

# Yapısal Eşitlik Modelinde Normallik İhlali: Bootstrap ML ve Bayesci İstatistik\*

Murat YILDIRIM<sup>1</sup> 

<sup>1</sup>Dr. Öğr. Üyesi, Tokat Gaziosmanpaşa Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, İşletme Bölümü, Tokat, Türkiye  
murat.myildirim@gop.edu.tr

## Makale Bilgileri

## ÖZ

**Makale Geçmişi**  
**Geliş:** 19/06/2023  
**Kabul:** 27/10/2023  
**Yayın:** 31/12/2023

**Anahtar Kelimeler:**  
Bootstrapping,  
Bayesci İstatistik,  
Yapısal Eşitlik  
Modeli.  
**JEL Kodları:** C14,  
C11, C51.

Yapısal eşitlik modeli çalışmalarında çoğunlukla klasik istatistik tercih edilmektedir ve bu nedenle de verilerin çok değişkenli normallik varsayımını sağlaması beklenir. Fakat ilgili literatüre incelendiğinde, çalışmaların birçoğunda bu varsayımın göz ardı edilerek devam edildiği tespit edilmiştir. Klasik istatistik kullanılarak gerçekleştirilen YEM çalışmalarında verilerin çok değişkenli normallik varsayımını sağlamaması, abartılmış ki kare değerleri nedeniyle aday modelin reddedilmesine ve model parametrelerinin testinde yanlış çıkarımlara sebebiyet verecek standart hataların hafife alınması gibi önemli sorunları ortaya çıkarmaktadır. Bu önemli sorunların üstesinden gelmek için klasik istatistikte önerilen stratejilerden biri Bootstrapping yaklaşımıdır. Bu yaklaşıma ek olarak günümüzde oldukça popüler olan Bayesci istatistiğin kullanımı önerilmektedir. Bu araştırmanın amacı, çok değişkenli normallik varsayımını ihlal eden bir YEM çalışmasında Bootstrap ML ile Bayesci yaklaşımı karşılaştırmaktır. Araştırmanın verisi Gelişmeleri Kaçırma Korkusu ölçeğine ait olup çok değişkenli normallik varsayımı Mardia'nın çok değişkenli basıklık ölçüsü ele alınarak değerlendirilmiştir. Bootstrap ML ile tahminleme işlemi gerçekleştirildiğinde tüm faktör yüklerinin anlamlı olduğu ve model uyumunda ise Bollen-Stine Bootstrap p değerinin 0,287 olduğu gözlemlenmiştir. Aynı model ve veriler için Bayesci istatistikte tahminler elde edildiğinde Bootstrap ML ile yakın sonuçlar elde edilmiş olup sonsal tahmin kontrolü 0,40 olarak tespit edilmiştir. Bu bulgulara göre her iki strateji de aynı sonuçlar vererek, mevcut modelin verilere uygun olduğunu bildirmiştir.

## Normality Violation in the Structural Equation Model: Bootstrap ML and Bayesian Statistics

## Article Info

## ABSTRACT

### Article History

**Received:** 19/06/2023  
**Accepted:** 27/10/2023  
**Published:** 31/12/2023

### Keywords:

Bootstrapping,  
Bayesian Statistics,  
Structural Equation  
Model.  
**Jel Codes:** C14, C11,  
C51.

Classical statistics are primarily used in structural equation model studies; therefore, the data are expected to provide the assumption of multivariate normality. However, when the relevant literature is examined, it has been determined that most studies have ignored this assumption. In SEM studies performed using classical statistics, the fact that the data do not provide the assumption of multivariate normality reveals essential problems, such as the rejection of the candidate model due to inflated chi-square values and the underestimation of the standard errors that will cause false inferences in the model parameters test. One of the strategies proposed in classical statistics to overcome these critical problems is the Bootstrapping approach. In addition to this approach, using Bayesian statistics, which is very popular today, is suggested. This study aims to compare Bootstrap ML and Bayesian approach in an SEM study that violates the multivariate normality assumption. The study's data belong to the Fear of Missing out on Developments scale, and the multivariate normality assumption was evaluated by considering Mardia's multivariate kurtosis measure. When the estimation process was performed with Bootstrap ML, it was observed that all factor loads were significant, and the Bollen-Stine Bootstrap p value was .287 in model fit. When estimations were obtained in Bayesian statistics for the same model and data, close results were obtained with Bootstrap ML, and the posterior estimation control was determined as .40. According to these findings, both strategies gave the same results and reported that the current model was suitable for the data.

