

**T.C.
TRAKYA ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ
BİYOİSTATİSTİK VE TIBBİ BİLİŞİM ANABİLİM DALI
YÜKSEK LİSANS PROGRAMI**

Tez Yöneticisi
Doç. Dr. Fatma Nesrin TURAN

**FARKLI BÜYÜKLÜKTEKİ VERİ SETLERİNDE
YAPISAL EŞİTLİK MODELİ VE MODEL UYUMU
TESTLERİNE GÖRE KARŞILAŞTIRMASI:
SİMÜLASYON ÇALIŞMASI ÖRNEĞİ**

(Yüksek Lisans Tezi)

Beyza İrem DALKILIÇ

Referans no: 10223743

EDİRNE – 2019

**T.C.
TRAKYA ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ
BİYOİSTATİSTİK VE TIBBİ BİLİŞİM ANABİLİM DALI
YÜKSEK LİSANS PROGRAMI**

Tez Yöneticisi
Doç. Dr. Fatma Nesrin TURAN

**FARKLI BÜYÜKLÜKTEKİ VERİ SETLERİNDE
YAPISAL EŞİTLİK MODELİ VE MODEL UYUMU
TESTLERİNE GÖRE KARŞILAŞTIRMASI:
SİMÜLASYON ÇALIŞMASI ÖRNEĞİ**

(Yüksek Lisans Tezi)

Beyza İrem DALKILIÇ

Destekleyen Kurum:

Tez no:

EDİRNE – 2019

T.C.
TRAKYA ÜNİVERSİTESİ
Sağlık Bilimleri Enstitü Müdürlüğü

O N A Y

Trakya Üniversitesi Sağlık Bilimleri Enstitüsü Biyoistatistik ve Tıbbi Bilişim Anabilim Dalı yüksek lisans programı çerçevesinde ve Fatma Nesrin TURAN danışmanlığında yüksek lisans öğrencisi Beyza İrem DALKILIÇ tarafından tez başlığı "Farklı Büyüklükteki Veri Setlerinde Yapısal Eşitlik Modeli ve Model Uyumu Testlerine göre Karşılaştırması: Simülasyon Çalışması Örneği" olarak teslim edilen bu tezin tez savunma sınavı 21.10.2019 tarihinde yapılarak aşağıdaki jüri üyeleri tarafından "**Yüksek Lisans Tezi**" olarak kabul edilmiştir.


İmza
Prof. Dr. Necdet SÜT

İmza
Doç. Dr. F. Nesrin TURAN



İmza
Doç. Dr. Hayriye ERTEM VEHİD



Yukarıdaki imzaların adı geçen öğretim üyelerine ait olduğunu onaylıyorum.

Prof. Dr. Tammam SİPAHİ
Enstitü Müdür V.



TEŞEKKÜR

Çalışmanın her aşamasında yardımlarını ve desteğini esirgemeyen danışman hocam Sn. Doç. Dr. Fatma Nesrin TURAN olmak üzere, çalışmamın oluşturulmasında katkı sağlayan Biyoistatistik ve tıbbi bilişim anabilim dalı başkanımız Sn. Prof. Dr. Necdet SÜT ve bütün bölüm üyelerine, bu süreçte bana her zaman yardımlarını sunan Sn. Arş. Görevlisi F. Betül ÖRS'e teşekkür ederim. Her zaman yanımda bulunan ve destek olan babam, annem, kardeşim ve tabii ki anlayışından ve sabrından dolayı biricik eşime teşekkürü borç bilirim.

İÇİNDEKİLER

GİRİŞ VE AMAÇ	1
GENEL BİLGİLER	3
YAPISAL EŞİTLİK MODELİ (YEM)	3
YAPISAL EŞİTLİK MODELİNE İLİŞKİN TEMEL KAVRAMLAR	4
YAPISAL EŞİTLİK MODELİNİN TARİHSEL GELİŞİMİ	5
NEDEN YAPISAL EŞİTLİK MODELLEMESİ KULLANILMALI	7
YAPISAL EŞİTLİK MODELİNDE KULLANILAN YAZILIM PROGRAMLARI	7
YAPISAL EŞİTLİK MODELİ VARSAYIMLARI	8
YAPISAL EŞİTLİK MODELİ YAPI TAŞLARI	9
YAPISAL EŞİTLİK MODELİ	13
YAPISAL EŞİTLİK MODELİ AŞAMALARI	14
GEREÇ VE YÖNTEMLER	34
BULGULAR	42
TARTIŞMA	73
SONUÇLAR	80
ÖZET	82

SUMMARY	84
KAYNAKLAR	86
ŞEKİLLER LİSTESİ	91
ÖZGEÇMİŞ	94
EKLER	95



SİMGE VE KISALTMALAR

η (Eta)	:Gizil içsel değişken
ξ (Ksi)	:Gizil dışsal değişken
ζ (Zeta)	:Gizil değişkenlerdeki hata
y	:İçsel gözlenen değişken vektörü
x	:Dışsal gözlenen değişken vektörü
γ (Gama)	:Gizil bağımsız değişkenlerle gizil bağımlı değişkenler arasındaki ilişkiyi gösteren katsayı
ε (Epsilon)	:Bağımlı gözlenen değişkendeki hata
B (Beta)	:Gizil içsel değişkenler katsayı matrisi
Γ (Gamma)	:Gizil dışsal değişkenler katsayı matrisi
δ (Delta)	:Bağımsız gözlenen değişkendeki hata
λ_x (Lamda x)	:Bağımsız gözlenen değişkenin gizil bağımsız değişkene ilişkin katsayısı
λ_y (Lamda y)	:Bağımlı gözlenen değişkenin gizil bağımlı değişkene ilişkin katsayısı
p	:Gözlenen değişkenlerin sayısı

Φ (Phi)	:Gözlenen deęişken kovaryans matrisi
Θ (Theta)	:Gösterge hata varyansları kovaryans matrisler
ADF	:Asimptotik Daęılım Fonksiyonu
AFA	:Açıklayıcı Faktör Analizi
AGFI	:Adjusted Goodness of Fit Index / Düzeltilmiş Uygunluk İndeksi
AIC	:Akaike Information Criterion / Akaike Bilgi Kriteri
BIC	:Bayesian Information Criterion / Bayesyen Bilgi Kriteri
CAIC	:Consistent Akaike Information Criterion / Tutarlı Akaike Bilgi Kriteri
CFA	:Confirmatory Factor Analysis
CFI	:Comparitive Fit Index / Karşılaştırmalı Uyum İndeksi
DFA	:Doęrulamalı Faktör Analizi
DWLS	:Diagonally Weighted Least Squares / Diyagonal Aęırlıklandırılmış En Küçük Kareler Yöntemi
ECVI	:Expected Cross-Validation Index / Beklenen Çapraz Geçerlilik İndeksi
EFA	:Exploratory Factor Analysis
EKK	:En Küçük Kareler Yöntemi
GFI	:Goodness of Fit Index / Uygunluk İndeksi
GLS	:Generalized Least Squares / Genelleştirilmiş En Küçük Kareler Yöntemi
IFI	:Incremental Fit Index / Artan Uyum İndeksi
MFI	:McDonald's Fit Index / McDonald's Uyum İndeksi
MIMIC	:Multiple Indicators Multiple Causes Çoklu Göstergeler Çoklu Nedenler Kuralı
ML	:Maximum Likelihood / Maksimum Olabilirlik Yöntemi
NFI	:Normed Fit Index / Normlaştırılmış Uyum İndeksi

NNFI	:Nonnormed Fit Index / Normlu Olmayan Uyum İndeksi
OLS	:Ordinary Least Squares / Sıradan en Küçük Kareler
PGFI	:Parsimonious Goodness of Fit Index / Kısıtlı Uygunluk İndeksi
PNFI	:Parsimonious Normed Fit Index / Standartlaştırılmış Kısıtlı Uygunluk İndeksi
RMR	:Root Mean Square Residual / Hata Kareleri Ortalamalarının Karekökü
RMSEA	:Root Mean Square Error of Approximation / Yaklaşık Hataların Ortalama Karekökü
sd	:Serbestlik Derecesi
SEM	:Structural Equation Modeling
SRMR	:Standardize Edilmiş Hata Kareleri Ortalamalarının Karekökü (Standartized Root Mean Square Residual)
ULS	:Unweighted Least Squares / Ağırlıklandırılmamış En Küçük Kareler
WLS	:Weighted Least Squares / Asimptotik Dağılımdan Bağımsız
WLSMV	:Diagonally Weighted Least Squares / Diagonal Ağırlıklandırılmış En Küçük Kareler Yöntemi
YEM	:Yapısal Eşitlik Modellemesi

GİRİŞ VE AMAÇ

Yapısal eşitlik modeli (YEM) çoklu regresyon, faktör analizi, yol analizi tekniklerinin kombinasyonundan oluşan istatistiksel bir tekniktir. Değişkenler arası nedensellik içeren yapıların incelenmesinde kullanılmaktadır. Daha çok tıp, sosyal bilimler ve psikoloji gibi alanlarda neden – sonuç ilişkisi barındıran soyut ölçülemeyen değişkenler içeren araştırmalarda kullanılan bir yöntemdir. Yapısal eşitlik modeli birbiriyle bağlantılı olan fakat tek başına ölçülemeyen değişkenlerin teorik modellerinin belirlenmesi, tahmini ve testini yapan bir analiz yöntemidir (1).

Yapısal eşitlik modeli bir veya birden fazla gizil değişken ile gözlenen değişkenler arası birbirleriyle olan ilişkileri eş zamanlı olarak test edilmesini sağlamaktadır (2). Yapısal eşitlik modeli gizil değişken, gözlenen değişken gibi kendine has bazı terimler içermektedir. Bu terimler genel bilgiler kısmında detaylıca açıklanmıştır.

Bu tez çalışmasının temel amacı, yapısal eşitlik modellemesinde dışsal gizil değişken sayısına göre oluşturulan iki farklı model; üç dışsal gizil değişkenli Model 1 ve dört dışsal gizil değişkenli Model 2 baz alınarak çok değişkenli normallik varsayımının sağlandığı simülasyon çalışmasında “tahmin tekniği” ve “örneklem hacmi” etmenlerinin etkilerini araştırmak ve bu etmenlerin uyum indeksleri üzerindeki etkileri doğrultusunda model uyum indekslerini karşılaştırmaktır. Bu amaç çerçevesinde, çok değişkenli normallik varsayımının sağlandığı durumlarda ML, GLSparametre tahmin yöntemleri kullanarak 300, 600, 1200 birimlik örneklem büyüklüklerinde "*chisq*", "*chisq/df*", "*pvalue*", "*GFI*", "*RMSEA*", "*CFI*", "*TLI*",

"SRMR", "RMR", "IFI", "NNFI", "NFI", "AGFI" uyum indeksleri karşılaştırması değerlendirilmiştir. Hangi uyum indeksi örneklem büyüklüğünden etkilendiği hangi uyum indeksinin parametre tahmininden etkilendiği en tercih edilebilir uyum indeksi hangisi olduğu simülasyon çalışmasıyla oluşturulan iki tip modelde testi yapılmıştır.



GENEL BİLGİLER

YAPISAL EŞİTLİK MODELİ (YEM)

Yapısal eşitlik modelleri (YEM), değişkenlerin kendi aralarındaki neden sonuç ilişkisine bağlı yapıların modellenmesinde kullanılan istatistiksel tekniktir. Yapısal eşitlik modeli kavramı birden fazla istatistiksel yöntemin genel adıdır (3,4). YEM, çok değişkenli regresyon ve faktör analizi yaklaşımlarının birleştirilmesiyle ortaya çıkmış bir yöntemdir (5,6).

Değişkenler arasındaki neden sonuç ilişkilerini açıklayabilen YEM, teorik kurulan modellerin bir bütün olarak test edilmesine ve değişkenler arasındaki doğrudan ve dolaylı etkilerin belirlenmesine imkan sağlayan model test etme ve geliştirme yöntemidir (2,7-8).

Yapısal eşitlik modellemesi, çok değişkenli veri setindeki değişkenler arası ilişkileri incelemek için kullanılan bir tekniktir. Yapısal eşitlik modellemesi ölçülen ve gizil değişkenler arasındaki ilişkilerin hipotezini bir model kapsamında sınamada kullanılan bir istatistik tekniğidir (5,6).

Değişkenler arası karşılıklı ilişkileri açıklayabilen olası teorik modellerin incelenmesinde kullanılan bir araç özelliğini taşımaktadır. Bir yapısal eşitlik modeli, analizde yer alan değişkenler ile nasıl oluşturulduğu ve ilgili değişkenlerin nasıl ilişkili olduğuna ilişkin hipotezleri sınamaya yöntemidir (9). Araştırmacı tarafından varsayılan teorik bir modelin nicel bir testini sağlama amacı ile gözlemlenen değişkenler arasındaki ilişkileri göstermek için çeşitli modeller kullanılır. YEM, değişkenlerin yapıları nasıl tanımladığını ve bu yapıların birbirleriyle

olan ilişkisini arařtırmak için çeřitli modeller kullanarak sınavabilen bir yaklařımdır (2). YEM, gizil deęiřkenler (latent variable) ve gözlenen deęiřkenler (observed variable) arasındaki nedensel iliřkilerin ve korelasyon iliřkilerinin bir arada bulunduęu modellerin analizini yapmaktadır (7,10). Bu teknik, özellikle sosyal bilimler alanında yapılan alıřmalarda deęiřkenler arasındaki iliřkilerin deęerlendirilmesi ve modellerin test edilmesi için sıklıkla kullanılan bir analiz teknięidir (11). Örneęin tıp literatüründe sıklıkla kullanılan Ware tarafından geliştirilen ve Pınar (12) tarafından Türk toplumunda geçerlik- güvenilirlik alıřması yapılan Yařam Kalitesi Öleęi (SF-36) fonksiyonel durum, esenlik, genel gıda anlayıřı ve global yařam kalitesi olmak üzere 4 Ana bařlık (gizil deęiřken) ve 36 maddeden (gözlenen deęiřken) oluřmaktadır.

YAPISAL EŐİTLİK MODELİNE İLİŐKİN TEMEL KAVRAMLAR

YEM, gözlenen deęiřkenler (observed variables) ve gizil deęiřkenler (7) arasındaki nedensel iliřkilerin ve korelasyon iliřkilerinin bir arada bulunduęu modellerin analizini yapmaktadır (4,5). “Bu teknik, özellikle sosyal bilimler alanında yapılan alıřmalarda deęiřkenler arasındaki iliřkilerin deęerlendirilmesi ve modellerin test edilmesi için sıklıkla kullanılan bir analiz teknięidir” (4).

YEM, dięer istatistik yöntemler gibi kendine özgü bazı kavramlar içermektedir. YEM’i anlatabilmek için öncelikle kendine özgü olan birkaç terimi tanımlamak gerekmektedir. Yapısal eřitlik modellerinde sıklıkla kullanılan bazı kavramlara ařaęıda yer verilmiřtir.

Gözlenen Deęiřkenler (Observed Variables)

Direkt ölçülebilen, gözlenebilen deęiřkenlerdir. Örneklemeden direkt ölçme ve gözlenme imkanı sunan deęiřkenlere gözlenen deęiřken demektedir. Gerekte ölçülen bu deęiřkenler, belirli bir testteki performans, bir envanter ya da bir ölçekteki soruların cevapları gibi bir örnek üzerinden ölçülerek kaydedilebilir (13).

Gizil Deęiřkenler (Latent Variables)

Doęrudan gözlenemeyen veya ölçülemeyen deęiřkenlere gizil deęiřkenler denmektedir. Gizil deęiřkenler doğrudan gözlenemedięi için ölçümü yapılamamaktadır. Bu nedenle gizil deęiřken gözlenen bir deęiřken ile iliřkilendirerek ölçümü yapılabilmektedir. (14). Arařtırmacılar, incelemek istedięi gizil deęiřkeni iyi temsil ettięine inandıęı ölçülebilir davranıř ve eylemleri belirleyerek tanımlamaktadırlar.

Bağımlı / Bağımsız Değişkenler

Başka değişkenlerin etkileri ile oluşan, gözlenebilen etkilenen değişkenlere bağımlı değişken denir.

Bağımlı değişkenin değerinin oluşmasında etki sağlayan, rasgele oluşan gözlenebilen değişkenlere bağımsız değişken denir (2,15).

İçsel (Endojen, Endogenous) Değişkenler

Modeldeki dışsal değişkenler tarafından direkt ya da indirekt olarak etkilenen gizil değişkenlerdir. Diğer değişkenler üzerine bağımlı olarak modellenmesi yapılır. İçsel değişkenlerin değerlerinin değişimi model ile açıklanamaz. Bunun yerine modeldeki diğer dış faktörlerden etkilendiği kabul edilmektedir (3).

Dışsal (Eksojen, Exogenous) Değişkenler

Modelde yer alan diğer değişkenlerin değerlerini etkileyen ve bağımsız değişkenler gizil değişkenlerdir. Dışsal değişkenlerdeki değerlerin dalgalanması model ile açıklanabilir. Çünkü bütün gizil değişkenler model belirlenmesinde yer almaktadır (14).

YAPISAL EŞİTLİK MODELİNİN TARİHSEL GELİŞİMİ

Yapısal eşitlik modelinin tarihsel ilerleyişini anlatabilmek için öncelikle bazı kavramları açıklamak gerekir. Bunlar, regresyon analizi, yol (path) analizi, doğrulayıcı faktör analizi ve yapısal eşitlik modelleridir (2).

İlk model, bir regresyon ağırlığını hesaplamak için bir korelasyon katsayısı ve en küçük kareler kriteri kullanan doğrusal regresyon modellerini içerir. “Karl Pearson 1896'da regresyon modellerinde iki değişken arasındaki ilişkiyi belirtmede kullanılan korelasyon katsayısı için bir endeks sağlayan bir formül oluşturdu” (16). Regresyon modeli, karesel artık hata miktarını en aza indiren bir dizi bağımsız gözlenen puanın (X puanlarının) doğrusal bir ağırlıklandırılmasıyla (16), bağımlı gözlenen değişken puanlarının (Y puanları) tahmin edilmesine izin vermektedir.

Doğrusal regresyon modelinin matematiksel temeli, temel cebire dayanmakta olup, regresyon analizi teorik bir modelin testini sağlar.

Birkaç yıl sonra, Charles Spearman (1904, 1927), faktör modelini oluşturmak için hangi öğelerin korelasyonu olduğunu belirlemek için korelasyon katsayısını kullandı.

Korelasyon analizinin temel fikri, eğer bir grup küme bağıntılıysa veya birlikte ilişkilendirilirse, küme kendisinin ilişkisinin toplanabileceğini, bir kurgu ölçen, tanımlayan veya çıkarıcı bir puan elde edebileceği yönündedir.

Spearman, faktör analizi terimini kullanan ilk kişidir. Thurstone, 1940'ta, faktör modellerinin uygulamalarını geliştirdi ve elde edilen araçları önerdi. Bugün kullanılan yetenek, başarı ve teşhis testleri ve envanterlerin çoğu, ölçek kullanılarak ölçülebilen yapılar, faktör analizi kullanılarak oluşturulmuştur.

Doğrulayıcı faktör analizi (DFA) terimi, Howe'un (1955) yaptığı çalışmalara dayanmaktadır. DFA yöntemi, 1960'lı yıllarda Karl Jöreskog tarafından, bir dizi ögenin bir yapının tanımlanıp tanımlanmadığını test etmek için geliştirilmiştir. Jöreskog 1963 yılında bilimsel araştırmasını tamamladı, 1969 yılında DFA ile ilgili ilk makaleyi yayınladı ve ardından 1973 yılında ilk DFA yazılım programının geliştirilmesine yardımcı oldu (3,17).

Açıklayıcı Faktör Analizi (AFA) p sayıda gözlenen değişkenden birbiriyle ilişkili ancak daha az sayıda ve birbirinden ilişkisiz yeni gizil değişkenlere (veri yapılarına) dönüştürerek bir oluşum ya da olayı açıkladığı varsayılan değişkenleri gruplamak amacıyla başvurulan bir yöntemdir (18). DFA ise kuramsal faktör modelinin istatistiksel anlamlılığını yani bu teorik yapıların varlığını test etmek için kullanılmakta olan bir yöntemdir (6, 18). Örnek bir çalışmada DFA, Goldberg (1990) tarafından "Büyük Beş" kişilik modelini doğrulamak için kullanılmıştır. Beş faktörlü dışavurum, uyumluluk, vicdan, nevrotiklik ve zekâ modeli beş varsayımsal faktörün her biri için çoklu gösterge değişkenlerinin kullanılmasıyla doğrulanmıştır (19).

Sewell Wright (1918, 1921, 1934), yol modelini geliştirmiştir. Yol modelleri, gözlenen değişkenler arasındaki daha karmaşık ilişkileri modellemek için korelasyon katsayıları ve regresyon analizini kullanmaktadır. Birçok açıdan, yol analizi, yol modelinde gözlenen değişkenler arasındaki ilişkiyi teorik olarak belirleyen bir dizi eşzamanlı regresyon denklemi çözmeyi içermektedir (2,7).

Son model tipi yapısal eşitlik modellemesidir. YEM modelleri esas olarak yol modellerini ve doğrulayıcı faktör modellerini birleştirir; yani, YEM modelleri hem gizil hem de gözlenen değişkenleri içerir. YEM'in gelişimi Karl Jöreskog (1969, 1973), Ward Keesling (1972) ve David Wiley (1973) tarafından olmuştur (8).

Jöreskog ve Van Thillo, başlangıçta LISREL yazılım programını geliştirdi. Tüm disiplinlerde yapısal eşitlik modeli 1994'ten beri geniş yer bulmuştur. Hershberger, 1994 ve

2001 yılları arasında YEM ile ilgili dergi makalelerinin ve YEM konusunu ele alarak yayınlayan dergilerin sayısının arttığını, söylemiştir.

NEDEN YAPISAL EŞİTLİK MODELLEMESİ KULLANILMALI

YEM'in diğer istatistiksel tekniklere göre tercih edilmesinin başlıca nedeni araştırmacıların, bilimsel araştırma alanlarını daha iyi anlamak için çok sayıda gözlenen değişken kullanma gereksinimi duymalarıdır. Temel istatistiksel yöntemler yalnızca sınırlı sayıda değişken kullanmakta olup, geliştirilmekte olan karmaşık teorileri ele alma becerisine sahiptir. Karmaşık teorileri anlamak için az sayıda değişken kullanılması sınırlayıcıdır. Örneğin, karmaşık bir teorik modeli incelemek için basit iki değişkenli korelasyonların kullanılması yeterli değildir. Aksine, yapısal eşitlik modellemesi karmaşık olayların istatistiksel olarak modellenmesine ve test edilmesine izin verir. Dolayısıyla YEM teknikleri, teorik modellerin nicel olarak doğrulanması (veya reddedilmesi) için tercih edilen bir yöntem haline gelmektedir (14).

