	QMatris_KA_OA	0,6414	0,9231	0,9352	0,8834	0,9024	-	0,8257
	QMatris_KA_RP_OA	0,6913	0,9485	0,9359	0,8836	0,9263	0,8934	0,9310
	QMatris_FA	0,7307	0,8777	0,9455	0,8908	0,8780	-	-

$\alpha_{S/1}$: Sayılar ve İşlemler/*Birinci Faktör*, $\alpha_{C/2}$: Cebir/ *İkinci Faktör*,

$\alpha_{G/3}$: Geometri/ *Üçüncü Faktör*, $\alpha_{V/4}$: Veri İşleme/ *Dördüncü Faktör*,

$\alpha_{R/5}$: Rutin olmayan problem çözme/ *Beşinci Faktör*, α_O : Okuduğunu anlama becerisi

Tablo 21 incelendiğinde, alt grup için test düzeyinde sınıflama doğrulukları ele alındığında en yüksek sınıflama doğruluğuna QMatris_KA_OA ile yapılan analiz sonucunda ulaşılmıştır. Ardından en yüksek sınıflama doğrulukları birbirine oldukça yakın olmakla birlikte sırasıyla QMatris_FA ve QMatris_KA ile yapılan sınıflama sonucunda elde edilmiştir. QMatris_KA_RP_OA ile yapılan sınıflama ve QMatris_KA_RP ile yapılan sınıflama ile oldukça yakın doğrulukta sınıflama sağlamakla birlikte bu matris ile en düşük sınıflama doğruluğu elde edilmiştir. Alt grup için uzman kanısına dayalı belirlenen Q-matrisleri göz önüne alınarak nitelik düzeyinde sınıflama doğrulukları incelendiğinde, her bir nitelik için tüm Q-matrisleri ile yüksek düzeyde sınıflama doğrulukları elde edilmiştir. α_S ve α_O niteliğine ilişkin sınıflama doğrulukları en yüksek QMatris_KA_RP_OA ile ve α_G ve α_R niteliğine ilişkin sınıflama doğrulukları en yüksek QMatris_KA_RP ile elde edilmişken α_C ve α_V niteliğine ilişkin sınıflama doğrulukları en yüksek QMatris_KA_OA ile elde edilmiştir. Alt grup verisi üzerinde yapılan faktör analizine dayalı belirlenen Q-matrisi göz önüne alınarak nitelik düzeyinde sınıflama doğrulukları incelendiğinde, her bir nitelik için oldukça yüksek düzeyde

sınıflama doğrulukları elde edilmesiyle birlikte sınıflama doğruluğu en yüksek α_5 ; en az ise α_3 niteliğine aittir.

Üst grup için test düzeyinde sınıflama doğrulukları ele alındığında en yüksek sınıflama doğruluğuna QMatris_KA ile yapılan analiz sonucunda ulaşılmıştır. Ardından en yüksek sınıflama doğrulukları birbirine oldukça yakın olmakla birlikte sırasıyla QMatris_KA_RP ve QMatris_FA ile yapılan sınıflama sonucunda elde edilmiştir. En düşük sınıflama doğruluğuna ise QMatris_KA_RP_OA ile yapılan analiz sonucunda ulaşılmıştır. Üst grup için uzman kanısına dayalı belirlenen Q-matrisleri göz önüne alınarak nitelik düzeyinde sınıflama doğrulukları incelendiğinde, her bir nitelik için tüm Q-matrisleri ile yüksek düzeyde sınıflama doğrulukları elde edilmiştir. α_S , α_C , α_V ve α_O niteliğine ilişkin sınıflama doğrulukları en yüksek QMatris_KA_RP_OA ile elde edilmişken α_G ve α_R niteliğine ilişkin sınıflama doğrulukları en yüksek QMatris_KA_RP ile elde edilmiştir. Üst grup verisi üzerinde yapılan faktör analizine dayalı belirlenen Q-matrisi göz önüne alınarak nitelik düzeyinde sınıflama doğrulukları incelendiğinde, her bir nitelik için yüksek düzeyde sınıflama doğrulukları elde edilmesiyle birlikte sınıflama doğruluğu en yüksek α_2 ; en az ise α_1 niteliğine aittir.

Araştırma Sorusu 2.b: Alt ve üst yetenek gruplarına yapılan bilişsel tanı değerlendirmelerinde, G-DINA Modeli altında uzman kanısı ile faktör analizi sonuçlarına dayalı oluşturulan Q-matrislerinin nitelik boyutunun farklı belirlenmesi model veri uyumunu nasıl etkilemektedir?

Bu araştırma sorusuna yanıt aramak amacıyla uzman kanısı ile faktör analizi sonuçlarına dayalı oluşturulan Q-matrisleri ile yapılan sınıflama analizlerine ilişkin mutlak ve bağıl model veri uyumları incelenmiştir. Tablo 22'de G-DINA Modeli altında alt ve üst gruplarda QMatris_KA, QMatris_KA_RP, QMatris_KA_OA, QMatris_KA_RP_OA ve QMatris_FA ile G-DINA modeline göre mutlak model veri uyum indeksleri yer almaktadır.

Tablo 22

Alt ve Üst Gruplarda Yapılan Sınıflama Analizlerine ait İlişkin Mutlak Model Uyumu İndeksleri

		RMSEA (%90 Güven aralığı)	SRMSR
Alt Grup	QMatris_KA	0,0548 [0,0503- 0,0593]	0,0718
	QMatris_KA_RP	0,0545 [0,0496- 0,0594]	0,0622
	QMatris_KA_OA	0,0556 [0,0509- 0,0604]	0,0721
	QMatris_KA_RP_OA	0,0525 [0,0470- 0,0580]	0,0603
	QMatris_FA	0,0517 [0,0456- 0,0578]	0,0639
Üst Grup	QMatris_KA	0,0424 [0,0375- 0,0473]	0,0581
	QMatris_KA_RP	0,0191 [0,0089- 0,0265]	0,0454
	QMatris_KA_OA	0,0419 [0,0367- 0,0471]	0,0570
	QMatris_KA_RP_OA	0,0253 [0,0170- 0,0324]	0,0460
	QMatris_FA	0,0336 [0,0271- 0,0398]	0,0536

Tablo 22 incelendiğinde, alt grupta çok az farkla da olsa, ele alınan tüm Q-matrislerinde G-DINA model altında kestirilen sınıflama sonucunda elde edilen RMSEA değerlerinin 0,05'ten büyük olduğu gözlemlenmiştir. Bu yüzden alt grupta hiçbir Q-matrisi ile model veri uyumunun sağlanamadığı yorumu yapılabilir. Ancak karşılaştırma yapıldığında en düşük RMSEA değerinden en yükseğine doğru sırasıyla QMatris_FA, QMatris_KA_RP_OA, QMatris_KA_RP, QMatris_KA ve QMatris_KA_OA ile elde edilmiştir. Benzer şekilde alt grupta ele alınan tüm Q-matrislerinde elde edilen SRMSR değerlerinin 0,05'ten büyük olduğu gözlemlenmiştir. Dolayısıyla alt grupta SRMSR indeksi açısından hiçbir Q-matrisi ile model veri uyumunu yeterli düzeyde sağlanamamıştır. Ancak karşılaştırma yapıldığında en düşük SRMSR değerinden en yükseğine doğru sırasıyla QMatris_KA_RP_OA, QMatris_KA_RP, QMatris_FA, QMatris_KA ve QMatris_KA_OA ile elde edilmiştir.

Üst grupta ise, ele alınan tüm Q-matrislerinde G-DINA model ile kestirilen sınıflama sonucunda elde edilen RMSEA değerlerinin tamamının 0,05'ten küçük olduğu gözlemlenmiştir. Dolayısıyla RMSEA açısından üst grupta her bir Q-matrisi ile model veri uyumunun sağlandığı yorumu yapılabilir. Bununla birlikte karşılaştırma yapıldığında en düşük RMSEA değerinden en yükseğine doğru sırasıyla QMatris_RP, QMatris_KA_RP_OA, QMatris_FA, QMatris_KA_OA ve QMatris_KA ile elde edilmiştir. SRMSR değerleri incelendiğinde ise QMatris_RP ve QMatris_KA_RP_OA ile yapılan sınıflama sonucunda 0,05'ten küçük olduğu; QMatris_FA, QMatris_KA_OA ve QMatris_KA ile yapılan sınıflama sonucunda 0,05'ten büyük olduğu gözlemlenmiştir. Dolayısıyla üst grupta SRMSR indeksi açısından rutin olmayan problem becerisinin bulunduğu Q-matrisi ile model veri uyumu sağlanmışken kalan diğer Q-matrisleri ile yeterli düzeyde uyum sağlanamamıştır. Bununla birlikte karşılaştırma yapıldığında en düşük SRMSR değerinden en yükseğine doğru sırasıyla QMatris_KA_RP, QMatris_KA_RP_OA, QMatris_FA, QMatris_KA_OA ve QMatris_KA ile elde edilmiştir. Her iki grup üzerinde yapılan analizlerde mutlak uyumun yorumlanmasının ardından bağıl uyum indekslerinin incelenmesine geçilmiştir.

Alt ve üst gruplarda uzman kanısına dayalı ve faktör analizi sonuçlarına dayalı oluşturulan Q-matrisleri ile yapılan sınıflama analizlerin bağıl model veri uyumu Tablo 23'te verilmiştir.

Tablo 23

Uzman Kanısına ve Faktör Analizi Sonuçlarına Dayalı Oluşturulan Q-Matrisleri ile Yapılan Sınıflama Analizlerine Ait İlişkin Bağıl Model Uyumu İndeksleri

		Loglikelihood	Deviance	AIC	BIC	CAIC	SABIC
Alt	QMatris_KA	-7484,864	14969,73	15191,73	15659,55	15770,55	15307,23
Grup	QMatris_KA_RP	-7379,082	14758,16	15084,16	15771,14	15934,14	15253,77
	QMatris_KA_OA	-7413,832	14827,66	15125,66	15753,64	15902,64	15280,70
	QMatris_KA_RP_OA	-7300,055	14600,11	15042,11	15973,54	16194,54	15272,07
	QMatris_FA	-6062,655	12125,31	12375,31	12902,14	13027,14	12505,38
Üst	QMatris_KA	-8828,325	17656,65	17878,65	18346,47	18457,47	17994,15
Grup	QMatris_KA_RP	-8697,739	17395,48	17721,48	18408,46	18571,46	17891,09
	QMatris_KA_OA	-8799,087	17598,17	17896,17	18524,15	18673,15	18051,21
	QMatris_KA_RP_OA	-8656,351	17312,70	17754,70	18686,13	18907,13	17984,66
	QMatris_FA	-7552,256	15104,51	15294,51	15694,90	15789,90	15393,36

Tablo 23 incelendiğinde, alt grupta G-DINA modelde kestirilen bağıl test uyum indekslerinin tamamında QMatris_FA kullanılarak yapılan sınıflamanın en iyi uyum sağladığı görülmüştür. Alt grupta uzman kanısına dayalı belirlenen Q-matrislerden ise en iyi uyum, tüm bağıl uyum

indekslerine göre, QMatris_KA_RP_OA ile yapılan sınıflamaya ait bulunmuştur. Bununla birlikte bağıl uyum indekslerinden BIC'e göre karşılaştırma yapıldığında en düşük değerden en yükseğine doğru sırasıyla QMatris_KA, QMatris_KA_OA ve QMatris_KA_RP ile elde edilmiştir.

Üst grupta da G-DINA modelde kestirilen bağıl test uyum indekslerinin tamamında QMatris_FA kullanılarak yapılan sınıflamanın en iyi uyum sağladığı görülmüştür. Üst grupta uzman kanısına dayalı belirlenen Q-matrislerden ise en iyi uyum BIC ve CAIC indekslerine göre QMatris_KA ile; AIC ve SABIC indekslerine göre ise QMatris_KA_RP yapılan sınıflamaya ait bulunmuştur. Bununla birlikte uzman kanısına dayalı belirlenen Q-matrisleri arasında bağıl uyum indekslerinden BIC'e göre karşılaştırma yapıldığında en düşük değerden en yükseğine doğru sırasıyla QMatris_KA, QMatris_KA_OA ve QMatris_KA_RP ile elde edilmiştir.

Araştırma Sorusu 2.c: Alt ve üst yetenek gruplarına yapılan bilişsel tanı değerlendirmelerinde, G-DINA Modeli altında uzman kanısı ile faktör analizi sonuçlarına dayalı oluşturulan Q-matrislerinin nitelik boyutunun farklı belirlenmesi tahmin ve kaydırma parametre kestirimlerini nasıl etkilemektedir?

Bu araştırma sorusuna yanıt aramak amacıyla öncelikle alt yetenek grubu üzerinde uzman kanısına ve faktör analizi sonuçlarına dayalı oluşturulan Q-matrisleri ile yapılan sınıflamalarda madde parametrelerinden tahmin ve kaydırma parametreleri incelenmiştir. Tablo 24'te alt grup örnekleme için QMatris_KA, QMatris_KA_RP, QMatris_KA_OA, QMatris_KA_RP_OA ve QMatris_FA ile G-DINA modeline göre maddelerin tahmin ve kaydırma parametreleri ile bu parametrelere ait standart hata değerleri yer almaktadır.


Tablo 24

Alt Yetenek Grubunda Q-Matrisleri ile Yapılan Sınıflama Analizlerine ait İlişkin Parametre Kestirimleri

	QMatris_KA		QMatris_KA_RP		QMatris_KA_OA		QMatris_KA_RP_OA		QMatris_FA	
	Tahmin(Sh)	Kaydırma(Sh)	Tahmin(Sh)	Kaydırma(Sh)	Tahmin(Sh)	Kaydırma(Sh)	Tahmin(Sh)	Kaydırma(Sh)	Tahmin(Sh)	Kaydırma(Sh)
s0203	0,3380(0,0386)	0,4590(0,0479)	0,3061(0,0396)	0,1475(0,0497)	0,3433(0,0348)	0,4646(0,0421)	0,2109(0,0351)	0,1448(0,0469)	0,2246(0,0307)	0,1003(0,0403)
s0204	0,2307(0,0327)	0,4186(0,0439)	0,3170(0,0340)	0,2685(0,0466)	0,2384(0,0320)	0,4268(0,0537)	0,2259(0,0372)	0,2758(0,0574)	0,1906(0,0275)	0,1407(0,0437)
s6471	0,2697(0,0334)	0,2338(0,0390)	0,3621(0,0342)	0,1893(0,0386)	0,2581(0,0417)	0,2399(0,0438)	0,2698(0,0408)	0,1483(0,0427)	0,2286(0,0347)	0,0737(0,0660)
s9074	0,0863(0,0323)	0,0709(0,0381)	0,1421(0,0256)	0,0490(0,0403)	0,0629(0,0296)	0,0694(0,0359)	0,0534(0,0246)	0,0507(0,0390)	0,0579(0,0200)	0,0854(0,0427)
s0504	0,1391(0,0257)	0,4024(0,0666)	0,2041(0,0264)	0,4049(0,0699)	0,1343(0,0332)	0,3887(0,0659)	0,0993(0,0351)	0,3833(0,0705)	0,1894(0,0354)	0,3430(0,0913)
s6470_A	0,1277(0,0252)	0,6051(0,0524)	0,2192(0,0251)	0,5056(0,0595)	0,1360(0,0254)	0,6052(0,0661)	0,1318(0,0253)	0,5214(0,0699)	0,1463(0,0232)	0,4205(0,1233)
s9342	0,0705(0,0323)	0,5062(0,0715)	0,3673(0,1483)	0,5075(0,0209)	0,3939(0,0435)	0,4001(0,0738)	0,4100(0,0748)	0,1033(0,1342)	-	
s0501	0,0101(0,0250)	0,4982(0,0660)	0,3001(0,0249)	0,4415(0,0722)	0,0301(0,0144)	0,4940(0,0695)	0,0138(0,0113)	0,4292(0,0730)	0,0489(0,0178)	0,2751(0,0800)
s9270	0,0713(0,0327)	0,6321(0,0733)	0,2304(0,0326)	0,6508(0,0814)	0,0794(0,0341)	0,6383(0,0742)	0,0875(0,0348)	0,6596(0,0759)	0,0003(0,0199)	0,0024(0,1100)
s3159	0,0051(0,0075)	0,5877(0,0745)	0,1161(0,6681)	0,6212(0,1426)	0,1681(0,0102)	0,3736(0,0755)	0,0001(0,2679)	0,3879(0,1304)	0,0155(0,0104)	0,6093(0,0853)
s0505	0,0479(0,0277)	0,4243(0,0831)	0,1394(0,0246)	0,4485(0,0913)	0,0491(0,0178)	0,4415(0,0832)	0,0378(0,0161)	0,4698(0,0886)	0,0371(0,0132)	0,3769(0,0966)
s9739	0,1201(0,0282)	0,5696(0,0838)	0,2108(0,0273)	0,5958(0,0827)	0,1174(0,0263)	0,5695(0,0818)	0,0713(0,0226)	0,5990(0,0759)	-	
s4427	0,0742(0,0276)	0,3094(0,0714)	0,1689(0,1494)	0,3236(0,1583)	0,1863(0,0304)	0,0001(0,0744)	0,1990(0,0217)	0,4501(0,1416)	0,1404(0,0270)	0,3770(0,0708)
s6188	0,0531(0,0291)	0,2938(0,0641)	0,1472(0,0280)	0,3132(0,0672)	0,0539(0,0314)	0,2983(0,0659)	0,0554(0,0343)	0,3120(0,0677)	-	
s0201	0,1372(0,0455)	0,0960(0,0443)	0,2027(0,0429)	0,0993(0,0461)	0,1502(0,0519)	0,0949(0,0459)	0,1641(0,0489)	0,1013(0,0493)	0,2487(0,0373)	0,1532(0,0551)
s5050_A1	0,2285(0,0296)	0,1295(0,0503)	0,3294(0,0321)	0,1484(0,0519)	0,2343(0,0324)	0,1213(0,0524)	0,1719(0,0330)	0,1254(0,0497)	0,1556(0,0318)	0,1774(0,0684)
s6963_B	0,2277(0,0408)	0,1795(0,0628)	0,2399(0,0422)	0,2032(0,0619)	0,2336(0,0402)	0,1741(0,0626)	0,1764(0,0398)	0,2100(0,0646)	0,2226(0,0248)	0,2570(0,0636)
s6370	0,1970(0,0263)	0,2822(0,0567)	0,2916(0,0273)	0,2800(0,0604)	0,1998(0,0279)	0,2698(0,0575)	0,1885(0,0294)	0,3620(0,0609)	-	
s3281	0,1861(0,0359)	0,6898(0,0381)	0,2415(0,0380)	0,5646(0,0414)	0,1946(0,0307)	0,6989(0,0538)	0,1398(0,0311)	0,5563(0,0594)	0,1022(0,0241)	0,4671(0,1130)
s8867	0,0263(0,0171)	0,2119(0,0604)	0,1288(0,0161)	0,2249(0,0608)	0,0240(0,0165)	0,2118(0,0611)	0,0320(0,0195)	0,2201(0,0587)	0,0185(0,0118)	0,3683(0,0695)
s6323_1	0,0463(0,0285)	0,4687(0,0706)	0,2025(0,0260)	0,4791(0,0730)	0,0527(0,0260)	0,4792(0,0731)	0,0945(0,0272)	0,5045(0,0726)	0,0975(0,0203)	0,4573(0,0695)
s7305_A	0,0101(0,1179)	0,7426(0,0634)	0,1045(0,0122)	0,7506(0,1580)	0,1501(0,0058)	0,4583(0,0648)	0,0153(0,0181)	0,5383(0,1672)	0,0089(0,0078)	0,7030(0,0786)
s0205	0,3303(0,0354)	0,4954(0,0459)	0,3973(0,1029)	0,4312(0,4906)	0,5778(0,0344)	0,1278(0,0543)	0,5880(0,1093)	0,0001(0,1949)	0,3477(0,0321)	0,4789(0,0555)
s0206	0,1387(0,0374)	0,4705(0,0757)	0,2358(0,0710)	0,4850(0,1628)	0,3999(0,0328)	0,0006(0,0766)	0,3986(0,1139)	0,1165(0,1254)	0,1669(0,0217)	0,5103(0,0720)
s6251	0,1156(0,0311)	0,5242(0,0742)	0,2879(0,0273)	0,5144(0,0779)	0,0976(0,0355)	0,5279(0,0748)	0,1221(0,0304)	0,5308(0,0775)	0,1166(0,0229)	0,6547(0,1307)
s1119	0,2751(0,0334)	0,5733(0,0522)	0,3818(0,0357)	0,5451(0,0580)	0,2798(0,0358)	0,5735(0,0602)	0,2846(0,0368)	0,5444(0,0617)	-	
s5752_3	0,0124(0,0148)	0,2912(0,0696)	0,2138(0,0138)	0,2787(0,0756)	0,0147(0,0168)	0,2832(0,0723)	0,0074(0,0097)	0,2988(0,0803)	0,0085(0,0079)	0,3768(0,0659)
s0507	0,0420(0,0197)	0,2746(0,0387)	0,1076(0,0187)	0,2356(0,0386)	0,0368(0,0221)	0,2686(0,0544)	0,0155(0,0144)	0,2499(0,0554)	0,0259(0,0178)	0,2586(0,0388)
s0503	0,3870(0,0396)	0,1719(0,0334)	0,3442(0,0399)	0,1620(0,0345)	0,3874(0,0486)	0,1721(0,0461)	0,2784(0,0447)	0,1702(0,0451)	0,3932(0,0396)	0,1793(0,0325)
s0502_2	0,2639(0,0364)	0,2012(0,0384)	0,2826(0,0405)	0,1628(0,0412)	0,2636(0,0421)	0,2239(0,0399)	0,1811(0,0408)	0,2015(0,0470)	0,1711(0,0367)	0,2032(0,0765)
Ortalama	0,1423(0,0329)	0,3938(0,0583)	0,2408(0,0624)	0,3677(0,0851)	0,1849(0,0301)	0,3365(0,0619)	0,1575(0,0443)	0,3222(0,0794)	0,1345(0,0239)	0,3220(0,0736)