**Atf/Citation:** Yıldırım, M. (2023). Yapısal Eşitlik Modelinde Normallik İhlali: Bootstrap ML ve Bayesci İstatistik, *Necmettin Erbakan Üniversitesi Siyasal Bilgiler Fakültesi Dergisi*, 5(2), 132-145.



"This article is licensed under a [Creative Commons Attribution-NonCommercial 4.0 International License](https://creativecommons.org/licenses/by-nc/4.0/). (CC BY-NC 4.0)"

\*Bu çalışma, "ASSESSMENT AND MANAGEMENT OF NORMALITY VIOLATION IN THE STRUCTURAL EQUATION MODELING: BOOTSTRAPPING AND BAYESIAN STATISTICS" başlığı ile 7th INTERNATIONAL BİLTEK CONGRESS ON CURRENT DEVELOPMENTS IN SCIENCE, TECHNOLOGY AND SOCIAL SCIENCES kongresinde özet bildiri olarak sunulmuştur. Etik Komite Onayı: Tokat Gaziosmanpaşa Üniversitesi Sosyal ve Beşeri Bilimler Araştırmaları Etik Kuruluna başvuruda bulunulmuş ve 27.04.2022 tarih 7. oturum ve 01-62 karar sayısı ile gerekli etik izinler alınmıştır.

## GİRİŞ

Yapısal eşitlik modeli (YEM) kullanarak herhangi bir çalışma yürütmeden önce bilinmesi ve sağlanması gereken iki temel varsayım vardır. Bunlar kavramsal ve istatistiksel varsayımlardır. Kavramsal varsayım, teoriye dayalı olarak neden sonuç ilişkilerinin doğru kurulması, örneklemin ana kütleyle temsil etmesi ve verilerin uygun ölçüm düzeyinden elde edilmesi ile ilgili konuları ele alır (Doğan, 2017: 17; Tarka, 2017: 4). Bu varsayımlar modelin kavramsal çerçevede değerlendirilmesi için gerekli varsayımlardır. Yanlış neden sonuç ilişkisi kurulmuş bir model çalışmasında tahminler ve test istatistikleri anlamlı çıksa da ortaya çıkan sonuçlar oldukça mantıksız olacaktır. Bu nedenle model çalışmalarında öncelikle kavramsal varsayımların sağlanması gerekmektedir (Liang, 2014: 16).

İstatistiksel varsayım ise tahmin teknikleri ile doğrudan ilişkili olduğundan dağılımsal varsayımlar olarak da ele alınır. Bu sebeple bu varsayım, verilerin bağımsız ve özdeş dağılımlı olmasının yanı sıra klasik istatistik kullanarak seçilen tahmin teknikleri (sıkça kullanılan Maximum Likelihood-ML) nedeniyle de çok değişkenli normallik varsayımı talep etmektedir. Bu yüzden YEM çalışmalarında klasik istatistikten bir parametre tahminleyicisi kullanılacak ise asimptotik teori göz önüne alınması gerekmektedir. Örneğin bir model çalışmasında yeterli büyüklükte bir örneklem hacmi ve verilerin normallığı sağlanır ise örneklem kovaryans matrisi  $S$ 'nin modele ait tahmini kovaryans matrisi  $\hat{\Sigma}$ 'nin yakınsaması önemli ölçüde sağlanacaktır (Liang, 2014: 12). Fakat bu yakınsama bahsedilen diğer tüm varsayımlar makul seviyede karşılanması ile mümkün olacaktır. Varsayımların ihlali yanıltıcı uyum sonuçları ile beraber anlamsız ilişki sonuçları ortaya çıkaracaktır (Doğan, 2017: 16).