YAPISAL EŞİTLİK MODELİNDE KULLANILAN YAZILIM PROGRAMLARI

Yapısal eşitlik modeli için birçok program üretilmiştir. Günümüzde yapısal eşitlik modeli için en çok kullanılan programlar; Lisrel, Amos, R, EQS, SAS diyebiliriz.

AMOS

COSAN

EQS

MATLAB

MECOSA 3

LINCS

LISCOMP

LISREL

Mx

Mx plus

R (Free open source software, R Team)

RAMONA

SAS

SEpath

STATA 12

STATISTICA/SEPATH

SYSTAT

şeklindedir (20). Bu yazılım programlarının her biri, farklı YEM uygulamalarını yürütmek için özel özellikler sunan, kendi yollarına özgü programlardır. Bu YEM yazılım programlarının birçoğu ham verilerin istatistiksel analizini sağlar (örneğin, korelasyonlar, eksik veri), eksik verilerin ele alınması ve aykırı değerlerin tespiti, programın sözdiziminin oluşturulması, modeli ve teorik bir modelin rakam ve verilerini alma ve vermeyi sağlar.

YAPISAL EŞİTLİK MODELİ VARSAYIMLARI

Yapısal eşitlik modelinin uygulanabilmesi ve uygulamaya sağlıklı yorum yapabilmemiz için bazı varsayımları sağlaması gerekmektedir. Varsayımları aşağıdaki şekilde sıralanabilir.

- Çok değişkenli normallik,
- Doğrusallık,
- Örneklem büyüklüğü,
- Basıklık ve çarpıklığın olmaması,
- Aykırı değerler olmaması,
- Korelasyonsuz hata terimleri,
- Çoklu doğrusal bağlantı olmaması,
- Çoklu göstergeler,
- Ölçek türü (aralıklı ya da oranlı ölçekle ölçülen uygun veriler)

YEM 'de çok değişkenli normallik önemli bir varsayımdır. Bu varsayımın ihlali ki-kare değerinin büyük çıkmasına ve sonucun anlamlı olmadığı halde anlamlı çıkmasına neden olabilir. Bu varsayımın ihlalinde ise dağılımdan bağımsız veya ağırlıklı yöntemler önerilmektedir (13). Örneklemin ölçeklemesindeki kısıtlar ya da ölçek seçimindeki hatalar, verinin normal dağılması varsayımını sağlamamasına neden olabilmektedir.

YEM 'de gizil değişkenler arasında ve gözlenen değişkenler ile gizil değişkenler arasındaki ilişkilerin doğrusal olduğu varsayılmaktadır. Bu varsayımın ihlalinde model uyum tahminleri ve standart hatalar yanlı olmaktadır. Regresyon analizinde olduğu gibi YEM 'de de orijinal verilerin üssel ve logaritmik dönüşümleri modele eklenebilmektedir. Gizil değişkenler arasındaki analiz edilemeyen ve korelasyon anlamına gelen çift yönlü eğik ok (kovaryans) ile gösterilebilirler (21).

Örneklem hacmi, genellikle 100'den az örneklem hacmi küçük, 100-200 arası örneklem hacmi orta ve 200'den fazla örneklem hacmi ise büyük örneklem hacimleri olarak tanımlanmaktadır (15).

YAPISAL EŞİTLİK MODELİ YAPI TAŞLARI

Yapısal denklem modellemesi (YEM), bir kavram olarak, açıklayıcı faktör analizi ve çok değişkenli regresyon gibi istatistiksel tekniklerin bir kombinasyonudur.

YEM 'in araştırmalarda kullanılan farklı türleri vardır. Araştırmacı seçimine göre bunların hepsini sırayla ya da bazılarını seçerek kullanabilir. Literatürde yaygın olarak kullanılmakta olan ve birçok araştırmacının ortak görüşü olan üç tip yapısal eşitlik modellemesine rastlanmaktadır (22). Bunlar:

- Yol (Path) analizi
- Doğrulayıcı faktör analizi
- Yapısal Eşitlik Modeli









Yol (Path) Analizi

1930'lu yıllarda Sewall Wright tarafından geliştirilen yol analizi, yapısal eşitlik modelleri için değişkenler arası istatistiksel ilişkileri başlangıç düzeyinde ayrıştırmak için kullanılan bir yöntem olarak düşünülebilir (13). Yol analizi nicel değişkenler arasındaki yapısal ilişkiyi kestirmenin yanı sıra bağımsız değişkenler üzerindeki toplam etkilerinin ne kadarının doğrudan ne kadarının dolaylı olarak ortaya çıktığını belirlemekte kullanılan bir yöntem olarak tanımlanabilir (2).

Yol analizi sembol ve diyagramları:

Bollen'ın (7) tarafından 1989 yılındaki çalışmasında ifade ettiği gibi bir yol diyagramı eşanlı eşitlikler sisteminin görsel olarak ifadesidir. Yol diyagramının temel avantajı, belirlenen varsayımsal ilişkilerin bir resimle gösterilmesidir.

Tablo 1. Yol analizinde kullanılan semboller(17)

	Gizil değişkeni simgelemektedir.
	Gözlenen değişkeni simgelemektedir.
	Gizil değişkenden gözlenen değişkene olan regresyon katsayısı
	Gizil değişkenler arasındaki nedensel ilişki
δ  	Bağımsız değişkenin gözlenen değişkenle ilgili ölçüm hatası
  ϵ	Bağımlı değişkenin gözlenen değişkenle ilgili ölçüm hatası

δ : Bağımsız gözlenen değişkendeki hata; ϵ : Bağımlı gözlenen değişkendeki hata

Yol analizinde, teorik model tarafından ima edilen ilişkiler yol diyagramında ifade edilebildiği gibi bir yapısal denklem grubu ile de temsil edilebilir. Gözlenen değişkenlerle yapılan yol modeline ait eşitlik aşağıda gösterilmektedir (23).

Tablo 2. Yol analizi diyagramında kullanılan semboller ve karşılıkları (17)

Sembol	Karşılığı
Y	Gözlenen içsel değişkenlerin p x 1 boyutlu vektörü
x	Gözlenen dışsal değişkenlerin q x 1 boyutlu vektörü
a	p x 1 boyutlu yapısal kesişimler vektörünü
B	p x p boyutlu içsel değişkenler arası katsayı matrisini,
Γ	p x q boyutlu dışsal değişkenlerle ilgili içsel değişkenler katsayı matrisini
ζ	p x 1 boyutlu hata vektörünü simgelemektedir

$$\eta = \gamma\xi + \zeta$$

$$x_1 = \lambda_1\xi + \delta_1$$


$$x_2 = \lambda_2\xi + \delta_2$$

$$Y_1 = \lambda_3\eta + \varepsilon_1$$

$$Y_2 = \lambda_4\eta + \varepsilon_2$$

δ_1 , δ_2 , ξ , ε_1 , ε_2 hata terimlerini tanımlamaktadır. γ_1 , gizil değişkenler arasındaki yol katsayısını göstermektedir.

δ_1 ve δ_2 arasında ya da ξ ve ε_1 arasında bir oto korelasyonun bulunmaması, bu değişkenler arasındaki kovaryansın sıfır olduğunu gösterir (24).



Şekil 1. Eşitlikleriyle gösterilen gizil değişken modeline ait yol diyagramı

Doğrulayıcı faktör analizi:

Doğrulayıcı faktör analizinin tanımını yapabilmek için önce faktör analizi kavramını tanımlamak gerekir.

Faktör analizinin altında yatan temel fikir, değişkenlerin bazılarının doğrudan gözlenebildiği ancak tüm değişkenlerin doğrudan gözlenemediğidir. Bu gözlemlenmemiş değişkenlere gizil değişkenler veya faktörler denir. Gizil değişkenler hakkında bilgi, gözlemlenen değişkenler üzerindeki etkilerini gözlemleyerek elde edilebilir. Faktör analizi, daha az miktarda gizil değişken oluşturmaya çalışan bir dizi gözlemlenmiş değişken arasındaki eş değişkenliği incelemektedir.

Faktör analizi teknikleri bazen değişkenler setinin faktörü (yapıyı) tanımladığını doğrulamak için bazen de hangi değişkenlerin faktörle ilişkili olduğunu açıklamak için kullanılmaktadır. Açıklayıcı faktör analizinde (AFA- Exploratory Factor Analysis (EFA)) veri setiyle uyumlu en iyi modeli bulmak için birçok alternatif model test edilmektedir. Doğrulayıcı faktör analizinde (DFA- Confirmatory Factor Analysis (CFA)) ise kuramsal faktör modelinin istatistiksel anlamlılığı, yani örneklem verisinin modeli doğrulayıp doğrulamadığı test edilmektedir. Bu aşamalar birlikte analiz edilebileceği gibi, AFA ve DFA olmak üzere iki farklı yöntem olarak da gerçekleştirilmektedir (2,25).

Açıklayıcı faktör analizindeki en büyük sorunlardan biri, önemli ölçüde anlamlı kısıtlamaları içermemesidir. Bunun nedeni, tahminleri çözmek için cebirsel matematiksel çözümün önemsiz olmaması, bunun yerine birinin başka çözümler araması gerektiğidir. Bu

problem kısmen, yinelemeli bir algoritmaya dayanan doğrulayıcı faktör modelinin geliştirilmesiyle çözülmüştür (26).

Doğrulayıcı Faktör Analizi (DFA), Açıklayıcı Faktör Analizinin (AFA) doğal bir uzantısıdır. DFA, gizil ve gözlenen değişkenler arasındaki ilişkilerin ölçüm modelleriyle ilgilenen YEM 'in bir parçasıdır. AFA'nın amacı değişkenler kümesinin altında yatan ve sayısı bilinmeyen faktörden oluşan yapıyı keşfetmeye yöneliktir. Ön varsayım, herhangi bir değişkenin herhangi bir faktörle bağlantılı olabileceğidir. Doğrulayıcı faktör analizinin amacı ise bilinen sayıda faktörün oluşturduğu yapının anlamlılığını istatistiksel olarak test etmektir. Başka bir ifadeyle DFA örneklem verilerinin önerilen modeli doğrulayıp doğrulamadığını kontrol etmek için kullanılır(17).

DFA'da analiz süreci, AFA gibi gözlenen değişkenlerin bir setiyle başlar ve faktörler altında daha küçük bir sayı kullanılarak değişkenler arasındaki ilişkiyi açıklamaya çalışır. AFA'da geleneksel olarak analizde yer alan tüm değişkenler tamamen standartlaştırılırlar. Bir korelasyon matrisi AFA'da giriş için kullanılır ve gizil faktörler ve göstergelerin her ikisi de tamamen standartlaştırılır, faktör varyansları bire eşittir, faktör yükleri standartlaştırılmış regresyon katsayıları veya korelasyonlar gibi yorumlanırlar. DFA'da tamamen standartlaştırılmış çözümlerin süreci olmasına rağmen, analizin çoğunda gizil veya gözlenen değişkenler standartlaştırılmazlar. Korelasyon matrisinin yerine (bir korelasyon matrisi tamamen standartlaştırılmış varyans-kovaryans matrisidir) DFA'da genel olarak varyans kovaryans matrisi veya ham veri kullanılmaktadır (27).

DFA'da girdi matrisi köşegendeki göstergeler varyanslarından ve köşegen dışındaki göstergeler kovaryanslarından oluşmaktadır (28).

YAPISAL EŞİTLİK MODELİ

Yapısal eşitlik modellemesi, çok değişkenli veri setindeki değişkenler arası ilişkileri incelemek için kullanılan, değişkenlerin sebep-sonuç ilişkisini açıklayabilen ve kuramsal modellerin bir bütün olarak test edilmesine olanak veren etkili bir model test etme ve geliştirme yöntemidir.


Modeller, araştırılan çeşitli gizil değişkenler arasındaki açıklayıcı ilişkiler hakkındaki teorileri test etmek amacıyla kullanılmaktadır (13). DFA ile aralarındaki temel fark, gizil değişkenlerin kendi aralarında çift yönlü ilişki yerine, yol analizi (gizli regresyon) etkilerine sahip olmalarıdır (29).Yapısal eşitlik modellemesi, ölçüm modeli ve yapısal model olmak üzere iki bölümden oluşmaktadır (15,17).

Ölçüm Modeli

Ölçüm modeli, gizil değişkenlerin gözlenen değişkenler tarafından nasıl tanımlandığını göstermekte ve gözlenen değişkenlerin ölçüm özelliklerini güvenilirlik ve geçerlik açısından tanımlamaktadır. Diğer bir ifade ile gözlenen ve gizil değişkenler arasındaki bağlantıları gösteren yapısal eşitlikler kümesi ölçüm modelidir (30).

Yapısal Model

Gizil değişkenler arasındaki ilişkileri özetleyen yapısal eşitlikleri içeren bölüm yapısal model olarak tanımlanmakta olup, gizil değişkenler arasında nedensel (dolaylı ve dolaysız) ilişkileri belirler, nedensel etkileri tanımlar ve açıklanan varyansı gösterir. (2,6-8).




Şekil 2. Yol analizi diyagramı yapısal eşitlik model gösterimi

YAPISAL EŞİTLİK MODELİ AŞAMALARI

Yapısal eşitlik modellemesinin kurulmasında amaç, veriye en iyi uyan modeli bulmaktır. Bu modeli belirlemek için yapısal eşitlik modellemesinde beş temel adım söz konusudur (2,15).

1. Model belirleme (Specification)
2. Model tanımlama (Identification)
3. Model tahmini (Estimation)
4. Model testi (Testing)
5. Model modifikasyonu (Modification)



Şekil 3. Yapısal eşitlik modeli temel aşamaları akış diyagramı (8)

Model Belirleme

Model belirleme aşaması genel olarak uygun teorik araştırmaları, bilgileri ve geliştirilen teorik modelleri içermektedir (31). Model belirleme, çalışılacak olan sözel hipotezin yol diyagramları ile teorik temellere göre tanımlama aşamasıdır. Modeli belirlemede varyans-kovaryans verileri kullanılarak karar verilir. Uygun bilgileri kullanabilmek için teorik modelin hangi değişkenleri içerdiği hangi değişkenlerin modelde yer almaması gerektiğini ve hangi değişkenlerin nasıl ilişkili olduğunu bilmek gereklidir. Gizil değişkenlerin hangi değişkenlerle ilişkili olup olmadığına ve ilişki varsa bu ilişkinin ne kadar olduğuna karar verilmelidir. Model belirlemede araştırmacı model içindeki tüm ilişki ve parametrelerle ilgilenir (31). Araştırmacı daha önceki çalışmaları ve teorik bilgileri dikkate alarak mantıklı açıklamalar yapıp modeli belirlemelidir (2).

YEM yaklaşımında model belirleme aşaması, tahmin yapabilmek için merkezi bir öneme sahiptir. En temel düzeyde, bir modelin değişkenler arasındaki ilişkiler hakkında istatistiksel

bir ifade olduđu ve modelin farklı analitik yaklaşımlar bağlamında farklı biçimler alabildiği söylenebilir. Model belirleme de bu analitik yaklaşımların şekil üzerinde ifade edilmesi olarak açıklanabilmektedir. Sıfır sıralı korelasyon bağlamında, iki deęişken arasında bulunan yönsüz ilişkiyi içeren tek model belirlenebilmektedir (10).

Model belirlenmesindeki amaç, deęişkenlerin kovaryans yapısına en uygun modeli bulmaktır. Eđer doğru model test edilen teorik modelle tutarlı deęilse, teorik model yanlış belirlenmiş demektir. Bu nedenle, araştırmacının amacı, örnek kovaryans matrisini oluşturan olası en iyi modeli belirlemektir. Örnek kovaryans matrisi, altta yatan fakat henüz bilinmeyen bir teorik model veya yapıyı (kovaryans yapısı olarak da bilinir) ima eder ve araştırmacının amacı, bu kovaryans yapısına en çok uyan modeli bulmaktır (2). Doğru modelle test edilecek teorik model arasındaki fark, herhangi bir parametrenin ya da deęişkenin modelden çıkartılması ve/veya modele dahil edilmesinden kaynaklanır. Örneğin, önemli bir parametre ve/veya deęişken modelden çıkartılabilir. Benzer şekilde, önemsiz bir parametre ve/veya deęişken modele dâhil edilebilir. Bu gibi durumlar, test edilecek modelin yanlış belirlenmesine sebep olmaktadır. Modelin yanlış belirlenmesi, parametre tahminlerinin yanlış olmasına sebep olmaktadır (2). Cooley (1978) bunun yapısal eşitlik modellemesinin en zor kısmı olduğunu belirtmiştir.

Model Tanımlama

Model tanımlaması, model parametrelerinin örneklem kovaryans matrisinden türetilip türetilmeyeceğini kontrol etmeyi içermektedir.

Yapısal eşitlik modellemesinde, araştırmacıların parametrelerin tahmininden önce tanımlama problemini çözmeleri çok önemlidir. Tanımlama probleminde “S örnek kovaryans matrisinde yer alan örnek verilere ve Σ popülasyon kovaryans matrisinin ima ettiği teorik model temelinde, benzersiz bir parametre tahmin seti bulunabilir mi?” sorusuna yanıt aranmaktadır. Model tanımlamasındaki amaç, örneklem kovaryans matrisi ve uygulanan teorik modele ilişkin toplum kovaryans matrisinin (Σ) parametre tahmininde tek olup olmadığının belirlenmesidir (2). Model tanımlama, teknik olmayan terimleri açıklamanın zor olduğu karmaşık bir konu olarak nitelendirilmektedir. Tanım konusu, veri ile tutarlı parametrelerin tek bir küme olup olmadığına odaklanmaktadır. Bu soru, çalışma kapsamında modelin yapısal parametreleri içindeki gözlenen deęişkenlerin, varyans-kovaryans matrisinin tersini doğrudan taşımaktadır. Yapısal parametrelerin deęerlerinin tek bir çözümünün bulunması durumunda, model tanımlama kabul edilmektedir. Bunun bir sonucu olarak, parametrelerin tahmin edilebilirliği kabul edilmekte ve bu nedenle model test edilebilmektedir. Verilerin birden fazla ima edilen teorik modele eşit derecede uyması, benzersiz tahminlerini elde etmek için modelde ve

verilerde yeterli kısıtlama olmaması bir sorundur. Bu nedenle, bu sorunu çözmek istiyorsak, bazı kısıtlamalar getirmemiz gerekir (2). Öte yandan bir modelin tanımlanamaması, parametrelerin keyfiliğe tabi olduğunu göstermektedir. Böylece farklı parametre değerlerinin aynı modeli tanımladığı anlaşılmaktadır. Bu durumda tüm parametreler için tutarlı tahminlere ulaşmak mümkün olmamakta ve bu nedenle model ampirik olarak değerlendirilememektedir (14).

Bir modeldeki her potansiyel parametre, serbest bir parametre, sabit bir parametre veya sınırlı bir parametre olarak belirtilmelidir. Serbest parametre, bilinmeyen ve bu nedenle tahmin edilmesi gereken bir parametredir. Sabit bir parametre, serbest olmayan, ancak tipik olarak 0 veya 1 olan belirli bir değere sabitlenmiş bir parametredir. Sınırlandırılmış bir parametre, bilinmeyen ancak bir veya daha fazla başka parametreye eşit olmak üzere sınırlandırılmış bir parametredir. Model tanımlaması, parametrelerin sabit, serbest veya kısıtlı olarak atanmasına bağlıdır. Model ve parametre özellikleri belirtildikten sonra, parametreler gizil varyans-kovaryans matrisi oluşturmak için birleştirilir. Bununla birlikte, sorun hala aynı Σ 'yı oluşturabilen birkaç parametre değerinin olmasıyla mevcuttur. İki veya daha fazla parametre değeri kümesi aynı üretiyorsa, eşdeğerdirler, yani eşdeğer modellerdir (32,34). Bir parametre tüm eşdeğer setlerde aynı değere sahipse, parametre tanımlanır. Eğer bir modelin tüm parametreleri varsa tanımlanır, ardından tüm model tanımlanır. Eğer biri veya birkaç parametre tanımlanmazsa, ardından tüm model tanımlanamaz. Geleneksel olarak, üç seviye model tanımlaması vardır. Bunlar, model parametrelerini benzersiz bir şekilde tahmin etmek için gerekli olan örnek varyans-kovaryans matrisindeki bilgi miktarına bağlıdır.

Üç model tanımlama seviyesi aşağıdaki gibidir:

Az tanımlanmış (under identified) model:

Az tanımlanmış model, S matrisinde yeterli bilgi olmadığı durumda bir veya daha fazla parametrenin yansız belirlenemediği bir model tanımlama türüdür. Bir başka ifade ile tahmin edilen parametre sayısının varyans ve kovaryans sayısından fazla olduğu durumda model yansız parametre tahminlerinin çözümü için bilgi yetersizliğini ifade etmektedir (2).

Tam tanımlanmış (just- identified) model:

Tam tanımlanmış model, sadece S matrisinde yeterli bilgi varsa tüm parametrelerin benzersiz bir şekilde belirlenmesi durumunda tanımlanır. Parametrelerin tümü yansız olarak saptanmış ise, S matrisindeki bilginin tam olarak yeterli olduğu durumu ifade etmektedir. Diğer bir ifadeyle, veri ve yapısal parametreler arasında birebir uygunluğun var olduğu durumdur. Veri, varyans ve kovaryans sayıları tahmin edilen parametrelerin sayısına eşittir. Ancak, tüm

parametreler için tek bir çözüm elde etmek mümkün değildir. Bunun nedeni serbestlik derecelerinin olmaması nedeniyle hiçbir zaman reddedilemeye bilmektedir (2).

Aşırı tanımlanmış (over-identified) model:

Aşırı tanımlanmış modelde, S matrisindeki bilgi gereğinden fazla olduğunda bir ya da birden fazla parametrenin tahmini için birden fazla yol olduğu durumdur. Tahmin edilen parametre sayısının varyans ve kovaryans sayısından daha az olduğundaki durumu ifade etmektedir. Bu durum, modelin reddi için olanak sağlayan pozitif serbestlik derecesi ile sonuçlanmakta ve böylece bilimsel kullanımı oluşturmaktadır (2).

Bir model tam veya çok fazla tanımlanmışsa, model tanımlanmıştır. Eğer bir model az tanımlanmamışsa, parametre tahminlerine güvenilmemelidir, yani model için serbestlik dereceleri negatiftir. Ancak, böyle bir model, ek kısıtlamalar getirilmesi durumunda tanımlanabilir, yani, serbestlik dereceleri 0'a eşit veya 0'dan büyüktür (pozitif değer). Bir modelin belirlenmesi için çeşitli koşullar vardır (2). Bu koşullardan biri, tanımlama için yeterli tek şart tahmin edilebilecek serbest parametre sayısıdır. İkinci koşul S matrisindeki farklı değerlerin sayısından küçük veya ona eşit olması gerektiği yalnızca köşegen varyans ve bir devre dışı kovaryans kümesidir. Örneğin, $S_{12} = S_{21}$ matrisin diyagonal köşesinde olduğundan, bu kovaryans terimlerinden sadece biri sayılır. S matrisindeki farklı değerlerin sayısı, $p(p + 1) / 2$ 'ye eşittir, burada p, gözlenen değişkenlerin sayısıdır.