Tablo 24 incelendiğinde, alt grup üzerinde G-DINA Modeline göre kestirilen tahmin parametrelerinin ortalaması en düşükten en yükseğe doğru sırasıyla Qmatris_FA, Qmatris_KA, Qmatris_KA_RP_OA, Qmatris_KA_OA ve Qmatris_KA_RP ile yapılan sınıflama sonucu elde edildiği görülmüştür. Alt grup üzerinde G-DINA Modeline göre kestirilen kaydırma parametrelerinin ortalaması incelendiğinde, Qmatris_FA ve Qmatris_KA_RP_OA ile yapılan sınıflamalar sonucunda birbiri ile oldukça az bir farkla (0,002) en düşük kaydırma parametresi değerlerinin elde edildiği görülmüştür. Geriye kalan Q-matrisleri kaydırma parametreleri açısından ortalaması en düşükten en yükseğe doğru sırasıyla Qmatris_KA_OA, Qmatris_KA_RP ve Qmatris_KA ile yapılan sınıflama sonucu elde edildiği görülmüştür.

Şekil 8 ve Şekil 9’da alt grupta uzman kanısına dayalı nitelik boyutu farklı belirlenen Q-matrisleri ile yapılan sınıflama analizlerine ait, sırasıyla, tahmin ve kaydırma parametrelerinin grafiksel gösterimleri yer almaktadır.



Şekil 8. Alt grupta nitelik boyutu farklı belirlenen Q-matrisleri ile yapılan sınıflama analizlerine ait tahmin parametreleri

Şekil 8 incelendiğinde, G-DINA modele göre kestirilen tahmin parametrelerine yönelik olarak Qmatris_KA_RP kullanılarak yapılan sınıflamada diğer Q-matrisleri ile elde edilen tahmin parametrelerine göre çoğunlukla daha büyük değerler edildiği gözlemlenmiştir. Bazı maddelerde (s9342, s0205, s0206) Qmatris_KA_RP_OA ile yapılan kestirimin lehine daha yüksek değerler elde edilmişken çoğunlukla daha düşük değerler elde edilmiştir. Bununla birlikte Qmatris_KA_RP ile Qmatris_KA_OA ile yapılan sınıflamalar tahmin parametresi bağlamında karşılaştırıldığında nitelik setinde okuduğunu anlama becerisinin olduğu Qmatris_KA_OA’nın daha düşük tahmin parametre kestimleri sağladığı görülmektedir.



Şekil 9. Alt grupta nitelik boyutu farklı belirlenen Q-matrisleri ile yapılan sınıflama analizlerine ait kaydırma parametreleri

Şekil 9 incelendiğinde, G-DINA modele göre kestirilen kaydırma parametrelerine ilişkin olarak Qmatris_KA_RP ve Qmatris_KA kullanılarak yapılan sınıflamalarda diğer Q-matrisleri ile elde edilen kaydırma parametrelerine göre çoğunlukla daha büyük değerler edildiği gözlemlenmiştir. Bazı maddelerde (s0203, s0204, s6471, s3281) Qmatris_KA_RP_OA ile yapılan kestirimin lehine daha yüksek değerler elde edilmişken çoğunlukla daha düşük değerler elde edilmiştir. Bununla birlikte Qmatris_KA_RP ile Qmatris_KA_OA ile yapılan sınıflamalar kaydırma parametresi bağlamında karşılaştırıldığında nitelik setinde okuduğunu anlama becerisinin olduğu Qmatris_KA_OA'nın daha düşük kaydırma parametre kestimleri sağladığı görülmektedir.


Üst yetenek grubu üzerinde uzman kanısına ve faktör analizi sonuçlarına dayalı oluşturulan Q-matrisleri ile yapılan sınıflamalarda madde parametrelerinden tahmin ve kaydırma parametrelerine incelenmiştir. Tablo 25'te üst grup örnekleme için QMatris_KA, QMatris_KA_RP, QMatris_KA_OA, QMatris_KA_RP_OA ve QMatris_FA ile G-DINA modeline göre maddelerin tahmin ve kaydırma parametreleri ile bu parametrelere ait standart hata değerleri yer almaktadır.

Tablo 25 Üst Yetenek Grubunda Q-Matrisleri ile Yapılan Sınıflama Analizlerine ait İlişkin Parametre Kestirimleri

	QMatris_KA		QMatris_KA_RP		QMatris_KA_OA		QMatris_KA_RP_OA		QMatris_FA	
	Tahmin(Sh)	Kaydırma(Sh)	Tahmin(Sh)	Kaydırma(Sh)	Tahmin(Sh)	Kaydırma(Sh)	Tahmin(Sh)	Kaydırma(Sh)	Tahmin(Sh)	Kaydırma(Sh)
s0203	0,4270(0,0453)	0,1835(0,0294)	0,4374(0,0416)	0,0968(0,0323)	0,4254(0,0475)	0,1787(0,0303)	0,4235(0,0467)	0,1548(0,0327)	0,4643(0,0403)	0,1491(0,0314)
s0204	0,4521(0,0455)	0,2539(0,0314)	0,4639(0,0416)	0,1925(0,0363)	0,4409(0,0470)	0,2440(0,0314)	0,4437(0,0461)	0,228(0,0333)	0,4548(0,0408)	0,2051(0,0332)
s6471	0,6283(0,0463)	0,1419(0,0231)	0,4769(0,0905)	0,1622(0,0304)	0,5834(0,0613)	0,1550(0,0228)	0,4592(0,0938)	0,168(0,0305)	0,5179(0,0665)	0,1264(0,0355)
s9074	0,3809(0,0545)	0,1722(0,0487)	0,1589(0,0696)	0,1794(0,0632)	0,2844(0,0608)	0,1111(0,0391)	0,1749(0,0716)	0,1728(0,0696)	0,3440(0,0665)	0,1292(0,0202)
s0504	0,4073(0,0556)	0,4044(0,0382)	0,3973(0,0970)	0,4482(0,0512)	0,3843(0,0656)	0,3963(0,0378)	0,3916(0,1036)	0,4524(0,0545)	0,4225(0,0690)	0,3427(0,0608)
s6470_A	0,3395(0,0287)	0,5782(0,0574)	0,3385(0,0297)	0,4701(0,0619)	0,3222(0,0282)	0,5325(0,0589)	0,3304(0,0294)	0,5276(0,0822)	0,2570(0,0345)	0,5438(0,0371)
s9342	0,3302(0,0468)	0,5777(0,0713)	0,3207(0,0430)	0,5157(0,1068)	0,3853(0,0697)	0,5749(0,0881)	0,2849(0,0497)	0,5299(0,1357)	-	-
s0501	0,0997(0,0388)	0,4752(0,0435)	0,1137(0,0346)	0,4810(0,0537)	0,0995(0,0388)	0,4643(0,0445)	0,1090(0,0359)	0,4433(0,0498)	0,1445(0,0346)	0,4693(0,0415)
s9270	0,1931(0,0396)	0,5904(0,0682)	0,1808(0,0359)	0,6020(0,0814)	0,1933(0,0493)	0,6740(0,0612)	0,1849(0,0393)	0,5909(0,0887)	0,1865(0,0296)	0,5807(0,0593)
s3159	0,0174(0,0132)	0,5332(0,0669)	0,0209(0,0152)	0,4794(0,0806)	0,0201(0,0576)	0,5973(0,0742)	0,0238(0,0195)	0,5974(0,1096)	0,0240(0,0140)	0,6198(0,0446)
s0505	0,021(0,02010)	0,3153(0,0712)	0,0523(0,0238)	0,1539(0,0961)	0,0430(0,0250)	0,3324(0,0723)	0,0395(0,0216)	0,2281(0,0804)	0,1160(0,0241)	0,4627(0,0524)
s9739	0,1217(0,0358)	0,5557(0,0626)	0,1478(0,0307)	0,5430(0,0681)	0,1375(0,0355)	0,5273(0,0596)	0,1481(0,0342)	0,5630(0,0768)	-	-
s4427	0,3227(0,0478)	0,3156(0,0632)	0,1242(0,0639)	0,2840(0,0788)	0,2451(0,0744)	0,1842(0,0652)	0,1125(0,0811)	0,1131(0,0893)	0,207(0,0505)	0,4232(0,0289)
s6188	0,3897(0,0524)	0,3228(0,0615)	0,3204(0,0771)	0,3378(0,0792)	0,3852(0,0599)	0,2278(0,0560)	0,2990(0,0783)	0,3005(0,0693)	0,3315(0,0625)	0,2855(0,043)
s0201	0,7434(0,0508)	0,1529(0,0552)	0,4197(0,0970)	0,0869(0,0732)	0,7553(0,0520)	0,1769(0,0634)	0,4043(0,0959)	0,0513(0,0473)	0,5977(0,0676)	0,2023(0,0319)
s5050_A1	0,2973(0,0492)	0,1353(0,0299)	0,3769(0,0429)	0,1249(0,0313)	0,3329(0,0508)	0,1605(0,0305)	0,3342(0,0477)	0,1168(0,0326)	0,3475(0,0469)	0,1372(0,0449)
s6963_B	0,4647(0,0471)	0,2660(0,0626)	0,4195(0,0874)	0,1773(0,0709)	0,4420(0,0557)	0,3125(0,0602)	0,4310(0,0892)	0,2391(0,0819)	0,4415(0,0627)	0,3138(0,0648)
s6370	0,2682(0,0477)	0,3492(0,0346)	0,3074(0,0408)	0,3303(0,0369)	0,2526(0,0468)	0,3425(0,0351)	0,2939(0,0471)	0,3374(0,0380)	0,3267(0,0393)	0,333(0,0359)
s3281	0,2603(0,0430)	0,4848(0,0333)	0,299(0,04120)	0,4606(0,0416)	0,2542(0,0452)	0,4785(0,0355)	0,2601(0,0440)	0,4676(0,0378)	0,264(0,0376)	0,4437(0,0385)
s8867	0,1014(0,0354)	0,1355(0,0509)	0,1247(0,0346)	0,0501(0,0563)	0,0737(0,0348)	0,2444(0,0579)	0,0985(0,0358)	0,1146(0,0567)	0,0741(0,0322)	0,1916(0,0545)
s6323_1	0,2198(0,0412)	0,5029(0,0705)	0,2312(0,0396)	0,4234(0,1104)	0,2400(0,0418)	0,5206(0,0725)	0,2357(0,0422)	0,4436(0,0910)	-	-
s7305_A	0,0212(0,0149)	0,6277(0,0674)	0,0183(0,0118)	0,5150(0,1030)	0,0249(0,0378)	0,6792(0,0757)	0,0163(0,0178)	0,5395(0,1304)	0,0198(0,0100)	0,7924(0,0375)
s0205	0,3658(0,0439)	0,4130(0,0327)	0,4374(0,0416)	0,0968(0,0323)	0,2751(0,0945)	0,2784(0,0486)	0,4141(0,0559)	0,0201(0,1098)	0,4046(0,0324)	0,2988(0,0463)
s0206	0,2780(0,0445)	0,3785(0,0675)	0,4639(0,0416)	0,1925(0,0363)	0,4394(0,1066)	0,3335(0,0799)	0,0319(0,1085)	0,2316(0,1082)	0,3611(0,0596)	0,3718(0,0539)
s6251	0,1965(0,0389)	0,4683(0,0671)	0,4769(0,0905)	0,1622(0,0304)	0,1737(0,0438)	0,4833(0,0637)	0,1939(0,0402)	0,4334(0,0781)	0,1849(0,0491)	0,4884(0,055)
s1119	0,3146(0,0294)	0,4175(0,0623)	0,1589(0,0696)	0,1794(0,0632)	0,3202(0,0296)	0,4324(0,0666)	0,3223(0,0296)	0,3827(0,0721)	-	-
s5752_3	0,0930(0,0313)	0,2623(0,0699)	0,3973(0,0970)	0,4482(0,0512)	0,0902(0,0307)	0,3403(0,0737)	0,0201(0,1921)	0,1504(0,0816)	0,1600(0,0307)	0,373(0,0477)
s0507	0,4428(0,0505)	0,2417(0,0307)	0,3385(0,0297)	0,2701(0,0619)	0,4324(0,0501)	0,2321(0,0325)	0,0828(0,0635)	0,2043(0,0376)	0,2582(0,0561)	0,249(0,0258)
s0503	0,6885(0,0444)	0,1474(0,0237)	0,3207(0,0430)	0,2157(0,1068)	0,6802(0,0456)	0,1406(0,0261)	0,3185(0,0998)	0,1274(0,0322)	0,5177(0,0619)	0,1289(0,0191)
s0502_2	0,5736(0,0469)	0,1387(0,0257)	0,1137(0,0346)	0,1481(0,0537)	0,4330(0,0647)	0,1237(0,0229)	0,2614(0,0909)	0,0765(0,0234)	0,2997(0,0595)	0,1082(0,0632)
Ortalama	0,3153(0,0409)	0,3514(0,0507)	0,2819(0,0535)	0,2943(0,0637)	0,3056(0,0443)	0,3493(0,0794)	0,2381(0,0617)	0,3032(0,0687)	0,2972(0,0453)	0,3373(0,0426)


Tablo 25 incelendiğinde, üst grup üzerinde G-DINA Modeline göre kestirilen tahmin parametrelerinin ortalaması en düşükten en yükseğe doğru sırasıyla Qmatris_KA_RP, Qmatris_FA, Qmatris_KA, Qmatris_KA_RP_OA, Qmatris_KA_OA ve ile yapılan sınıflama sonucu elde edildiği görülmüştür. Üst grup üzerinde G-DINA Modeline göre kestirilen kaydırma parametrelerinin ortalaması incelendiğinde en düşükten en yükseğe doğru sırasıyla Qmatris_KA_RP_OA, Qmatris_KA_RP, Qmatris_FA, Qmatris_KA_OA ve Qmatris_KA_ ile yapılan sınıflama sonucu elde edildiği görülmüştür.

Şekil 10 ve Şekil 11’de üst grupta uzman kanısına dayalı nitelik boyutu farklı belirlenen Q-matrisleri ile yapılan sınıflama analizlerine ait, sırasıyla, tahmin ve kaydırma parametrelerinin grafiksel gösterimleri yer almaktadır.



Şekil 10. Üst grupta nitelik boyutu farklı belirlenen Q-matrisleri ile yapılan sınıflama analizlerine ait tahmin parametreleri

Şekil 10 incelendiğinde, G-DINA modele göre kestirilen tahmin parametrelerine yönelik olarak Qmatris_KA_OA kullanılarak yapılan sınıflamada diğer Q-matrisleri ile elde edilen tahmin parametrelerine göre çoğunlukla daha büyük değerler edildiği gözlemlenmiştir. Bazı maddelerde (s3281, s6251, s5752_3) Qmatris_KA_RP ile yapılan kestirimin lehine daha yüksek değerler elde edilmişken çoğunlukla daha düşük değerler elde edilmiştir. Bununla birlikte Qmatris_KA_RP ile Qmatris_KA_OA ile yapılan sınıflamalar tahmin parametresi bağlamında karşılaştırıldığında nitelik setinde rutin olamayan problem çözme becerisinin olduğu Qmatris_KA_RP’nin daha düşük tahmin parametre kestimleri sağladığı görülmektedir.