Gerçekleştirilecek bir YEM çalışması için kavramsal ve istatistiksel varsayımların sağlanmasının ardından model için uygun tahmin tekniği seçilir. YEM için ilk dönem çalışmalarında ML ve GLS (Genelleştirilmiş En Küçük Kareler Yöntemi- Generalized Least Squares- GLS) tahmin yaklaşımları kullanılmaktaydı. Her iki yaklaşımda verilerin sürekli ve çok değişkenli normal olmasını talep etmekteydi. Bu nedenle ilerleyen dönemde, YEM araştırmaları için fazlaca eleştiri gelen konular üzerinde durulmaya başlanmıştır. Bu konular çok değişkenli normallik ihlali ve kategorik/sıralı nitelikteki veri gruplarıdır (Matsueda, 2012:17- 42). Konuyla ilgili ilk araştırmalar ADF (Asymptotically Distribution Free- ADF, Browne, 1984) yöntemi ile kendisini göstermiştir. ADF tekniği, normallığe karşı oldukça duyarsız olmasına rağmen fazla örneklem hacmi ile çalıştığından dolayı çok fazla ilgi görmemiştir. İlerleyen dönemde hesaplama kolaylıkları sayesinde farklı durumlar için uygun tahmin teknikleri geliştirilmiştir (Hair vd., 2014: 575).

YEM çalışmalarında normallik ihlalinin sonuçları ile ilgili araştırmayı West vd., (1995) gerçekleştirmiş olup bu konuda dört maddeyi içeren bulgular tespit etmişlerdir. Bu bulguları şu şekilde özetleyebiliriz: Birincisi, hem ML hem de GLS ile yapılan çalışmalarda normallik ihlalinin giderek artması  $\chi^2$  değerini aşırı derecede büyük hale getirir. Bu durum, yani sahte yüksek  $\chi^2$  değeri, aday modelin yanlış bir biçimde reddedilmesine sebebiyet verir. Bu sonuç ise araştırmacıları örneklemin ötesinde aday model üzerinden yeniden bir değerlendirme yapmalarına yol açar. İkincisi, veriler normal dağılım gösterse bile örneklem boyutu küçük olduğu durumlarda ML ve GLS tahmin edicileri abartılmış  $\chi^2$  değerleri verir. Ayrıca hem normallik ihlal edilir hem de örneklem boyutu küçük olursa tahmin edicilerde yakınsamama ve yanlış çıkarımlar elde edilir. Üçüncüsü, normallik sağlanmadığında bazı uyum indeksleri kısmen hafife alınacak değerler verir. Sonuncu ise, normallik ihlali durumunda sahte düşük standart hatalar elde edilir. Bu durum bazen orta derecede bazen de yüksek derecede kendini gösterir. Sahte düşük standart hata ifadesi, standart hataların yanlışlığını ifade etmektedir. Bu konu araştırmada model parametreleri test edilirken kendini gösterir. Örneğin yol katsayıları ana kütlede anlamsız olsalar bile örneklem sonucunda test edilirken istatistiksel olarak anlamlı çıkar (Byrne, 2016: 366- 367). Netice itibarıyla standart hataların yanlışlığı birinci tip hataya sebep olur. Birinci tip hata gerçekte doğru olan sıfır hipotezinin reddidir. Model parametreleri test edilir iken kurulan sıfır hipotezinde parametreler sıfıra eşit olarak kurulur. Sonuç olarak bir araştırmada çok değişkenli normallik ihlali ile neticelenen standart hataların yanlışlığını şu şekilde yorumlayabiliriz; anlamlı olmayan bir ilişki normallik ihlali sonucunda standart hataların yanlışlığın oluşması ile anlamlı çıkacaktır.

Klasik istatistiği kullanan tüm tekniklerde normalliğin oldukça önemli olmasına rağmen ilgili literatür incelendiğinde bu durumun pervasızca göz ardı edildiğini dair oldukça fazla kanıt vardır. Bu durum için örneğin Micceri (1989), psikometri çalışmalarının çoğunluğunda hem tek değişkenli hem de çok değişkenli normalliğin ihlal edildiğini tespit etmiştir. Ayrıca Zhu (1997), çoğu araştırmacının bu ihlalden bile habersiz olduklarını vurgulamıştır (Byrne, 2016: 336).