Model tanımlamada izlenecek adımlar:

Modelin faktörü boyutu dikkate alınmadan ya gösterge işaretleri belirlenerek ya da faktör varyansları sabitlenerek ölçeklenmiş olmalıdır.

Gerekli ancak tek başına yeterli olmayan tanımlama koşulu;

Bağımsız kovaryans denklemlerinin sayısı ile bağımsız parametrelerin sayısı arasında bir ilişki olduğu için gerekli koşulların test edilmesi kolaydır. Kovaryans denklemi

$$\Sigma = \Lambda\Phi\Lambda' + \Theta,$$

$q(q + 1) / 2$ bağımsız denklemleri ve s, Φ ve Θ cinsinden $qs + s(s + 1) / 2 + q(q + 1) / 2$ bağımsız parametrelerini içerir. Modelin bağımsız, kısıtlanmamış parametrelerinin sayısı, $q(q + 1) / 2$ 'ye eşit veya daha az olmalıdır.

Gözlenen değişkenlerin sayısı q olduğunda, S örnek kovaryans matrisindeki farklı değerler $q(q+1) / 2$ 'ye eşit olmaktadır. Model tanımını için gerekli koşulu kontrol etmek için modeldeki bağımsız parametrelerin sayısı, S örnek kovaryans matrisindeki elemanların sayısından çıkarılmaktadır (2,11).

Basit modeller dışında, yapısal eşitlik modelinde tanımlama problemine çözüm her zaman kolay değildir. Model karmaşıklıkça modeldeki parametrelerin tanımlı oldukları bilinen varyans, kovaryans ve diğer parametreler cinsinden yazılmasına çalışılarak tanımlılığın ispatlanmasında hataların yapılması olasılığı artmaktadır. $\Sigma=\Sigma(\theta)$ eşitliği modelin tanımlı olmasını açıklamasına rağmen, modelin karmaşıklığı arttığında ise uygulanabilirliği azalmaktadır (7). Bu noktada tanımlamanın, gözlenen değişkenlerin dağılımına ilişki bilgiden hareketle yapılması da olasıdır. Eğer değişkenler çok değişkenli normal dağılıma sahip ise o zaman gözlenen değişkenlerin dağılımını karakterize eden parametreler ana kütle kovaryans matrisi ve ana kütle ortalaması konumundadır. Bunlar bir dağılımın birinci ve ikinci momentleridir. Ana kütle kovaryans matrisi tanımlanan bilginin kaynağını oluşturmaktadır. Bu nedenle, yapısal eşitlik modellemesi analizinde model tanımlaması için farklı kurallar bulunmaktadır (7,15,25-31).

- t – kuralı
- İki adım kuralı
- Çoklu göstergeler çoklu nedenler kuralı (Multiple Indicators Multiple Causes – MIMIC)

t-kuralı:

Model tanımlamasının gerekli ama yeterli olmayan ve en kolay kuralıdır. t kuralı, gözlenen değişkenlerin kovaryans matrisindeki artıksız (nonredundant) elemanların sayısının, θ 'daki bilinmeyen parametrelerin sayısına eşit veya daha büyük olmasıdır.

$$t \leq \frac{1}{2}(p + q)(p + q + 1)$$

Burada (p+q) gözlenen değişkenlerin t ise θ 'daki serbest parametrelerin sayısını göstermektedir. t-kuralı, modelin eksik tanımlı olduğunu daha çabuk ortaya çıkardığı için oldukça kullanışlıdır fakat bu kural modelin tanımlı olmasını garanti etmemektedir. Bu nedenle farklı kurallar geliştirilmiştir (7).

İki adım kuralı:

İki adım kuralı tanımlanma için yeterli bir şarttır. İki aşamadan oluşan modelin ilk kısmında model DFA modeli gibi ele alınır ve eğer tanımlı olduğuna karar verilirse ikinci adıma geçilir. İkinci adımda ise gizil değişken modeli incelenir. Her bir gizil değişken hatasız ölçülmüş bir gözlenen değişken gibi ele alınır. İki adımdan da tanımlı sonucu çıkarsa modelin tanımlı olduğu söylenir (7).

Çoklu göstergeler çoklu nedenler kuralı (MIMIC) kuralı:

YEM'in en çok uygulama alanı bulan özel durumlarından biri Çoklu Gösterge Çoklu Nedensellik (MIMIC) Modelleridir. MIMIC modeller tek bir gizil değişkenin çoklu göstergesi ve çoklu nedenselliği olan gösterge değişkenleri

$$\eta = B\eta + \Gamma\xi + \zeta$$

$$y = \Lambda_y \eta + \varepsilon$$

$$x = \xi$$

şeklinde gösterilir. MIMIC modellerde tanımlanma koşulu p , y değişkenlerinin sayısını göstermek üzere $p \geq 2$ ve q , x değişkenlerinin sayısını göstermek üzere $q \geq 1$ eşitsizliklerinin sağlanmasıdır. Bu durum tanımlama için gerekli olmayan ancak yeterli bir koşuldur. Böyle olduğunda model tanımlıdır denir (7).

Yapısal Eşitlik Modeli Tahmini

YEM sürecinde tanımlanmadan sonra gelen aşama modelin tahminidir. Modelden elde edilecek sonuçların güvenilirliği açısından, bu aşamada seçilecek yöntemin doğruluğu ve başarısı son derece önemlidir. Tahminin başarısı için ilk şart parametrelerin tanımlanmış olmasıdır. Model parametreleri tanımlanmış ve gözlenen kovaryans matrisi verilmişse, model parametreleri uygun tahmin yöntemi seçilerek tahmin edilebilir.

YEM'de test edilmesi gereken temel hipotez modelin veriye uyumlu olduğunu gösteren; gözlenen kovaryans matrisinin tahmini kovaryans matrisine eşitliğinin sınanmasıdır.

$$H_0 = \Sigma = \Sigma(\theta)$$

$$H_1 = \Sigma \neq \Sigma(\theta)$$

Tahmin sürecinde amaç, modelden elde edilen kovaryans matrisi ($\Sigma(\theta)$) ile örneklem kovaryans matrisi arasındaki farkı minimum yapan fark (uyum) fonksiyonunu bulmaktır. Modeldeki değişkenlerin farklı dağılımsal varsayımlarına göre farklı tahmin yöntemleri, farklı uyum fonksiyonları bulunmaktadır (13).

Aslında, YEM yazılım programları yardımıyla veriye model uydurma süreci, $\Sigma(\theta)$ matrisindeki parametrelerin, S örneklem kovaryans matrisindeki parametrelere en yakın olana kadar devam eden yakınsama süreci olarak düşünülebilir (13). Eşitlikte verilen sıfır hipotezinde θ , $(q \times 1)$ boyutlu model parametre vektörü olmak üzere, YEM'de model doğru ve parametreler biliniyor ise Σ , $\Sigma(\theta)$ 'ya eşit olacaktır. Ancak pratikte kitle parametreleri genellikle bilinmez, bu nedenle θ parametreler vektörü, örneklem kovaryans matrisi S kullanılarak tahmin edilir. Burada S, $(p \times p)$ boyutlu ve Σ kitle kovaryans matrisinin yansız bir tahmincisidir.

Modele ilişkin parametreler bilinmeyip tahmin edilmeleri gerektiğinden denklemde θ yerine $\hat{\theta}$ ikame edileceğinden öne sürülen kovaryans matrisi $\Sigma(\theta)$ yerine $\hat{\Sigma}(\hat{\theta})$ kullanılmaktadır ($\hat{\Sigma}(\hat{\theta}) = \hat{\Sigma}$) (15). Parametre tahminleri için, örneklem kovaryans matrisi S ile modele ilişkin tahmini kovaryans matrisi $\hat{\Sigma}$ arasındaki (S- $\hat{\Sigma}$) farkın en küçüklenmesini sağlayacak bir fonksiyon gereklidir (2).

Karşılaştırma Σ ve S arasındaki farkları minimize eden belirli bir uyum fonksiyonunun kullanımını gerektirmektedir. Bu fonksiyon, Σ ve S arasındaki uyumu gösteren uygunluk fonksiyonu olarak bilinmekte ve $F=F[S,\Sigma(\theta)]$ olarak gösterilmektedir. $F[S,\Sigma(\theta)]\geq 0$ fonksiyonu sürekli ve nicel olmalıdır. $\theta =\hat{\theta}$ 'daki minimize edilmiş uyum fonksiyonu, $\hat{\Sigma}$ 'göre S'nin uyumunun yakınlığının bir ölçüsü olan $F(S,\hat{\Sigma})$ gibi gösterilen ($\hat{\Sigma}(\hat{\theta}) = \hat{\Sigma}$)'deki uyum fonksiyonunun değeridir. S= $\hat{\Sigma}$ için, uyum fonksiyonu sıfır olarak tanımlanır. Bu nedenle S- $\hat{\Sigma}$ yaklaşık olarak sıfır olmalıdır (17).

Yapısal eşitlik modellemesinde en yaygın kullanılan parametre tahmin teknikleri aşağıda verilmiştir (7,13,35-36).

1. Maksimum Olabilirlik- En Çok Olabilirlik (Maximum Likelihood-ML)
2. Ağırlıklandırılmamış En Küçük Kareler (Unweighted Least Squares- Ordinary Least Squares-ULS-OLS)
3. Genelleştirilmiş En Küçük Kareler (Generalized Least Squares- GLS)
4. Asimptotik Olarak Dağılımdan Bağımsız Yöntem (Asymptotically Distribution Free Method-Weighted Least Squares-ADF-WLS)
5. Diyagonal Ağırlıklandırılmış En Küçük Kareler Yöntemi (Diagonally Weighted Least Squares- DWLS)

Ağırlıklandırılmamış en küçük kareler (ULS) tahminleri tutarlıdır, dağılım ve istatistiksel testlerle ilgi varsayımları yoktur ve ölçüğe bağımlıdır. S ile $\hat{\Sigma}$ arasındaki farkın karelerinin toplamının en küçüklenmesine dayanan bir yöntem olup, istatistiksel testler için dağılım varsayımı gerektirmez ancak ölçekten bağımsız olmadığı için benzer ya da aynı ölçükle ölçülmüş veriler için kullanılması önerilir. Genelleştirilmiş en küçük kareler (GLS) ve maksimum olabilirlik (ML) tahmin yöntemleri için gözlenen verinin normal dağılıma uygunluğu aranmaktadır ve ölçekten bağımsız olup, asimptotik yöntemlerdir. Hem genelleştirilmiş en küçük kareler (GLS) hem de maksimum olabilirlik (ML) tahmin yöntemlerinin asimptotik özelliklere sahip olması tercih edilmektedir. Bir başka ifadeyle; geniş

örneklem büyüklüğü, minimum varyans ve yansızlık gibi özelliklere sahip olmaları istenmektedir. Ağırlıklandırılmamış en küçük kareler (ULS) tahmin yöntemi, genellikle büyük örnek boyutu gerektirmekte ve bunun bir sonucu olarak normallik varsayımına bağlı olmayan, asimptotik dağılımdan bağımsız (WLS) tahminci olarak kabul edilmektedir (2). Normallik varsayımının sağlanamadığı durumlarda ise eliptik dağılım teorisine (elliptical distribution theory) dayalı tahmin yöntemleri ile rastgele dağılım fonksiyonu (arbitrary distribution function-WLS) olarak bilinen bir diğer yöntem kullanılmaktadır (8). Benzer şekilde normallik varsayımı gerektirmeyen bir diğer yöntem Satorra-Bentler Dayanıklı EÇO (Robust ML) yöntemidir (13). Bu yöntem gibi pek çok başka dayanıklı tahminci ve varsayımlardan sapmalar durumunda kullanılan pek çok başka tahmin yöntemi mevcuttur.

Maksimum olabilirlik- En çok olabilirlik (Maximum Likelihood - ML):

En Çok Olabilirlik (ML) yöntemi YEM'de kullanılan en yaygın tahmin tekniğidir. Anakütle kovaryans matrisinin Σ , gözlenen kovaryans matrisinin S olarak temsil edildiği tahmin süreci, böylece istatistiksel model tarafından belirtilen kovaryans matrisi ile gözlenen kovaryans matrisinin karşılaştırmasını içermektedir. En çok olabilirlik tahmin süreci, normal örnekleme hatalarından kaynaklanan S ve $\hat{\Sigma}$ arasındaki farklılıkların maksimize edilmiş olasılığının bir kümesini bulana kadar parametre değerlerinin tahminlerini kademeli olarak artırmak suretiyle yinelemeli olarak işlemektedir. Bunu gerçekleştirmek ile S ve $\hat{\Sigma}$ arasındaki sapmaları en aza indiren bir model-uyum prosedürü sağlanmaktadır. YEM modellerinin en çok olabilirlik yöntemi ile tahmininde yaygın olarak kullanılan uyum fonksiyonu, olabilirlik oranının logaritmasına dayanmaktadır. Bu uyum fonksiyonu aşağıdaki şekilde ifade edilmektedir (37). Bu yöntemde en küçüklenmesi istenilen uyum fonksiyonu,

$$F_{ML} = \log|\hat{\Sigma}(\theta)| + tr \left(S\hat{\Sigma}^{-1}(\theta) \right) - \log|S| - (p + q)$$

şeklinde olup p içsel gizil değişkenlerin göstergelerini, q dışsal gizil değişkenlerin göstergelerini ve tr bir matris izini, $\hat{\Sigma}$ tahmin modeli gözlenen değişkenleri varyans-kovaryans matrisini, S gözlenen değişkenlerin örneklem kovaryans matrisini ifade etmektedir (35). Birinci ve üçüncü terimler ile ikinci ve dördüncü terimler birbirini yok ettiğinde F_{ML} için beklenen değer sıfır olmaktadır. Bu durumda, model ve veri mükemmel uyum sağlamaktadır. S ve $\Sigma(\theta)$ matrislerinin pozitif tanımlı (tekil olmayan) matrislerdir. F_{ML} uyum fonksiyonun bazı varsayımları vardır. Bunlar, çok değişkenli normal dağılıma uygunluk göstermesi varsayımı, diğeri ise örneklem kovaryans matrisi S 'nin Wishart dağılımına uygunluk göstermesi varsayımıdır. En çok olabilirlik tahmin edicileri F_{ML} asimptotik olarak yansızlık gibi özelliklere

sahiptirler, ölçekleri değişmez ve yapı katsayılarının en iyi tahminini sağlamaktadırlar. En çok olabilirlik kestiriminin birçok özelliği yapısal eşitlik sürecinde temel bir rol oynamaktadır (37).

Gözlenen değişkenlerin çok değişkenli normal dağılım varsayımı altında en çok olabilirlik tahmincilerinin asimptotik, tarafsız, tutarlı ve etkili olması ya da büyük bir örneklem olması istenmektedir. Çok değişkenli normal dağılımında en ufak sapmalarda asimptotik standart hatalar ve ki-kare test istatistiğinde problemlere yol açmaktadır. Tüm varsayımlar sağlandığı ve model doğru belirlendiğinde büyük örneklem için ML tahmincileri asimptotik, tarafsız, tutarlı ve etkin olarak tam bir bilgi sağlamaktadır (8,26-38).

Ağırlıklandırılmamış en küçük kareler (Unweighted least squares- Ordinary least squares-ULS-OLS):

Bu tahmin yönteminin temel avantajı normal varsayımı gerektirmemesi ve tahmin denklemlerinin çözümünün kolay olmasıdır. Ancak burada da diğer tüm tahmin tekniklerinde olduğu gibi θ 'nın tanımlı olması varsayımı mevcuttur.

Bu parametre tahmin yöntemi örneklem kovaryans matrisinden modelden elde edilen kovaryans matrisinin ($\Sigma(\theta)$) çıkarılmasından elde edilen artık matrisinin ($S-\Sigma(\theta)$) karelerinin toplamının minimize edilmesine dayanmakta olup fark fonksiyonu aşağıda verilmiştir (7,35).

$$F_{ULS} = \frac{1}{2} tr[(S - \Sigma(\theta))^2]$$

şeklinde olup, tr matrisin izi, S gözlenen kovaryans matrisi, $\Sigma(\theta)$ modele ilişkin tahmini kovaryans matrisi ve parametre vektörüdür. Bu yöntemde ($S-\Sigma(\theta)$) kalıntı matrisi örneklem kovaryans matrisi ile modele ilişkin tahmin matrisi arasındaki farktan oluşmaktadır.

Bu tahmin yönteminin temel avantajı normal varsayımı gerektirmemesi ve tahmin denklemlerinin çözümünün kolay olmasıdır. Bu yöntemin temel dezavantajı ise veri seti çok değişkenli normal dağılıma sahip olmadığında ve kovaryans matrisi analiz sürecinde kullanılmadığında model uyumu ile ilgili olasılıksal çıkarsamaların yetersiz olmasıdır (35). Analiz sırasında kovaryans matrisi yerine korelasyon matrisi kullanılırsa F_{ULS} değerleri değişir. Daha genel bir biçimde ölçek değiştiği zaman sonuçlar da değişmektedir (7). Ölçek değişmezlik ve ölçek bağımsızlık özelliklerine sahip olmamasıdır.

Ağırlıklandırılmamış en küçük kareler yöntemi, genellikle analizde kullanılan değişkenler aynı ölçü birimiyle ölçüldüğü zaman kullanılır (13). Veri setinde, basık dağılımlı değişkenler olduğunda ULS kestiricisiyle ki-kare uyum testi, parametre tahminleri ve standart hataların asimptotik olarak yansız tahminleri elde edilebilmektedir. Bu nedenle çok değişkenli normal varsayımının sağlanamaması durumunda, ULS kestiricisi, ML ve GLS kestiricilerine göre teorik açıdan birçok avantaja sahiptir (39).

Genelleştirilmiş en küçük kareler (Generalized Least Squares - GLS):

Genelleştirilmiş En Küçük Kareler (GLS) tahmincisi ilk olarak Aitken (1934,1935) tarafından geliştirilmiş ve daha sonra Jöreskog ve Goldberger (1972) tarafından YEM için uyarlanmıştır (23).

GLS yönteminde, varyans ve kovaryanslara göre artıklar matrisinin elemanlarını varyansı ve kovaryansına göre ağırlıklandırılır; bu nedenle regresyon analizinde otokorelasyon ve eşit olmayan varyanslılık durumunda GLS kullanılabilir (33). Çok değişkenli normallik varsayımı ile değişkenlerin sürekli olması varsayımı bulunmaktadır (14). GLS, ULS yönteminin kullanılabilmesi için gerekli bazı varsayımların sağlanmadığı durumlarda tercih edilen bir yöntemdir.

ULS yönteminde kalıntılara ilişkin ortalamanın sıfır ve artıkların her değişken için sabit varyanslı olduğu varsayılır. Aynı zamanda artıkların birbirinden bağımsız olması gerekmektedir. Bu varsayımların YEM’de her zaman sağlanması mümkün olmamaktadır. Söz konusu varsayımların sağlanmaması durumunda EKK tahmincisinin kullanılması sonuçların güvenilirliği açısından hatalı olacağından bu durumda artıklara ilişkin varsayımlar gerektirmeyen GLS tahmincisini kullanmak uygun olacaktır. ML ve GLS yöntemleri; ULS yönteminden farklı olarak ölçekte sabit ve bağımsızdır (25).GLS tahmincisinde uyum fonksiyonu,

$$F_{GLS} = \left(\frac{1}{2}\right) tr\{(S - \Sigma)V\}^2$$

biçimindedir. Burada tr matrisin izi, S gözlenen kovaryans matrisi, $\Sigma(\theta)$ modele ilişkin tahmini kovaryans matrisi, θ parametre vektörü ve W^{-1} artıkların $p \times p$ boyutlu ağırlık matrisidir. Bu yöntemin genelleştirilmiş olarak adlandırılmasının nedeni eşit olmayan varyanslara karşı standardize edebilmek amacıyla verinin ağırlıklandırılmasıdır.

Asimptotik olarak dağılımdan bağımsız yöntem (Weighted Least Squares - WLS):

YEM’de çok değişkenli normal dağılım varsayımının ihlali söz konusu olduğunda Browne (1974, 1977, 1984) tarafından geliştirilen bu yöntem genelleştirilmiş en küçük kareler tahmin yöntemine dayanmaktadır. Bu tahmin yöntemi, çok değişkenli normal dağılım varsayımını gerektirmemektedir. Asimptotik dağılım fonksiyonu (WLS), çarpıklık ve basıklığın söz konusu olduğu verilere de uygulanabilmektedir (8).

Bentler ve Dudgeon, Hu ve arkadaşları ve birçok araştırmacı, WLS tahminlerinin istenilen asimptotik özelliklere sahip olabilmesi için büyük örneklem hacimleriyle çalışılması gerektiğini vurgulamışlardır.

Veri setinde, basık dağılımlı değişkenler olduğunda WLS kestiricisiyle ki-kare uyum testi, parametre tahminleri ve standart hataların asimptotik olarak yansız tahminleri elde edilebilmektedir. Bu nedenle çok değişkenli normallik varsayımının sağlanamaması durumunda, WLS kestiricisi, ML ve GLS kestiricilerine göre teorik açıdan birçok avantaja sahiptir (39).

Diyagonal ağırlıklandırılmış en küçük kareler yöntemi (Diagonal Weighted Least Squares - DWLS):

Değişken sayısı çok olduğu zaman asimptotik kovaryans matrislerinin hesaplanması çok zaman alır ve hafızada büyük bir yer kaplar. Değişken sayısı çok olduğunda kullanılan alternatif bir yaklaşım, tahmini katsayıların sadece asimptotik varyanslarını hesaplar. Bu yöntem, kategorik veriler için parametre tahmininde sıklıkla kullanılmaktadır. Diyagonal ağırlıklandırılmış en küçük kareler yöntemi, robust ağırlıklandırılmış en küçük kareler yöntemi (Robust Weighted Least Squares Mean and Variance) (WLSMV) olarak da adlandırılmaktadır. Bu yöntem kategorik verileri içeren YEM’de parametreleri sağlam ve doğru bir biçimde tahmin edebilmek için polikorik korelasyonları kullanmaktadır (31).

$$FDWLS=(\hat{\rho}-\rho(\theta))\hat{W}(\hat{\rho}-\rho(\theta))$$

Yapısal Eşitlik Modellemesinde Model Uygunluğunun Değerlendirilmesinde Kullanılan Uyum İndeksleri / Modelin Testi

Modelin tahmini sonrasında modelin test edilmesi süreci başlamaktadır. Bu aşamada verinin önerilen modele uyumu belirlenir. “Teorik (kurulan) model örneklem verisi ile ne ölçüde uyumlu” sorusuna bu aşamada yanıt aranmaktadır (2). Diğer bir deyişle; örnek veri tarafından desteklenen teorik modelin doğruluk derecesi belirlenmelidir. Ölçülen değişkenler arasında gözlenen kovaryans matrisi ile gizil kovaryans matrisinin ne oranda benzeştiği bu uygunluk derecesini belirlemektedir. Veri-model uyumunun test edilmesi, başka bir deyişle teorik modelin örnek veriler tarafından ne derece desteklendiğinin belirlenmesi işlemi gerçekleştirilmektedir. Uyum ise, bir modelin veriyi yani varyans kovaryans matrisi yeniden üretebilme kabiliyeti olarak adlandırılır (40).