Şekil 11. Üst grupta nitelik boyutu farklı belirlenen Q-matrisleri ile yapılan sınıflama analizlerine ait kaydırma parametreleri

Şekil 11 incelendiğinde, G-DINA modele göre kestirilen kaydırma parametrelerine ilişkin Qmatris_KA_OA ve Qmatris_KA kullanılarak yapılan sınıflamalarda diğer Q-matrisleri ile elde edilen kaydırma parametrelerine göre çoğunlukla daha büyük değerler edildiği gözlemlenmiştir. Bazı maddelerde (s0203, s0204, s6471, s3281) Qmatris_KA_RP_OA ile yapılan kestirimin lehine daha yüksek değerler elde edilmişken çoğunlukla daha düşük değerler elde edilmiştir. Bununla birlikte Qmatris_KA_RP ile Qmatris_KA_OA ile yapılan sınıflamalar kaydırma parametresi bağlamında karşılaştırıldığında nitelik setinde okuduğunu anlama becerisinin olduğu Qmatris_KA_OA'nin daha düşük kaydırma parametre kestimleri sağladığı görülmektedir.

İkinci araştırma sorusuna ilişkin bulgular şu şekilde özetlenebilir: Genel olarak, alt grupta konu alanına ilişkin niteliklere ek olarak okuduğunu anlama becerisi ile birlikte ele alındığında yapılan sınıflamaya dayalı olarak öğrencilerin maddeleri doğru cevaplama yönü olarak üst gruba kıyasla daha uygun sınıflamalar elde edilmiştir. Bu bulguya paralel olarak Kroll ve Miller (1993) tarafından yapılan çalışmada iyi problem çözücülerin yeterli düzeyde okuduğunu anlama becerilerine sahip olduğunu, fakat iyi çözücüler ve kötü çözücüler arasında matematiğin temel becerilerine sahip olma konusunda büyük farklılıkların olmadığı görülmüştür. Buna karşılık üst grupta, konu alanına ilişkin niteliklere ek olarak rutin olmayan problem çözme becerisi ile birlikte ele alındığında yapılan sınıflamaya dayalı olarak öğrencilerin maddeleri doğru cevaplama yönü olarak alt gruba kıyasla daha uygun sınıflamalar elde edilmiştir. Carboni'nin (2001) çalışmasına göre rutin olmayan problemler rutin olan problemlere göre üst düzeyde bulunan öğrencilerin ayırt edilmesinde kaynak sağlayıcı olabileceği vurgulanmıştır. Bu araştırma sorusu ile öğrenci

başarı puanlarının yığılımlarının farklılaşmasından farklı olarak yayılımlarının, ele alınan kuram çerçevesinde, sınıflamayı nasıl etkilediğine yönelik test edilememiştir. Ancak ilgili durum sonraki araştırma sorusu ile incelenmeye çalışılmıştır.

Üçüncü Araştırma Sorusuna İlişkin Bulgular

Çalışmanın üçüncü araştırma sorusu kapsamında analizler çarpıklık katsayıları 0, 0,5, 0,75, 1, 1,25, 1,5 ve 2 olan örneklemeler üzerinde yapılmıştır. Bu araştırma sorusuna yönelik uzman görüşüne dayalı olarak belirlenen QMatris_KA kullanılmıştır.

Araştırma Sorusu 3.a: Bilişsel tanı değerlendirmelerinde, G-DINA Modeli altında farklı dağılım koşulları (Çarpıklık katsayıları 0, 0,5, 0,75, 1, 1,25, 1,5 ve 2) test ve nitelik düzeyinde sınıflama doğruluklarını nasıl etkilemektedir?

Bu araştırma sorusuna yanıt aramak amacıyla farklı dağılım özelliklerine sahip örneklemeler üzerinde uzman görüşüne dayalı olarak belirlenen Q-matrisi ile yapılan sınıflama analizinin test ve nitelik düzeyinde sınıflama doğrulukları incelenmiştir. Tablo 26'da normal ve çarpık örneklemeler için QMatris_KA ile G-DINA modele göre kestirilen test ve nitelik düzeyinde sınıflama doğrulukları yer almaktadır.

Tablo 26

Çarpıklık Katsayıları 0, 0,5, 0,75, 1, 1,25, 1,5 ve 2 Olan Gruplar Üzerinde Yapılan Sınıflama Analizlerine Ait Test ve Nitelik Düzeyinde Sınıflama Doğrulukları

	Test düzeyinde Sınıflama Doğruluğu	Nitelik Düzeyinde Sınıflama Doğruluğu			
		α_S	α_C	α_G	α_V
Normal	0,8975	0,9412	0,9783	0,9720	0,9743
ÇK:0,5	0,8836	0,9659	0,9521	0,9476	0,9515
ÇK:0,75	0,8606	0,9891	0,9452	0,9514	0,9416
ÇK:1	0,8279	0,9782	0,9390	0,9211	0,9357
ÇK:1,25	0,8523	0,9620	0,9458	0,9322	0,9417
ÇK:1,5	0,8174	0,9742	0,9452	0,8922	0,9367
ÇK:2	0,7109	0,8920	0,9208	0,8557	0,9190

Tablo 26 incelendiğinde, test düzeyinde sınıflama doğrulukları ele alındığında en yüksek sınıflama doğruluğuna normal dağılım koşulunda yapılan analiz sonucunda ulaşılmıştır. Çarpık dağılım koşullarında yapılan sınıflamalar karşılaştırıldığında ise en yüksek sınıflama doğruluğundan en düşüğe doğru sırasıyla ÇK:0,5, ÇK:0,75, ÇK:1,25, ÇK:1, ÇK:1,5 ve ÇK:2

örneklemelerinde elde edilmiştir. Bu sıralamada ÇK:1 ve ÇK:1,25 örneklemeleri dışında çarpıklık değeriinin artışı ile test düzeyinde sınıflama doğruluklarının azaldığı görölmektedir. Nitelik düzeyinde sınıflama doğrulukları incelendiğinde, kendi aralarında cebir ve veri işleme nitelikleri benzer doğrulukta sınıflama oranlarına sahipken, içlerinde çarpıklık değeri artışı ile sınıflama doğrulukların tutarlı bir eğilim sergilememektedir. Ancak ÇK:1,25, ÇK:1,5 ve ÇK:2 örneklemelerinde bir değeri hariç (ÇK:1,5 örnekleminde sayılar ve işlemler niteliği hariç) çarpıklık değeri arttıkça nitelik düzeyinde sınıflama doğrulukları düşmektedir.

Araştırma Sorusu 3.b: Bilişsel tanı değeriendirmelerinde, G-DINA Modeli altında farklı dağılım koşulları (Çarpıklık katsayıları 0, 0,5, 0,75, 1, 1,25, 1,5 ve 2) model veri uyumunu nasıl etkilemektedir?

Bu araştırma sorusuna yanıt aramak amacıyla farklı dağılım özelliklerine sahip örneklemeler üzerinde uzman görüşüne dayalı olarak belirlenen Q-matrisi ile yapılan sınıflama analizlerine ilişkin mutlak ve bağıl model veri uyumları incelenmiştir. Tablo 27'de normal ve çarpık dağılım koşullarında QMatris_KA ile G-DINA model altında elde edilen mutlak model veri uyum indeksleri yer almaktadır.

Tablo 27

Çarpıklık Katsayıları 0, 0,5, 0,75, 1, 1,25, 1,5 ve 2 Olan Gruplarda Yapılan Sınıflama Analizlerine ait Mutlak Model Uyumu İndeksleri

	RMSEA (%90 Güven aralığı)	SRMSR
Normal	0,0179 [0,0078-0,0251]	0,0537
ÇK:0,5	0,0257 [0,0251-0,0191]	0,0608
ÇK:0,75	0,0222 [0,0509- 0,0604]	0,0528
ÇK:1	0,0415 [0,0366-0,0464]	0,0730
ÇK:1,25	0,0306 [0,0248- 0,0361]	0,0577
ÇK:1,5	0,0166 [0,0045-0,0241]	0,0540
ÇK:2	0,0296 [0,0237-0,0352]	0,0508

Tablo 27 incelendiğinde, tüm dağılım koşullarında RMSEA değerlerinin 0,05'ten küçük olduğu görülmüştür. Dolayısıyla RMSEA açısından her bir örnekleme model veri uyumunun sağlandığı yorumu yapılabilir. Bununla birlikte karşılaştırma yapıldığında en düşük RMSEA değerinden en yükseğine doğru sırasıyla ÇK:1,5, Normal, ÇK:0,75, ÇK:0,5, ÇK:2, ÇK:1,25 ve ÇK: 1 örneklemeleri üzerinde elde edilmiştir. SRMSR değerleri incelendiğinde ise tüm dağılım koşullarında 0,05'ten büyük olduğu görülmüştür. Karşılaştırma yapıldığında en düşük SRMSR değerinden en yükseğine doğru sırasıyla ÇK:2, ÇK:0,75, Normal, ÇK:1,5, ÇK:1,25, ÇK:0,5, ve ÇK: 1 örneklemeleri üzerinde elde edilmiştir. Artan çarpıklık katsayılarına sahip olan örneklemeler üzerinde yapılan sınıflama sonucunda elde edilen mutlak uyum indeksleri dalgalanmalar gözlemlenmektedir. Her bir dağılım üzerinde yapılan analizlerde mutlak uyumun yorumlanmasının ardından bağıl uyum indekslerinin incelenmesine geçilmiştir.

Normal ve çarpık dağılım koşullarında QMatris_KA ile G-DINA model altında elde edilen sınıflama analizlerine ait bağıl model veri uyumu Tablo 28'de verilmiştir.

Tablo 28

Çarpıklık Katsayıları 0, 0,5, 0,75, 1, 1,25, 1,5 ve 2 Olan Gruplarda Yapılan Sınıflama Analizlerine ait Bağıl Model Uyumu İndeksleri

	Loglikeliho od	Deviance	AIC	BIC	CAIC	SABIC
Normal	-5502,833	11005,67	11227,67	11695,49	11806,49	11343,17
ÇK:0,5	-6029,639	12059,28	12281,28	12749,1	12860,1	12396,78
ÇK:0,75	-7560,192	15342,38	15342,38	15810,43	15921,43	15458,1
ÇK:1	-8175,152	16350,3	16572,3	17040,12	17151,12	16687,8
ÇK:1,25	-7781,783	15563,57	15785,57	16253,39	16364,39	15901,07
ÇK:1,5	-7230,488	14460,98	14682,98	15150,8	15261,8	14798,48
ÇK:2	-8567,645	17135,29	17357,29	17825,11	17936,11	17472,79

Tablo 28 incelendiğinde, G-DINA modelde kestirilen bağıl test uyum indekslerinin tamamına göre en iyi uyum normal dağılım üzerinde yapılan sınıflama sonucunda elde edildiği görülmüştür. Bağıl test uyum indekslerinin tamamına göre en az uyum ise ÇK:2 örnekleme üzerinde yapılan sınıflama sonucunda elde edildiği görülmüştür. Ancak her örneklem grubunda sınıflama sonucunda elde edilen bağıl uyum indeksleri birlikte değişkenlik göstermemiştir. Bağıl uyum indekslerinden BIC'e göre karşılaştırma yapıldığında en düşük değerden en yükseğine doğru sırasıyla Normal, ÇK:0, ÇK: 0,5, ÇK: 1,5, ÇK: 0,75, ÇK: 1,25, ÇK:1 ve ÇK:2 örneklemeleri üzerinde elde edilmiştir. Çarpıklık değerlerinin artışına ilişkin incelemede mutlak uyum indeksine göre bağıl uyum indeksi daha az dalgalanma göstermektedir.

Araştırma Sorusu 3.c: Bilişsel tanı değerlendirmelerinde, G-DINA Modeli altında farklı dağılım koşulları (Çarpıklık katsayıları 0, 0,5, 0,75, 1, 1,25, 1,5 ve 2) tahmin ve kaydırma parametre kestirimlerini nasıl etkilemektedir?

Bu araştırma sorusuna yanıt aramak amacıyla farklı dağılım özelliklerine sahip örneklemeler üzerinde uzman görüşüne dayalı olarak belirlenen Q-matrisi ile yapılan sınıflama analizlerinden elde edilen tahmin ve kaydırma parametre kestirimlerinin ortalamaları incelenmiştir. Tablo 29'da normal ve çarpık dağılım koşullarında QMatris_KA ile G-DINA

model altında elde edilen tahmin ve kaydırma parametre kestirimleri ile parametrelere ait standart hata değerlerinin ortalaması yer almaktadır.

Tablo 29

Çarpıklık Katsayıları 0, 0,5, 0,75, 1, 1,25, 1,5 ve 2 Olan Gruplar Üzerinde Yapılan Sınıflama Analizlerine Ait Ortalama Parametre Kestirimleri

	Tahmin(Sh)	Kaydırma(Sh)
Normal	0,2504(0,0194)	0,4540(0,0492)
ÇK:0,5	0,2379(0,0182)	0,4488(0,0862)
ÇK:0,75	0,2175(0,0284)	0,3720(0,0707)
ÇK:1	0,1835(0,0262)	0,4124(0,0723)
ÇK:1,25	0,1871(0,0233)	0,4216(0,0767)
ÇK:1,5	0,1087(0,0236)	0,5227(0,0956)
ÇK:2	0,1108(0,0574)	0,5425(0,1982)

Tablo 29 incelendiğinde, en düşük tahmin parametresi ortalaması sırasıyla ÇK:1,5, ÇK:2, ÇK:1, ÇK:1,25, ÇK:0,75, ÇK:0,5 ve Normal örneklemelerde yapılan sınıflama sonucu elde edilmiştir. Genel anlamda çarpıklık arttığında tahmin parametre değerlerinin azalma eğiliminde olduğu gözlemlenmiştir. Bununla birlikte tahmin parametresine ait standart hataların ortalamasının iki durum haricinde (Normal ve ÇK:0,5 ile ÇK:0,75 ve ÇK:1) çarpıklık değeri arttıkça standart hataların da arttığı gözlemlenmiştir. Madde bazında incelemeler yapıldığında ÇK:1,5 ve ÇK:2 koşulları altında bazı maddelerin tahmin parametre değerlerinin 0,0001 olduğu görülmüştür. Dolayısıyla bu kestirimler elde edilen ortalama değerlerinin ciddi manada düşmesine sebep olmaktadır. Bununla birlikte çok düşük tahmin parametresine sahip maddelerin yüksek standart hatalara sahip olduğu görülmüştür.

En düşük kaydırma parametresi ortalaması sırasıyla ÇK:0,75, ÇK:1, ÇK:1,25, ÇK:0,5, normal, ÇK:1,5 ve ÇK:2 örneklemelerde yapılan sınıflama sonucu elde edilmiştir. Çarpıklık arttığında kaydırma parametre değerleri üzerinde tutarlı bir yönde değişim olmamakla birlikte dalgalanmaların olduğu gözlemlenmiştir. Ancak parametere ortalamalarındaki bu dalgalanmanın aksine kaydırma parametresine ait standart hataların ortalama değerleri incelendiğinde çarpıklık değeri arttıkça standart hataların da arttığı gözlemlenmiştir. Özellikle ÇK:2 koşulunda standart hata ortalamasının oldukça yüksek olduğu (0,1982) dikkat çekmektedir. Madde bazında incelemeler yapıldığında ÇK:2 koşulunda bazı maddelerin kaydırma parametre değerlerinin 0,9'un üzerinde olduğu görülmüştür. Dolayısıyla bu kestirimler elde edilen ortalama değerlerinin yükselmesine sebep olmaktadır.

Bununla birlikte çok yüksek kaydırma parametresine sahip maddelerin yüksek standart hatalara sahip olduđu görölmüştür.



BÖLÜM V

SONUÇ VE TARTIŞMA

Bu bölümde araştırma sonucunda elde edilen bulgular alanyazındaki bulgular ile tartışılarak sonuca bağlanmış ve elde edilen sonuçlar doğrultusunda araştırmacı ve uygulayıcılara önerilerde bulunulmuştur.

Sonuçlar

Birinci Araştırma Sorusuna İlişkin Sonuç ve Tartışma

Çalışmanın birinci araştırma sorusu kapsamında öncelikle uzman kanısına dayalı olarak belirlenen Q-matrisleri ile evren veri seti üzerinde incelemeler yapılmıştır. İlk olarak Q-matrisleri uzman kanısına dayalı olarak belirlenmiş, ardından bu matrise dayalı yapılan geçerleme sonucunda tüm modifikasyon önerileri dikkate alınmış ve daha sonra geçerleme sonucundaki modifikasyon önerilerinden gerekli olanların dikkate alınmasıyla elde edilen üç Q-matris ile sınıflandırma yapılmıştır. Sonuçlar maddeler halinde sunulmuştur.

- G-DINA Modeli altında test düzeyinde en yüksek sınıflamayı, geçerleme yönteminin önerdiği modifikasyonlardan Mesa plot incelemeleri ve uzman görüşleri doğrultusunda uygun görülenlerin kabul edilmesi sonucunda belirlenen Q-matrisi ile elde edilmiştir. Nitelik düzeyinde sınıflama doğrulukları incelendiğinde, bu matrisin dört nitelikten iki niteliğe ait sınıflama doğruluğunun da en yüksek olduğu görülmüştür. Diğer iki niteliğe ait sınıflama doğruluğu ise geçerleme yönteminin önerdiği hiçbir modifikasyonun dikkate alınmadığı, yalnızca uzman görüşüne dayalı olarak belirlenen Q-matrisi ile yapılan sınıflama sonucunda elde edilmiştir. Hem test

hem nitelik düzeyinde, geçerleme yönteminin önerdiği modifikasyonların tamamının dikkate alınmasıyla belirlenen Q-matrisi kullanıldığında en az sınıflama doğruluğu elde edilmiştir. Sonuç olarak, geçerleme yöntemi uygulanmayan ve geçerleme yöntemi uygulaması sonucunda uygun görülen modifikasyonların kabul edilmesiyle belirlenen Q-matrisleri birbirine yakın doğrulukta sınıflama yapsa da en iyi sınıflama doğruluğunu sağlayan Q-matrisinin geçerleme modifikasyonlarından uygun görülen modifikasyonların kabul edilmesiyle belirlenen Q-matris ile yapılan sınıflamaya aittir. Q-matrisinde yapılan modifiyeler sonucunda sınıflama doğruluklarının değiştiği sonucuna paralel olarak, Rupp & Templin (2008a) bir niteliği ölçen maddelerin oranının ve bir madde tarafından ölçülen niteliklerin sayısının sınıflama doğruluğunu etkileyebileceğini göstermiştir. de la Torre & Chiu (2016) alan uzmanları tarafından oluşturulan Q-matrisindeki nitelikler ile ilişkilendirmelerin genellikle öznel olarak değerlendirildiği dolayısıyla bu durumun bireylerin yanlış sınıflandırılmasına yol açabileceğini belirtmiştir.