Normallik ihlalini karşın uluslararası literatür bulgularından bazı önemli kanıtlar yukarıda bahsedildiği gibi olup ulusal literatürde ise bu durumu da kapsayan geniş bir sistematik araştırma yakın dönemde Durak (2021) tarafından YEM'in işletme alanındaki uygulamaları üzerinden gerçekleştirilmiştir. Durak (2021), yaptığı çalışmada 2020 ile 2021 yılları arasında TR Dizinde taranan ve işletme alanıyla ilgili 148 YEM çalışmasını ele almıştır. Toplam 148 çalışmadan sadece sekizinin çok değişkenli normalliği ele aldığını ve %95'inin ise bu durumu ele almadığını tespit etmiştir. Ayrıca çok değişkenli normalliği ele alan sekiz çalışmadan üçünün, çok değişkenli normalliği sağlamadan analize devam ettiğini ve bu konuda herhangi bir strateji izlenmediğini aktarmıştır. Buna ek olarak çok değişkenli normalliği ele alan bir çalışmada ise herhangi bir kanıt ya da delile ulaşılmadan normalliğin sağlandığını ifade etmiştir. Sonuç değerlendirmesi ise 148 çalışmadan sadece 4'nün çok değişkenli normalliği kanıtlarıyla ele aldığı ve %29'nun ise sadece tek değişkenli normallik incelemesi ile analizlere devam ettiği yönünde olmuştur (Durak, 2021: 97).

Uygulamada çok değişkenli normallik ihlalini ele almak için geliştirilen stratejilerden biri "Bootstrapping- Önyükleme" yaklaşımıdır. Bu yaklaşım tahmin tekniği olarak algılanmamalıdır. Çünkü Bootstrapping dört tahminleme süreçlerinden biridir (Bolat, 2009: 98- 99). Bu yaklaşım süreci, küçük örneklem boyutuna sahip veriler ya da çok değişkenli normalliği sağlamayan verilerin değerlendirilmesinde kullanılmaktadır. İlk kez Efron (1979) tarafından tanıtılmış olup teknolojik gelişmeler sayesinde kullanımı bilgisayarda sağlanmıştır. Önyükleme, orijinal ölçeğin birden çok alt boyutlu örneklemelerini sağlar. Bu sayede tahminleme işlemi bu alt boyutlardan yukarı çekme olarak ifade edilir. Bootstrapping parametrik olmayan bir önyüklemedir. Parametrik önyükleme ise teorik olarak seçilen olabilirlik fonksiyonundan Monte Carlo yöntemi ile rastgele örneklem sürecidir. Parametrik önyükleme işlemi için faktör analizinde ML tahminlerinde yanlışlıkların değerlendirilmesi örnek olarak verilebilir (Byrne, 2016: 367; Ievers-Landis vd., 2011: 620; Efron, 1979: 1- 26; Ichikawa ve Konishi, 1995: 77).

Bootstrapping, karmaşık durumlar için güven aralıkları, yanlışlıkların düzeltilmesini ve varyansların tahmin edilmesini sağlar. Bu sonuçları elde etmede, sürecin işleyişi şu şekilde açıklanmaktadır: Bootstrapping, popülasyonu en iyi temsil ettiği düşünülen orijinal bir örnek belirler ve bu örneğin alt boyutlarında türetme işlemine başlar. Türetme işlemi sonucunda binden fazla örnek elde edilir. Her bir örnekten parametre tahmin işlemi yapılarak yukarı yönlü tahminlerin ortalaması alınarak nihai tahmin elde edilir (Kline, 2005: 197).

Uygulama verilerinin çok değişkenli normallik ihlaline karşı oldukça güçlü bir yaklaşım klasik istatistik çatısının dışında Bayesci istatistikte yer almaktadır. Çoğu araştırmacı klasik istatistik kullanımı üzerinde yoğunlaştığı için genellikle normallik ihlali durumunda Bootstrapping yaklaşımını tercih etmektedirler. Hâlbuki araştırmacıları Bayesci yaklaşıma yöneltecek oldukça güçlü özellikler yaklaşımın kendisinde vardır. Bu özellikler, çekiciliği nedeniyle Bayesci yaklaşımı kullanmak için motivasyon kaynakları olarak adlandırılmaktadır. Bayesci yaklaşımın normallik ihlali ve örneklem hacminin küçük olması durumlarındaki yetenekleri ise şunlardır:

YEM çalışmalarının çoğunluğunda ML tahmin edicisi kullanılmaktadır. ML genel olarak parametre tahminleri ile onların standart hatalarını verir. Varsayımı ise asimptotik teori kapsamında tahminlerin dağılımının normal olduğudur. Bu durum ihlaline örnek olarak aracılık analizinde dolaylı etki analizi verilebilir. ML'nin asimptotik bakış açısının aksine Bayesci yaklaşım, büyük örneklem teorisine dayanmaz ve sonsal dağılımdan normal olduğuna bakmadan tüm dağılımlardan tahminleme işlemi yapar (Muthen ve Asparouhov, 2012: 314).