Yapısal eşitlik modellemesinin temel hipotezi gereği, tahmin edilen parametreler yardımıyla üretilen kovaryans matrisinin ($\Sigma(\theta)$) örneklem kovaryans matrisine çok benzer olması istenmekte ve örneklem kovaryans matrisi ile üretilen kovaryans matrisi arasındaki farkın sıfır olması ($S - \Sigma(\theta) = 0$) χ^2 değerinin sıfır çıkmasına neden olmaktadır. Bu durum, modelin verilerle mükemmel bir uyum göstermesi demektir. YEM’de model uyumunun değerlendirilmesi için birçok uyum indeksi bulunmaktadır. Bu uyum indekslerinin çoğu, teorik

olarak önerilen modelin kovaryans matrisi ile örneklem kovaryans matrisinin karşılaştırılmasına dayanmaktadır. Bu iki matrisin birbirine benzememesi, yani matrisler arasındaki farkın çok olması verinin teorik modele uyum sağlamadığını, bu iki matris arasındaki farkın çok az olması ise verinin teorik modelle iyi uyum sağladığını göstermektedir (2,7-8).

Uyum indeksleri:

Bu aşamada öncelikle kestirilen parametreler incelenir. Bir önceki adımda hesaplanan faktör yüklerinin yüksek ve hata varyanslarının düşük olması gerekmektedir (41). Ardından model için hesaplanan uyum indekslerinin incelemesi aşaması gerçekleştirilir. Veriye uyumunun farklı yönlerini, farklı ölçütler temelinde değerlendiren çok sayıda uyum indeksi bulunmaktadır (2,8).

İdeal bir uyum indeksinin aşağıdaki özelliklere sahip olması beklenir.

- Uyum indeksinin almış olduğu değer, uyum derecesini gösterdiğinden bazı indeks değerlerinin 0'a, bazı indeks değerlerinin de 1 değerine yakın olmaları istenir.
- Örneklem hacminden bağımsız olmalıdır.
- Yorumlayabilmek ve güven aralıklarını elde edebilmek için bilinen dağılımsal karakteristiklere sahip olması istenir.

Genel modelin uyum indeksi başlığı altında incelenen uyum indekslerinin sayısı oldukça fazla olup birbirinin yerine kullanılmayan pek çok test ve ölçüt geliştirilmiştir. Neredeyse otuzdan fazla farklı indeks arasından hangisinin en iyi olduğuna dair bir uzlaşma sağlanmamıştır (42). Aynı zamanda söz konusu indekslerin sınıflandırılması açısından da literatürde bir görüş birliği bulunmamaktadır. Widaman (2003)'e göre YEM'deki uyum indekslerini iki grupta incelemek mümkündür. Mutlak uyum indeksleri (Absolute Fit Index) ve Artımsal uyum indeksleri (Incremental Fit Index). Hoyle ve Panter (10) ise mutlak uyum indeksleri, örnek çapına bağlı indeksler ve merkezi olmayan indeksler şeklinde üçlü bir sınıflandırma yapmıştır. YEM'de model uygunluğunun değerlendirmesinde kullanılan bir başka uyum indeksleri sınıflandırılması da; mutlak (absolute), artan (incremental) ve tutumlu (parsimonious) uyum indeksleri olarak üç gruba ayrılır. Bu nedenle en çok kullanılan uyum indeksleri, yukarıdaki sınıflandırma dikkate alınarak verilmiştir. Merkezi olmayan dağılımlarla ilgili indeksler ise ayrı bir başlık altında incelenecektir.

Mutlak uyum indeksleri:

Mutlak uyum indeksleri, örnek verilerle uyumlu olası bir modelin nasıl olacağı ve en iyi uyum sağlayan modelin hangisi olduğunu belirlemektedir. Bu ölçümler, önerilen modelin verilerle ne kadar uyumlu olduğunun en temel göstergesini sağlamaktadır. Artımlı uyum

indekslerinin tersine bu hesaplamalar temel model ile karşılaştırılmasına dayanmamakta, ancak onun yerine model uyumlarının hiçbir modelle karşılaştırmadan en iyi nasıl ölçüleceğini göstermektedir.

Bu kategoriye dahil olanlar Ki kare istatistiği, uygunluk indeksi (Goodness of Fit Index-GFI), düzeltilmiş uygunluk indeksi (Adjusted Goodness of Fit Index-AGFI), hata kareleri ortalamalarının karekökü (Root Mean Square Residual-RMR) ve standardize edilmiş hata kareleri ortalamalarının karekökü (Standardized Root Mean Square Residual-SRMR) indeksleridir (43). Her uyum indeksi önerilen modelin uyumunun başka bir yönünü temsil etmekte ve model uyumu için sınırlı bir bilgi kaynağı oluşturmaktadır. Bu nedenle, bir modeli reddetmek ya da kabul etmek yönünde verilecek kararın her zaman birden fazla uyum indeksine göre olması önerilmektedir (13).

a. Ki kare (χ^2 test istatistiği):

Ki-kare test istatistiği, modelin uyum iyiliğini test eden uyum iyiliği indekslerinden istatistiksel temele dayanan ve uyum iyiliği indekslerinin hesaplanmasında kullanılan uyumun en temel indeks denilebilir. Kavramsal olarak bu uyum iyiliği indeksi gözlenen kovaryans matrisi ve model kovaryans matrisi arasındaki farkın ve örneklem büyüklüğünün bir fonksiyonudur ve aşağıdaki şekilde hesaplanır (13).

$$\chi^2 = (N - 1)F_{min}$$

Ki kare değerinin sıfır değerini alması mükemmel uyumu ya da örneklem kovaryans matrisi ile teorik modele ilişkin kovaryans matrisi ($\Sigma(\theta)$) arasında farkın olmadığını gösterir (2).

Model uyum değerlendirmesi, genellikle bir çıkarımsal uyum iyiliği indeksi bazında, açıklayıcı değerler ya da alternatif göstergelerle gerçekleştirilmektedir. Bir modelin uyum iyiliğini genel uyum değerlendirmesine yönelik bir indeks üzerinde fikir birliği olmasa da en yaygın olarak kullanılan uyum indeksi ki kare istatistiği olmuştur (44).

Ki kare değeri genel model uyumunu değerlendirmek için geleneksel bir ölçü olarak kabul edilmektedir. Yani, H_0 hipotezi, tahmin edilen (beklenen) varyans kovaryans matrisinin örnek (gözlenen) varyans kovaryans matrisinden sapmasını ve bu sapmanın büyüklüğünü değerlendirmektedir (43,44). Kavramsal olarak bu uyum ölçüsü gözlenen kovaryans matrisi ve model kovaryans matrisi arasındaki farkın ve örneklem büyüklüğünün bir fonksiyonudur (15). Bu test en basit anlamıyla örneğe ait kovaryans matrisi ile modele ilişkin tahmini kovaryans matrisi arasındaki uyum değerinin, kullanılan veri sayısı eksi bir ile çarpılmasından elde edilir. Elde edilen sonuç χ^2 dağılımı olarak hesaplanır.

Ki kare istatistiğinin çok değişkenli normallik varsayımı ile geniş örneklem büyüklüğü varsayımı bulunmaktadır. Bunun yanı sıra gözlenen değişkenler için ki-kare istatistiği, çok değişkenli normallikten, korelasyon büyüklüğünden, tekli varyanstan, örneklem büyüklüğünden etkilenmektedir (8). Geniş örneklemelerde ki-kare değeri bundan etkileneceğinden ki karenin serbestlik derecesine bölünmesiyle elde edilen sonuç raporlanmaktadır (8). Ki karenin serbestlik derecesine oranının 3 ya da 3'ten küçük olması beklenir. Bollen (1989) (7) ise χ^2 / sd uyum iyiliği hesaplamasının 5 ve 5'ten küçük olması durumunda da model-veri uyumunu sağladığını belirtmektedir.

χ^2 test istatistiği örneklem büyüklüğünden etkilenmekte ve örnek büyüklüğü arttıkça artmaktadır. χ^2 test istatistiği örneklem büyüklüğüne duyarlı olduğu için çeşitli uyum indekslerinin geliştirilmesine neden olmuştur (45).

b. Uyum iyiliği indeksi (Goodness of Fit Index-GFI):

GFI, χ^2 testine alternatif olarak Jöreskog ve Sörbom (1984) tarafından geliştirilen ilk uyum indeksidir. GFI, önerilen model tarafından açıklanan varyans ve kovaryansın miktarının bir indeksidir. Bu nedenle regresyondaki R^2 gibi düşünülebilir (13,40).

GFI, tahmini ana kütle kovaryansları tarafından açıklanan varyans oranını hesaplamaktadır. Bu istatistik, 0-1 arasında değişmektedir. Örnek boyutu ile karşılaştırıldığında serbestlik derecesi büyük olduğu zaman GFI aşağı doğru bir eğime sahip olmaktadır. Buna ek olarak parametre sayısı artarken, GFI'nın da arttığı belirlenmiş ve büyük örneklerde yukarı doğru bir eğilime sahip olduğu saptanmıştır. Geleneksel olarak 0,90 bitiş noktasının geniş kapsamlı olarak GFI için tavsiye edilmekte, ayrıca simülasyon çalışmaları faktör yükleri ve örnek büyüklüğü düşük olduğunda 0,95 gibi yüksek bir bitirme noktasının daha uygun olduğu ifade edilmektedir. Bu indeksin hassasiyeti göz önüne alınarak, son yıllarda daha az kullanıma sahip olduğu ve hatta bu indeksin kullanılmamasının tavsiye edildiği görülmektedir (43). GFI değeri 1.0'a ne kadar yakın olursa uyum o kadar iyi demektir.

c. Düzeltilmiş uyum iyiliği indeksi (Adjusted Goodness of Fit Index -AGFI):

Modelde değişken sayısı fazla iken ve karmaşık modellerde iyi sonuç vermediği ifade edilen GFI uyum indeksi yerine model karmaşıklığından kaynaklanan yanlışlığı düzeltmek için AGFI uyum indeksi geliştirilmiştir. AGFI, gözlenen değişken sayısı ve modelin serbestlik derecesine göre düzeltilmiş bir GFI değeridir. Eğer hedef modelin serbestlik derecesi, temel modelin serbestlik derecesine yaklaşırsa AGFI, GFI'ya yaklaşır. GFI'da olduğu gibi AGFI değeri de regresyondaki düzeltilmiş R^2 gibi düşünülebilir (13,40).

AGFI örnek büyüklüğü ile artmaya eğilimlidir ve GFI'da olduğu gibi AGFI için sınır değerleri 0 ve 1 arasında değişmektedir. Genellikle 0,90 ya da daha yüksek değerler iyi uyum sağlayan bir model olarak kabul edilmektedir. Bu iki uyum indeksinin üzerindeki örnek büyüklüğünün kötü etkisi göz önüne alındığında, tek başlarına bir indeks olarak güvenilmemekle birlikte kovaryans yapı analizlerinde sıklıkla raporlanmaktadır (13,43).

d. Hata Kareler ortalamasının karekökü (Root Mean Square Residuals -RMR):

Örnek kovaryans matrisi ile modelden elde edilen kovaryans matrisi arasındaki fark matrisinin (artık matrisinin) kareler ortalamasının karekökü alınarak hesaplanır (2,8).

RMR, 0 ile 1 aralığında değerler alır ve RMR değerinin sıfıra yakın olması iyi uyumun göstergesidir. RMR uyum indeksinin dezavantajı ise ölçekten bağımsız olmamasıdır yani bu ölçeklerin hepsi farklı ise RMR değerinin yorumlanması zorlaşır (8). Değişkenlere ait ölçüğün bilinmediği durumlarda elde edilen RMR değerini yorumlamak mümkün olmayacaktır. Aynı zamanda bu ölçüt, değişkenler varyans ve kovaryansının büyüklüğüne göre de değişkenlik göstermektedir. Bu problemi aşmak için Standartlaştırılmış Hata Ortalamasının Karekökü-SRMR uyum indeksi geliştirilmiştir (46).

e. Standartlaştırılmış hata kareler ortalamasının karekökü (Standardized Root Mean Square Residuals-SRMR):

RMR değerinin değişkenlerin ölçüğüne bağlılığını ortadan kaldırmak için önerilmiştir. SRMR, gözlenen ve tahmin edilen kovaryans matrisleri arasındaki fark matrisinin elemanlarından oluşan artıkların bir ölçüsüdür (8).

SRMR değerinde, 0 ile 1 aralığında değerler alır. SRMR değeri 0'a yaklaştıkça iyi uyum belirtecektir (8). SRMR değerinin 0'a eşitliği mükemmel uyumu, 0,05'ten küçük değerleri için iyi bir uyumu ve 0,05 ile 0,10 arasındaki değerler için kabul edilebilir bir uyumu işaret etmektedir.

Artan uyum indeksleri:

Artan uyum indeksleri, test edilen model ile daha kısıtlı, iç içe olan temel modeli uyum gelişim oranlarını ölçerek karşılaştırmaktadır (9). Bütün gözlenen değişkenlerin ilişkisiz olduğu sıfır modeli en çok kullanılan temel modeldir (47). Artan uyum indeksleri kısaca temel model ile test edilen modelin karşılaştırılmasında kullanılmaktadır. Artan uyum indeksleri arasında Normlaştırılmış Uyum İndeksi (NFI), Artan Uyum İndeksi (IFI), Normlaştırılmamış Uyum İndeksi (NNFI) ve Karşılaştırmalı Uyum İndeksi (CFI) gibi indeksler verilebilir (9).

a. Normlaştırılmış uyum indeksi (Normed Fit Index-NFI):

Model uyum değerlendirmeleri için çok kullanışlı başka bir uyum indeksidir. NFI uyum indeksi olarak bilinen bu istatistik H_0 modelin χ^2 değerleri ile modelin χ^2 değerlerinin karşılaştırılmasıyla değerlendirilmektedir. H_0 model, ölçülen tüm değişkenlerin ilişkisiz olduğunu belirten, incelenen değişkenler arasında hiçbir ilişkinin olmadığı uç bir örneği temsil eder ve sıfır modele karşılık önerilen modelin karşılaştırılması fikrine dayanmaktadır (13,43). Bentler ve Bonnet (1980) (47) 0 ile 1 arasında değişen bu istatistiğin iyi bir uyum göstermesi için 0,90'dan büyük değerlerini tavsiye etmektedir. NFI indeks değeri için 0,90-0,94 arasında olması kabul edilebilir uyumu, 0,95 ve üzeri değerler ise mükemmel uyumu gösterir. Bu indeks için en büyük dezavantaj, örnek büyüklüğüne duyarlı olmasıdır, 200'den az örnekler için uyum azalmaktadır, bu nedenle sadece NFI'ya dayanarak karar verilmesi tavsiye edilmemektedir.

b. Normlaştırılmamış uyum indeksi (NNFI):

Tucker ve Lewis (1973) tarafından önerilen FA modelleri için önerilen daha sonra Bentler ve Bonnet (1980) tarafından YEM için geliştirilen NNFI indeksi, NFI uyum indeksi parametre sayısı ve örneklem büyüklüğünden etkilenmesi gibi dezavantajları ortadan kaldırmak için ileri sürülen bir diğer artımsal uyum indeksidir. NNFI normlaştırılmamış bir ölçüt olması nedeniyle zaman zaman [0,1] aralığının dışında da değerler alabilmektedir. Yüksek NNFI değerleri iyi bir uyumun göstergesi olmakla beraber 0,97 iyi uyum ve 0,95 değeri ise kabul edilebilir uyum için eşik değerlerdir (48).

c. Artan uyum indeksi (Incremental Fit Index-IFI):

Bollen tarafından geliştirilen artan uyum indeksi, Bollen'in artan uyum indeksi BL89, IFI olarak da bilinmektedir. IFI, [0,1] arasında değerler alır. IFI değeri 1'e yaklaştıkça modelin uyumu artar. 0.90'ı aşan değerler kabul edilebilir uyumun, 0.95'i aşan değerler iyi uyumun göstergesidir (14).

d. Karşılaştırmalı uyum indeksi (Comparative Fit Index, CFI):

Bentler (1990) tarafından geliştirilen indeks değişkenler arasında hiçbir ilişkinin olmadığını varsayan temel model ile önerilen modeli karşılaştırmak üzerine kurulmuştur (13,40). Model uygunluğunun değerlendirilmesinde örnek çapı büyüklüğünü ve modeldeki serbestlik derecesini dikkate alır. CFI, Bentler tarafından, Bentler Fit Index (BFI)'nin düzenlenmesi sonucu elde edilmiş bir indekstir. CFI, [0,1] arasında değerler alır. CFI'nın 0,97 ve üzeri değerleri mükemmel uyumu, 0,95 ve üzeri ise kabul edilebilir uyumu gösterir. Bazı

arařtırmacılar için bu sınır 0.90 olarak kabul edilmektedir (2,8,13-23). NNFI ile karşılaştırıldıđında CFI örnekleme sayısından daha az etkilenir.

Tutumlu uyum indeksleri:

Tutumlu uyum indekslerinde, karşılaştırılan modeller içinde daha az serbest parametreye (ya da daha çok serbestlik derecesine) sahip olan modeller seçilmektedir. Tutumlu uyum indeksleri belirli bir seviyede uyuma ulaşabilmek için parametre tahminlerinin sayısının önemli olduğunu vurgulamaktadır. Uyum indekslerinin eşik seviyelerini yorumlamak zor hale geldikçe, diđer uyum indeks ölçüleri ile beraber tutumlu uyum indekslerinin kullanımı da tavsiye edilmektedir (2,43). Tutumlu uyum indeksleri arasında Yaklaşık Hataların Ortalama Karekökü (RMSEA), McDonald's Uyum İndeksi (MFI), Akaike Bilgi Kriteri (AIC), Tutarlı Akaike Bilgi Kriteri (CAIC), Bayesyan Bilgi Kriteri (BIC), Beklenen Çapraz Geçerlilik İndeksi (ECVI), Tutarlı Uyum İndeksi (PGFI), Tutarlı Standart Uyum İndeksi (PNFI) gibi indeksler yer almaktadır (9,25).

a. Hata kareleri ortalaması yaklaşımı (Root Mean Square Error of Approximation- RMSEA):

Steiger ve Lind (1980) tarafından, YEM'de, modelden elde edilen kovaryans matrisinin, örneklemeden elde edilen kovaryans metrisine uygunluk düzeyini bulmak için geliştirilmiştir (40, 49). Son yıllarda "en bilgilendirici uyum indekslerinden" biri olarak kabul edilmektedir. RMSEA modelin, ne kadar iyi olduğunu söylemekte fakat modeldeki tahmin parametrelerinin sayısına olan duyarlılığı nedeniyle parametre sayısının daha az olacağı modeli seçmektedir. RMSEA değerinin 0.05'e eşit ya da altındaki değerler iyi uyum, 0.05 ile 0.08 arasında olması yeterli uyum, 0.08 ile 0.10 arasında olması kabul edilebilir uyum, 0.10'dan büyük olması ise kabul edilemez uyum olarak adlandırılmaktadır (8,23-40).

RMSEA'nın en büyük avantajlarından biri de bu değer etrafında hesaplanabilecek bir güven aralığı yeteneğidir. İstatistik değerlerin dağılımının bilinmesine rağmen bu mümkündür ve H_0 hipotezin daha kesin test edilmesine izin vermektedir. Genellikle RMSEA ile bağlantılı olarak bildirilen ve iyi uyum sağlayan alt limit 0 üst limit 0,08'e yakın olmalıdır (43,50).

b. Tutarlı normlaştırılmış uyum indeksi (Parsimonious Normed Fit Index- PNFI):

PNFI, NFI'nın serbestlik derecelerinin hesaba katılıp yeniden düzenlenmesiyle elde edilmektedir. Teorik olarak [0,1] aralığında olması gerekmez de, 1'e yakın değerleri iyi uyuma işaret etmektedir (51). Serbestlik derecesini karşılaştırmak için kullanılır. NFI'ya dayanmaktadır. Farklı serbestlik derecelerine sahip modellerin karşılaştırılmasında kullanılmaktadır. Kısıtlı tüm veri için serbestlik derecesinin oranı olan PR oranı ile NFI

değerinin çarpımı ile hesaplanmaktadır. Kabul edilebilir uyum düzeyi için hiçbir eşik seviyesi tavsiye edilmezken, diğer uyum indeksleri için 0,90 ve üzerinde değerler elde ederken kısıtlı uyum indeksleri için 0,50 civarında değer elde etmenin mümkün olduğu belirtilmektedir (2,35).

c. Kısıtlı uygunluk indeksi (Parsimonious Goodness Of Fit Index- PGFI):

Kısıtlı Uygunluk İndeksi serbestlik derecesini azaltmak için ayarlanmış GFI'ya dayanmaktadır. Bir modeldeki kısıtlılık tüm veri için serbestlik derecesinin oranı (PR) tarafından belirlenmektedir. GFI ile bağlantılı PR için kullanılan farklı bir oranda maksimum serbestlik derecesi $n(n+1)/2$ olarak belirlenmiştir. $PR \cdot GFI$ değerleri $[0,1]$ arasında değişmekte olup, $\geq 0,85$ için modelin iyi bir uyum gösterdiği ifade edilmektedir.

d. Akaike bilgi kriteri (AIC):

Japon istatistikçi Hirotugu Akaike (1973,1987) tarafından geliştirilen indeks, aynı örneklemden aynı değişkenlerin ölçülmesi ile oluşturulan alternatif modellerin karşılaştırılması için önerilmiştir (7,8,35). AIC, model uygunluğunun değerlendirilmesinde en çok kullanılan indekslerden biridir. Uyumun kötülüğü indeksi olarak da adlandırılan AIC indeksinin uygulama biçimi diğer indekslerden farklıdır. AIC'de temel amaç elde edilen veriler ile mümkün modeller arasında gerçeğe en yakın modelin seçimini sağlamaktır. En küçük AIC değerini veren modelin en iyi model olduğu kabul edilir. Ancak burada unutulmaması gereken AIC'nin bir anlamlılık testi değil betimsel bir ölçüt olduğudur. En küçük AIC değerini veren model en iyi uyumu gösterir (7,8,35).

e. Tutarlı akaike bilgi kriteri (Consistent Akaike Information Criterion- CAIC):

Bozdoğan (1987), Akaike'nin prensiplerini bozmadan matematiksel istatistik kurallarını kullanarak CAIC'i geliştirmiştir (15,25,40). AIC'in aksine direkt olarak örneklem büyüklüğünü hesaba katar. Küçük değerleri daha iyi uyumu göstermektedir (25, 40). Çalışmaları sonucunda AIC indeksi asimptotik olarak tutarlı duruma gelmiştir. AIC'e benzer şekilde rakip modellerin karşılaştırılmasında en küçük CAIC değerine sahip model seçilmektedir (52).

f. Bayesyen bilgi kriteri (Bayesian Information Criterion- BIC):

AIC indeksinde olduğu gibi, farklı sınıfların göreceli uyumlarını karşılaştırmak için kullanılır. AIC değerinde olduğu gibi düşük BIC değerleri daha iyi uyumlu modeli belirtmektedir (35,40). BIC, model karmaşıklığı ve örnek büyüklüğünden kaynaklanan sapmaları dengeleyebilen bir testtir ve modeldeki parametre sayısı az, örnek büyüklüğü fazla olduğu durumlarda AIC yerine tercih edilmektedir (21)

Tablo 3. Uyum indeksleri güven aralıkları

Uygunluk İndeksleri	İyi uyum	Kabul edilebilir uyum
χ^2	$0 < \chi^2 \leq 2sd$	$2sd \leq \chi^2 \leq 3sd$
χ^2/sd	$0 \leq \chi^2/sd \leq 2$	$2 \leq \chi^2/sd \leq 3$
P value	$0,05 \leq p \leq 1$	$0,01 \leq p \leq 0,05$
GFI	$0,95 \leq GFI \leq 1,0$	$0,90 \leq GFI \leq 0,95$
RMSEA	$0 \leq RMSEA \leq 0,05$	$0,05 \leq RMSEA \leq 0,08$
CFI	$0,97 \leq CFI \leq 1,0$	$0,95 \leq CFI \leq 0,97$
TLI	$TLI \geq 0,95$	$TLI \geq 0,95$
SRMR	$0 \leq SRMR \leq 0,05$	$0,05 \leq SRMR \leq 0,10$
RMR	$RMR \leq 0,10$	$RMR \leq 0,10$
IFI	$IFI \geq 0,90$	$IFI \geq 0,90$
NNFI	$0,97 \leq NNFI \leq 1,0$	$0,95 \leq NNFI \leq 0,97$
NFI	$0,95 \leq NFI \leq 1,0$	$0,90 \leq NFI \leq 0,95$
AGFI	$0,90 \leq AGFI \leq 1,0$	$0,85 \leq AGFI \leq 0,90$

χ^2 : Ki Kare Test İstatistiği

GEREÇ VE YÖNTEMLER

SİMÜLASYON ÇALIŞMASI

Kurulan Modeller

Simülasyon çalışması için belirlenen modeller (Model 1 ve Model 2) aşağıda verilmiştir.