- Mutlak model veri uyumu sonuçlarına göre, RMSEA ve SRMSR uyum indeksleri ele alındığında geçerleme modifikasyonlarının tamamı ya da bir kısmı dikkate alınmasıyla belirlenen Q-matrisleri uyum sağlamış olmasının yanında geçerleme yönteminin uygulandığı Q-matrisleri, geçerleme yönteminin uygulanmadığı Q-matrisine göre daha iyi bir uyuma sahiptir. Yani geçerleme yöntemi mutlak uyum indekslerinde iyileşmeler sağlamıştır. Benzer şekilde Koyuncu (2020), önerdiği geçerleme yönteminin kullanılmasıyla elde edilecek Q-matrislerinden daha da düşük RMSEA ve SRMSR değerleri elde edilebileceği belirtmiştir. Bağlı model veri uyum sonuçlarına göre, AIC, BIC, CAIC ve SABIC istatistikleri açısından karşılaştırıldığında geçerleme yönteminin verdiği tüm modifikasyonların kabul edilmesiyle belirlenen Q-matrisi diğer iki Q-matrise göre daha iyi model veri uyumu sağlamıştır. Uygun modifikasyonların kabul edilmesiyle belirlenen Q-matrisi ise geçerleme yöntemi uygulanmayan Q-matrise göre daha iyi model veri uyumu sağlamıştır. Sonuç olarak tüm modifikasyonların kabul edilmesiyle belirlenen Q-matrisi daha iyi derece mutlak uyuma ve daha iyi bağlı uyuma sahip olduğunu ve dolayısıyla istatistiksel olarak tercih edilmesi gerektiğini göstermektedir. Model veri uyumu bağlamında Kalkan, Kelecioğlu ve Başokçu (2018) en önemli değişkenlerinden birinin Q matris geçerliliği olduğunu belirtmiştir. Wang ve arkadaşlarının (2020) vurguladığı gibi, yapılan bir geçerleme süreci sonunda elde

edilen Q-matrisinin daha iyi model-veri uyumlarına sahip olması, Q-matrisinin makul ve yorumlanabilir olduğunu garanti etmemektedir ve alan bilgisine dayalı uzman kararlarına yine de başvurulmalıdır. Bu yüzden model uyumu açısından hem istatistiksel olarak hem de teoriye uygun olarak belirlenen Q-matrisinin kullanımının uygun olabileceği sonucuna varılmaktadır.

- Parametre kestirimleri sonuçlarına göre ise tahmin parametrelerinin ortalaması en düşükten yükseğe doğru sırasıyla; geçerleme yöntemi uygulaması sonucunda uygun görülen modifikasyonların kabul edilmesiyle belirlenen Q-matrisi, geçerleme yapılmayan Q-matrisi ve tüm modifikasyonların kabul edilmesiyle belirlenen Q-matrisi olduğu bulunmuştur. Bu sonuçlara benzer bir şekilde Koyuncu (2020), önerdiği geçerleme yöntemini kullanarak belirlediği Q-matrisi, yalnızca uzman kanısına dayalı olarak belirlediği Q-matrisinden daha da düşük tahmin parametre değerleri elde etmiştir. Kaydırma parametrelerinin ortalaması en düşükten yükseğe doğru sırasıyla geçerleme yöntemi uygulaması sonucunda uygun görülen modifikasyonların kabul edilmesiyle belirlenen Q-matrisi, tüm modifikasyonların kabul edilmesiyle belirlenen Q-matrisi ve olduğu ve geçerleme yapılmayan Q-matrisi olduğu bulunmuştur. Rupp ve Templin'in (2008a) bulgularına göre bir madde için 0 olması gereken bir Q-matris girdisi 1 olarak değiştirildiğinde, kaydırma parametresi değerinde artış olduğu gözlemlenirken, tahmin parametresi kestirimi genellikle aynı kalmıştır. Bunun aksine, bir madde için 1 olması gereken bir Q-matris girdisi 0 olarak değiştirildiğinde, tahmin parametresi değerinde artış olduğu gözlemlenirken kaydırma parametresi kestirimi genellikle aynı kalmıştır. Bir madde için hem 0 olması gereken bir Q-matris girdisi 1 ve hem de 1 olması gereken bir Q-matris girdisi 0 olarak değiştirildiğinde hatalı belirlemenin etkisi, hem kaydırma hem de tahmin parametreleri için artan bir ortalama mutlak sapmada gözlemlenmiştir. Bu çalışmanın bulguları incelendiğinde, geçerleme yönteminin önerdiği modifikasyonlardan uygun görülenlerin dikkate alınmasıyla belirlenen Q-matris girdilerindeki yapılan değişikliklere yönelik olarak Rupp ve Templin'in (2008a) bulgularının ışığında hatalı belirlemenin yapılmadığına işaret etmektedir. Sonuç olarak en iyi parametre kestirimlerinin, geçerleme yöntemi uygulaması sonucunda uygun görülen modifikasyonların kabul edilmesiyle belirlenen Q-matrisi ile yapılan sınıflama ile elde edildiği söylenebilir. Bu yüzden sonraki araştırma sorularına ilişkin olarak yapılacak uzman kanısına dayalı Q-matrisleri için uygun görülen

modifikasyon önerileri ile geçerleme yapılan Q-matrisi kullanılmıştır. Bu sonuca paralel olarak de la Torre ve Akbay (2019) geçerleme yöntemi bir q-vektörünü önermiş olsa da, Q-matrisini düzeltmeye ilişkin nihai kararın, ilgili maddeye ait q-vektörü ve test tarafından ölçülen nitelikler dikkatlice değerlendirildikten sonra uzman kararına dayandırılması gerekliliğini vurgulamıştır.

Bu araştırma sorusu kapsamında, uzman kanısına dayalı Q-matrislerinin ardından, faktör analizi sonuçlarına dayalı olarak belirlenen Q-matrisleri ile evren veri seti üzerinde incelemeler yapılmıştır. İlk olarak Q-matrisi faktör analizi sonucunda ortaya çıkan faktör deseni kullanılarak belirlenmiş, ardından bu matrise dayalı yapılan geçerleme sonucunda modifikasyon önerileri dikkate alınmış ve elde edilen iki Q-matris ile sınıflandırma yapılmıştır. Sonuçlar şu şekilde sıralanabilir:

- G-DINA Modeli altında geçerleme yöntemi sonucunda modifikasyon önerileri dikkate alınarak belirlenen Q-matrisi, geçerleme yapılmayan Q-matrisine göre test düzeyinde daha yüksek doğrulukta sınıflamayı sağlamıştır. Nitelik düzeyinde sınıflama doğrulukları incelendiğinde her iki matris de dört nitelikten ikişer niteliğe ait sınıflama doğruluğunun da daha yüksek olduğu görülmüştür. Sonuç olarak, geçerleme yöntemi uygulanmayan ve geçerleme yöntemi uygulaması sonucunda test düzeyinde, geçerleme yapılan Q-matris geçerleme yapılmayan Q-matrise göre daha yüksek doğrulukta sınıflama yapsa da birbirine oldukça yakın doğrulukta sınıflama yaptıkları görülmüştür. Bu sonuç doğrultusunda Faktör analizine dayalı belirlenen Q-matrislerine geçerleme yönteminin uygulanmasına gerek olmadığı sonucuna ulaşılmıştır.
- Mutlak model veri uyumu sonuçlarına göre, her iki Q-matrisi mükemmel uyum göstermiş ve çok küçük farklılıkla da olsa geçerleme yönteminin uygulandığı Q-matrisi, geçerleme yönteminin uygulanmadığı Q-matrisine göre daha iyi bir uyuma sahip olduğu görülmüştür. Yani uzman kanısına dayalı olarak geliştirilen Q-Matrisleri ile yapılan sınıflamalara benzer şekilde geçerleme yöntemi faktör analizine dayalı olarak geliştirilen Q-matrislerinde olduğu gibi mutlak uyum indekslerinde iyileşmeler sağlamıştır. Bağlı model veri uyum sonuçlarına göre, ele alınan tüm indeksler açısından karşılaştırıldığında geçerleme yönteminin uygulandığı Q-matrisi geçerleme yönteminin uygulanmadığı Q-matrise göre daha iyi model veri uyumu sağlamıştır.

- Parametre kestirimleri sonuçlarına göre ise tahmin ve kaydırma parametrelerinin ortalaması geçerleme yönteminin uygulanmadığı Q-matrisine göre geçerleme yönteminin uygulandığı Q-matrisi ile yapılan sınıflamada daha düşük olduğu gözlemlenmiştir. Ancak bu farkın da %2 oranında yapılan Q-matris girdi modifikasyonundan olduğu ve bu farkın da oldukça küçük olduğu gözlemlenmiştir. Sonuç olarak faktör analizi ile belirlenen Q-matris için geçerleme yönteminin önerdiği modifikasyon sayısının oldukça az olması sebebiyle ilgili modifikasyon önerileri dikkate alınarak elde edilen Q-matris ile modifikasyon yapılmayan Q-matris karşılaştırıldığında, araştırma kapsamında ele alınan kriterler açısından benzer oldukları söylenebilir. Bu yüzden sonraki araştırma sorularına ilişkin olarak yapılacak faktör analizine dayalı Q-matrisleri için geçerleme yapmaya ihtiyaç duyulmamıştır. Bu yüzden sonraki araştırma sorularına ilişkin olarak yapılacak faktör analizine dayalı Q-matrisleri için geçerleme süreci kullanılmamıştır. Ancak unutulmamalıdır ki boyutluluk gruba bağlı olarak değişkenlik gösterebilmektedir. Bu yüzden her bir dağılım koşulu için faktör analizi uygulanmış ve nitelik seti gruba bağımlı olarak belirlenmiştir.
- Birinci araştırma sorusunun sonuçları doğrultusunda Q-matris geçerleme sonuçları, uzmanlar için bir referans olarak kullanılabilir ve testin bilişsel yapısına dayalı bir uzman kararı gereklidir (Wang, Cai ve Tu; 2020). Diğer bir deyişle geçerleme yapıldıktan sonra modifikasyonun kabul edilmesi için alan bilgisine ihtiyaç duyulmaktadır. Ancak faktör analizine dayalı Q-matrisinin belirlenmesinde geçerleme yapmaya gerek olmadığı sonucuna ulaşılmıştır. Bununla birlikte bu çalışmanın ele aldığı ders ve öğrenci grubu bağlamında sınırlandırılmak suretiyle, faktör analizine dayalı Q-matrisleri ile yapılan sınıflamalar uzman kanısına dayalı oluşturulan Q-matrisleri ile yapılan sınıflamalara benzer sonuçlar ürettiği görülmüştür.

İkinci Araştırma Sorusuna İlişkin Sonuç ve Tartışma

Çalışmanın ikinci araştırma sorusu kapsamında alt ve üst yetenek grupları üzerinde incelemeler yapılmıştır. Önceki araştırma sorusu sonuçları doğrultusunda geçerlemesi yapılan Q-matrise ek olarak rutin olmayan problem çözme becerisi ve okuduğunu anlama becerisi gerektiren maddeler ile ayrı ayrı ve birlikte olacak şekilde nitelik setine eklenmiş ve

toplamda uzman kanısına dayalı beş farklı Q-matrisi elde edilmiştir. Ayrıca her bir yetenek düzeyindeki grup için faktör analizi yapılmış ve belirlenen faktör yapısına dayalı olarak belirlenen Q-matrisi ile sınıflandırma yapılmıştır. Bu araştırma sorusuna ilişkin sonuçlar şu şekilde sıralanabilir:

- Alt yetenek grubu üzerinde G-DINA Modeli altında en yüksek doğrulukta test düzeyinde sınıflama, konu alanına ek okuduğunu anlama becerisine dayalı olarak belirlenen Q-matrisi ile elde edilmiştir. Ardından en yüksek sınıflama doğruluğuna faktör analizine dayalı belirlenen Q-matrisi ile elde edilmiştir. Ancak Q-matriste rutin olmayan problem çözme becerisi bulunduğu durumda yapılan analizler ile en düşük sınıflama doğrulukları elde edilmiştir. Üst yetenek grubu üzerinde G-DINA Modeli altında en yüksek doğrulukta test düzeyinde sınıflama, konu alanına dayalı olarak belirlenen Q-matrisi ile elde edilmiştir. Geriye kalan Q-matrislerden test düzeyinde ikinci en yüksek sınıflama konualanı ve rutin olmayan problem çözme becerisi ile oluşturulan Q-matrisi ile elde edilmiştir. En düşük doğrulukta test düzeyinde sınıflama, konu alanı ve okuduğunu anlama becerisi ile oluşturulan Q-matrisi ile elde edilmiştir. Beş nitelik düzeyine sahip olan faktör analizine dayalı belirlenen Q-matrisi ve rutin olmayan problem çözme becerisi ile oluşturulan Q-matrisinden daha az doğrulukta sınıflama sağlasa da rutin olmayan problem çözme becerisine ek olarak okuduğunu anlama becerisi ile belirlenen Q-matrisinden daha yüksek doğrulukta sınıflama sağlamaktadır. Böylelikle üst yetenek grubu üzerinde yapılan sınıflamada maddeleri doğru cevaplama okuduğunu anlama becerisinin Q-matris belirlemede uygun bir nitelik olmadığı söylenebilir. Benzer bir çıkarımla üst yetenek grubu üzerinde rutin olmayan problem çözme becerisinin maddeleri doğru cevaplamak için ilişkili bir nitelik olduğu düşünülebilir. Alt ve üst grupta yapılan sınıflamaların sonuca paralel olarak, Im ve Corter (2011) test maddelerini çözmek için gerekli olan temel bir niteliğin hariç tutulmasıyla doğru sınıflandırılan bireylerin oranının düştüğünü raporlamıştır.
- Mutlak model veri uyumu sonuçlarına göre, RMSEA ve SRMSR uyum indeksleri birlikte değerlendirildiğinde ele alındığında alt grupta hiçbir Q-matrisi ile model veri uyumunun sağlanamadığı ancak üst grupta rutin olmayan problem becerisinin bulunduğu Q-matrisleri ile yeterli düzeyde uyum sağlanmıştır. Lei ve Li'nin (2016) çalışmasında, veriler G-DINA için üretildiğinde, RMSEA, orijinal Q-matrisi yerine aşırı belirlenmiş Q-matrisini destekleme eğilimindeyken, N=500 örneklem

büyükliğünde orijinal Q-matrisi yerine yetersiz tanımlanmış Q-matrisine dayalı yapılan sınıflamayı destekleme eğiliminde olduğu görülmüştür. Bağlı model veri uyumu sonuçlarına göre ise hem alt hem de üst grupta en iyi model uyumu faktör analizine dayalı belirlenen Q-matrisi ile sağlanmıştır. Uzman kanısına dayalı belirlenen Q-matrislerden ise en iyi uyum, alt grupta tüm bağlı uyum indekslerine göre, konu alanı, rutin olmayan problem çözme becerisi ve okuduğunu anlama becerisi ile oluşturulan Q-matrisi ile yapılan sınıflamaya ait bulunmuşken üst grupta en iyi uyum BIC ve CAIC indekslerine göre konu alanına dayalı belirlenen Q-matrisi ile; AIC ve SABIC indekslerine göre ise rutin olmayan problem çözme becerisi ile oluşturulan yapılan sınıflamaya ait bulunmuştur. Sonuç olarak faktör analizine dayalı belirlenen Q-matrisi iyi düzeyde mutlak uyum sağlamış ve en iyi bağlı uyum indekslerine sahip olduğundan bu Q-matris sınıflama yapmak için uygun kestirimler sağlayacaktır. Ancak uzman kanısına dayalı oluşturulan Q-matrisleri ile sınıflama yapılması durumunda, mutlak ve bağlı uyum indeksleri birlikte ele alındığında, rutin olmayan problem çözme becerisi üst grup için; okuduğunu anlama becerisi alt grup için belirlenen Q-matrisi ile sınıflama yapılması model veri uyumunu iyileştirdiği sonucuna varılmıştır.

- Parametre kestirimleri sonuçlarına göre ise alt grupta tahmin parametrelerinin ortalaması en düşük; faktör analizine dayalı belirlenen Q-matrisi ile yapılan sınıflama sonucunda edilmiştir. Uzman kanısına dayalı olarak belirlenen Q-matrislerinin içinden tahmin parametrelerinin ortalaması en düşük olarak ise konu alanına dayalı oluşturulan Q-matrisi ile yapılan sınıflama sonucu elde edilmiştir. Alt grupta tahmin parametrelerine ait standart hatalarının ortalaması en düşük iki Q-matrisi sırasıyla faktör analizine dayalı belirlenen Q-matrisi ile konu alanına ek okuduğunu anlama becerisi ile tanımlanan Q-matrisi ile yapılan sınıflama sonucunda elde edilmiştir. Alt grupta kaydırma parametrelerinin ortalaması en düşük olarak konu alanına ek okuduğunu anlama becerisine dayalı oluşturulan Q-matrisi ile yapılan sınıflama sonucu elde edilmiştir. Alt grupta kaydırma parametrelerine ait standart hatalarının ortalaması en düşük Q-matrisi rutin olmayan konu alanı, problem çözme becerisine ek olarak okuduğunu anlama becerisi ile belirlenen Q-matrisi ile yapılan sınıflama sonucunda elde edilmiştir. Üst grupta ise tahmin parametrelerinin ortalaması en düşük; konu alanına ek rutin olmayan problem çözme becerisi ile belirlenen Q-matrisi ile yapılan sınıflama sonucunda edilmiştir. Bu duruma yönelik olarak nitelik

sayısı daha fazla olmasına rağmen rutin olmayan problem becerisinin bulunduğu Q-matrisi ile daha düşük değerlerin elde edilmesinin eksik belirlenmeye işaret ettiği düşünülebilir. Üst grupta tahmin parametrelerine ait standart hatalarının ortalaması en düşük iki Q-matrisi sırasıyla faktör analizine dayalı belirlenen Q-matrisi ile konu alanına ek rutin olmayan problem çözme becerisi ile tanımlanan Q-matrisi ile yapılan sınıflama sonucunda elde edilmiştir. Üst grupta kaydırma parametrelerinin ortalaması en düşük olarak konu alanına ek rutin olmayan problem çözme becerisine dayalı oluşturulan Q-matrisi ile yapılan sınıflama sonucu elde edilmiştir. Üst grupta tahmin parametrelerine ait standart hatalarının ortalaması en düşük Q-matrisi faktör analizine dayalı olarak belirlenen Q-matrisi ile yapılan sınıflama sonucunda elde edilmiştir. Tüm bu bulgular birlikte değerlendirildiğinde, alt grupta faktör analizi ve okuduğunu anlama becerilerinin dahil edilmesiyle; üst grupta ise faktör analizi ve rutin olmayan problem becerisi ile belirlenen Q-matrisleri ile daha uygun sınıflamalar elde edilmiştir. de la Torre, Hong ve Deng'in (2010) belirttiği gibi daha düşük düzeyde kaydırma ve tahmin parametresi, daha kaliteli madde parametre kestirimi ve sınıflandırma doğruluğu ile ilişkilidir.