Küçük örneklem hacmine sahip modellerde ML'nin kullanımı ya da diğer asimptotik teoriye dayanan tahmin yöntemlerinin kullanılması uygun değildir. Nedeni, standartlaştırılmış parametre tahminlerinin dağılımının bilinmemesidir. Bu sebep ile asimptotik teoriye dayalı formüller kullanarak tahminler elde edilememektedir. Ayrıca ML ile yapılan tahminlemede eğer örneklem boyutu küçük ise

birçok önemli sorun ortaya çıkmaktadır. Bunlar, tahminlemede yakınsamanın olmaması, uygun olmayan (negatif varyans gibi) çıktılar ve yanlış uyum değerleri olarak verilmektedir. Bu sorunlardan kurtulmak için iyi bir yol, simülasyon tabanlı bir parametre tahminleyicisi yani Bayesci yaklaşımı kullanmaktır (Oezchowski, 2014: 854; Scheines vd., 1999: 39). Lee ve Song (2004), normal dağılım sergileyen küçük hacimli bir model için ML'nin çıkarımlar üretmez iken Bayesci yaklaşımın ürettiğini yaptıkları çalışmada elde etmişlerdir (Lee ve Song, 2004: 653).

Bu araştırmanın amacı, çok değişkenli normallik varsayımını ihlal eden bir YEM çalışmasında bahsi geçen bu iki yaklaşımın bir karşılaştırmasını yapmaktır. Araştırma üç bölümden oluşmaktadır. Birinci bölümde araştırmanın metodolojisi, ikinci bölümde analiz ve bulgular yer alırken üçüncü bölümde ise sonuç kısmı yer almaktadır.

### 1.ARAŞTIRMANIN METODOLOJİSİ

#### 1.1 Araştırmanın Evreni ve Örneklemi

Araştırmanın evreni, Tokat Gaziosmanpaşa Üniversitesi'nde okuyan 18 yaş ve üzeri sosyal medya kullanımı olan lisan öğrencileri olarak belirlenmiştir. Araştırma verisi için ilk olarak Tokat Gaziosmanpaşa Üniversitesi Sosyal ve Beşeri Bilimler Araştırmaları Etik Kuruluna başvuruda bulunulmuş olup 27.04.2022 tarih 7. oturum ve 01-62 karar sayısı ile gerekli etik izinler alınmıştır. Örneklem yöntemi olarak kolayda örneklem yöntemi kullanılmıştır. Araştırmanın verisi öğrencilere yöneltilen anketler vasıtasıyla elde edilmiş olup örneklem hacmi 275'tir. Elde edilen örneklem hacmi tek faktörlü ve 10 maddeden oluşan bir model için oldukça yeterli olduğu literatüre göre oldukça aşikardır (Durak, 2021: 98).