Model 1:

Birinci model üç dışsal, bir içsel gizil değişken; üç dışsal gizil değişkenin her birinin dörder adet gözlenen değişkeni bulunmaktadır. Bir içsel gizil değişken ise iki adet gözlenen değişkenden oluştuğu varsayılarak model bir oluşturulmuştur.

y içsel gözlenen değişkeninin ölçüm modeli aşağıdaki gibidir.

$$y = \Lambda_{\eta} \eta + \varepsilon$$

$$\begin{bmatrix} y_1 \\ y_2 \end{bmatrix} = \begin{bmatrix} \lambda_{11}^y \\ \lambda_{21}^y \end{bmatrix} \times [\eta_1] + \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \end{bmatrix}$$

$$y_1 = \lambda_{11}^y \eta_1 + \varepsilon_1$$

$$y_2 = \lambda_{21}^y \eta_1 + \varepsilon_2$$

x dışsal gözlenen değişkeninin ölçüm modeli aşağıdaki gibidir.

$$x = \Lambda_x \xi + \delta$$

$$\begin{bmatrix} x_1 \\ x_2 \\ x_3 \\ x_4 \\ x_5 \\ x_6 \\ x_7 \\ x_8 \\ x_9 \\ x_{10} \\ x_{11} \\ x_{12} \end{bmatrix} = \begin{bmatrix} \lambda_{11} & 0 & 0 & 0 \\ \lambda_{21} & 0 & 0 & 0 \\ \lambda_{31} & 0 & 0 & 0 \\ 0 & \lambda_{42} & 0 & 0 \\ 0 & \lambda_{52} & 0 & 0 \\ 0 & \lambda_{62} & 0 & 0 \\ 0 & 0 & \lambda_{73} & 0 \\ 0 & 0 & \lambda_{83} & 0 \\ 0 & 0 & \lambda_{93} & 0 \\ 0 & 0 & 0 & \lambda_{104} \\ 0 & 0 & 0 & \lambda_{114} \\ 0 & 0 & 0 & \lambda_{124} \end{bmatrix} \times \begin{bmatrix} \xi_1 \\ \xi_2 \\ \xi_3 \end{bmatrix} + \begin{bmatrix} \delta_1 \\ \delta_2 \\ \delta_3 \\ \delta_4 \\ \delta_5 \\ \delta_6 \\ \delta_7 \\ \delta_8 \\ \delta_9 \\ \delta_{10} \\ \delta_{11} \\ \delta_{12} \end{bmatrix}$$

$$x_1 = \lambda_{11}^x \xi_1 + \delta_1$$

$$x_2 = \lambda_{21}^x \xi_1 + \delta_2$$

$$x_3 = \lambda_{31}^x \xi_1 + \delta_3$$

$$x_4 = \lambda_{42}^x \xi_2 + \delta_4$$

$$x_5 = \lambda_{52}^x \xi_2 + \delta_5$$

$$x_6 = \lambda_{62}^x \xi_2 + \delta_6$$

$$x_7 = \lambda_{73}^x \xi_3 + \delta_7$$

$$x_8 = \lambda_{83}^x \xi_3 + \delta_8$$

$$x_9 = \lambda_{93}^x \xi_3 + \delta_9$$

$$x_{10} = \lambda_{104}^x \xi_4 + \delta_{10}$$


$$x_{11} = \lambda_{114}^x \xi_4 + \delta_{11}$$

$$x_{12} = \lambda_{124}^x \xi_4 + \delta_{12}$$

Yapısal model:

$$\eta = B\eta + \Gamma\xi + \delta$$

$$\eta_1 = \gamma_{11}\xi_1 + \gamma_{12}\xi_2 + \gamma_{13}\xi_3 + \zeta_1$$



Şekil 4. Model 1 yol diyagramı

Model 1' in ortalama vektörü

$$\mu_1 = (\bar{y}_1 \quad \bar{y}_2 \quad \bar{x}_1 \quad \bar{x}_2 \quad \bar{x}_3 \quad \bar{x}_4 \quad \bar{x}_5 \quad \bar{x}_6 \quad \bar{x}_7 \quad \bar{x}_8 \quad \bar{x}_9 \quad \bar{x}_{10} \quad \bar{x}_{11} \quad \bar{x}_{12})$$

$$\mu_1 = (100 \ 100 \ 100 \ 100 \ 100 \ 100 \ 100 \ 100 \ 100 \ 100 \ 100 \ 100 \ 100 \ 100)$$

ve kovaryans matrisi

$$\Sigma_1 = \begin{bmatrix} 1 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 \\ 0.3 & 1 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 \\ 0.3 & 0.3 & 1 & 0.5 & 0.5 & 0.5 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 \\ 0.3 & 0.3 & 0.5 & 1 & 0.5 & 0.5 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 \\ 0.3 & 0.3 & 0.5 & 0.5 & 1 & 0.5 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 \\ 0.3 & 0.3 & 0.5 & 0.5 & 0.5 & 1 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 \\ 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 1 & 0.5 & 0.5 & 0.5 & 0.3 & 0.3 & 0.3 & 0.3 \\ 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.5 & 1 & 0.5 & 0.6 & 0.3 & 0.3 & 0.3 & 0.3 \\ 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.5 & 0.5 & 1 & 0.5 & 0.3 & 0.3 & 0.3 & 0.3 \\ 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.5 & 0.6 & 0.3 & 1 & 0.3 & 0.3 & 0.3 & 0.3 \\ 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 1 & 0.5 & 0.5 & 0.5 \\ 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.5 & 1 & 0.5 & 0.5 \\ 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.5 & 0.5 & 1 & 0.5 \\ 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.5 & 0.5 & 0.5 & 1 \end{bmatrix}$$

olarak alınmıştır.

Model 2

İkinci model ise dört dışsal, bir içsel gizil değişken; dört dışsal gizil değişkenin her birinin üçer adet gözlenen değişkeni bulunmaktadır. Bir içsel gizil değişken ise iki adet gözlenen değişkenden oluştuğu varsayılarak model iki oluşturulmuştur.

y içsel gözlenen değişkeninin ölçüm modeli aşağıdaki gibidir.

$$y = \Lambda_{\eta} \eta + \varepsilon$$

$$\begin{bmatrix} y_1 \\ y_2 \end{bmatrix} = \begin{bmatrix} \lambda_{11}^y \\ \lambda_{21}^y \end{bmatrix} \times [\eta_1] + \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \end{bmatrix}$$

$$y_1 = \lambda_{11}^y \eta_1 + \varepsilon_1$$

$$y_2 = \lambda_{21}^y \eta_1 + \varepsilon_2$$

x dışsal gözlenen değişkeninin ölçüm modeli aşağıdaki gibidir.

$$x = \Lambda_x \xi + \delta$$

$$\begin{bmatrix} x_1 \\ x_2 \\ x_3 \\ x_4 \\ x_5 \\ x_6 \\ x_7 \\ x_8 \\ x_9 \\ x_{10} \\ x_{11} \\ x_{12} \end{bmatrix} = \begin{bmatrix} \lambda_{11} & 0 & 0 \\ \lambda_{21} & 0 & 0 \\ \lambda_{31} & 0 & 0 \\ \lambda_{41} & 0 & 0 \\ 0 & \lambda_{52} & 0 \\ 0 & \lambda_{62} & 0 \\ 0 & \lambda_{72} & 0 \\ 0 & \lambda_{82} & \lambda_{93} \\ 0 & 0 & \lambda_{103} \\ 0 & 0 & \lambda_{113} \\ 0 & 0 & \lambda_{123} \end{bmatrix} \times \begin{bmatrix} \xi_1 \\ \xi_2 \\ \xi_3 \\ \xi_4 \end{bmatrix} + \begin{bmatrix} \delta_1 \\ \delta_2 \\ \delta_3 \\ \delta_4 \\ \delta_5 \\ \delta_6 \\ \delta_7 \\ \delta_8 \\ \delta_9 \\ \delta_{10} \\ \delta_{11} \\ \delta_{12} \end{bmatrix}$$

$$x_1 = \lambda_{11}^x \xi_1 + \delta_1$$

$$x_2 = \lambda_{21}^x \xi_1 + \delta_2$$

$$x_3 = \lambda_{31}^x \xi_1 + \delta_3$$

$$x_4 = \lambda_{41}^x \xi_1 + \delta_4$$

$$x_5 = \lambda_{52}^x \xi_2 + \delta_5$$

$$x_6 = \lambda_{62}^x \xi_2 + \delta_6$$

$$x_7 = \lambda_{72}^x \xi_2 + \delta_7$$

$$x_8 = \lambda_{82}^x \xi_2 + \delta_8$$

$$x_9 = \lambda_{93}^x \xi_3 + \delta_9$$

$$x_{10} = \lambda_{103}^x \xi_3 + \delta_{10}$$


$$x_{11} = \lambda_{113}^x \xi_3 + \delta_{11}$$

$$x_{12} = \lambda_{123}^x \xi_3 + \delta_{12}$$

Yapısal model:

$$\eta = B\eta + \Gamma\xi + \delta$$

$$\eta_1 = \gamma_{11}\xi_1 + \gamma_{12}\xi_2 + \gamma_{13}\xi_3 + \gamma_{14}\xi_4 + \zeta_1$$



Şekil 5. Model 2 yol diyagramı

Model 2 için ortalama vektör

$$\mu_2 = (\bar{y}_1 \quad \bar{y}_2 \quad \bar{x}_1 \quad \bar{x}_2 \quad \bar{x}_3 \quad \bar{x}_4 \quad \bar{x}_5 \quad \bar{x}_6 \quad \bar{x}_7 \quad \bar{x}_8 \quad \bar{x}_9 \quad \bar{x}_{10} \quad \bar{x}_{11} \quad \bar{x}_{12})$$

$$\mu_2 = (100 \ 100 \ 100 \ 100 \ 100 \ 100 \ 100 \ 100 \ 100 \ 100 \ 100 \ 100 \ 100 \ 100)$$

$$\Sigma_2 = \begin{bmatrix} 1 & 0.5 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 \\ 0.5 & 1 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 \\ 0.3 & 0.3 & 1 & 0.5 & 0.5 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 \\ 0.3 & 0.3 & 0.5 & 1 & 0.5 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 \\ 0.3 & 0.3 & 0.5 & 0.5 & 1 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 \\ 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 1 & 0.5 & 0.5 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 \\ 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.5 & 1 & 0.5 & 0.3 & 0.5 & 0.3 & 0.3 & 0.3 & 0.3 \\ 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.5 & 0.5 & 1 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 \\ 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 1 & 0.5 & 0.6 & 0.3 & 0.3 & 0.3 \\ 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.5 & 1 & 0.5 & 0.3 & 0.3 & 0.3 \\ 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.6 & 0.5 & 1 & 0.3 & 0.5 & 0.3 \\ 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 1 & 0.5 & 0.5 \\ 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.5 & 1 & 0.5 \\ 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.3 & 0.5 & 0.5 & 1 \end{bmatrix}$$

Kullanılan Program

Simülasyon çalışması, açık kaynak kodlu R programlama dilinde “*lavan*” , “*corpcor*” , “*mvtnorm*” , “*semPlot*” , “*foreach*” paketleri kullanılarak gerçekleştirilmiştir (Ek-1, Ek-2).

Dağılım Koşulu

Kurulan her iki modelde yer alan gözlenen değişkenler için veriler, belirlenen ortalama vektör ve kovaryans matrisi dikkate alınarak çok değişkenli normal dağılımdan türetilmiştir.

Örneklem Büyüklükleri

Simülasyon çalışmasında, belirlenen dağılımsal koşullar için örneklem büyüklüğü (n) 300, 600, 1200 birim olarak alınmış, işlem 1000 kere uygulanmış ve sonuçların ortalaması alınarak sonuçlar bulunmuştur.

Kullanılan Parametre Tahmin Teknikleri

Yapısal eşitlik modellemesinde yaygın olarak kullanılan normal dağılım varsayımına uyan; En Çok Olabilirlik (ML), Genelleştirilmiş En Küçük Kareler (GLS), yöntemleri kullanılmaktadır.

Karşılaştırmada Kullanılan Model Uyum İndeksleri

Model uyum indeksi olarak "*chisq*", "*chisq/df*", "*pvalue*", "*GFI*", "*RMSEA*", "*CFI*", "*TLI*", "*SRMR*", "*RMR*", "*IFI*", "*NNFI*", "*NFI*", "*AGFI*" indeksleri karşılaştırma için kullanılmıştır.

Belirlenen Dağılımsal Koşullar

Çok değişkenli normal dağılım varsayımına uyması için veriler türetilirken çok değişkenli normal dağılım koşulu altında türetildiği için çok değişkenli normal dağılım sınaması yapılmamıştır.

Simülasyon Çalışmasının Adımları

Her iki model içinde aynı adımlar uygulanmıştır.

- Modeller için ortalama vektör ve kovaryans matrisi baz alınarak çok değişkenli normal dağılıma uygun veri türetilmiştir.
- Türetilmiş verilerin sütun isimleri verilmiştir.
- Belirlenen sayılarda iki tasarım için de modelleri oluşturulmuştur.
- Sınaması yapılırken ayrı ayrı yapısal eşitlik, doğrulayıcı faktör analizi ve yol analizi sınamaları yapılmıştır.
- Modellere uygun YEM’de kullanılan tahmin teknikleri uygulanmıştır.

- Model uyum testlerinden seçilen uyum indekslerine bakılmıştır.
- Bu işlemler 1000 defa tekrarlanmıştır.
- Yol diyagramı çizdirilmiştir.
- Bu işlemler sırasıyla 300, 600, 1200 gözlem olacak şekilde tekrarlanmıştır.



BULGULAR

Bu tez çalışmasında, simülasyon çalışması yapılarak belirtilen modellere (Model 1, Model 2) belirtilen YEM tahmin teknikleri uygulanarak uyum indeksleri karşılaştırması yapılmak istenmiştir. Belirtilen gözlem sayıları ile YEM tekniği yorumlanması için elde edilen sonuçlar amacımız doğrultusunda sunulmuştur.

Yapılan çalışmada ortalama, standart sapma ve kovaryans matrisi ile çok değişkenli normal dağılıma uygun veri üretilmiştir.

Çok değişkenli normal dağılım varsayımına uygun olarak üretilen üç dışsal gizil değişkenli model (Model-1) ve dört dışsal gizil değişkenli modele (Model-2) YEM tahmin tekniklerinin uygulanması sonucunda elde edilen simülasyon sonuçlarına göre üretilen bazı modellerde eksik veri kaynaklı optimizasyon problemi, negatif varyans ve boyut sorunu ile karşılaşmıştır.

MODEL 1 UYGULAMA SONUÇLARI

ML Tahmin Tekniğine Göre Simülasyon Sonuçları

Model 1 için yapılan simülasyon çalışmasında, çok değişkenli normal dağılımdan türetilen veri setlerine ML parametre tahmin yöntemi uygulanarak elde edilen model uyum indekslerinin örneklem büyüklüklerine göre (300, 600, 1200) aldığı değerler aşağıdaki tabloda verilmiştir.

Tablo 4. ML tahmin tekniğinde uyum indeksi değerleri

Uygunluk İndeksleri	İyi uyum/ kabul edilebilir uyum	Gözlem Sayısı		
		300	600	1200
χ^2	$0 < \chi^2 \leq 2sd$ $2sd < \chi^2 \leq 3sd$	78,4933	82,7694	93,3757
Sd		71	71	71
χ^2/sd	$0 \leq \chi^2/df \leq 2$ $2 \leq \chi^2/ \leq 3$	1,105539437	1,165766197	1,315150704
P value	$0,05 \leq p \leq 1$ $0,01 \leq p \leq 0,05$	0,3375	0,2637	0,1245
GFI	$0,95 \leq GFI \leq 1,0$ $0,90 \leq GFI \leq 0,95$	0,9645	0,9807	0,9889
RMSEA	$0 \leq RMSEA \leq 0,05$ $0,05 \leq RMSEA \leq 0,08$	0,0165	0,0146	0,015
CFI	$0,97 \leq CFI \leq 1,0$ $0,95 \leq CFI \leq 0,97$	0,9934	0,9955	0,9961
TLI	$0,97 \geq TLI \geq 1$ $0,95 \geq TLI \geq 0,97$	0,9934	0,9948	0,9951
SRMR	$0 \leq SRMR \leq 0,05$ $0,05 \leq SRMR \leq 0,10$	0,0327	0,024	0,0182
RMR	$RMR \leq 0,10$	0,0324	0,0239	0,0182
IFI	$IFI \geq 0,90$	0,9949	0,996	0,9962
NNFI	$0,97 \leq NNFI \leq 1,0$ $0,95 \leq NNFI \leq 0,97$	0,9934	0,9948	0,9951
NFI	$0,95 \leq NFI \leq 1,0$ $0,90 \leq NFI \leq 0,95$	0,9491	0,9924	0,9842
AGFI	$0,90 \leq AGFI \leq 1,0$ $0,85 \leq AGFI \leq 0,90$	0,9475	0,9714	0,9836

Tablo 4 incelendiğinde; örneklem büyüklüğü arttıkça AGFI, NNFI, IFI, TLI, CFI, GFI, χ^2 ve χ^2/sd uyum indeksi değerleri de artmaktadır. Simülasyon çalışması çalışma tasarımında belirlenen 300, 600 ve 1200 örneklem sayısı dışında 50, 100, 150 ve 200 gözlem sayısı içinde denenmiş fakat belirlenen modeller için uyumsuzluk göstermiş; 50, 100, 150 gözlem içeren simülasyonda negatif varyans hatası vermiştir. Uyum indeksi değerleri “NFI” uyum indeksi dışında 300, 600, 1200 örneklem büyüklüğünde iyi uyum sınırları içinde değerler almıştır. “NFI” ve “p value” değerleri hariç örneklem büyüklüğü arttıkça ideal uyum sınırları içindeki değerlere yaklaştığı görülmektedir. RMSEA ve IFI uyum indeksleri için en iyi uyum sağlayan değer 600 gözlem sayısında olduğu görülmüştür. p değerinde örneklem büyüklüğü arttıkça iyi uyum değerinde azalmakta olduğu ve kabul edilir uyum sınırına yaklaştığı görülmüştür. NFI

uyum indeksinde ise 300 gözlem sayısında kabul edilebilir uyum sınırları içindeyken 600 ve 1200 örneklem büyüklüğünde iyi uyum sınırları içinde yer aldığı görülmüştür. Ayrıca, bu indekslerin örneklem büyüklüklerine göre değişimi aşağıda grafikler ile gösterimi yapılmıştır.

GLS Tahmin Tekniğine Göre Simülasyon Sonuçları

Model 1 için yapılan simülasyon çalışmasında, çok değişkenli normal dağılımdan türetilen veri setlerine GLS parametre tahmin yöntemi uygulanarak elde edilen model uyum indekslerinin örneklem büyüklüklerine göre (300, 600, 1200) aldığı değerler aşağıdaki tabloda verilmiştir.