- İkinci araştırma sorusu kapsamında alt ve üst yetenek gruplarında yapılan sınıflamalar kendi aralarında karşılaştırıldığında ise her iki grup aynı test soruları almasına rağmen madde parametreleri, model veri uyumu ve sınıflama doğrulukları açısından birbirinden oldukça farklı sonuçlar edilmiştir. Bu bulguya paralel olarak Lee, Park, & Taylan (2011) ile Zhao (2013) yaptıkları çalışmalarda kullandıkları veriler TIMSS 2007 4. sınıf Matematik kitapçıklarından 4 ve 5'ten elde ettikleri çalışmaların bulguları gösterilebilir. Bu iki çalışmada DINA Modeli altında aynı form ve maddeler kullanılmasına rağmen, ilgili çalışmalara dahil edilen örneklemelerin farklı olmasından kaynaklı olarak kestirimler birbirinden farklı elde edilmiştir. Kalkan ve diğerlerinin (2018) yaptığı gerçek veri analizinde, farklı modellerden elde ettikleri madde parametre tahminleri arasındaki farkların oldukça yüksek olduğu ifade edilmiştir. Benzer şekilde de la Torre ve Lee (2010), simüle edilen verilerde DINA model parametrelerinin değişmez özelliğinin sağlanmasına rağmen gerçek verilerdeki madde parametre tahminlerinde tutarsızlıklar olduğunu belirtmiştir.

Üçüncü Araştırma Sorusuna İlişkin Sonuç ve Tartışma

Çalışmanın üçüncü araştırma sorusu kapsamında çarpıklık katsayıları 0, 0,5, 0,75, 1,0, 1,25, 1,50 ve 2 olan gruplar üzerinde incelemeler yapılmıştır. İlgili araştırma sorusu için konu alanına dayalı belirlenen Q-matrisine dayalı yapılan sınıflamalar incelenmiştir. Sonuçlar maddeler halinde sıralanmıştır:

- Aynı Q-matrisin değişen çarpıklık değerlerine sahip örneklemeler üzerinde yapılan sınıflamalar incelendiğinde, sınıflama doğruluklarına göre en yüksek sınıflama doğruluğuna normal dağılım koşulunda yapılan analiz sonucunda ulaşılmıştır. Genel anlamda, çarpıklık değeri arttıkça test düzeyinde sınıflama doğruluklarının düştüğü gözlemlenmiştir. Çarpıklığın 1,25'ten fazla olduğu durumlarda, çarpıklık katsayısı arttıkça, genel anlamda, nitelik düzeyinde de sınıflama doğruluklarının azaldığı görülmüştür.
- Artan çarpıklık katsayılarına sahip olan örneklemeler üzerinde yapılan sınıflama sonucunda elde edilen mutlak uyum indekslerinde ise dalgalanmalar gözlemlenmiştir. Ancak bağıl uyum indekslerinden BIC'e göre karşılaştırma yapıldığında bağıl uyum indeksi daha az dalgalanma göstermiş ve çarpıklık değeri azaldıkça model veri uyumunda iyileşmeler gözlemlenmiştir.
- Parametre kestirimleri incelendiğinde, tahmin parametresine ait standart hataların ortalamasının, genel anlamda, çarpıklık değeri arttıkça standart hataların da arttığı gözlemlenmiştir. Benzer şekilde, genel anlamda, kaydırma parametresine ait standart hataların ortalama değerleri incelendiğinde çarpıklık değeri arttıkça standart hataların da arttığı gözlemlenmiştir.
- G-DINA modeli altında konu alanına göre belirlenen Q-matrisi ile yapılan kestirimler sonucunda elde edilen sınıflamalar çarpıklık katsayısı 1,25'e kadar birbirine yakın düzeydeyken çarpıklık katsayıları 1,5 ve 2 olan örneklemeler üzerinde kestirimlerin birbirinden oldukça farklılaştığı görülmüştür. Bu bulgulara benzer şekilde MacDonald (2013) yaptığı simülasyon çalışmasında hafif çarpık yetenek dağılımı durumuna (ÇK:0,5 ve ÇK:-0,5) ve Q-matris hatalı tanımlama yoğunluğuna karşı birbirine yakın ve dayanıklı kestirimler yaptığını göstermiştir.

Özetle, bilişsel tanı modelleri eğitim alanında yapılan değerlendirmenin öğrenmeyi kolaylaştırabilecek bir araç olarak kullanılmasına olanak sağlayan bir potansiyele sahiptir (de la Torre, Hong & Deng, 2010). Bu yaklaşım doğrultusunda bilişsel tanı modellerinden

G-DINA'nın daha geniş alanda uygulamalarını teşvik etmek için, bu çalışma ile, Q-matrisin farklı belirlenmesinin, değişen dağılım türünün, kaydırma ve tahmin parametresi kestirimleri, sınıflama doğrulukları ve model veri uyumu üzerindeki etkisini araştırılmıştır. Q-matris geçerleme süreci yapılan kestirimler için büyük önem taşımaktadır. Ancak istatistiksel geçerleme yöntemi sonuçları, doğrudan almak yerine uzmanlar için bir referans olarak kullanılmalıdır. Çünkü süreçte testin bilişsel yapısına dayalı bir uzman kararı gereklidir (Wang, Cai & Tu, 2020). Diğer bir deyişle geçerleme yapıldıktan sonra modifikasyonun kabul edilmesi için alan bilgisine ihtiyaç duyulmaktadır. Ancak faktör analizine dayalı Q-matrisinin belirlenmesinde geçerleme yapmaya gerek olmadığı sonucuna ulaşılmıştır. Bununla birlikte bu çalışmanın ele aldığı ders ve öğrenci grubu bağlamında sınırlandırılmak suretiyle, faktör analizine dayalı Q-matrisleri ile yapılan sınıflamaların uzman kanısına dayalı oluşturulan Q-matrisleri ile yapılan sınıflamalara benzer sonuçlar ürettiği görülmüştür. Chen, Liu, Xu ve Ying (2012) Q-matrisini herhangi bir uzman girdisi olmaksızın yalnızca öğrenci cevaplarına göre belirleyen bir yöntem önermiştir. Ancak bu yöntem yalnızca DINA ve DINO modeli üzerinde test edilmiştir. Araştırmacılar Q-matrisi için önerdikleri kestirim yönteminin diğer bilişsel tanı modellerinde de kullanılabileceğini belirtmiştir. Benzer şekilde bu çalışma kapsamında kullanılmayan diğer modeller için de Q-matrisinin belirlenmesinde faktör analizinin kullanılabileceği düşünülmektedir. Sonuç olarak faktör analitik yöntemle belirlenen Q-matrisi ile BTM'ye dayalı sınıflama yapılabilir. Bu sonuca ek olarak boyutlar altında toplanan maddelerin ortak özellikleri belirlendiği takdirde ortaya çıkabilecek nitelikler bağlamında madde-nitelik ilişkisi için iyi bir bir kılavuz görevi üstlenebileceği düşünülmektedir. Wang, Cai ve Tu (2020), olabilirlik oranı testine dayalı yaklaşımları kullanarak önerdiği Q-matris geçerleme yöntemlerinden elde edilen sonuçların uzmanlar için tamamlayıcı bilgiler sağlayabileceğini belirtmiştir. Q-matrisinin faktör analizi ile yalnızca öğrenci verilerine dayalı olarak elde edilmesi, hem öğrenci yanıtları hem de uzman kanısı gerektiren Q-matris doğrulama yöntemleriyle karşılaştırıldığında, uzmanların öznel eğilimlerini sonucunda yanlış belirlemeleri önlemekle kalmaz, aynı zamanda uzmanların iş yükünü de azaltır (Wang ve diğ., 2020). Faktör analitik yöntemlere dayalı olarak Q-matrisinin belirlenmesiyle alan uzmanlarının ön görmedikleri çözüm stratejileri gibi farklı bir niteliğin maddenin doğru çözümünde etkili olabileceği konusunda ipuçları sağlayabileceği düşünülmektedir. Araştırmadaki evren veri seti normal dağılımdan farklılaşan çarpık ve sivri bir dağılıma sahiptir. Parametrik bir yaklaşım barından faktör analizinin evren veri seti üzerinde yapılması, yapılan bu sınıflamanın kalitesini

etkilemektedir. Öğrenci yanıtlarına dayalı açımlayıcı faktör analitik tekniklerle Q-matrisinin belirlenmesi madde veya nitelik sayısı büyük olduğunda hesaplanması kolay değildir (Chiu, 2013). Bu çalışma kapsamında ise otuz maddeyi cevaplayan öğrenci yanıtlarından yararlanılarak yapılan faktör analizi sonucunda az sayıda boyut çıkmış ve yorumlaması zor olmamıştır. Ancak belirtildiği gibi madde ve boyut sayısının fazla olduğu durumlarda parametre kestirimleri ve sınıflama doğruluğunun olumsuz etkilenebileceği düşünülmektedir. Farklı yetenek gruplarında yapılan sınıflamalar karşılaştırıldığında her iki gruptan elde edilen sınıflamalar madde parametreleri, model veri uyumu ve sınıflama doğrulukları açısından birbirinden oldukça farklı sonuçlar sağlamıştır. Bir diğer deyişle parametre değişmezliği sağlanamamıştır. Üst grupta ve alt grupta farklı nitelik setiyle belirlenen Q-matrisleri gruba bağımlı olarak değişen uygunlukta sınıflama sağlamıştır. Bunun temel nedeninin maddeyi cevaplama gerekliliği bilişsel süreçlerin gruplar arasında farklılaşması olarak görülmektedir. Bu sebeple bilişsel tanı değerlendirmelerinde grup özellikleri göz önünde bulundurularak Q-matrisin belirlenmesi önem taşımaktadır. Aynı Q-matrisin değişen çarpıklık değerlerine sahip örneklemeler üzerinde yapılan sınıflamalar incelendiğinde, ele alınan değerlendirme kriterlerine göre, genel olarak, çarpıklığın 1,25'ten fazla olduğu durumlarda uygun sonuçlar elde edilememektedir. Dolayısıyla çalışma kapsamında kullanılan model ile sınırlı olmak koşulu ile, bilişsel tanı değerlendirmelerinde bireylerin dağılımı önem taşımaktadır.

Öneriler

Uygulayıcılara Yönelik Öneriler

Çalışma kapsamında ele alınan sonuçlar doğrultusunda sahadaki uygulayıcılara yönelik öneriler aşağıda sıralanmıştır.

- Uzman görüşüne dayalı Q-matrisinin belirlenmesinde geçerleme sürecinden yararlanılmalıdır. Kullanılan istatistiksel geçerleme süreci mutlaka uzman ve mesa plot değerlendirmeleri ile yeniden gözden geçirilerek gerekli olan modifikasyonlar kullanılmalıdır.
- Q-matrisi belirlemede uzman görüşü gibi önsel bilgilerden faydalanılamayan durumlarda, faktör analizi ile elde edilen bir Q-matrisi yeterince iyi sonuçlar

sağladığından Q-matrisinin belirlenmesinde faktör analitik yöntemler kullanılarak sınıflama yapılması önerilebilir. Bununla birlikte faktör analizine dayalı Q-matrislerin belirlenmesinin ardından geçerleme sürecinin uygulanmasına gerek duyulmayabilir.

- Bilişsel tanı değerlendirmelerinde farklı yetenek düzeylerindeki öğrenci gruplarında madde özellik ilişkisini belirlemede farklı niteliklerin maddeyi doğru cevaplamada etkili olabileceği göz önünde bulundurulmalıdır. Bu doğrultuda Q-matrisi belirlemede ilgili yetenek düzeyinde maddeyi doğru cevaplamada ilişki olabileceği düşünülen farklı boyuttaki nitelik veya nitelikler mevcut Q-matrisine eklenerek kullanılabilir.
- Bilişsel tanı değerlendirmelerinde grup dağılımının çarpıklık değeri 1,25'in üstüne çıktığında araştırma kapsamında ele alınan model ve kestirim yöntemlerine dayalı analizlerin uygun sınıflama yapamadıkları görülmüştür. Dolayısıyla araştırmacılara, çalışma kapsamında kullanılan model ve kestirim yöntemi ile sınırlandırılmak üzere, normallik varsayımının test edilmesi önerilmektedir.

Araştırmacılara Yönelik Öneriler

Çalışma kapsamında ele alınan sonuçlar doğrultusunda araştırmacılara yönelik öneriler aşağıda sıralanmıştır.

- Bu çalışmada iki farklı yetenek düzeyi (alt grup ve üst grup) ve yedi farklı çarpıklık katsayısı (0, 0,5, 0,75, 1,0, 1,25, 1,50 ve 2) koşul olarak ele alınmıştır. Daha fazla yetenek düzeyi ve farklı çarpıklık katsayıları kullanılarak araştırma tekrarlanabilir.
- Araştırma kapsamında tüm veriden çekilen örneklem her koşul için bir kez elde edilmiştir. Yeterince büyük veri setlerinin kullanıldığı başka araştırmalarda daha fazla sayıda örneklem elde edilerek analizler tekrarlanabilir.
- Araştırma kapsamında kullanılan fonksiyon ile istenilen özellikte örneklem elde edilmesinde yeniden örnekleme yapılmamaktadır. İstenilen özellikte dağılımın elde edilmesinde seçilen bir bireyin tekrar örnekleme dahil edilebildiği ve böylelikle istenen örnekleme daha yakın özellikte dağılım özelliği gösteren örneklem çekilmesinde Atalay Kabasakal ve Gündüz (2020) tarafından geliştirilen R'da "drawsample" paketini kullanarak bir çalışma yapılabilir.

- Araştırma kapsamında yalnızca G-DINA modeli altında ve MMLE/EM algoritması kullanılarak kestirimler elde edilmiştir (Ma & de la Torre, 2020). Başka araştırmacılar mevcut çalışmadaki model ve kestirim yöntemi yerine başka modeller ve kestirim yöntemlerini kullanarak bir çalışma yürütebilirler.
- Veriye dayalı olarak Q-matris belirlemede araştırma kapsamında ele alınan faktör analizi yönteminde temel eksenler kullanılmış ve faktör yükü için 0,30 kriteri baz alınmıştır. Farklı faktör analitik yöntemler ve 0,32, 0,40 gibi sıklıkla kullanılan değerler baz alınarak bir çalışma yapılabilir.
- Uzman kanısına dayalı olarak geliştirilen Q-matrisinde tüm uzmanların görüşleri birleştirilerek elde edilmiştir. Başka araştırmalarda her bir uzmanın oluşturduğu Q-matrisleri ayrı ayrı ele alınarak değerlendirilip Q-matris geçerleme yönteminden elde edilen sonuçlar altında çalışılabilir.

KAYNAKLAR

- Ardıç, E. Ö. (2020). *Bilişsel tanı ve çok boyutlu madde tepki modellerinin sınıflama doğruluğu ve parametrelerinin karşılaştırılması*. Doktora Tezi, Hacettepe Üniversitesi Eğitim Bilimleri Enstitüsü, Ankara.
- Başokçu, T. O. (2012). DINA Model parametreleri kullanılarak tahminlenen madde ayıricılık indekslerinin incelenmesi. *Eğitim ve Bilim*, 37(163), 310-321.
- Başokçu, T. O. (2018). *Uluslararası geniş ölçekli sınavlarda Türkiye'nin matematik başarısını arttırabilmek için bir model önerisi: Bilişsel tanıya dayalı izleme modelinin etkililiği*. TÜBİTAK SOBAG Proje. Proje No: 115K531. 10 Ocak 2020 tarihinde <https://app.trdizin.gov.tr/proje/TVRnMU56SXk/uluslararasi-genis-olcekli-sinavlarda-turkiye-nin-matematik-basarisini-arttirabilmek-icin-bir-model-onerisi-bilissel-taniya-dayali-izleme-modelinin-etkililigi> sayfasından erişilmiştir.
- Baykal Yetimler, D. (2019). *Bilişsel tanı modellerinde hata Q-matrisi yöntemi ile öğrencilerin hata profillerinin belirlenmesi*. Yüksek Lisans Tezi, Ege Üniversitesi Eğitim Bilimleri Enstitüsü, İzmir.
- Büyüköztürk, Ş., Çokluk, Ö., & Köklü, N. (2012). *Sosyal bilimler için istatistik*. Ankara: Pegem.
- Büyüköztürk, Ş., Kılıç Çakmak, E., Akgün, Ö.E., Karadeniz, Ş. & Demirel, F. (2012). *Bilimsel araştırma yöntemleri*. Ankara: Pegem.
- Carboni, L. W. (2001). Number sense every day. 11 Kasım 2018 tarihinde <http://www.learnnc.org/lp/pages/numsense0402-1> sayfasından erişilmiştir.