#### 1.1.1 Araştırmada Kullanılan Ölçek ve Anketin Oluşumu

Araştırma verisi elde edebilmek için lisan öğrencilerine yöneltilen anket, toplamda iki bölümden oluşmaktadır. Birinci bölüme geçmeden önce çalışmanın içeriğini ifade eden ve verilerin hangi amaçlarla, nasıl kullanılacağını özetleyen giriş kısmı yer almaktadır. İlk bölümde katılımcıların demografik yapıları hakkında bilgi edinebilmek için bazı ifadeler yöneltilmiştir. İkinci bölümde ise "Gelişmeleri Kaçırma Korkusu- Fomo" ölçeği yer almaktadır. Ölçek, ilk kez Przybylski vd. tarafından 2013 yılında sosyal ağlardaki gelişimlerden habersiz olamama ya da gelişmeleri kaçırmış hissi nedeniyle sosyal ağlarda fazlaca zaman harcanmasına neden olan yeni bir bağımlılık türü olarak ortaya çıkmıştır (Dossey, 2014: 69- 73; Przybylski vd., 2013: 1841- 1848). Türkçe güvenirlik ve geçerlilik çalışması Gökler vd. tarafından 2015 yılında yapılmıştır (Gökler vd., 2015: 53- 59). Ölçek 5'li Likert tipinde, toplam 10 ifadeden oluşmakta olup tek faktörlü bir yapıya sahiptir. Katılımcıların ölçekten alabilecekleri puanlar 10- 50 arasında değişmektedir. Ölçeğin Türkçe'ye uyarlanması Gökler vd. (2015), faktör yüklerini 0,36- 77 aralığında, Cronbach's Alpha katsayısı 0,81 olarak bulmuşlardır. Uyarlama çalışması sonucunda Gökler vd. ölçeğin üniversite öğrencilerinde geçerli ve güvenilir bir ölçek olduğu ortaya çıkarmıştır.

#### 1.1.2. Verilerin Değerlendirilmesi

Araştırma verisi, SPSS 26 ve AMOS 23 paket programlar vasıtasıyla değerlendirilmiştir. Araştırma için ilk olarak demografik yapı ve Fomo ölçeğinin güvenirlik analizi incelenmiştir. Verilerin çok değişkenli normalliği AMOS 23 paket programında Mardia'nın çok değişkenli basıklık ölçüsü ele alınarak değerlendirilmiştir. Verilerin normallik ihlali durumunda geliştirilen tekniklerden biri olan ve klasik istatistikte yer alan Bootstrap ML yaklaşımı ile tahminleme işleminin tüm safhaları gerçekleştirilmiştir. Model uyumu konusu ise Bollen-Stine bootstrap ile değerlendirilmiştir. Normallik ihlaline karşı oldukça güçlü olan verilerin normal olup olmadığına bakmaksızın sonsal dağılımdan tahminleme işlemini yapan Bayesci yaklaşım ise aynı program vasıtasıyla değerlendirilmiştir. Her iki yaklaşım ile tahminleme işleminin ardından bu iki yaklaşımın karşılaştırılması yapılmıştır.

### 2. ANALİZ VE BULGULAR

Analiz ve bulgular safhası araştırmanın amacı doğrultusunda iki ana bölümden oluşmaktadır. Fakat ilk olarak ölçeğe ait güvenirlik ve tanımlayıcı istatistik incelenmiştir.

**Tablo 1.** Katılımcıların Tanımlayıcı İstatistikleri

Değişkenler	Gruplar	Sıklık	%
Cinsiyet	Kadın	181	65.8
	Erkek	94	34.2
Okul Türü	Fakülte	272	98.9
	Meslek Yüksekokul	2	.7
	Yüksekokul	1	.4
Sınıf Düzeyi	1. sınıf	128	46.5
	2. sınıf	105	38.2
	3. sınıf	28	10.2
	4. sınıf	4	1.5
	Uzatmalı	10	3.6
Yaş Aralığı	18- 22 yaş	237	86.2
	23- 27 yaş	33	12.0
	28- 32 yaş	3	1.1
	33 ve üstü yaş	2	.7

Ölçeğe ait güvenilirlik analizi Cronbach's Alpha katsayısı ile değerlendirilmiş olup 0,719 olarak elde edilmiştir. Bu sonuç bilimsel çalışmada kullanılması için yeterli olduğu sonucunu vermektedir (Özdamar, 2013: 554- 555). Ayrıca ölçekten alınan toplam puan 24,19 olup ifade ortalaması ise 2,41'dir. Bu sonuç katılımcıların Fomo ölçeğinin 5'li Likert yapısında "Biraz Doğru" seçeneğinde yoğunlaştıklarını göstermektedir. Ölçeğin yapı geçerliliği için doğrulayıcı faktör analizi- DFA AMOS programında gerçekleştirilmiştir. Programda normallik testi ve bu testin yanı sıra çok değişkenli normallik ihlal eden değişkenleri veren seçenek işaretlenmiştir. Bulgular ise şöyle elde edilmiştir:

**Tablo 2.** Normalliğin Değerlendirilmesi

Değişkenler	min	max	skew	c.r.	kurtosis	c.r.
F10	1,000	5,000	,759	5,138	-,697	-2,361
F9	1,000	5,000	-,567	-3,842	-,955	-3,232
F8	1,000	5,000	,846	5,728	-,580	-1,964
F7	1,000	5,000	,218	1,477	-1,185	-4,010
F6	1,000	5,000	,276	1,869	-1,065	-3,607
F5	1,000	5,000	-,380	-2,571	-,953	-3,225
F4	1,000	5,000	1,146	7,759	,170	,576
F3	1,000	5,000	1,249	8,457	,623	2,109
F2	1,000	5,000	1,568	10,617	1,741	5,895
F1	1,000	5,000	1,573	10,646	2,081	7,045
Çok Değişkenli					15,541	8,318

Tablo 2'de her bir gösterge değişkene ait çarpıklık ve basıklık değerleri ve bu değerlere ait kritik oran (c.r.) değerleri (çarpıklık ve basıklık değerlerinin istatistiksel anlamlılığı test etmek için) yer almaktadır. Her bir değişkene ait basıklık ve çarpıklık değerleri tek değişkenli normalliğin



değerlendirilmesi için ele alınır. Fakat bir model çalışması için gerekli olan çok değişkenli normalliğin sağlanmasıdır. Bu konuda bilinmesi gereken bir önemli husus vardır o da şudur: “Çok değişkenli normallığe ulaşmak için tek değişkenli normallik gerekli bir koşuldur, ancak yeterli değildir”. Veri setindeki değişkenler tek değişkenli normallik gösterse bile çok değişkenli normallik sağlanamayabilir. Bu nedenle her iki duruma da dikkat etmek gerekir. Tek değişkenli normallik ve aykırı değerlerin varlığını incelemek, çok değişkenli normallik için yararlı olabilir. Tabloda yer alan kritik oran değerleri tahminin standart hataya bölünmesiyle elde edilmektedir. Bu oran “birim normal değişken” z skoru olarak dağılır. Belirli bir önem seviyesinde örneğin 0,05’lik için kritik oran  $\pm 1.96$ ’lık sınırlar dışında kalan bir sonuç, normalliğin sağlanmadığına işaret eder. Çok değişkenli normalliğin değerlendirilmesi için literatürde izlenen safhalar ise şu şekilde özetlenmektedir: İstatistiksel araştırmalar, çarpıklığın ortalamaların etki testleri üzerinde etkili olma eğiliminde olduğunu belirtirken basıklığın ise varyans kovaryans testlerini ciddi biçimde etkilediğini tespit etmişlerdir. YEM çalışmaları, kovaryans yapı analizlerini kullanıldığından basıklık ölçüsü oldukça endişe vericidir. Bununla birlikte YEM çalışmalarında çok değişkenli basıklık ölçüsünün son derece zararlı olacağı aşikârdır. Bu bilgiler ışığında çok değişkenli normallik için tek değişkenli normallığe bunun için de göstergelerin basıklık ve çarpıklık ölçüleri ile bir değerlendirme yaparak bir değerlendirilmeye gidilmelidir. Bu noktada basıklık ve çarpıklık değerlerinin pozitif ve negatif olması dağılımın dağılış biçimi hakkında bilgi vermesinin yanı sıra belli değerler altında olması da normallik hakkında bilgi sahibi olmamızı sağlar. Ayrıca aykırı gözlemler de bu değerlendirmenin içinde olacaktır. Bütün bu araştırmalar çok değişkenli normalliğin değerlendirilmesi konusunun oldukça zor olduğuna işaret eder. Bu yüzden literatürde pratik bir yol, Mardia’nın çok değişkenli basıklık ölçüsüne bakarak bir değerlendirmenin doğru olacağını belirtmiştir. West vd., (1995) basıklık değerinin  $>7$  normallığı ihlal edeceğini belirtmişlerdir. Byrne ise Bentler (2005)’den alıntı yaparak uygulamada  $>5$ ’den büyük değerlerin normal dağılmayan verilerin bir göstergesi olarak ele almıştır (Byrne, 2010: 68, 103, 104, 336).