Tablo 5. GLS tahmin tekniğinde uyum indeksi değerleri


Uygunluk İndeksleri	İyi uyum/ kabul edilebilir uyum	Gözlem Sayısı		
		300	600	1200
χ^2	$0 < \chi^2 \leq 2sd$ $2sd < \chi^2 \leq 3sd$	74,4495	79,2949	89,0105
Sd		71	71	71
χ^2/sd	$0 \leq \chi^2/sd \leq 2$ $2 \leq \chi^2/sd \leq 3$	1,048584	1,1168	1,2536
P value	$0,05 \leq p \leq 1$ $0,01 \leq p \leq 0,05$	0,4201	0,3202	0,1638
GFI	$0,95 \leq GFI \leq 1,0$ $0,90 \leq GFI \leq 0,95$	0,9644	0,9811	0,9894
RMSEA	$0 \leq RMSEA \leq 0,05$ $0,05 \leq RMSEA \leq 0,08$	0,0125	0,0123	0,0133
CFI	$0,97 \leq CFI \leq 1,0$ $0,95 \leq CFI \leq 0,97$	0,9736	0,9804	0,9825
TLI	$0,97 \geq TLI \geq 1$ $0,95 \geq TLI \geq 0,97$	0,9848	0,98	0,9783
SRMR	$0 \leq SRMR \leq 0,05$ $0,05 \leq SRMR \leq 0,10$	0,0393	0,0268	0,0196
RMR	$RMR \leq 0,10$	0,0392	0,0267	0,195
IFI	$IFI \geq 0,90$	0,9889	0,985	0,9833

Tablo 5. (devam) GLS tahmin tekniğinde uyum indeksi değerleri

Uygunluk İndeksleri	İyi uyum/ kabul edilebilir uyum	Gözlem Sayısı		
		300	600	1200
NNFI	$0,97 \leq NNFI \leq 1,0$ $0,95 \leq NNFI \leq 0,97$	0,9848	0,98	0,9783
NFI	$0,95 \leq NFI \leq 1,0$ $0,90 \leq NFI \leq 0,95$	0,7779	0,8689	0,9222
AGFI	$0,90 \leq AGFI \leq 1,0$ $0,85 \leq AGFI \leq 0,90$	0,9474	0,972	0,9843

Tablo 5 incelendiğinde; örneklem büyüklüğü arttıkça AGFI, SRMR, CFI uyum indeksi değerleri de artarak iyi uyumun üst sınırına yaklaşmaktadır. Ki kare, Ki kare/sd, p, GFI, TLI, IFI, NNFI, AGFI uyum indeksleri de iyi uyum sınırları içinde yer almaktadır; gözlem sayısı arttıkça iyi uyumun alt sınırına doğru yaklaşmaktadır. NFI uyum indeksi 300 ve 600 gözlem sayısında uyum göstermezken 1200 gözlem sayısında kabul edilebilir uyum göstermektedir. RMSEA uyum indeksi için tüm gözlem sayısı için iyi uyum gösterirken; 600 gözlem sayısı en iyi uyumu göstermektedir. RMR uyum indeksinde 300 ve 600 gözlem sayısında iyi uyum gösterirken 1200 gözlem sayısı için uyum göstermemektedir. Ayrıca, bu indekslerin örneklem büyüklüklerine göre değişimi aşağıda grafikler ile yapılmıştır.

Model 1 için tüm uyum indeksleri tahmin tekniklerine göre ve gözlem sayısına göre aldığı değerler aşağıdaki şekillerde gösterilmiştir.




Şekil 6. Model 1 için tahmin tekniklerine göre ki kare değerleri grafiği

Şekil 6 incelendiğinde en yüksek ki kare değerini ML tahmin yönteminde 1200 gözlem sayısında aldığı görülmüştür. En düşük ki kare değerini ise GLS tahmin yönteminde 300 gözlem sayısında almıştır. Bütün tahmin teknikleri için 71 serbestlik derecesinde iyi uyum göstermektedir.




Şekil 7. Model 1 için tahmin tekniklerine göre ki kare serbestlik derecesi oranları grafiği

Şekil 7 incelendiğinde en yüksek ki kare / sd değerini ML tahmin yönteminde 1200 gözlem sayısının aldığı görülmüştür. En düşük ki kare/sd değerini ise GLS tahmin yönteminde 300 gözlem sayısında aldığı görülmüştür. Bütün tahmin teknikleri için 71 serbestlik derecesinde iyi uyum göstermektedir.




Şekil 8. Model 1 için tahmin tekniklerine göre p değerleri grafiği

Şekil 8 de tahmin tekniklerinden en yüksek p değeri 300 gözlem sayısında GLS tahmin tekniği olurken; en düşük p değeri ML tahmin tekniği 1200 gözlem sayısı için olmuştur.. Tahmin teknikleri iyi uyum değer aralığında yer almaktadır. P değeri için GLS tahmin tekniği daha iyi sonuç vermiştir.




Şekil 9. Model 1 için tahmin tekniklerine göre GFI uyum indeksi değerleri grafiği

Şekil 9’da görüldüğü üzere en yüksek GFI değerini GLS tahmin yönteminde 1200 gözlem sayısında almıştır. En düşük GFI değerini ise GLS tahmin yönteminde 300 gözlem sayısında almıştır. Bütün tahmin teknikleri iyi uyum göstermektedir. Ayrıca iki tahmin tekniğinin birbirine çok yakın değerler aldığı görülmüştür.




Şekil 10. Model 1 için tahmin tekniklerine göre RMSEA uyum indeksi değerleri grafiği

Şekil 10'da en yüksek RMSEA değeri ML tahmin tekniği için 300 gözlem sayısı değeridir. En düşük RMSEA değeri GLS tahmin tekniği 300 gözlem değerleridir. Değerlerin tümü iyi uyum değer sınırında yer almaktadır. Değerler birbirine çok yakın olmakla birlikte GLS yönteminin daha iyi sonuç vermiştir denilebilir.




Şekil 11. Model 1 için tahmin tekniklerine göre CFI uyum indeksi değerleri grafiği

Şekil 11’de en yüksek CFI değeri ML parametre tahmin yönteminde 1200 gözlem sayısı için olurken, en düşük CFI değeri GLS tahmin tekniği 300 gözlem sayısı için olmuştur. Değerler iyi uyum değer sınırında yer almaktadır. CFI değeri için ML tahmin tekniği daha iyi sonuç vermiştir.




Şekil 12. Model 1 için tahmin tekniklerine göre TLI uyum indeksi değerleri grafiği

Şekil 12’de en yüksek TLI değeri 1200 gözlem sayısı için ML tahmin tekniği olurken; en düşük TLI değeri GLS tahmin tekniği 300 gözlem sayısı için olmuştur. Tahmin teknikleri için TLI değerleri iyi uyum değer sınır aralığında yer almaktadır. TLI değeri için ML tahmin tekniği daha iyi sonuç vermiştir.




Şekil 13. Model 1 için tahmin tekniklerine göre SRMR uyum indeksi değerleri grafiği

Şekil 13’de en yüksek SRMR değeri 300 gözlem sayısı için GLS tahmin tekniği olurken; en düşük SRMR değeri ML tahmin tekniği 1200 gözlem sayısı için olmuştur. Tahmin teknikleri için SRMR değerleri iyi uyum değer sınır aralığında yer almaktadır. SRMR değeri için ML tahmin tekniği daha iyi sonuç vermiştir.




Şekil 14. Model 1 için tahmin tekniklerine göre RMR uyum indeksi değerleri grafiği

Şekil 14’de en yüksek RMR değeri 300 gözlem sayısı için GLS tahmin tekniği olurken, en düşük RMR değeri ML tahmin tekniği 1200 gözlem sayısı için olmuştur. Tüm tahmin teknikleri için RMR değerleri iyi uyum değer sınır aralığında yer almaktadır. ML parametre tahmin yöntemi RMR değeri için daha iyi sonuç verdiği söylenebilir.




Şekil 15. Model 1 için tahmin tekniklerine göre IFI uyum indeksi değerleri grafiği

Şekil 15’de en yüksek IFI değeri 1200 gözlem sayısı için ML tahmin tekniği olurken; en düşük IFI değeri GLS tahmin tekniği 1200 gözlem sayısı için olmuştur. IFI değerlerinin tümü iyi uyum sınırları içinde yer almaktadır. ML tahmin yöntemi daha iyi sonuç verdiği görülmektedir.




Şekil 16. Model 1 için tahmin tekniklerine göre NNFI uyum indeksi değerleri grafiği

Şekil 16’da en yüksek NNFI değeri 1200 gözlem sayısı için ML tahmin tekniği olurken, en düşük NNFI değeri GLS tahmin tekniği 1200 gözlem sayısı için olmuştur. NNFI uyum indeksi değeri GLS tahmin tekniğinde 1200 gözlem sayısında iyi uyumun en alt sınırında yer almaktadır. Tüm değerler iyi uyum sınırları içinde yer almaktadır. ML tahmin tekniği daha iyi sonuç verdiği görülmüştür.



Şekil 17. Model 1 için tahmin tekniklerine göre NFI uyum indeksi değerleri grafiği

Şekil 17’de en yüksek NFI değeri 1200 gözlem sayısı için ML tahmin tekniği olurken, en düşük NFI değeri GLS tahmin tekniği 300 gözlem sayısı için olmuştur. NFI uyum indeksi değeri GLS tahmin tekniği 300 ve 600 gözlem sayısında uyumsuzluk göstermektedir. GLS tahmin tekniği 1200 gözlem sayısı, ML tahmin tekniği 300 gözlem sayısındaki değerler kabul edilebilir uyum sınırı içinde yer alırken geri kalan diğer değerler iyi uyum sınırları içinde yer almaktadır. ML tahmin yöntemi ve yüksek gözlem sayısında daha iyi uyum gösterdiği söylenebilir.



Şekil 18. Model 1 için tahmin tekniklerine göre AGFI uyum indeksi değerleri grafiği

Şekil 18’de en yüksek AGFI değeri 1200 gözlem sayısı için GLS tahmin tekniği olurken; en düşük AGFI değeri GLS tahmin tekniği 300 gözlem sayısı için olmuştur. AGFI uyum indeksi değerleri iyi uyum sınırları içinde yer almaktadır. Ayrıca ML tahmin tekniği ve GLS tahmin tekniği aynı gözlem sayılarındaki değerleri birbirine çok yakın değerler almıştır.

MODEL 2 SİMÜLASYON ÇALIŞMASI

ML Tahmin Tekniğine Göre Simülasyon Sonuçları

Model 2 için yapılan simülasyon çalışmasında, çok değişkenli normal dağılımdan türetilen veri setlerine ML parametre tahmin yöntemi uygulanarak elde edilen model uyum indekslerinin örneklem büyüklüklerine göre (300, 600, 1200) aldığı değerler aşağıdaki tabloda verilmiştir.

Tablo 6. Model 2 için ML tahmin tekniğine göre uyum indeksi değerleri

Uygunluk İndeksleri	İyi uyum/ kabul edilebilir uyum	Gözlem Sayısı		
		300	600	1200
χ^2	$0 < \chi^2 \leq 2sd$ $2sd < \chi^2 \leq 3sd$	71,5783	73,6965	79,4519
Sd		67	67	67
χ^2/sd	$0 \leq \chi^2/sd \leq 2$ $2 \leq \chi^2/sd \leq 3$	1,0683	1,0999	1,1858
P value	$0,05 \leq p \leq 1$ $0,01 \leq p \leq 0,05$	0,3945	0,3489	0,2421
GFI	$0,95 \leq GFI \leq 1,0$ $0,90 \leq GFI \leq 0,95$	0,9677	0,9829	0,9906
RMSEA	$0 \leq RMSEA \leq 0,05$ $0,05 \leq RMSEA \leq 0,08$	0,014	0,0114	0,011
CFI	$0,97 \leq CFI \leq 1,0$ $0,95 \leq CFI \leq 0,97$	0,9945	0,9966	0,9975
TLI	$0,97 \geq TLI \geq 1$ $0,95 \geq TLI \geq 0,97$	0,9945	0,9966	0,9969
SRMR	$0 \leq SRMR \leq 0,05$ $0,05 \leq SRMR \leq 0,10$	0,0316	0,0234	0,0179
RMR	$RMR \leq 0,10$	0,0314	0,0233	0,0179
IFI	$IFI \geq 0,90$	0,9967	0,9975	0,9977
NNFI	$0,97 \leq NNFI \leq 1,0$ $0,95 \leq NNFI \leq 0,97$	0,9954	0,9966	0,9969
NFI	$0,95 \leq NFI \leq 1,0$ $0,90 \leq NFI \leq 0,95$	0,9499	0,9734	0,9854
AGFI	$0,90 \leq AGFI \leq 1,0$ $0,85 \leq AGFI \leq 0,90$	0,9493	0,9732	0,9853

Tablo 6 incelendiğinde; örneklem büyüklüğü arttıkça AGFI, NNFI, IFI, SRMR, RMR, TLI, CFI, GFI, RMSEA, p, ki kare, ki kare/sd uyum indeksi değerleri iyi uyum göstermektedir. NFI uyum indeksi için 300 gözlem sayısında kabul edilebilir uyum göstermekte iken 600 ve 1200 gözlem sayısında iyi uyum göstermektedir.


GLS Tahmin Tekniğine Göre Model 2 Simülasyon Sonuçları

Model 2 için yapılan simülasyon çalışmasında, çok değişkenli normal dağılımdan türetilen veri setlerine GLS parametre tahmin yöntemi uygulanarak elde edilen model uyum indekslerinin örneklem büyüklüklerine göre (300, 600, 1200) aldığı değerler aşağıdaki tabloda verilmiştir.

Tablo 7. Model 2 için GLS tahmin tekniğine göre uyum indeksi değerleri


Uygunluk İndeksleri	İyi uyum/ kabul edilebilir uyum	Gözlem Sayısı		
		300	600	1200
χ^2	$0 < \chi^2 \leq 2sd$ $2sd < \chi^2 \leq 3sd$	68,3041	71,584	77,4623
Sd		67	67	67
χ^2/sd	$0 \leq \chi^2/sd \leq 2$ $2 \leq \chi^2/sd \leq 3$	1,0194	1,0684	1,156
P value	$0,05 \leq p \leq 1$ $0,01 \leq p \leq 0,05$	0,4698	0,3925	0,2733
GFI	$0,95 \leq GFI \leq 1,0$ $0,90 \leq GFI \leq 0,95$	0,9674	0,9829	0,9908
RMSEA	$0 \leq RMSEA \leq 0,05$ $0,05 \leq RMSEA \leq 0,08$	0,0107	0,0099	0,01
CFI	$0,97 \leq CFI \leq 1,0$ $0,95 \leq CFI \leq 0,97$	0,98	0,9865	0,9894
TLI	$0,97 \geq TLI \geq 1$ $0,95 \geq TLI \geq 0,97$	0,9956	0,989	0,987
SRMR	$0 \leq SRMR \leq 0,05$ $0,05 \leq SRMR \leq 0,10$	0,0376	0,0258	0,019
RMR	$RMR \leq 0,10$	0,0375	0,0257	0,019
IFI	$IFI \geq 0,90$	0,9969	0,9922	0,9908
NNFI	$0,97 \leq NNFI \leq 1,0$ $0,95 \leq NNFI \leq 0,97$	0,9956	0,989	0,9873
NFI	$0,95 \leq NFI \leq 1,0$ $0,90 \leq NFI \leq 0,95$	0,80029	0,8862	0,9351
AGFI	$0,90 \leq AGFI \leq 1,0$ $0,85 \leq AGFI \leq 0,90$	0,9489	0,9732	0,9855

Tablo 7 incelendiğinde; örneklem büyüklüğü arttıkça AGFI, NNFI, IFI, SRMR, RMR, TLI, CFI, GFI, RMSEA, p, ki kare, ki kare/sd uyum indeksi değerleri iyi uyum göstermektedir. NFI uyum indeksi için 300 ve 600 gözlem sayısında uyum göstermemekte ancak 1200 gözlem sayısında kabul edilebilir uyum göstermektedir.




Şekil 19. Model 2 için tahmin tekniklerine göre ki kare değerleri grafiği

Şekil 19’da görüldüğü üzere en yüksek ki kare değerini ML tahmin yönteminde 1200 gözlem sayısında almıştır. En düşük ki kare değerini ise GLS tahmin yönteminde 300 gözlem sayısında almıştır. Bütün tahmin teknikleri için 67 serbestlik derecesinde iyi uyum göstermektedir.




Şekil 20. Model 2 için tahmin tekniklerine göre ki kare serbestlik derecesi oranı grafiği

Şekil 20’de en yüksek ki kare / sd değerini ML tahmin yönteminde 1200 gözlem sayısında almıştır. En düşük ki kare değerini ise GLS tahmin yönteminde 300 gözlem sayısında almıştır. Bütün tahmin teknikleri için 67 serbestlik derecesinde iyi uyum göstermektedir.




Şekil 21. Model 2 için tahmin tekniklerine göre p değerleri grafiği

Şekil 21’de en yüksek p değeri 300 gözlem sayısında GLS tahmin tekniği olurken, en düşük p değeri ML tahmin tekniği 1200 gözlem sayısı için olmuştur. Bütün tahmin teknikleri için iyi uyum değer sınırında yer almaktadır. GLS tahmin yöntemi p değeri için daha iyi sonuç vermiştir.




Şekil 22. Model 2 için tahmin tekniklerine göre GFI uyum indeksi değerleri grafiği

Şekil 22’de görüldüğü üzere en yüksek GFI değerini GLS tahmin yönteminde 1200 gözlem sayısında almıştır. En düşük GFI değerini ise GLS tahmin yönteminde 300 gözlem sayısında almıştır. Bütün tahmin teknikleri iyi uyum göstermektedir. İki yöntemde aynı gözlem sayılarında birbirine çok yakın değerler almıştır.




Şekil 23. Model 2 için tahmin tekniklerine göre RMSEA uyum indeksi değerleri grafiği

Şekil 23’de en yüksek RMSEA değeri ML tahmin tekniği için 300 gözlem sayısı değeridir. En düşük RMSEA değeri GLS tahmin tekniği 600 gözlem sayısı değeridir. Değerlerin tümü iyi uyum değer sınırında yer almaktadır. GLS tahmin yöntemi RMSEA değeri için daha iyi değer almaktadır.




Şekil 24. Model 2 için tahmin tekniklerine göre CFI uyum indeksi değerleri grafiği

Şekil 24’de en yüksek CFI değeri 1200 gözlem sayısı için ML tahmin tekniği olurken, en düşük CFI değeri GLS tahmin tekniği 300 gözlem sayısı için olmuştur. Bütün tahmin teknikleri için iyi uyum değer sınırında yer almaktadır. CFI değeri için ML tahmin tekniği daha iyi sonuç vermektedir.




Şekil 25. Model 2 için tahmin tekniklerine göre TLI uyum indeksi değerleri grafiği

Şekil 25’de en yüksek TLI değeri 1200 gözlem sayısı için ML tahmin tekniği olurken, en düşük TLI değeri GLS tahmin tekniği 1200 gözlem sayısı için olmuştur. TLI değeri için tüm değerler iyi uyum değer sınır aralığında yer almaktadır. ML tahmin tekniği TLI değeri için daha iyi sonuç vermektedir.




Şekil 26. Model 2 için tahmin tekniklerine göre SRMR uyum indeksi değerleri grafiği

Şekil 26’da en yüksek SRMR değeri 300 gözlem sayısı için GLS tahmin tekniği olurken, en düşük SRMR değeri ML tahmin tekniği 1200 gözlem sayısı için olmuştur. Tahmin teknikleri için SRMR değerleri iyi uyum değer sınır aralığında yer almaktadır. ML tahmin tekniği SRMR değeri için daha iyi sonuç vermektedir.




Şekil 27. Model 2 için tahmin tekniklerine göre RMR uyum indeksi değerleri grafiği

Şekil 27’de en yüksek RMR değeri 300 gözlem sayısı için GLS tahmin tekniği olurken, en düşük RMR değeri ML tahmin tekniği 1200 gözlem sayısı için olmuştur. Tüm tahmin teknikleri için RMR değerleri iyi uyum değer sınır aralığında yer almaktadır. Değerler birbirine yakın olmakla birlikte ML tahmin tekniği daha iyi sonuç verdiği görülmektedir.




Şekil 28. Model 2 için tahmin tekniklerine göre IFI uyum indeksi değerleri grafiği

Şekil 28’de en yüksek IFI değeri 1200 gözlem sayısı için ML tahmin tekniği olurken, en düşük IFI değeri GLS tahmin tekniği 1200 gözlem sayısı için olmuştur. IFI değerlerinin tümü iyi uyum sınırları içinde yer almaktadır. IFI değeri için ML tahmin tekniği daha iyi sonuç vermektedir.




Şekil 29. Model 2 için tahmin tekniklerine göre NNFI uyum indeksi değerleri grafiği

Şekil 29’da en yüksek NNFI değeri 1200 gözlem sayısı için ML tahmin tekniği olurken, en düşük NNFI değeri GLS tahmin tekniği 1200 gözlem sayısı için olmuştur. NNFI uyum indeksi değeri tüm değerler için iyi uyum sınırları içinde yer almaktadır. NNFI değeri için ML daha iyi sonuç vermektedir.



Şekil 30. Model 2 için tahmin tekniklerine göre NFI uyum indeksi değerleri grafiği

Şekil 30’da en yüksek NFI değeri 1200 gözlem sayısı için ML tahmin tekniği olurken, en düşük NFI değeri GLS tahmin tekniği 300 gözlem sayısı için olmuştur. NFI uyum indeksi değeri GLS tahmin tekniği 300 ve 600 gözlem sayısında uyumsuzluk, 1200 gözlem sayısında kabul edilebilir uyum göstermektedir. WLS tahmin tekniği 1200 gözlem sayısı, ML tahmin tekniği 300 gözlem sayısı ve GLS tahmin tekniği 600 gözlem sayısındaki değerler kabul edilebilir uyum sınırı içinde yer alırken diğer değerler iyi uyum sınırları içinde yer almaktadır.



Şekil 31. Model 2 için tahmin tekniklerine göre AGFI uyum indeksi değerleri grafiği

Şekil 31’de en yüksek AGFI değeri 1200 gözlem sayısı için GLS tahmin tekniği olurken; en düşük AGFI değeri GLS tahmin tekniği 300 gözlem sayısı için olmuştur. AGFI uyum indeksi değerleri iyi uyum sınırları içinde yer almaktadır. Ayrıca tahmin teknikleri aynı gözlem sayılarındaki değerleri birbirine çok yakın değerler almıştır.

TARTIŞMA

YEM’de değerlendirme yapabilmek için birçok kıstas değerlendirmesi yapmak gerekir. Normallik koşuluna sağlayıp sağlamadığı, farklı parametre tahmin yöntemleri, kullanılan farklı uyum indeksi değerleri, veride bulunan dışsal gizil değişken ile içsel gizil değişken sayısına göre sonuçlar farklılık göstermektedir. YEM’de parametre tahmin testleri ve model uygunluğunun değerlendirmesi için birçok çalışma yapılmıştır. Bu tez çalışmasında normallik koşulu sağlandığında; normal dağılım varsayımına uyan “ML” ve “GLS” parametre tahmin yöntemleri ile model uyum indekslerinden ki kare, ki kare/df, p değeri, GFI, RMSEA, CFI, TLI, SRMR, RMR, IFI, NFI, NNFI, AGFI uyum indeksleri karşılaştırması yapılmıştır. Bu tezde yapılan simülasyon çalışmasında da örneklem sayısını arttırdıkça her iki modelde yakınsama hatası, modelin tanımlama hatası ve negatif varyans hatası azalmıştır hatta 300 gözlemden sonra bu hatalar ile karşılaşılmamıştır. Literatürde de karşılan bu sorun ve örneklem sayısı artmasıyla yakınsama hatası ve negatif varyans hatasının azaldığı bulgusuna paralellik göstermektedir. Boomsma (53) ile Chen ve ark. (54) yaptığı simülasyon çalışmalarında örneklem büyüklüğünün artmasıyla modelin yakınsama hatasının azaldığını söylemişlerdir.