- Ceylan, S. (2019). *Bilişsel tanı modellerinde data/Q-matris genişletme yönteminin örtük sınıf dağılımları üzerinde etkisi*. Yüksek Lisans Tezi, Ege Üniversitesi Eğitim Bilimleri Enstitüsü, İzmir. <https://tez.yok.gov.tr> sayfasından erişilmiştir.
- Chen, Y., Liu, J., Xu, G., & Ying, Z. (2015). Statistical analysis of Q-matrix based diagnostic classification models. *Journal of the American Statistical Association*, 110(510), 850–866. <https://doi.org/10.1080/01621459.2014.934827>
- Cheng, Y. (2010). Improving cognitive diagnostic computerized adaptive testing by balancing attribute coverage: The modified maximum global discrimination index method. *Educational and Psychological Measurement*, 70(6), 902-913.
- Chiu, C. Y. (2008). *Cluster analysis for cognitive diagnosis: Theory and applications*. PhD Thesis, University of Illinois, Illinois.
- Chiu, C. Y. (2013). Statistical refinement of the Q-matrix in cognitive diagnosis. *Applied Psychological Measurement*, 37(8), 598-618. doi:10.1177/0146621613488436.
- Chiu, C. Y., & Douglas, J. (2013). A nonparametric approach to cognitive diagnosis by proximity to ideal response patterns. *Journal of Classification*, 30(2), 225-250. <https://doi.org/10.1007/s00357-013-9132-9>
- Chiu, C.-Y., Douglas, J., & Li, X. (2009). Cluster analysis for cognitive diagnosis: Theory and applications. *Psychometrika*, 74(4), 633–665. <https://doi.org/10.1007/s11336-009-9125-0>
- Close, C. N., Davison, M. L., & Davenport, E. C. (2012). *An exploratory technique for finding the Q-matrix in cognitive diagnostic assessment: Combining theory with data*. Paper presented at the Annual Meeting of the National Council on Measurement in Education, Vancouver, British Columbia, Canada.
- Collares, C. F. (2021, February 3). A primer on cognitive diagnostic modelling for the healthcare professions education. <https://psyarxiv.com/jr4m6/>
- Cui, Y., Gierl, M. J., & Chang, H. H. (2012). Estimating classification consistency and accuracy for cognitive diagnostic assessment. *Journal of Educational Measurement*, 49(1), 19-38.

- DeCarlo, L. T. (2011). On the analysis of fraction subtraction data: The DINA model, classification, latent class sizes, and the Q-matrix. *Applied Psychological Measurement*, 35, 8-26. <https://doi.org/10.1177/0146621610377081>
- DeCarlo, L. T. (2012). Recognizing uncertainty in the Q-matrix via a Bayesian extension of the DINA model. *Applied Psychological Measurement*, 36(6), 447-468.
- de la Torre, J. (2008). An empirically based method of Q-matrix validation for the DINA model: Development and applications. *Journal of Educational Measurement*, 45(4), 343-362.
- de la Torre, J. (2009). DINA model and parameter estimation: A didactic. *Journal of Educational and Behavioral Statistics*, 34(1), 115–130. <https://doi.org/10.3102/1076998607309474>
- de la Torre, J. (2011). The generalized DINA model framework. *Psychometrika*, 76(2), 179-199.
- de la Torre, J., & Akbay, L. (2019). Implementation of cognitive diagnosis modeling using the GDINA R package. *Eurasian Journal of Educational Research*, 80, 171-192. <http://dx.doi.org/10.14689/ejer.2019.80.9>
- de la Torre, J., & Chiu, C.-Y. (2016). A general method of empirical Q-matrix validation. *Psychometrika*, 81, 253-273.
- de la Torre, J., & Chiu, C. Y. (2016). A general method of empirical Q-matrix validation. *Psychometrika*, 81(2), 253-273. <https://doi.org/10.1007/s11336-015-9467-8>
- de La Torre, J., & Douglas, J. A. (2004). Higher-order latent trait models for cognitive diagnosis. *Psychometrika*, 69(3), 333-353.
- de la Torre, J., Hong, Y., & Deng, W. (2010). Factors affecting the item parameter estimation and classification accuracy of the DINA model. *Journal of Educational Measurement*, 47(2), 227-249. <https://doi.org/10.1111/j.1745-3984.2010.00110.x>
- de la Torre, J., & Lee, Y. S. (2010). A note on the invariance of the DINA model parameters. *Journal of Educational Measurement*, 47(1), 115-127.
- de la Torre, J., & Lee, Y. S. (2013). Evaluating the Wald test for item-level comparison of saturated and reduced models in cognitive diagnosis. *Journal of Educational Measurement*, 50(4), 355-373. <https://doi.org/10.1111/jedem.12022>

- Dogan, E. (2006). Establishing construct validity of the mathematics subtest of the university entrance examination in Turkey: A rule space application (Order No. 3237082). Available from ProQuest Dissertations & Theses Global. (305357289). Retrieved from <https://search.proquest.com/docview/305357289?accountid=11054>
- Feng, Y. (2013). *Estimation and Q-matrix validation for diagnostic classification models*. Doctoral Dissertation, University of South Carolina College of Arts and Sciences, Columbia.
- Fialkowski, A. C. (2018). SimMultiCorrData: Simulation of Correlated Data with Multiple. <https://cran.r-project.org/web/packages/SimMultiCorrData/index.html>
- Fischer, G. (1973). The linear logistic test model as an instrument in educational research. *Acta Psychologica*, 37, 359-374.
- Fleishman, A. I. (1978). A method for simulating non-normal distributions. *Psychometrika*, 43, 521-532.
- Gall, M. D., Gall, J. P., & Borg, W. R. (2007). *Educational Research: An Introduction* (8. Ed.). New York: Longman.
- George, A. C., & Robitzsch, A. (2014). Multiple group cognitive diagnosis models, with an emphasis on differential item functioning. *Psychological Test and Assessment Modeling*, 56(4), 405.
- George, A. C., & Robitzsch, A. (2015). Cognitive Diagnosis Models in R: A Didactic. *The Quantitative Methods for Psychology*, 11(3), 189-205.
- Gierl, M. J., Alves, C., & Majeau, R. T. (2010). Using the attribute hierarchy method to make diagnostic inferences about examinees' knowledge and skills in mathematics: An operational implementation of cognitive diagnostic assessment. *International Journal of Testing*, 10(4), 318-341.
- Gündüz, T., Çakan, M. (2020). TIMSS 2015 Türkiye örnekleminde matematik başarı testine dayalı olarak öğrencilerin Bilişsel Tanı Modelleri ile sınıflandırılması. *Necatibey Eğitim Fakültesi Elektronik Fen ve Matematik Eğitimi Dergisi*, 14(2), 1040-1079. <https://doi.org/10.17522/balikesirnef.741401>
- Haertel, E. H. (1989). Using restricted latent class models to map the skill structure of achievement items. *Journal of Educational Measurement*, 26(4), 301-321.

- Henson, R., Roussos, L., Douglas, J., & He, X. (2008). Cognitive diagnostic attribute-level discrimination indices. *Applied Psychological Measurement*, 32(4), 275-288.
- Henson, R., & Templin, J. (2007, Nisan). *Large-scale language assessment using cognitive diagnosis models*. Paper presented at the Annual Meeting of the National Council for Measurement in Education, Chicago, Illinois.
- Im, S., & Corter, J. E. (2011). Statistical consequences of attribute misspecification in the rule space method. *Educational and Psychological Measurement*, 71, 712-731.
- Im, S., & Park, H. J. (2010). A comparison of US and Korean students' mathematics skills using a cognitive diagnostic testing method: linkage to instruction. *Educational Research and Evaluation*, 16(3), 287-301.
- Junker, B. W., & Sijtsma, K. (2001). Cognitive assessment models with few assumptions, and connections with nonparametric item response theory. *Applied Psychological Measurement*, 25(3), 258-272.
- Kabasakal, K. A., & Gündüz, T. (2020). Drawing a sample with desired properties from population in R package “drawsample”. *Eğitimde ve Psikolojide Ölçme ve Değerlendirme Dergisi*, 11(4), 405-429. <https://doi.org/10.21031/epod.790449>
- Kalkan, Ö.K. (2016). *Bilişsel tanı modellerinin değişen koşullar altında karşılaştırılması: DINA, RDINA, HODINA ve HORDINA Modelleri*. Doktora tezi, Hacettepe Üniversitesi Eğitim Bilimleri Enstitüsü, Ankara. <https://tez.yok.gov.tr> sayfasından erişilmiştir.
- Karasar, N., (1999). *Bilimsel araştırma yöntemi*. Ankara: Nobel.
- Koyuncu, M. S. (2020). *Bilişsel tanı modellerinde yapısal eşitlik modeli ile q-matris doğruluğunun belirlenmesi*. Doktora Tezi, Gazi Üniversitesi Eğitim Bilimleri Enstitüsü, Ankara. <https://tez.yok.gov.tr> sayfasından erişilmiştir.
- Kunina-Habenicht, O., Rupp, A. A., Wilhelm, O. (2009). A practical illustration of multidimensional diagnostic skills profiling: Comparing results from confirmatory factor analysis and diagnostic classification models. *Studies in Educational Evaluation*, 35, 64-70.

- Kunina-Habenicht, O., Rupp, A. A., 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.
- Lee, Y. S., Park, Y. S., & Taylan, D. (2011). A cognitive diagnostic modeling of attribute mastery in Massachusetts, Minnesota, and the US national sample using the TIMSS 2007. *International Journal of Testing*, 11(2), 144-177.
- Lee, Y. W. & Sawaki, Y. (2009). Cognitive diagnosis and Q-matrices in language assessment. *Language Assessment Quarterly*, 7, 108-112.
- Lei, P. W., & Li, H. (2016). Performance of fit indices in choosing correct cognitive diagnostic models and Q-matrices. *Applied Psychological Measurement*, 40(6), 405–417. <https://doi.org/10.1177/0146621616647954>
- Leighton, J. P., Gierl, M. J., & Hunka, S. M. (2004). The Attribute Hierarchy Method for Cognitive Assessment: A Variation on Tatsuoaka's Rule-Space Approach. *Journal of Educational Measurement*, 41(3), 205–237. <https://doi.org/10.1111/j.1745-3984.2004.tb01163.x>
- Li, H. (2016). *Estimation of Q-matrix for dina model using the constrained generalized dina framework*. Doctoral Dissertation, Columbia University The Graduate School of Arts and Sciences, United States.
- Lissitz, R. W., Hou, X., & Slater, S. C. (2012). The contribution of constructed response items to large scale assessment: Measuring and understanding their impact. *Journal of Applied Testing Technology*, 13, 1–50.
- Liu, Y., Tian, W., & Xin, T. (2016). An application of M2 statistic to evaluate the fit of cognitive diagnostic models. *Journal of Educational and Behavioral Statistics*, 41(1), 3–26. doi:10.3102/1076998615621293.
- Ma, W., & de la Torre, J. (2016). A sequential cognitive diagnosis model for polytomous responses. *British Journal of Mathematical and Statistical Psychology*, 69, 253-275.
- Ma, W. (2017). *A sequential cognitive diagnosis model for graded response: model development, Q-matrix validation, and model comparison* (Doctoral dissertation). Retrieved from <https://rucore.libraries.rutgers.edu/rutgers-lib/55582/>

- Ma, W., & de la Torre, J. (2018). GDINA: The generalized DINA model framework. R Package Version 2.0.8. Retrieved from <https://cran.r-project.org/package=GDINA>
- Ma, W., & de la Torre, J. (2020). GDINA: An R Package for Cognitive Diagnosis Modeling. *Journal of Statistical Software*, 93(14), 1-26.
- MacDonald, G. T. (2013). *The performance of the linear logistic test model when the Q-matrix is misspecified: A simulation study*. Doctoral Dissertation, University of South Florida Philosophy in Curriculum and Instruction, United States.
- Maydeu-Olivares, A., & Joe, H. (2014). Assessing approximate fit in categorical data analysis. *Multivariate Behavioral Research*, 49(4), 305–328. doi:10.1080/00273171.2014.911075
- Morgan, G. A., Leech, N. L., Gloeckner, G. W., & Barrett, K. C. (2004). *SPSS for introductory statistics: Use and interpretation*. Psychology.
- Nájera, P., Sorrel, M. A., & Abad, F. J. (2019). Reconsidering Cutoff Points in the General Method of Empirical Q-Matrix Validation. *Educational and Psychological Measurement*, 79(4), 727–753. <https://doi.org/10.1177/0013164418822700>
- Nájera, P., Sorrel, M. A., de la Torre, J., & Abad, F. J. (2020). Improving robustness in Q-matrix validation using an iterative and dynamic procedure. *Applied Psychological Measurement*, 44(6), 431-446.
- Ömür Sünbül, S. (2013). *Bilişsel tanı modellerinde parametre kestirimini ve sınıflama tutarlılığını etkileyen faktörlerin incelenmesi*. Doktora Tezi, Mersin Üniversitesi Eğitim Bilimleri Enstitüsü, Mersin. <https://tez.yok.gov.tr> sayfasından erişilmiştir.
- Pöhler, B., George, A. C., Prediger, S., & Weinert, H. (2017). Are word problems really more difficult for students with low language proficiency? Investigating percent items in different formats and types. *International Electronic Journal of Mathematics Education*, 12(3), 667-687.
- R Core Team. (2019). *R: A language and environment for statistical computing*. Vienna, Austria. Retrieved September 10, 2019, from R Core Team. Retrieved from <http://www.R-project.org/>
- Revelle, W. (2018) psych: Procedures for Personality and Psychological Research. Version 1.8.12. <https://CRAN.R-project.org/package=psych>

- Rodriguez, M. (2003). Construct equivalence of multiple-choice and constructed response items: A random effects synthesis of correlations. *Journal of Educational Measurement*, 40, 163–184.
- Rupp, A. A., & Templin, J. (2008a). The effects of Q-matrix misspecification on parameter estimates and classification accuracy in the DINA model. *Educational and Psychological Measurement*, 68(1), 78–96. <https://doi.org/10.1177/0013164407301545>
- Rupp, A. A., & Templin, J. (2008b). Unique characteristics of diagnostic classification models: A comprehensive review of the current state-of-the-art. *Measurement: Interdisciplinary Research and Perspectives*, 6(4), 219–262. <http://dx.doi.org/10.1080/15366360802490866>
- Sarkar, D. (2008). *lattice: Multivariate Data Visualization with R*. Springer-Verlag, New York.
- Sorrel, M. A., Olea, J., Abad, F. J., de la Torre, J., Aguado, D., & Lievens, F. (2016). Validity and reliability of situational judgement test scores: A new approach based on cognitive diagnosis models. *Organizational Research Methods*, 19(3), 506–532.
- Şen, S., & Arican, M. (2015). A diagnostic comparison of Turkish and Korean students' mathematics performances on the TIMSS 2011 assessment. *Journal of Measurement and Evaluation in Education and Psychology*, 6(2), 238–253. doi: 10.21031/epod.65266
- Şen, S., & Bradshaw, L. (2017). Comparison of relative fit indices for diagnostic model selection. *Applied Psychological Measurement*, 41(6), 422–438. <https://doi.org/10.1177/0146621617695521>
- Templin, J. (2006). *CDM: Cognitive diagnosis modeling with Mplus*. Retrieved from <http://jtemplin.myweb.uga.edu/cdm/cdm.html>
- Templin, J. L., & Henson, R. A. (2006). Measurement of psychological disorders using cognitive diagnosis models. *Psychological Methods*, 11(3), 287.
- Uyumaz, G. (2016). *DINA modelde Q-matrisinin hatalı belirlenmesinin farklı örneklem büyüklüklerinde parametre kestirimine ve bireylerin sınıflandırılmasına etkisi*. (Doktora Tezi). Ankara Üniversitesi, Eğitim Bilimleri Enstitüsü, Ankara. <https://tez.yok.gov.tr> sayfasından erişilmiştir.

- Wang, D., Cai, Y., & Tu, D. (2020). Q-matrix estimation methods for cognitive diagnosis models: Based on partial known Q-matrix. *Multivariate Behavioral Research*, 1-13. <https://doi.org/10.1080/00273171.2020.1746901>.
- Wickham, H., François, R., Henry, L., & Müller, K. (2019). dplyr: A Grammar of data manipulation. Version 0.8.0.1. <https://CRAN.R-project.org/package=dplyr>.
- Wiersma, W., & Jurs, S. G. (2005). *Research methods in education: An introduction*. Boston: Pearson.
- Yakar, L. (2017). *Bilişsel tanı ve çok boyutlu madde tepki kuramı modellerinin karşılıklı uyumlarının incelenmesi*. Doktora Tezi, Hacettepe Üniversitesi Eğitim Bilimleri Enstitüsü, Ankara. <https://tez.yok.gov.tr> sayfasından erişilmiştir.
- Zhan, P., Ma, W., Jiao, H., & Ding, S. (2020). A sequential higher order latent structural model for hierarchical attributes in cognitive diagnostic assessments. *Applied Psychological Measurement*, 44(1), 65-83.
- Zhao, F. (2013). *Using noncompensatory models in cognitive diagnostic mathematics assessments: an evaluation based on empirical data*. Doctoral Dissertation, University of Kansas Department of Psychology and Research in Education. Kansas. Available from ProQuest Dissertations & Theses Global.