Tablo 8. GFI uyum indeksinin tahmin parametresi ve gözlem sayısına göre Model 1 ve Model 2 için aldığı değerler

Tahmin tekniği	Gözlem Sayısı	GFI model1	GFI model2
ML	300	0.9645	0.9677
ML	600	0.9807	0.9829
ML	1200	0.9889	0.9906
GLS	300	0.9644	0.9674
GLS	600	0.9811	0.9829
GLS	1200	0.9894	0.9908

Tablo 8' e göre GFI uyum indeksi değerleri için her iki modelde de gözlem sayısı arttıkça değerlerin yükseldiği daha iyi uyum verdiği görülmüştür. ML ve GLS tahmin tekniklerine göre aynı gözlem sayılarında değerler birbirine çok yakın çıkmıştır. Özdamar ve Doğan yaptığı çalışmada GFI uyum indeksinin örneklem sayısından etkilendiğini, 150 ve üstü örneklemde kabul edilebilir uyum aralığında olduğunu söylemiştir (55). Jöreskog (26) 2005 yılında yaptığı çalışmada, model uyumunun değerlendirmesinde GFI uyum indeksinin değerlendirmesinin önemli olduğunu savunmakta fakat buna karşın Schermelleh ve Engel (48), 2003 yılında yaptığı çalışmada GFI uyum indeksinin diğer artan uyum indekslerine göre daha yüksek kestirimler gerçekleştirdiğini; modelin doğru ya da yanlış tanımlanmasından GFI uyum indeksi değerinin etkilenmediği sonucuna ulaşmıştır.

Tablo 9. RMSEA uyum indeksinin tahmin parametresi ve gözlem sayısına göre Model 1 ve Model 2 için aldığı değerler

Tahmin tekniği	Gözlem Sayısı	RMSEA model1	RMSEA model2
ML	300	0.0165	0.014
ML	600	0.0146	0.0114
ML	1200	0.015	0.011
GLS	300	0.0125	0.0107
GLS	600	0.0123	0.0099
GLS	1200	0.0133	0.01

Bu tez çalışmasındaki bulgulara göre RMSEA uyum indeksinin örneklem sayısından diğer uyum indekslerine göre çok fazla etkilenmediğini görülmüştür. Parametre tahmin yöntemlerine göre az da olsa farklı sonuçlar verdiğini söyleyebiliriz. Bütün gözlem sayılarında ve tahmin tekniklerinde iyi uyum içerisinde olduğunu, GLS parametre tahmin yöntemi daha iyi

sonular verdiđini, gzlem sayısı arttıka ufakta olsa uyum deđerlerinde iyileşme olduđunu syleyebiliriz. Literatrde yapılan alıřmalara gre; Chen, Bollen ve Curran'ın (54), farklı rnekleme hacimleri ve verilerin farklı dađılım gsterdikleri modellerde, model uyum indekslerini incelediđi simlasyon alıřmasında RMSEA uyum indeksinin en iyi uyum indeksi olduđunu belirtmişlerdir. Chen, Bollen ve Curran alıřmalarında RMSEA uyum indeksinin rnekleme hacminden etkilendiđini ve rnekleme hacmi arttıka bu etkinin ortadan kaybolduđunu ifade etmişlerdir (57). Herzog ve Boomsma'nın (2009) (58), yaptıkları alıřmada RMSEA uyum indeksi deđerinin rnekleme hacmi arttıka azaldıđını sylemiřtir. Cangr ve Ercan'ın (59) yaptıđı alıřmada ise RMSEA uyum indeksinin kk rneklemlere gre byk rneklemlerde daha iyi sonu verdiđini, RMSEA uyum indeksinin rnekleme byklđnden nemli lde etkilenmediđini, hatta rnekleme hacminden bađımsız olduđu savunmuşlardır. Hu ve Bentler (9), ML ve GLS parametre tahmin teknikleri, farklı rnekleme sayılarında, farklı modellerin uyum indeksleri zerindeki etkilerini inceledikleri simlasyon alıřmasında, ML ve GLS tahmin teknikleriyle elde edilen RMSEA uyum indeksinin benzer sonu verdiđini rnekleme sayısına daha az duyarlı olduklarını bulmuşlardır.

Tablo 10. CFI uyum indeksinin tahmin parametresi ve gzlem sayısına gre Model 1 ve Model 2 iin aldıđı deđerler

Tahmin tekniđi	Gzlem Sayısı	CFI model1	CFI model2
ML	300	0.9934	0.9945
ML	600	0.9955	0.9966
ML	1200	0.9961	0.9975
GLS	300	0.9736	0.98
GLS	600	0.9804	0.9865
GLS	1200	0.9825	0.9894

Tablo 11. TLI uyum indeksinin tahmin parametresi ve gzlem sayısına gre Model 1 ve Model 2 iin aldıđı deđerler

Tahmin tekniđi	Gzlem Sayısı	TLI model1	TLI model2
ML	300	0.9934	0.9954
ML	600	0.9948	0.9966
ML	1200	0.9951	0.9969
GLS	300	0.9848	0.9956
GLS	600	0.98	0.989
GLS	1200	0.9783	0.987

Bu tez alıřmasındaki sonulara gre CFI uyum indeksi gzlem sayısından ok nemli derecede etkilenmediđini, her iki parametre yntemi birbirine yakın sonular vermekte olduđu fakat ML parametre tahmin ynteminde daha iyi uyum deđeri aldıđını model 2' nin daha yksek

sonular verdiđi grlmŖtr. TLI uyum indeksi iin ise ML parametre tahmin ynteminde rneklem sayısı arttıa artıŖ gsterdiđi GLS parametre tahmin ynteminde ise azalıŖ gstermiŖtir. Parametre tahmin yntemlerinden etkilendiđini syleyebiliriz. Gzlem sayısı arttıa ML parametre tahmin yntemi iin sabit bir deđere ulaŖtıđını syleyebiliriz fakat aynı durum GLS parametre tahmin yntemi iin syleyemeyiz. Literatrde ise zdamar ve Dođan yaptıđı alıŖmada CFI uyum indeksinin rneklem sayısından az etkilendiđini sylemiŖtir; CFI ve TLI uyum indekslerinin 150 rneklem stnde mkemmelen uyum yakaladıđını sylemiŖtir (55). Lei ve Lomax (1), ML ve GLS parametre tahmin teknikleriyle elde ettikleri CFI ve TLI uyum indekslerinin rneklem hacminden etkilendiđini ancak 500 ve zerinde hacmi olan rneklemlerde (byk rneklem) etkinin ortadan kalktıđını ifade etmiŖlerdir. Hu ve Bentler ise (9) CFI uyum indeksi iin ML ve GLS parametre tahmin tekniklerinde rneklem byklđnden etkilenmediđini ifade etmiŖlerdir.

Tablo 12. SRMR uyum indeksinin tahmin parametresi ve gzlem sayısına gre Model 1 ve Model 2 iin aldıđı deđerler

Tahmin tekniđi	Gzlem Sayısı	SRMR model1	SRMR model2
ML	300	0.0327	0.0316
ML	600	0.024	0.0234
ML	1200	0.0182	0.0179
GLS	300	0.0393	0.0376
GLS	600	0.0268	0.0258
GLS	1200	0.0196	0.019

Bu tez alıŖmasında da rneklem sayısı arttıa SRMR deđerinin dŖtđ gzlemlenmiŖtir. Her iki parametre tahmin ynteminde birbirine ok yakın deđerler aldıđı yani parametre tahmin yntemlerinden etkilenmediđini syleyebiliriz. Iacobucci (2010) (56) rneklem byklđnn model uyum indeksleri zerindeki etkilerini araŖtırdıđı simlasyon alıŖmasında SRMR uyum indeksinin rneklem byklđnn artıŖına paralel dŖŖ gsterdiđini sylemiŖtir. Cangr ve Ercan ise yaptıđı alıŖmada SRMR rneklem sayısından etkilendiđini, parametre tahmin yntemlerinden etkilenmediđini sylemiŖlerdir.

Tablo 13. RMR uyum indeksinin tahmin parametresi ve gözlem sayısına göre Model 1 ve Model 2 için aldığı değerler

Tahmin tekniği	Gözlem Sayısı	RMR model1	RMR model2
ML	300	0.0324	0.0314
ML	600	0.0239	0.0233
ML	1200	0.0182	0.0179
GLS	300	0.0392	0.0375
GLS	600	0.0267	0.0257
GLS	1200	0.0195	0.019

Bu tez çalışmasında RMR uyum indeksinde gözlem sayısı arttıkça düşüş gözlemlenmektedir. Parametre tahmin yönteminden çok fazla etkilenmediğini her iki parametre tahmini için iki modelde de çok fark yoktur. Sivo ve arkadaşlarının (60) 2006 yılındaki çalışmalarında RMR uyum indeksinin örneklem büyüklüğünden etkilendiğini belirtmiştir. Anderson ve Gerbing yaptığı çalışmada RMR indeksinin örneklem büyüklüğünden etkilendiğini ve örneklem büyüklüğü arttıkça model uyumunun iyileştiğini ifade etmiştir. Sivo ve arkadaşları ile Anderson ve Gerbing'in (12) yaptığı çalışmayla paralellik göstermektedir ve örneklem büyüklüğünden etkilendiğini söyleyebiliriz.

Tablo 14. IFI uyum indeksinin tahmin parametresi ve gözlem sayısına göre Model 1 ve Model 2 için aldığı değerler

Tahmin tekniği	Gözlem Sayısı	IFI model1	IFI model2
ML	300	0.9949	0.9967
ML	600	0.996	0.9975
ML	1200	0.9962	0.9977
GLS	300	0.9889	0.9969
GLS	600	0.985	0.9922
GLS	1200	0.9833	0.9908

Yapılan bu tez çalışmasında da gözlem sayısından etkilenmediği görülmüş ayrıca parametre tahmin yöntemlerinden de etkilenmediği görülmüştür. ML, GLS parametre tahmin yöntemleri için denenen gözlem sayıları dışında 75, 100 ve 150 gözlem sayısında da denemiş gözlem sayısı arttıkça değerler sabite yaklaştığı görülmüştür. Doğan (3) (2015) yaptığı çalışmada IFI uyum indeksinin örneklem büyüklüğünden etkilenmediğini ve 300 birimlik örneklem büyüklüğünden sonra bu indeksin sabit bir değere ulaştığını belirtmiştir.

Tablo 15. NNFI uyum indeksinin tahmin parametresi ve gözlem sayısına göre Model 1 ve Model 2 için aldığı değerler

Tahmin tekniği	Gözlem Sayısı	NNFI model1	NNFI model2
ML	300	0.9934	0.9954
ML	600	0.9948	0.9966
ML	1200	0.9951	0.9969
GLS	300	0.9848	0.9956
GLS	600	0.98	0.989
GLS	1200	0.9783	0.9873

Yapılan bu tez çalışmasında NNFI uyum indeksi için her iki model içinde ML, GLS tahmin tekniklerinde 300,600 ve 1200 gözlem sayılarında birbirine çok yakın sonuçlar verdiği görülmüştür. Parametre tahmin yöntemleri bakımından ML parametre tahmin yöntemi daha iyi sonuçlar verdiği; GLS parametre tahmin yönteminde gözlem sayısı arttıkça değerlerin düştüğünü yani iyi uyumun üst sınırından uzaklaştığını söyleyebiliriz. Hu ve Bentler (9) ile Fan ve ark. (61) 1999 yılında yaptığı çalışmalarda, Sivo ve ark. (60) ise 2006 yılında yaptığı çalışmada ve Şen ve Yılmaz'ın (49) 2013 yılında yaptığı çalışmalarında NNFI uyum indeksi değerlerinin örneklem büyüklüğüne az duyarlı olduğunu belirtmişlerdir. Ayrıca Şen (2013) çalışmasında NNFI uyum indeks için 100 birimlik örneklem büyüklüğünün yeterli olacağını vurgulamıştır. Lei ve Lomax (1) ise 2005 yılındaki çalışmalarında ise NNFI uyum indeksi örneklem büyüklüğünden etkilendiğini ve örneklem büyüklüğünün 500 birimden fazla olduğunda bu etkinin ortadan kalktığını bildirmişlerdir.

Tablo 16. NFI uyum indeksinin tahmin parametresi ve gözlem sayısına göre Model 1 ve Model 2 için aldığı değerler

Tahmin tekniği	Gözlem Sayısı	NFI model1	NFI model2
ML	300	0.9491	0.9499
ML	600	0.9724	0.9734
ML	1200	0.9842	0.9854
GLS	300	0.7779	0.8029
GLS	600	0.8689	0.8862
GLS	1200	0.9222	0.9351

NFI uyum indeksi için yapılan bu çalışmada gözlem sayısı ve parametre tahmin yöntemlerinden etkilendiğini söyleyebiliriz. Gözlem sayısı arttıkça daha iyi uyum değeri vermiştir. GLS parametre yönteminde 300 ve 600 gözlem sayısında her iki model içinde uyum sağlamamıştır. NFI uyum indeksi uyum iyiliğine bakılırken tek başına seçilmemelidir.

Schermelleh ve Engel (48) 2003 yılında yaptığı çalışmada modelin doğru ya da yanlış tanımlanmasından NFI uyum indeksi değerlerinin etkilendiği sonucuna ulaşmıştır.

Tablo 17. AGFI uyum indeksinin tahmin parametresi ve gözlem sayısına göre Model 1 ve Model 2 için aldığı değerler

Tahmin tekniği	Gözlem Sayısı	AGFI model1	AGFI model2
ML	300	0.9475	0.9493
ML	600	0.9714	0.9732
ML	1200	0.9836	0.9853
GLS	300	0.9474	0.9489
GLS	600	0.972	0.9732
GLS	1200	0.9843	0.9855

AGFI uyum indeksi değerleri gözlem sayısından etkilendiği görülmüştür. Parametre tahmin yöntemlerinden etkilendiği görülmüştür. Özdamar ve Doğan yaptığı çalışmada AGFI uyum indeksinin örneklem sayısından etkilendiğini, 150 ve üstü örneklemde kabul edilebilir uyum aralığında olduğunu söylemiştir (55).

SONUÇLAR

Yapılan simülasyon çalışması sonucunda; GFI, SRMR, RMR, NFI, AGFI uyum indeksleri örneklem büyüklüğünden etkilendiği tespit edilmiştir. CFI, TLI, NFI uyum indeksi değerleri de parametre tahmin yöntemlerinden etkilendiği tespit edilmiştir. GFI ve AGFI uyum indeksleri tüm gözlem sayılarında ve tahmin tekniklerine göre iki modelde de birbirine çok yakın değerler aldığı gözlemlenmiştir. TLI ve CFI gözlem sayısından etkilenmediği; parametre tahmin yöntemlerinden etkilendiği görülmüştür. SRMR ve RMR uyum indeksleri gözlem sayısından etkilendiği; parametre tahmin yönteminden etkilenmediği görülmüştür. IFI uyum indeksi model 1 için parametre tahmin tekniklerinden etkilendiği, model 2 için etkilenmediğini her iki model için ancak gözlem sayısından etkilenmediğini söyleyebiliriz. NNFI ve RMSEA uyum indeksleri parametre tahminleri ve gözlem sayısından etkilenmemekte olduğu görülmüştür. AGFI uyum indeksinin tahmin tekniğinden etkilenmediği, ancak gözlem sayısından etkilendiği görülmüştür.

GFI, RMSEA, RMR, IFI, AGFI uyum indeksleri tüm değerler için iyi uyum değerleri arasında yer almaktadır.

NFI uyum indeksinin GLS tahmin tekniklerinde 300 ve 600 gözlemde uyum göstermediği, ML tahmin tekniği 300 gözlem, GLS 1200 gözlemde kabul edilebilir uyum, diğer değerler iyi uyum gösterdiği görülmüştür.

Her iki modelde de iyi uyum, kabul edilebilir uyum, uyumsuzluk gösteren deęer gözeleri aynı gözlem sayısı ve parametre tahmininde olduęu görölmüştür.

Model 1 ve model 2 için en çok gözlem sayısından ve parametre tahmininden etkilenen uyum indeksinin NFI olduęu gözlemlenmiştir. IFI, TLI, CFI uyum indeksleri NFI uyum indeksine göre daha az etkilendięi gözlemlenmiştir. RMSEA, NNFI, GFI ve AGFI uyum indeksleri neredeyse etkilenmedięi görölmüştür.

Yapılan bu normal dağılım gösteren ve 300, 600, 1200 gözlem içeren iki çeşit modelden oluşan simülasyon çalışmasında, her iki model içinde RMSEA ve NNFI uyum indeksleri önerilebilirken; yine her iki model için NFI uyum indeksinin tek başına belirleyici deęer olarak kullanılmaması önerilir. Gözlem sayısı 300 gözlem genellikle literatürde kabul edilmekle beraber yapılan bu simülasyon çalışmasında 600 gözlem ve üstünün her iki parametre tahmin tekniğinde daha iyi sonuç verdięi; 1000 ve üstü gözlem sayısında uyum iyilięi deęerleri sabit bir deęere yaklaştıęı görölmüştür. Literatürde geęen ve kullanılan parametre tahmin testlerinde bu tez çalışmasında normal varsayımı adı altında olduęu için kullanılan “ML” ve “GLS” parametre tahmin tekniklerinden “ML” parametre tahmin tekniğini büyük çoğunlukla daha iyi sonuç verdięi söylenebilir.

ÖZET

Yapısal eşitlik modeli (YEM) gözlemlenebilen ve gözlemlenemeyen değişkenler arası ilişkileri bir mantık dahilinde modelleyerek çözümü kolaylaştırmaya yarayan ve direk ve indirekt etkileri ortaya koyan istatistiksel teknikler toplamıdır. Modeli belirleme, tahmin etme ve test ederek nedensel ve teorik ilişkileri ortaya koyan yöntemler bütünüdür. Bu tez çalışmasında YEM varsayımları sağlayan iki adet model R istatistiksel programda simülasyon çalışması yapılarak oluşturulmuştur. Yapısal eşitlik modellemesinde dışsal gizil değişken sayısına göre oluşturulan iki farklı model, üç dışsal gizil değişkenli Model 1 ve dört dışsal gizil değişkenli Model 2 baz alınarak çok değişkenli normallik varsayımının sağlandığı simülasyon çalışmasında “tahmin tekniği” ve “örneklem hacmi” etmenlerinin etkilerini araştırmak ve bu etmenlerin uyum indeksleri üzerindeki etkileri doğrultusunda model uyum indekslerini karşılaştırmaktır. Bu amaç çerçevesinde, çok değişkenli normallik varsayımının sağlandığı durumlarda ML ve GLS parametre tahmin yöntemleri kullanarak 300, 600, 1200 birimlik örneklem büyüklüklerinde oluşturulan yapısal eşitlik modellemesine ilişkin model uyum indeksleri karşılaştırmalı olarak değerlendirilmiştir.

Yapılan simülasyon çalışmasında iterasyon sayısı ise 1000 olarak belirlenmiştir. Simülasyon çalışması sonucunda, örneklem büyüklüğü ve standart sapma, korelasyon matrisi ve buna bağlı oluşturulan korelasyon matrisi değişimine bağlı optimizasyon, negatif varyans

tahmini problemleri ve tanımlama hataları ile karşılaşmıştır. Bu problemlerin örneklem büyüklüğünün artmasıyla ortadan kalktığı gözlenmiştir. Değişkenler arası korelasyonun artmasıyla da bu sorunların ortadan kalktığı gözlenmiştir.

Çalışmada kurulan modeller (Model 1, Model 2) için en çok gözlem sayısından ve parametre tahmininden etkilenen uyum indeksi NFI olduğu gözlemlenmiştir. IFI, TLI, CFI uyum indeksleri NFI uyum indeksine göre daha az etkilendiği gözlemlenmiştir. RMSEA, GFI, NNFI ve AGFI uyum indeksleri neredeyse etkilenmemektedir. Model 1 ve Model 2 için RMSEA ve NNFI uyum indeksleri tercih edilmelidir. RMSEA ve NNFI uyum iyiliği indekslerinin tercih edilmesi; NFI uyum iyiliği indeksinin ise gözlem sayısından en çok etkilenen olduğu için tercih edilmemesi önerilir. Ayrıca gözlem sayısı arttıkça tüm uyum iyiliği indeksleri daha iyi sonuç verdiği önerilen gözlem sayısının 500 ve üstü gözlem sayısı olduğu düşünülmektedir.

Anahtar Kelimeler: Yapısal Eşitlik Modeli, Uyum iyiliği indeksleri, Parametre tahmin yöntemi, Gözlem sayısı, Simülasyon çalışması

COMPARISON OF STRUCTURAL EQUATION MODEL AND MODEL COMPLIANCE TESTS IN DATA SETS WITH DIFFERENT SIZES: EXAMPLE OF SIMULATION STUDY

SUMMARY

Structural equation model is the sum of all statistical methods used for logical modeling the relationships between observable and unobservable variables, facilitating its results and exhibiting direct and indirect effects. It is a set of methods that establish causal and theoretical relations through determining, predicting and testing the model. The present thesis study created two models ensuring SEM assumptions through simulation study in R statistical software. In structural equation modelling, two different models are created according to the number of exogenous latent variables as Model 1 with three exogeneous latent variables and Model 2 with four exogenous latent variables. The simulation study, which is based on these two models and ensures multivariate normality assumption, aims to analyze the effects of “estimation technique” and “sample size” and compare model fit indices according to their effects on fit indices. Within this scope, when multivariate normality assumption is ensured, the present thesis study comparatively evaluates model fit indices regarding structural equation modelling created in 300, 600 and 1200 units of sample size using ML and GLS parameter estimation methods.

Iteration number is determined as 1000 in simulation study. Simulation study results in negative variance estimation problems, identification errors and optimization problems due to sample size and standard deviation, correlation matrix and correspondingly formed correlation

matrix. These problems are observed to be removed upon increasing sample size. In addition, increasing intervariable correlation is also observed to remove these problems.

Among models established in the study (Model 1, Model 2), NFI is observed to be the fit index mostly affected by the number of observations and parameter estimation. IFI, TLI, CFI fit indices are found to be affected less than NFI fit index. RMSEA, GFI, NNFI and AGFI fit indices are almost not affected. While RMSEA and NNFI fit indices can be advised for Model 1 and Model 2. RMSEA and NNFI goodness of fit indices should be preferred; however, NFI goodness of fit index should not be preferred due to its being mostly affected by the number of observations. In addition, as the number of observations increases, the number of observations suggested for giving better results for all goodness of fit indices is thought to be “500 and above”.

Keywords: Structural Equation Model, Goodness of Fit Indices, Parameter Estimation Method, Number of Observation, Simulation Study.

KAYNAKLAR

1. Lei M, Lomax RG. The effect of varying degrees of nonnormality in structural equation modeling. *Structural equation modeling: A Multidisciplinary Journal* 2005;12(1):1-27.
2. Lomax RG, Schumacker RE. A beginner's guide to structural equation modeling. 3rd ed. New York: Routledge, 2004:55-120.
3. Doğan İ. Farklı Veri Yapısı ve Örneklem Büyüklüklerinde Yapısal Eşitlik Modellerinin Geçerliği ve Güvenirliğinin Değerlendirilmesi (tez). Eskişehir: Eskişehir Osmangazi Üniversitesi Sağlık Bilimleri Enstitüsü; 2015.
4. Çokluk Ö, Şekercioğlu G, Büyüköztürk Ş. Sosyal bilimler için çok değişkenli istatistik SPSS ve LISREL uygulamaları. Ankara: Pegem Akademi, 2016:251-400.
5. Şimşek ÖF. Yapısal eşitlik modellemesine giriş temel ilkeler ve LISREL uygulamaları. Ankara: Ekinoks, 2007.
6. Cangür Ş. Yapısal Eşitlik Modellemesinde Kullanılan Model Uyum İndekslerinin Karşılaştırılması (tez). Bursa: Uludağ Üniversitesi Sağlık Bilimleri Enstitüsü; 2012.
7. Bollen KA. *Structural equations with latent variables*. New York: John Wiley and Sons Inc, 1989.
8. Kline RB. *Principles and practice of structural equation modeling* 3rd ed. New York: The Guilford Press, 2011.

9. Hu LT, Bentler PM. Cutoff criteria for fit indexes in covariance structure analysis: conventional criteria versus new alternatives. *Structural Equation Modeling: a Multidisciplinary Journal* 1999;6(1):1-55.
10. Hoyle RH. *Structural equation modeling: concepts, issues, and applications*. California: Sage Publications Inc, 1995.
11. Raykov T, Marcoulides GA. *A first course in structural equation modeling*. 2nd ed. New Jersey: Lawrence Erlbaum Associates Publishers, 2012.
12. Anderson JC, Gerbing DW. The effect of sampling error on convergence, improper solutions, and goodness-of-fit indices for maximum likelihood confirmatory factor analysis. *Psychometrika* 1984;49(2):155-73.
13. Raykov T, Marcoulides GA. On multilevel model reliability estimation from the perspective of structural equation modeling. *Structural Equation Modeling: A Multidisciplinary Journal*. 2006;13(1):130-41.
14. Byrne BM. *Structural equation modeling with AMOS: basic concepts, applications, and programming*. 2nd ed. New York: Routledge/Taylor & Francis Group, 2010.
15. Bayram N. *Yapısal eşitlik modellemesine giriş, AMOS uygulamaları*. Bursa: Ezgi Kitabevi, 2013.
16. Umurca NS. *GSM Operatörlerinin Hizmet Kalitesi ile Müşteri Memnuniyeti Arasındaki İlişkinin Yapısal Eşitlik Modellemesi ile Araştırılması (tez)*. İstanbul: İstanbul Aydın Üniversitesi Sosyal Bilimleri Enstitüsü; 2017.
17. Çelik HE, Yılmaz V. *LISREL 9.1 ile yapısal eşitlik modellemesi: temel kavramlar-uygulamalar-programlama*. 3. baskı. Ankara: Anı Yayıncılık, 2016.
18. Özdamar K. *Paket programlar ile istatistiksel veri analizi (çok değişkenli analizler)*. 5. baskı. Eskişehir: Kaan Kitabevi, 2004.
19. Horzum MB, Tuncay A, Padır MA. Adaptation of big five personality traits scale to Turkish culture. *Sakarya University Journal of Education*, 2017;7(2):398-408.
20. Steiger JH, Lind JC. Statistically based tests for the number of common factors. At the Annual Meeting of the Psychometric Society 1980.
21. Ayyıldız H, Cengiz E. Pazarlama modellerinin testinde kullanılacak yapısal eşitlik modeli (YEM) üzerine kavramsal bir inceleme. *Süleyman Demirel Üniv İktisadi ve İdari Bilimler Fakültesi Derg* 2006;11(2):63-84.

22. Demiralay T. Hekimlerde Örgütsel Sessizliğin Yapısal Eşitlik Modeli ile İncelenmesi (tez). Edirne: Trakya Üniversitesi Sosyal Bilimler Enstitüsü; 2014.
23. Kaplan D. Structural equation modeling: foundations and extensions. 2nd ed. California: Sage Publications Inc, 2008.
24. Johnson RA, Wichern DW. Applied multivariate statistical analysis. New Jersey: Pearson Education Inc, 2002:481-529.
25. Akıncı ED. Yapısal Eşitlik Modellerinde Bilgi Kriterleri (tez). İstanbul: Mimar Sinan Güzel Sanatlar Üniversitesi Fen Bilimleri Enstitüsü; 2007.
26. Jöreskog KG. A general approach to confirmatory maximum likelihood factor analysis. Psychometrika 1969;34(2):183-202.
27. Brown TA. Confirmatory factor analysis for applied research. Kenny DA, (Ed). New York: A Division of Guilford Publications Inc; 2006. p.40-49.
28. Doğan M. Doğrulayıcı Faktör Analizinde Örneklem Hacmi, Tahmin Yöntemleri Ve Normalliğin Uyum Ölçütlerine Etkisi (tez). Eskişehir: Eskişehir Osmangazi Üniversitesi Fen Bilimleri Enstitüsü; 2013.
29. Meydan CH, Şeşen H. Yapısal eşitlik modellemesi AMOS uygulamaları. Ankara: Detay Yayıncılık; 2011.
30. Yılmaz V, Varol S. 4. Hazir yazilimler ile yapisal eşitlik modellemesi: AMOS, EQS, LISREL. Dumlupınar Üniversitesi Sosyal Bilimler Dergisi 2015;(44):28-44.
31. Arslan MST. Ordinal Değişkenli Yapısal Eşitlik Modellerinde Kullanılan Parametre Tahmin Yöntemlerinin Karşılaştırılması (tez). Eskişehir: Eskişehir Osmangazi Üniversitesi Fen Bilimleri Enstitüsü; 2011.
32. Hershberger SL. The growth of structural equation modeling: 1994-2001. Structural Equation Modeling: A Multidisciplinary Journal. 2003;10(1):35-46.
33. MacCallum RC, Wegener DT, Uchino BN, Fabrigar LR. The problem of equivalent models in applications of covariance structure analysis. Psychological Bulletin 1993;114(1):185-199.
34. Raykov T, Penev S. On structural equation model equivalence. Multivariate Behavioral Research 1999;34(2):199-244.
35. Mulaik SA. Linear causal modeling with structural equations. New York: Chapman and Hall/CRC, 2009.

36. Özdamar K. Eğitim, sağlık ve davranış bilimlerinde ölçek ve test geliştirme yapısal eşitlik modellenmesi. Eskişehir: Nisan Kitabevi Yayınları, 2016.
37. Grace JB. Structural equation modeling and natural systems. Louisiana: Cambridge University Press, 2006.
38. Anderson JC, Gerbing DW. Structural equation modeling in practice: a review and recommended two-step approach. *Psychological Bulletin* 1988;103(3):411-23.
39. Mueller RO. Structural equation modeling: back to basics. *Structural Equation Modeling: A Multidisciplinary Journal* 1997;4(4):353-69.
40. Erkorkmaz Ü, Etikan İ, Demir O, Özdamar K, Sanisoğlu SY. Doğrulayıcı faktör analizi ve uyum indeksleri. *Türkiye Klinikleri Journal of Medical Sciences* 2013;33(1):210-23.
41. Tabachnick BG, Fidell LS, Ullman JB. Using multivariate statistics. 6th ed. New Jersey: Pearson; 2007: 681-785.
42. Tanguma J. Effects of sample size on the distribution of selected fit indices: a graphical approach. *Educational and Psychological Measurement* 2001;61(5):759-76.
43. Hooper D, Coughlan J, Mullen RM. Structural equation modelling: guidelines for determining model fit. *Electronic Journal of Business Research Methods* 2008;6(1):53-60.
44. Vieira AL. Interactive LISREL in practice. New York: Springer, 2011:73-86.
45. Weng LJ, Cheng CP. Why might relative fit indices differ between estimators? *Structural Equation Modeling: A Multidisciplinary Journal* 1997;4(2):121-8.
46. Bentler PM. EQS structural equations program manual. Encino: Multivariate Software Inc, 1995:114-7.
47. Bentler PM, Bonett DG. Significance tests and goodness of fit in the analysis of covariance structures. *Psychological Bulletin* 1980;88(3):588-606.
48. Schermelleh-Engel K, Moosbrugger H, Müller H. Evaluating the fit of structural equation models: tests of significance and descriptive goodness-of-fit measures. *Methods of Psychological Research Online* 2003;8(8):23-74.
49. Şen R, Yılmaz V. Model belirlemesi, örneklem hacmi ve tahmin yönteminin yapısal eşitlik modelleri uyum ölçütlerine etkisi. *Dumlupınar Üniversitesi Sosyal Bilimler Dergisi* 2013;38:239-52.

50. Barrett PT. Structural equation modelling: adjudging model fit. *Personality and Individual Differences* 2007;42(5):815-24.
51. Hair J, Anderson R, Tatham R, Black W. *Multivariate data analysis*. 5th ed. New Jersey: Prentice Hall, 1998:639-65.
52. Bozdogan H. Model selection and Akaike's information criterion (AIC): The general theory and its analytical extensions. *Psychometrika* 1987;52(3):345-70.
53. Boomsma A. *On The Robustness of LISREL (Maximum Likelihood Estimation) Against Small Sample Size and Non-Normality (Dissertation)*. Groningen: University of Groningen; 1983.
54. Chen F, Bollen KA, Paxton P, Curran PJ, Kirby JB. Improper solutions in structural equation models: Causes, consequences, and strategies. *Sociological Methods & Research* 2001;29(4):468-508.
55. Doğan İ, Özdamar K. The effect of different data structures, sample sizes on model fit measures. *Communications in Statistics-Simulation and Computation* 2017;46(9):7525-33.
56. Iacobucci D. Structural equations modeling: fit indices, sample size, and advanced topics. *Journal of Consumer Psychology* 2010;20(1):90-8.
57. Chen F, Curran PJ, Bollen KA, Kirby J, Paxton P. An empirical evaluation of the use of fixed cutoff points in RMSEA test statistic in structural equation models. *Sociological Methods & Research* 2008;36(4):462-94.
58. Herzog W, Boomsma A. Small-sample robust estimators of noncentrality-based and incremental model fit. *Structural Equation Modeling: A Multidisciplinary Journal* 2009;16(1):1-27.
59. Cangur S, Ercan I. Comparison of model fit indices used in structural equation modeling under multivariate normality. *Journal of Modern Applied Statistical Methods* 2015;14(1):152-67.
60. Sivo SA, Fan X, Witta EL, Willse JT. The search for "optimal" cutoff properties: fit index criteria in structural equation modeling. *The Journal of Experimental Education* 2006;74(3):267-88.
61. Fan X, Thompson B, Wang L. Effects of sample size, estimation methods, and model specification on structural equation modeling fit indexes. *Structural Equation Modeling: A Multidisciplinary Journal* 1999;6(1):56-83.

ŞEKİLLER LİSTESİ

ŞEKİLLER

Şekil 1. Eşitlikleriyle gösterilen gizil değişken modeline ait yol diyagramı	12
Şekil 2. Yol analizi diyagramı yapısal eşitlik model gösterimi.....	14
Şekil 3. Yapısal eşitlik modeli temel aşamaları akış diyagramı (8)	15
Şekil 4. Model 1 yol diyagramı.....	36
Şekil 5. Model 2 yol diyagramı.....	39
Şekil 6. Model 1 için tahmin tekniklerine göre ki kare değerleri grafiği	46
Şekil 7. Model 1 için tahmin tekniklerine göre ki kare serbestlik derecesi.....	47
Şekil 8. Model 1 için tahmin tekniklerine göre p değerleri grafiği	48
Şekil 9. Model 1 için tahmin tekniklerine göre GFI uyum indeksi değerleri grafiği	49
Şekil 10. Model 1 için tahmin tekniklerine göre RMSEA uyum indeksi	50
Şekil 11. Model 1 için tahmin tekniklerine göre CFI uyum indeksi.....	51
Şekil 12. Model 1 için tahmin tekniklerine göre TLI uyum indeksi	52

Şekil 13. Model 1 için tahmin tekniklerine göre SRMR uyum indeksi	53
Şekil 14. Model 1 için tahmin tekniklerine göre RMR uyum indeksi	54
Şekil 15. Model 1 için tahmin tekniklerine göre IFI uyum indeksi değerleri grafiği.....	54
Şekil 16. Model 1 için tahmin tekniklerine göre NNFI uyum indeksi	55
Şekil 17. Model 1 için tahmin tekniklerine göre NFI uyum indeksi	56
Şekil 18. Model 1 için tahmin tekniklerine göre AGFI uyum indeksi	57
Şekil 19. Model 2 için tahmin tekniklerine göre ki kare değerleri grafiği	60
Şekil 20. Model 2 için tahmin tekniklerine göre ki kare serbestlik	61
Şekil 21. Model 2 için tahmin tekniklerine göre p değerleri grafiği	62
Şekil 22. Model 2 için tahmin tekniklerine göre GFI uyum indeksi.....	63
Şekil 23. Model 2 için tahmin tekniklerine göre RMSEA uyum indeksi	64
Şekil 24. Model 2 için tahmin tekniklerine göre CFI uyum indeksi	65
Şekil 25. Model 2 için tahmin tekniklerine göre TLI uyum indeksi	66
Şekil 26. Model 2 için tahmin tekniklerine göre SRMR uyum indeksi	67
Şekil 27. Model 2 için tahmin tekniklerine göre RMR uyum indeksi	68
Şekil 28. Model 2 için tahmin tekniklerine göre IFI uyum indeksi	69
Şekil 29. Model 2 için tahmin tekniklerine göre NNFI uyum indeksi	70
Şekil 30. Model 2 için tahmin tekniklerine göre NFI uyum indeksi.....	71
Şekil 31. Model 2 için tahmin tekniklerine göre AGFI uyum indeksi değerleri grafiği	72

TABLolar

Tablo 1. Yol analizinde kullanılan semboller(17).....	10
Tablo 2. Yol analizi diyagramında kullanılan semboller ve karşılıkları (17)	11
Tablo 3. Uyum indeksleri güven aralıkları	33
Tablo 4. ML tahmin tekniğinde uyum indeksi değerleri	43
Tablo 5. GLS tahmin tekniğinde uyum indeksi değerleri	44

Tablo 6. Model 2 için ML tahmin tekniğine göre uyum indeksi değerleri	58
Tablo 7. Model 2 için GLS tahmin tekniğine göre uyum indeksi değerleri.....	59
Tablo 8. GFI uyum indeksinin tahmin parametresi ve gözlem sayısına göre Model 1 ve Model 2 için aldığı değerler	74
Tablo 9. RMSEA uyum indeksinin tahmin parametresi ve gözlem sayısına göre Model 1 ve Model 2 için aldığı değerler	74
Tablo 10. CFI uyum indeksinin tahmin parametresi ve gözlem sayısına göre Model 1 ve Model 2 için aldığı değerler	75
Tablo 11. TLI uyum indeksinin tahmin parametresi ve gözlem sayısına göre Model 1 ve Model 2 için aldığı değerler	75
Tablo 12. SRMR uyum indeksinin tahmin parametresi ve gözlem sayısına göre Model 1 ve Model 2 için aldığı değerler	76
Tablo 13. RMR uyum indeksinin tahmin parametresi ve gözlem sayısına göre Model 1 ve Model 2 için aldığı değerler	77
Tablo 14. IFI uyum indeksinin tahmin parametresi ve gözlem sayısına göre Model 1 ve Model 2 için aldığı değerler	77
Tablo 15. NNFI uyum indeksinin tahmin parametresi ve gözlem sayısına göre Model 1 ve Model 2 için aldığı değerler	78
Tablo 16. NFI uyum indeksinin tahmin parametresi ve gözlem sayısına göre Model 1 ve Model 2 için aldığı değerler	78
Tablo 17. AGFI uyum indeksinin tahmin parametresi ve gözlem sayısına göre Model 1 ve Model 2 için aldığı değerler	79

ÖZGEÇMİŞ

Ad Soyad: Beyza İrem DALKILIÇ

Doğum tarihi ve yeri : 25.08.1992- EDİRNE

İletişim adresi: mermerbeyza@gmail.com

Eğitim

- Lise : Keşan Anadolu Lisesi
Fen 2006-2010
- Üniversite : Mimar Sinan Güzel Sanatlar Üniversitesi
İstatistik 2010-2014
- Yüksek Lisans : Trakya Üniversitesi
Biyoistatistik ve Tıbbi Bilişim 2016-

Deneyim

- Türkiye İş Bankası 2016-2018

EKLER

- Ek-1** :Model 1 için oluşturulan simülasyon çalışması R kodu
- Ek-2** :Model 2 için oluşturulan simülasyon çalışması R kodu
- Ek-3** :Model 1 yol diyagramı
- Ek-4** :Model 2 yol diyagramı

Ek-1

Model 1 için oluşturulan simülasyon çalışması R kodları

```
library(miscTools)
library(lavaan)
library(corpcor)
library(mvtnorm)
library(semPlot)
library(foreach)

ort1<-rep(100,14)

RR1<-symMatrix(c(1.0,0.5,0.3,0.3,0.3,0.3,0.3,0.3,0.3,0.3,0.3,0.3,0.3,0.3,
  1.0,0.3,0.3,0.3,0.3,0.3,0.3,0.3,0.3,0.3,0.3,0.3,0.3,0.3,
  1.0,0.5,0.5,0.5,0.3,0.3,0.3,0.3,0.3,0.3,0.3,0.3,0.3,
  1.0,0.5,0.5,0.3,0.3,0.3,0.3,0.3,0.3,0.3,0.3,0.3,
  1.0,0.5,0.3,0.3,0.3,0.3,0.3,0.3,0.3,0.3,
  1.0,0.3,0.3,0.3,0.3,0.3,0.3,0.3,0.3,
  1.0,0.5,0.5,0.5,0.3,0.3,0.3,0.3,
  1.0,0.5,0.6,0.3,0.3,0.3,0.3,
  1.0,0.5,0.3,0.3,0.3,0.3,
  1.0,0.3,0.3,0.3,0.3,
  1.0,0.5,0.5,0.5,
  1.0,0.5,0.5,
  1.0,0.5,
  1.0),14)

ss1<- rep(1,14)
kovaryans1<-cor2cov(RR1,ss1)

R1<-make.positive.definite(kovaryans1)
is.positive.definite(R1)
```

Ek -1 devam

Ek-1 devam Model 1 için oluşturulan simülasyon çalışması R kodları

```
##### Simulasyon #####
Results<- NULL
set.seed(1113)
Results = data.frame(foreach(i=1:1000, .combine = rbind) %do% {
  data<-rmvnorm(100, mean = ort1, sigma = R1, method="chol", pre0.9_9994 = FALSE )
  colnames(data)<-
c("y1","y2","x1","x2","x3","x4","x5","x6","x7","x8","x9","x10","x11","x12")
  mymodel <- '
n1 =~ y1 + y2
s1 =~ x1 + x2 + x3 + x4
s2 =~ x5 + x6 + x7 + x8
s3 =~ x9 + x10 + x11 + x12
n1 ~ s1 + s2 + s3
'
  myfit<-NULL
  myfit <- lavaan::sem(mymodel, data = data)
myfit <- lavaan::sem(mymodel, data = data, estimator = "GLS")
myfit <- lavaan::sem(mymodel, data = data, estimator = "ULS")
myfit <- lavaan::sem(mymodel, data = data, estimator = "WLS")

  fitMeasures(myfit, c("chisq", "df","pvalue", "gfi", "rmsea","cfi","tli","srmr","rmr","ifi",
"nnfi", "nfi", "agfi" ))
})
Result <- NULL
Result<-round(apply(Results,2,mean),4)
Result
semPaths(myfit, whatLabels="par", layout = "tree")
```

Ek-2

Model 2 için oluşturulan simülasyon çalışması R kodları


```
library(miscTools)
library(lavaan)
library(corpcor)
library(mvtnorm)
library(semPlot)
library(foreach)
ort2<-rep(100,14)
RRmodel_2 <- symMatrix(c(1.0,0.5,0.3,0.3,0.3,0.3,0.3,0.3,0.3,0.3,0.3,0.3,0.3,0.3,
      1.0,0.3,0.3,0.3,0.3,0.3,0.3,0.3,0.3,0.3,0.3,0.3,0.3,0.3,
      1.0,0.5,0.5,0.3,0.3,0.3,0.3,0.3,0.3,0.3,0.3,0.3,0.3,0.3,
      1.0,0.5,0.3,0.3,0.3,0.3,0.3,0.3,0.3,0.3,0.3,
      1.0,0.3,0.3,0.3,0.3,0.3,0.3,0.3,0.3,
      1.0,0.5,0.5,0.3,0.3,0.3,0.3,0.3,0.3,
      1.0,0.5,0.3,0.3,0.3,0.3,0.3,0.3,
      1.0,0.3,0.3,0.3,0.3,0.3,0.3,
      1.0,0.5,0.6,0.3,0.3,0.3,
      1.0,0.5,0.3,0.3,0.3,
      1.0,0.3,0.3,0.3,
      1.0,0.5,0.5,
      1.0,0.5,
      1.0),14)
ss2<-c(rep(1, 14))
kovaryans2<-cor2cov(RRmodel_2,ss2)
R2<-make.positive.definite(kovaryans2)
is.positive.definite(R2)
```

Ek-2 devam Model 2 için oluşturulan simülasyon çalışması R kodları

```
Results<- NULL
set.seed(1113)
Results = data.frame(foreach(i=1:1000, .combine = rbind) %do% {
  data2<-rmvnorm(300, mean = ort2,sigma = R2, method="chol", pre0.9_9994 = FALSE)

  colnames(data2)<-c("y1","y2","x1","x2","x3","x4","x5","x6","x7","x8","x9","x10","x11","x12")
  mymodel2 <- '
n1 =~ y1 + y2
s1 =~ x1 + x2 + x3
s2 =~ x4 + x5 + x6
s3 =~ x7 + x8 + x9
s4 =~ x10 + x11 + x12
n1 ~ s1 + s2 + s3 + s4
'
  myfit2<-NULL
  myfit2 <- lavaan::sem(mymodel2, data = data2, estimator = "ML")
  myfit2 <- lavaan::sem(mymodel2, data = data2, estimator = "GLS")
  myfit2 <- lavaan::sem(mymodel2, data = data2, estimator = "ULS")
  myfit2 <- lavaan::sem(mymodel2, data = data2, estimator = "WLS")
  fitMeasures(myfit2, c("chisq", "df", "pvalue", "gfi", "rmsea", "cfi", "tli", "srmr", "rmr", "ifi",
"nnfi", "nfi", "agfi"))
})
Result2 <- NULL
Result2<-round(apply(Results,2,mean),4)
Result2
SemPaths(myfit2, whatLabels="par", layout = "tree")
```

Ek-3
Model 1 yol diyagramı



Ek-4
Model 2 yol diyagramı