EKLER

EK 1: İstenen özellikteki örneklemin çekilmesinde kullanılan fonksiyon

```
draw_sample <- function(dist,n,skew_value,kurtosis_value,location= 0,
                        delta_var = 0,output_name = c("sample","default"))
{
  # required packages
  require(dplyr)
  require(psych)
  require(SimMultiCorrData)
  require(lattice)

  # rename the data
  names(dist) <- c("id","x")
  # arrange rows in an ascending order
  dist <- arrange(dist, x)
  x <- dist$x

  if(n >= length(x)){
    stop("Cannot take a sample larger than the length of the data")
  }

  # random generation for the normal distribution
  reference <- matrix(rnorm(length(x),0,1),ncol=1)
  reference <- reference*(1+delta_var) + location

  # Calculate Fleishman's third order constants for the specified skewness
  and standardized kurtosis
  constants <- find_constants(method = c("Fleishman"), skews = skew_value,s
kurts = kurtosis_value)$constants

  # conduct Fleishman's power method
  reference <- -constants[3] + constants[2]*reference + constants[3]*reference^2 + constants[4]*reference^3
  # arrange vector in an ascending order
  reference <- sort(reference,decreasing = FALSE)

  # decide to the number of breakpoints
  breakpoints <- ifelse(length(hist(reference)$breaks)>= length(hist(x)$breaks),length(hist(reference)$breaks),length(hist(x)$breaks))
  # divide/cut of x and reference with same cutpoints
  x_cut <- as.numeric(cut(x, breakpoints,include.lowest = TRUE))
  reference_cut <- as.numeric(cut(reference,breakpoints,include.lowest = TRUE))

  # create a new data frame, includes x and reference and their factor levels
  dist2 <- as.tbl(data.frame(dist,x_cut,reference,reference_cut))
  # calculate how many students are at each level in both distributions
  dist2 <- dist2 %>% add_count(x_cut)%>% rename(n_x_cut=n)
  dist2 <- dist2 %>% add_count(reference_cut) %>%rename(n_reference_cut=n)

  # filter first row of each category
  x_cut <- dist2 %>% group_by(x_cut) %>% filter(row_number() == 1L)
```

```

x_cut_f <- x_cut$n_x_cut
# filter first row of each category
reference_cut <- dist2 %>% group_by(reference_cut) %>% filter(row_number
() == 1L)
reference_cut_f <- reference_cut$n_reference_cut

# Calculate the probability to be used in the sample_n() function
if(length(x_cut_f)==length(reference_cut_f)){
  p <- rep(reference_cut_f,x_cut_f)
}else if(length(x_cut_f)>length( reference_cut_f)) {
  reference_cut_f = c(reference_cut_f, rep(reference_cut_f[length( refere
nce_cut_f)],(length( x_cut_f)-length( reference_cut_f))))
  p <- rep(reference_cut_f,x_cut_f)
}else{
  x_cut_f = c(x_cut_f, rep(x_cut_f[length( x_cut_f)],(length( reference_c
ut_f)-length( x_cut_f))))
  p <- rep(reference_cut_f,x_cut_f)
}
# Control the length of the vector p
if(length(p)==dim(dist2)[1]){
  dist2 <- mutate(dist2,p)
}else if(length(p)>(dim(dist2)[1])){
  dist2 <- mutate(dist2,p=p[1:dim(dist2)[1]])
}else{
  dist2 <- mutate(dist2,p=c(p,rep(1,(dim(dist2)[1]-length(p))))))
}

# Add the probability vector as a column to dist2
dist2$p <- dist2$p/ dist2$n_x_cut

# Draw a sample and extract the first two columns
S1 <- sample_n(dist2,n, replace = FALSE, weight = p)[,c(1:2)]

# Save the output
if (output_name[2] == "default") {
  wd <- paste(getwd(), "/", sep = "")
}else {wd <- output_name[2]}
fileName <- paste( output_name[1], wd, ".dat", sep = "")
capture.output(data.frame(S1), file = fileName)

# Organize the output
dist2 <- dist2 %>% mutate(type="population")
S1 <- S1 %>% mutate(type="sample")
result <- rbind( dist2[,c(1,2,9)],S1)
histogram(~x|type,data=result,xlab="Score")

# To capture the graph
graph <- histogram(~x|type,data=result,xlab="Score")
trellis.device(device="png", filename=paste( output_name[1], wd, ".png", s
ep = ""))
print(graph)
dev.off()

```

```

# Output with three components
output <- list(desc = data.frame(data = c("population", "reference", "sample"),
mean = round(c(mean(x, na.rm=TRUE), mean(reference), mean(S1$x)), 3),
              sd= round(c(sd(x, na.rm=TRUE), sd(reference), sd(S1$x)), 3),
              skew= round(c(describe(x)$skew, describe(reference)$skew, describe(S1$x)$skew), 3), kurtosis=round(c(describe(x)$kurtosis, describe(reference)$kurtosis, describe(S1$x)$kurtosis), 3)), sample = as.tbl(data.frame(S1)[, -3]), graph = trellis.last.object()
)
return(output)
}

```



EK 2a: Proje kapsamında ele alınan katılımcılara ait betimsel istatistikler



Proje kapsamındaki ön test ve son test uygulamasının her ikisine birden katılan 3705 öğrencinin son teste ait betimsel istatistikleri aşağıda sunulmuştur (Başokçu, 2018).



	DENEY-1	DENEY-2	KONTROL
N	1306	1230	1169
ORTALAMA	11,01	9,93	9,24
MEDYAN	9,00	9	8,00
VARYANS	40,34	32,12	30,35
STANDART S	6,35	5,69	5,51
MİNİMUM	0	0	0
MAKSİMUM	30	30	30
RANJ	30	30	30
ÇARPIKLIK	0,945	0,989	0,581

EK 2b: Proje kapsamında hesaplanan madde istatistikleri

No	P _j	r _{jx}	r _{pbis}	r _{bis}	No	P _j	r _{jx}	r _{pbis}	r _{bis}
1	0,63	0,47	0,39	0,32	16	0,63	0,58	0,46	0,39
2	0,56	0,59	0,47	0,4	17	0,49	0,72	0,57	0,50
3	0,41	0,51	0,43	0,36	18	0,38	0,66	0,55	0,49
4	0,5	0,76	0,59	0,53	19	0,21	0,53	0,6	0,55
5	0,36	0,51	0,47	0,4	20	0,41	0,39	0,36	0,29
6	0,36	0,52	0,45	0,38	21	0,28	0,34	0,36	0,29
7	0,14	0,39	0,56	0,52	22	0,24	0,35	0,39	0,33
8	0,11	0,27	0,46	0,42	23	0,38	0,53	0,46	0,39
9	0,16	0,21	0,31	0,25	24	0,21	0,23	0,3	0,24
10	0,20	0,31	0,38	0,32	25	0,28	0,48	0,47	0,41
11	0,29	0,30	0,30	0,22	26	0,31	0,31	0,33	0,25
12	0,22	0,50	0,54	0,49	27	0,23	0,57	0,62	0,57
13	0,28	0,28	0,30	0,23	28	0,41	0,62	0,53	0,47
14	0,5	0,51	0,41	0,34	29	0,36	0,41	0,39	0,32
15	0,48	0,43	0,36	0,28	30	0,06	0,17	0,48	0,44
Ortalama						0,336	0,448	0,443	0,380

EK 3: Normallik ilişkin grafiksel incelemeler





EK 4: Dağılım koşullarını elde etmede kullanılan örnek kodlar

Üst düzey yetenek grubu için


-Yazılan kod:

```
ustgrups <- draw_sample(tum_veri, n=500, skew_value=0, kurtosis_value=0,  
location =15, delta_var = 0,output_name = c("ustgrups","01"))
```

-Çekilen örnekleme ait çıktıları:

```
> ustgrups  
$desc  
      data  mean   sd  skew kurtosis  
1 population 9.709 5.770 0.939  0.597  
2 reference 14.996 0.988 -0.007 -0.022  
3   sample 14.314 4.457 -0.035 -0.169
```

\$graph



[illegible]

300	1916	20	360	732	2	420	2748	14	480	4116	11
301	1649	18	361	1028	10	421	1941	10	481	1747	9
302	983	17	362	1321	16	422	4227	19	482	486	18
303	567	16	363	2587	20	423	3518	16	483	1422	6
304	3319	15	364	3499	20	424	3325	16	484	1940	13
305	4	18	365	2299	11	425	1665	14	485	2738	11
306	2673	16	366	2537	16	426	3981	13	486	2794	16
307	2005	12	367	2314	18	427	4023	13	487	4115	15
308	3374	14	368	3891	18	428	341	20	488	1849	15
309	1213	5	369	1545	17	429	2569	9	489	3296	21
310	2388	15	370	1307	11	430	1313	3	490	1610	20
311	1079	16	371	498	6	431	2462	13	491	1898	8
312	4031	20	372	714	13	432	2154	9	492	1946	16
313	2014	12	373	3467	16	433	1519	9	493	1046	22
314	4122	18	374	1126	10	434	1584	8	494	3795	18
315	287	16	375	1379	12	435	690	13	495	112	16
316	858	16	376	1318	16	436	1528	12	496	668	5
317	3205	17	377	987	13	437	2715	11	497	1711	10
318	2093	17	378	2153	15	438	1268	20	498	2137	22
319	2902	9	379	1680	9	439	3549	19	499	479	9
320	3955	21	380	1795	23	440	2049	12	500	3450	21
321	339	7	381	2311	11	441	1600	15			
322	4013	21	382	3939	13	442	1727	11			
323	3431	8	383	1497	9	443	2032	5			
324	1171	18	384	2928	9	444	2166	15			
325	3535	17	385	1974	12	445	3238	18			
326	2542	16	386	1093	17	446	2429	18			
327	2633	12	387	1965	19	447	2150	16			
328	2036	13	388	3275	10	448	3794	6			
329	1640	16	389	2584	3	449	3983	18			
330	2777	20	390	3722	13	450	3988	12			
331	2886	10	391	1976	13	451	1582	4			
332	2510	14	392	752	13	452	845	14			
333	645	16	393	299	19	453	1409	7			
334	1033	15	394	2012	16	454	1919	12			
335	2506	20	395	1591	8	455	2085	15			
336	2558	12	396	3841	10	456	3764	11			
337	323	11	397	115	10	457	653	16			
338	3191	15	398	4162	11	458	1785	8			
339	1953	12	399	3622	11	459	2547	14			
340	4182	17	400	3227	13	460	4114	16			
341	3154	18	401	1086	16	461	2472	17			
342	1355	19	402	1352	14	462	2654	16			
343	4121	16	403	2852	8	463	4268	14			
344	37	10	404	814	7	464	3244	23			
345	3961	10	405	2985	13	465	1855	19			
346	1973	14	406	1099	14	466	4228	10			
347	3019	13	407	2216	15	467	438	6			
348	862	19	408	508	13	468	2554	17			
349	1477	15	409	1668	13	469	3806	6			
350	921	16	410	3272	18	470	3508	12			
351	701	19	411	3799	12	471	2358	14			
352	3702	12	412	3825	14	472	260	16			
353	839	5	413	2487	19	473	2964	8			
354	892	12	414	3915	16	474	3519	22			
355	3530	14	415	4290	23	475	3860	14			
356	2593	8	416	2433	19	476	3077	8			
357	521	10	417	523	6	477	1975	12			
358	2223	8	418	3585	9	478	3476	13			
359	3475	23	419	1103	12	479	2685	10			

ÇK=2,00 olan grup için


-Yazılan kod:

```
carpik2ss <- draw_sample(dist=tum_veri[,c(1,2)], n=500, skew_value=2,  
kurtosis_value=7, location=5, delta_var=4, output_name=c("carpik","2ss"))
```

-Çekilen örnekleme ait çıktılar:

```
> carpik2ss  
$desc  
      data  mean    sd  skew kurtosis  
1 population  9.709  5.770 0.939   0.597  
2 reference 42.220 67.100 2.970  12.334  
3   sample  4.576  3.358 2.124   5.196
```

\$graph



\$sample			id	x		id	x		id	x		id	x	
	id	x	60	1848	8	120	1247	5	180	2632	3	240	992	2
1	3967	3	61	631	2	121	764	4	181	2075	2	241	512	2
2	826	3	62	3525	8	122	2641	7	182	1606	2	242	2588	3
3	597	3	63	2394	2	123	4073	4	183	2717	2	243	4214	2
4	1969	3	64	2495	3	124	1693	12	184	1751	1	244	3783	2
5	1514	3	65	2903	6	125	2659	1	185	3094	2	245	2642	6
6	413	8	66	4165	3	126	811	4	186	3142	6	246	3608	3
7	4094	2	67	2014	12	127	973	2	187	4100	3	247	357	6
8	2263	3	68	3116	2	128	1511	3	188	442	1	248	511	2
9	704	2	69	3462	3	129	1164	5	189	3252	2	249	825	3
10	4012	3	70	2812	2	130	3419	3	190	465	3	250	1337	3
11	628	6	71	1567	3	131	2301	5	191	2837	2	251	3662	3
12	1300	2	72	3397	4	132	2447	3	192	1206	4	252	1354	2
13	1601	3	73	1868	2	133	4149	3	193	966	3	253	1776	2
14	2829	3	74	2674	13	134	3624	2	194	3398	2	254	3224	4
15	1210	6	75	1506	3	135	4115	15	195	1442	4	255	314	9
16	3212	2	76	232	3	136	1959	3	196	3948	2	256	2232	4
17	318	6	77	359	2	137	3589	2	197	3301	5	257	1584	8
18	675	3	78	63	3	138	2913	3	198	3930	2	258	3629	10
19	1339	2	79	1272	7	139	1774	4	199	2766	5	259	2690	3
20	192	2	80	183	3	140	1963	3	200	1821	2	260	3192	3
21	4007	3	81	1853	15	141	482	9	201	3151	3	261	3646	3
22	3423	3	82	2002	3	142	765	1	202	1323	7	262	2901	2
23	2745	3	83	3977	19	143	2324	5	203	2047	3	263	532	3
24	2362	3	84	3575	3	144	687	3	204	2936	2	264	3498	8
25	2983	4	85	3217	3	145	3295	6	205	706	3	265	509	3
26	3435	3	86	365	3	146	4257	3	206	1345	3	266	2538	10
27	3402	2	87	2448	3	147	1576	2	207	1313	3	267	941	3
28	230	2	88	4078	3	148	961	3	208	1349	9	268	1951	2
29	393	2	89	324	3	149	1159	3	209	2483	5	269	1974	12
30	4175	3	90	178	2	150	1373	2	210	71	4	270	4044	3
31	3114	3	91	3775	1	151	777	3	211	123	3	271	360	3
32	2391	3	92	4010	3	152	3240	5	212	2574	3	272	2764	3
33	1280	2	93	703	2	153	556	3	213	2453	2	273	4079	4
34	2584	3	94	3259	5	154	1112	3	214	3875	4	274	2759	9
35	3031	2	95	2736	3	155	946	3	215	957	7	275	1758	2
36	1158	4	96	546	5	156	1717	4	216	384	5	276	4108	3
37	3640	2	97	1613	3	157	1705	3	217	1383	3	277	2868	5
38	4272	9	98	2276	5	158	1205	3	218	593	11	278	1618	2
39	816	3	99	932	2	159	98	4	219	167	2	279	1699	4
40	3880	3	100	1416	3	160	1725	3	220	2933	5	280	912	19
41	1548	8	101	2315	5	161	4093	2	221	3611	5	281	1813	11
42	3913	8	102	189	3	162	2478	5	222	2688	4	282	376	4
43	2477	2	103	1856	2	163	2496	3	223	4195	2	283	3170	5
44	1779	2	104	1418	2	164	571	3	224	1342	5	284	2265	2
45	1314	4	105	2400	3	165	3065	14	225	719	2	285	620	4
46	3056	4	106	3868	2	166	386	2	226	406	3	286	383	3
47	1130	8	107	1163	3	167	452	2	227	1326	12	287	145	1
48	1046	22	108	2251	3	168	1319	3	228	1773	3	288	3063	2
49	82	9	109	2520	3	169	3695	4	229	270	3	289	783	3
50	95	3	110	1838	11	170	2512	12	230	1305	11	290	2035	6
51	674	2	111	3616	2	171	3893	2	231	758	3	291	1958	12
52	134	3	112	1724	7	172	2940	5	232	4236	2	292	4052	4
53	1167	2	113	4045	1	173	1915	3	233	199	14	293	73	3
54	75	3	114	1494	3	174	1508	10	234	2578	2	294	3081	6
55	2914	3	115	2463	4	175	1859	4	235	1638	5	295	3292	5
56	420	11	116	3335	1	176	390	3	236	1788	9	296	2459	12
57	2327	3	117	715	14	177	774	1	237	3358	4	297	2334	2
58	385	2	118	3302	3	178	1153	3	238	3676	3	298	1310	8
59	3689	3	119	207	6	179	2524	2	239	2559	3	299	2088	2

300	3515	2	360	170	2	420	4235	5	480	1933	8
301	1232	3	361	2277	5	421	827	2	481	1589	12
302	1967	4	362	3617	3	422	1026	5	482	2356	4
303	2833	2	363	2386	11	423	2838	3	483	3965	3
304	560	3	364	1966	4	424	3559	4	484	3826	5
305	2698	4	365	4111	4	425	3264	4	485	3112	8
306	3288	2	366	2094	7	426	2249	4	486	4263	3
307	4105	3	367	3636	9	427	2050	6	487	3296	21
308	1196	3	368	996	4	428	1277	8	488	1704	4
309	366	2	369	4107	0	429	2565	3	489	3226	9
310	279	3	370	1108	14	430	4146	5	490	1295	2
311	1127	2	371	1415	4	431	2343	8	491	3526	9
312	3993	5	372	4066	9	432	2535	7	492	1787	6
313	4217	2	373	3417	4	433	3477	7	493	2681	5
314	2488	15	374	3017	4	434	454	3	494	1988	3
315	1203	11	375	2805	3	435	2291	6	495	1493	3
316	836	5	376	2441	3	436	682	3	496	1154	4
317	2728	5	377	2390	7	437	2011	10	497	493	6
318	1465	5	378	2661	19	438	2184	11	498	3002	3
319	2186	5	379	37	10	439	3340	4	499	3059	5
320	414	3	380	3718	7	440	1559	2	500	651	1
321	4244	8	381	1169	4	441	3365	6			
322	2845	5	382	2426	2	442	26	4			
323	2937	1	383	3102	4	443	1628	3			
324	3618	2	384	489	5	444	1227	4			
325	3466	3	385	1396	3	445	2876	2			
326	3308	5	386	2665	3	446	1233	6			
327	35	3	387	1497	9	447	3111	3			
328	2768	5	388	443	3	448	169	2			
329	2660	7	389	3747	5	449	3524	11			
330	4057	4	390	721	2	450	2591	4			
331	4274	3	391	1214	3	451	1563	6			
332	1685	4	392	1763	5	452	4206	3			
333	48	2	393	208	2	453	181	2			
334	2831	4	394	2598	4	454	1909	4			
335	2827	2	395	3969	4	455	2849	3			
336	1135	7	396	1151	3	456	3578	3			
337	2836	6	397	3902	3	457	4106	5			
338	1044	13	398	2767	3	458	2355	3			
339	4172	3	399	778	10	459	1839	6			
340	1721	8	400	401	3	460	1931	3			
341	3422	3	401	654	12	461	877	18			
342	4287	1	402	4088	5	462	1265	4			
343	2289	7	403	689	0	463	1260	4			
344	1619	3	404	1964	4	464	952	7			
345	256	3	405	3136	2	465	1456	5			
346	229	5	406	2915	5	466	1925	3			
347	524	9	407	2502	5	467	1007	5			
348	3568	3	408	4260	5	468	2464	13			
349	3139	3	409	581	3	469	2092	3			
350	4103	11	410	993	3	470	591	7			
351	3992	3	411	3173	3	471	3972	1			
352	669	3	412	1147	7	472	1139	6			
353	133	3	413	1423	5	473	1237	9			
354	3651	3	414	2521	7	474	1477	15			
355	3196	3	415	2566	3	475	1736	16			
356	2008	4	416	2802	4	476	972	2			
357	466	7	417	846	7	477	3057	3			
358	2541	3	418	4247	8	478	1386	7			
359	3982	16	419	4095	3	479	3654	2			

EK 5: PVAF için kesme puan hesaplama

```
ESP_hesaplama.R* x
1 #Gerekli Paketler ve Girdiler #####
2 library(GDINA)
3 library(boot)
4
5 dat <- `tum_veri(1_0)`      # ogrenci cevapları
6 Q <- `QMatris.KA(3u)`      # Q-matrisi
7 N <- nrow(dat)              # öğrenci sayısı(4292)
8 J <- ncol(dat)              # madde sayısı(30)
9 K <- ncol(Q)                # Nitelik Sayısı
10
11
12
13 #GDINA Kestirimleri#
14 fit <- GDINA(dat = dat, Q = Q, model = "GDINA") # GDINA analizi
15 gs <- coef(fit, what = "gs") # madde parametreleri
16 IQ <- as.double(1 - apply(gs, 2, mean)[1] - apply(gs, 2, mean)[2]) # Ortalama madde kalitesi
17
18 #Najera, Sorrel,ve Abad'ın (2019) Optimum kesme puan belirleme fonksiyonu#
19 eps_optimal <- function(N, IQ, J){
20
21   res <- inv.logit(-0.4045140782147791 +
22                 4.8404850955032684E-4*N +
23                 2.8667570118638275*IQ +
24                 -0.003315555999671906*J)
25   return(res)
26 }
27
28 #Evren verisi ile uzman görüşü ile oluşturulan Q-matris için optimum kesme puanı hesaplama#
29 eps <- eps_optimal(N, IQ, J)
30 eps
31
```

EK 6: Uzman Görüşü Formu

Sayın,

Bu uzman değerlendirme formu ile Gazi Üniversitesi Eğitimde Ölçme ve Değerlendirme Anabilim Dalı'nda Prof. Dr. Mehtap Çakan'ın danışmanlığında yürütülen Arş. Gör. Tuba GÜNDÜZ'ün doktora tez çalışmasında kullanılmak üzere görüşlerinizin alınması amaçlanmaktadır.

Bu amaç için “Uluslararası Geniş Ölçekli Sınavlarda Türkiye'nin Matematik Başarısını Arttırabilmek İçin Bir Model Önerisi: Bilişsel Tanıya Dayalı İzleme Modelinin Etkililiği” başlıklı ve 115K531 No'lu TÜBİTAK Projesi kapsamında kullanılan 6.sınıf öğrencilerine yönelik hazırlanmış açık uçlu ve çoktan seçmeli maddelerden oluşan 30 soruluk başarı testi maddelerinin verilen nitelik setleriyle eşleştirilmesine ihtiyaç duyulmaktadır.

Sizden istenen, aşağıda verilen nitelik setlerindeki özelliklerden maddelerin hangisi ya da hangileri ile ilişkili olduğu konusundaki görüşlerinizi en sağ sütundaki bölüme işaretlemenizdir. Sorular her bir nitelik seti için bir ya da birden fazla nitelikle ilişkili olabilir. **Eğer maddenin belirtilen nitelikle ilişkili olduğunu düşünüyorsanız ilgili hücreye 1; ilişkili olmadığını düşünüyorsanız 0 yazınız.** Aşağıda bir madde ve bir nitelik seti eşleştirmesi ile ilgili bir örnek yer almaktadır.

Eşleştirilmesi istenen nitelik seti olarak öğrenme alanları (Sayılar ve İşlemler, Cebir, Geometri ve Ölçme, Veri İşleme) ile sorunun doğru çözümünde ilişkili olabileceği düşünülen ve araştırma kasamında ele alınan becerilere (okuduğunu anlama becerisi ve rutin olmayan problem çözme becerisi) ilişkin bilgiler size sunulmuştur. Ayrıca soruya ilişkin başka görüşleriniz varsa yazabilirsiniz.

Değerli katkılarınız için teşekkür ederim.

Tuba Gündüz

Soru X) $(3+24) \div 9$ cevabını bulunuz.

	Toplama	Çıkarma	Çarpma	Bölme	İşlem Önceliği
Soru X	1	0	0	1	1

(Testte yer alan her bir madde için aşağıdaki verilen sorulara yönelik uzman görüşleri toplanmıştır.)

A.

	Sayılar ve İşlemler	Cebir	Geometri ve Ölçme	Veri İşleme
Soru 1				



B. Sorunun doğru çözümüne ilişkin olarak, madde “okuduğunu anlama becerisi (muhakeme becerisi)” gerektirmekte midir/ ile ilişkili olabilir mi?

() Evet () Hayır


C. Sorunun doğru çözümüne ilişkin olarak, madde “rutin olmayan problem çözme becerisi” gerektirmekte midir/ ile ilişkili olabilir mi ?

() Evet () Hayır


EK 7: Modifikasyon önerisi verilen maddelere ait Mesa Plotlar




Mesa Plot for Item 17




Mesa Plot for Item 19




Mesa Plot for Item 20




Mesa Plot for Item 23



Mesa Plot for Item 25



Mesa Plot for Item 26



EK 8: Yapılan ilk AFA sonucu

```
> faktor_ana
Factor Analysis using method = pa
Call: fa(r = tum_veri, nfactors = 4, n.obs = 4292, fm = "pa",
  cor = "tet")
```

Standardized loadings (pattern matrix) based upon correlation matrix

	PA2	PA1	PA4	PA3	h2	u2	com
s0203	0.01	0.06	-0.01	0.63	0.44	0.56	1.0
s0204	-0.06	0.09	0.01	0.54	0.32	0.68	1.1
s6471	0.38	-0.06	0.16	0.25	0.35	0.65	2.2
s9074	0.51	0.00	0.16	0.30	0.61	0.39	1.9
s0504	0.27	-0.16	0.38	0.25	0.38	0.62	3.1
s6470_A	-0.03	0.07	0.24	0.15	0.13	0.87	1.9
s9342	0.06	0.12	0.18	0.04	0.11	0.89	2.1
s0501	0.12	0.10	0.21	0.50	0.56	0.44	1.6
s9270	-0.12	0.12	0.42	0.10	0.26	0.74	1.5
s3159	0.09	0.01	0.70	0.08	0.62	0.38	1.1
s0505	0.22	0.08	0.63	0.08	0.73	0.27	1.3
s9739	0.01	0.24	0.34	-0.02	0.27	0.73	1.8
s4427	0.36	0.06	0.33	-0.11	0.33	0.67	2.2
s6188	0.40	0.10	0.24	-0.19	0.30	0.70	2.3
s0201	0.56	0.00	0.16	-0.14	0.36	0.64	1.3
s5050_A1	0.16	0.48	0.00	0.14	0.43	0.57	1.4
s6963_B	0.05	0.31	0.06	0.09	0.19	0.81	1.3
s6370	0.19	0.30	-0.02	0.15	0.25	0.75	2.2
s3281	0.07	0.49	0.04	0.06	0.36	0.64	1.1
s8867	0.16	0.73	-0.03	0.15	0.78	0.22	1.2
s6323_1	-0.07	0.26	0.19	0.03	0.15	0.85	2.1
s7305_A	-0.14	0.57	0.52	0.09	0.93	0.07	2.2
s0205	0.02	0.32	0.13	-0.02	0.17	0.83	1.4
s0206	0.04	0.33	0.13	0.00	0.20	0.80	1.3
s6251	0.14	0.37	0.10	-0.03	0.26	0.74	1.4
s1119	0.01	0.14	0.21	0.10	0.15	0.85	2.2
s5752_3	0.38	0.50	0.14	-0.06	0.67	0.33	2.1
s0507	0.58	0.20	-0.03	0.11	0.55	0.45	1.3
s0503	0.55	0.05	-0.02	0.14	0.40	0.60	1.1
s0502_2	0.65	0.17	0.00	0.06	0.59	0.41	1.2

	PA2	PA1	PA4	PA3
SS loadings	3.32	3.47	3.11	1.94
Proportion Var	0.11	0.12	0.10	0.06
Cumulative Var	0.11	0.23	0.33	0.39
Proportion Explained	0.28	0.29	0.26	0.16
Cumulative Proportion	0.28	0.57	0.84	1.00

With factor correlations of

	PA2	PA1	PA4	PA3
PA2	1.00	0.47	0.48	0.40
PA1	0.47	1.00	0.61	0.48
PA4	0.48	0.61	1.00	0.44
PA3	0.40	0.48	0.44	1.00

Mean item complexity = 1.7

Test of the hypothesis that 4 factors are sufficient.

The degrees of freedom for the null model are 435 and the objective function was 12.19 with Chi Square of 52160.5

The degrees of freedom for the model are 321 and the objective function was 0.94

The root mean square of the residuals (RMSR) is 0.02
The df corrected root mean square of the residuals is 0.03

The harmonic number of observations is 4292 with the empirical chi square 2060.29 with prob < 4.7e-251
The total number of observations was 4292 with Likelihood Chi Square = 4002.25 with prob < 0

Tucker Lewis Index of factoring reliability = 0.903
RMSEA index = 0.052 and the 90 % confidence intervals are 0.05 0.053
BIC = 1317.24
Fit based upon off diagonal values = 0.99
Measures of factor score adequacy



EK 9: GDINA paketi kullanıcı ara yüzü

GDINA GUI

Input

Estimation Settings

Estimation Summary

Model Fit

Parameter Estimates

Q-matrix Validation Outputs

Model selection Outputs

Plots

About this graphical user interface

This GUI application is developed with Shiny and shinydashboard and distributed as part of the GDINA R package by Wenchao Ma and Jimmy de la Torre. For examples, tutorials, and citation information, among others, please visit [this website](#).

The GUI application, as well as the GDINA R package, is free, and you can redistribute it and/or modify it under the terms of the GNU General Public License as published by the Free Software Foundation version 3 of the License. The program is distributed in the hope that it will be useful, but WITHOUT ANY WARRANTY; without even the implied warranty of MERCHANTABILITY or FITNESS FOR A PARTICULAR PURPOSE. See the GNU General Public License for more details.

Should you have any comments or suggestions, please email Wenchao Ma at wenchao.ma@ua.edu.

Import response matrix

Browse...

tum_veri(1_0).csv

Upload complete

☒ Header

Separator

☐ Tab ☐ Comma ☒ Semicolon ☐ Space

Import Q-matrix

Browse...

QMatrix.KA(3u).csv

Upload complete

☒ Header

Separator

☐ Tab ☐ Comma ☒ Semicolon ☐ Space

First 6 observations of the responses

s0203	s0204	s6471	s9074	s0504	s6470_A	s9342	s0501	s9270	s3159	s0505	s9739	s4427	s6188	s0201	s5050_A1	s6963_B	s6370	s3281	s8867	s6323_1	s7305_A	s0205	s0206	s6251	s1119
0	0	0	0	0	0	0	0	0	0	0	0	1	0	1	0	0	0	0	0	1	0	1	0	0	
1	1	0	0	0	0	0	1	0	0	0	0	1	1	0	1	0	0	1	0	0	0	1	1	1	
1	1	1	1	1	1	0	1	1	0	1	0	1	1	1	1	0	0	0	1	0	0	1	1	1	
1	1	1	1	0	1	0	0	0	0	0	1	0	1	1	1	0	1	1	1	1	0	0	0	1	
1	1	1	1	1	1	0	0	0	0	0	0	0	1	1	1	0	0	0	0	0	0	0	0	0	
0	0	1	0	1	1	0	1	0	0	0	0	1	0	0	0	1	0	1	0	0	0	1	1	0	

First 6 items of the Q-matrix

Sayılar_ve_Islemler	Cebir	Geometri_ve_Olcme	Veri_Isleme
0	0	0	1
0	0	0	1
0	1	0	0

GDINA GUI

Input

Estimation Settings

Estimation Summary

Model Fit

Parameter Estimates

Q-matrix Validation Outputs

Model selection Outputs

Plots

Measurement models

Select a single CDM for all items

GDINA [Generalized deterministic inputs, noisy and gate] model

Or choose "To be specified..." above and enter a vector of models (comma delimited without quotation marks)

GDINALDINA,LLM...

☐ Monotonic Constraints?

☐ Sequential models for polytomous responses?

Other settings

Joint attribute distributions:

☒ Saturated model

☐ Higher-order Rasch model

☐ Higher-order 1PL model

☐ Higher-order 2PL model

☐ Uniform distribution

Model diagnostics:

☒ Q-matrix validation?

☒ Item-level model selection (only applicable for G-DINA model)?

CLICK TO ESTIMATE!

GDINA GUI

Input

Estimation Settings

Estimation Summary

Model Fit

Parameter Estimates

Q-matrix Validation Outputs

Model selection Outputs

Plots

Model estimation summary

Estimation summary

```

Call:
GDINA::GDINA(dat = dat, Q = Q, model = m, sequential = input$seq,
  att.dist = H0dist, mono.constraint = input$mono, verbose = 0,
  higher.order = list(model = nom))

GDINA version 2.8.0 (2020-05-23)
=====
Data
# of individuals groups items
      4292         1      30
=====
Model
Fitted model(s)      = GDINA
Attribute structure   = saturated
Attribute level       = Dichotomous
=====
Estimation
Number of iterations = 198

For the final iteration:
Max abs change in item success prob. = 0.0001
Max abs change in mixing proportions = 0.0000
Change in -2 log-likelihood          = 0.0000
Converged?                          = TRUE

Time used                  = 5.31 secs

Test Fit Statistics
Loglik = -67985.66

AIC      = 136177.32 | penalty [2 * p] = 206.00
BIC      = 136935.86 | penalty [log(n) * p] = 861.54
CAIC     = 136935.86 | penalty [(log(n) + 1) * p] = 864.54
SABIC    = 136985.57 | penalty [log((n + 2)/24) * p] = 534.25

No. of parameters (p) = 103
No. of estimated item parameters = 88
No. of fixed item parameters = 0
No. of distribution parameters = 15

Attribute Prevalence
Level Level1
A1 0.8396 0.1604

```

Classification summary

Classification Accuracy

Test level accuracy = 0.8485

Pattern level accuracy:

0000	1000	0100	0010	0001	1100	1010	1001	0110	0101	0011	1110
0.9784	0.3823	0.0000	0.0000	0.2541	0.3297	0.4133	0.0000	0.6949	0.4994	0.1883	0.0000
1101	1011	0111	1111								
0.0000	0.0000	0.7623	0.8967								

Attribute level accuracy:

A1	A2	A3	A4
0.9478	0.9420	0.9280	0.9331

GDINA GUI

Input

Estimation Settings

Estimation Summary

Model Fit

Parameter Estimates

Q-matrix Validation Outputs

Model selection Outputs

Plots

Relative test fit

```

Loglikelihood = -67985.66
Deviance     = 135971.3
AIC          = 136177.3
AIC Penalty  = 206
BIC          = 136832.9
BIC penalty  = 861.54
CAIC         = 136935.9
CAIC Penalty = 861.5683
SABIC        = 136985.6
SABIC Penalty = 534.2528

```

Absolute test fit

H0 = 1891.657 (df= 362) p-value 0

RMSEA = 0.0324 with 90 % CI: [0.031 , 0.0338]

SRMR = 0.053

	mean[stats]	max[stats]	max[z.stats]	p-value	adj.p-value
Proportion correct	0.0000	0.0028	0.3537	0.7236	1
Transformed correlation	0.0020	0.2297	15.0487	0.0000	0
Log odds ratio	0.2156	1.9644	14.1730	0.0000	0

Note: p-value and adj.p-value are associated with max[z.stats].
adj.p-values are based on the holm method.

Item-fit plot specifications

Plot type:

☒ log odds ratio



☐ transformed correlation

☒ Holm-Bonferroni adjusted?

[Download Plot as PDF File](#)

Heatmap plots

129



EK 10: Q-matrisi için G-DINA modele göre kestirilen öğrencilerin gizil sınıflarda yer alma oranları

```
> coef(modelkestirim3u, "lambda")
p(0000) p(1000) p(0100) p(0010) p(0001) p(1100) p(1010) p(1001) p(0110) p(0101) p(0011)
0.5808 0.0230 0.0028 0.0001 0.0249 0.0056 0.0101 0.0001 0.0049 0.0842 0.0035
p(1110) p(1101) p(1011) p(0111) p(1111)
0.0011 0.0000 0.0000 0.1383 0.1206

> coef(modelkestirim3uPVAF, "lambda")
p(0000) p(1000) p(0100) p(0010) p(0001) p(1100) p(1010) p(1001) p(0110) p(0101) p(0011)
0.5170 0.0067 0.0510 0.0050 0.0009 0.0000 0.0034 0.0010 0.0217 0.1544 0.0177
p(1110) p(1101) p(1011) p(0111) p(1111)
0.0000 0.0000 0.0000 0.1115 0.1098

> coef(modelkestirim3uPVAF3u, "lambda")
p(0000) p(1000) p(0100) p(0010) p(0001) p(1100) p(1010) p(1001) p(0110) p(0101) p(0011)
0.5381 0.0034 0.0215 0.0037 0.0138 0.0000 0.0000 0.0000 0.0076 0.1614 0.0000
p(1110) p(1101) p(1011) p(0111) p(1111)
0.0001 0.0000 0.0004 0.1450 0.1050

> coef(modelkestirimFA, "lambda")
p(0000) p(1000) p(0100) p(0010) p(0001) p(1100) p(1010) p(1001) p(0110) p(0101)
0.5036 0.0022 0.1334 0.0000 0.0377 0.0220 0.0000 0.0083 0.0227 0.0528
p(0011) p(1110) p(1101) p(1011) p(0111) p(1111)
0.0046 0.0079 0.0536 0.0048 0.0187 0.1278

> coef(modelkestirimFAPVAF, "lambda")
p(0000) p(1000) p(0100) p(0010) p(0001) p(1100) p(1010) p(1001) p(0110) p(0101)
0.5030 0.0027 0.1320 0.0000 0.0366 0.0234 0.0000 0.0096 0.0237 0.0506
p(0011) p(1110) p(1101) p(1011) p(0111) p(1111)
0.0047 0.0074 0.0550 0.0042 0.0213 0.1258
```



GAZİLİ OLMAK AYRICALIKTIR..