Tablo 2’de tek değişkenli çarpıklık değerleri 0,759 ile 1,573 değerleri arasında değişirken basıklık değerleri ise -0,697 ile 2,081 değerleri arasında değişim göstermektedir. Kritik oran değerleri incelendiği basıklıkta bir göstergenin, çarpıklıkta ise iki gösterge değişkenin normallik sınırları arasında kaldığını belirtir. Tablonun en altında ise Mardia’nın çok değişkenli basıklık ölçüsü ile birlikte bu değerlerin kritik oran değeri yer almaktadır. Çok değişkenli basıklık ölçüsü 15,541 ve kritik oran değeri ise 8,318’dir. Bu bulgular neticesinde verilerin normal dağılmadığını söyleyebiliriz. AMOS programı tek değişkenli aykırı değerler hakkında bilgi vermese de çok değişkenli aykırı değerlerin varlığının belirlenmesine olanak tanır. Bu belirleme işlemini test istatistikleri ile birlikte karesi alınmış Mahalanobis uzaklık ölçüsü ile sağlar. Mahalanobis uzaklık ölçüsü, verilerin ağırlık merkezinden yani çok değişkenli ortalamadan her bir değişkenin uzaklığıdır. Mahalanobis d-squared değerlerine sahip değişkenler, çok değişkenli aykırı değerler olma olasılığına sahiptirler. Kline’a göre Mahalanobis d-squared “serbestlik derecesi değişken sayısına eşit merkezi bir ki-kare istatistiği olarak dağılır”. İstatistiksel anlamlılığı için ise daha sıkı bir p değerini ( $p < 0,001$ ) önermektedir. (Kline, 2011: 54). Mahalanobis d-squared değerleri ve bunlara ait p değerleri Tablo 3’de yer almaktadır.

**Tablo 3. Gözlemlerin Çok Değişkenli Ortalamadan Uzaklıkları (Mahalanobis Distance)**

Gözlem numaraları	Mahalanobis d-squared	p1	p2
180	37,153	,000	,015
56	33,925	,000	,001
270	32,988	,000	,000
181	28,540	,001	,001
138	25,287	,005	,011
44	24,259	,007	,013
65	23,438	,009	,015
98	21,944	,015	,065
153	21,667	,017	,046
229	21,637	,017	,021
123	20,765	,023	,053
205	20,487	,025	,045

...		...	...	...
-----	--	-----	-----	-----

Tablo 3’de Mahalanobis d-squared değerlerinin bir alt kümesi ve ilişkili p değerleri program sayesinde azalan bir sıralama ile verilmiştir. Bu noktada 180. gözlemin en yüksek Mahalanobis d-squared değerine sahip olduğu görülmektedir. İkinci sırada 56. gözlem yer almaktadır. Bu iki değer arasındaki fark ve diğer gözlemler arasındaki uzaklık farkları fazla bir kırılma olmamasına işaret etmektedir. Bu durumda aykırı bir gözlemin Mahalanobis d-squared değerlerine göre oluşmadığını söylemek mümkündür. Aykırı bir gözlemin, verideki tüm diğer gözlemlerden Mahalanobis d-squared değeri ile ayrılması durumuna sahip olması beklenir. Bunun yanı sıra ayrıca bakılması gereken yer p1 ve p2 değerleridir. p1 sütunu normalliğin sağlandığı varsayıldığında her bir gözlemin Mahalanobis d-squared değerlerini aşma olasılığını verir. Örneğin normallik sağlandığında, 180. gözlemin Mahalanobis d-squared değerinin 37,153 değerini aşma olasılığının <,000 olduğunu belirtir. p2 sütunu ise normallik sağlandığında herhangi bir durum için en büyük Mahalanobis d-squared değerlerinin 37,153’ü aşma olasılığının >,000 olduğunu (>,015>,000) ortaya koymaktadır (Byrne, 2016: 377).

Tablodaki p1 ve p2 değerleri ile birlikte Mahalanobis d-squared değerleri incelendiğinde oldukça fazla gözlemin çok değişkenli aykırı gözlem olduğu sonucuna varılır. Fakat oldukça fazla gözlemin bu durum olduğu için her birisi için bu stratejiye göre verilerin değerlendirilmesi oldukça güç olacaktır. Bu yüzden mevcut veri yapısı ile tahminleme işleminin olası durumlarını araştırmak için Bootstrap ML yaklaşımı kullanılmıştır. Programda 500 önyüklem ve yanlışlıkların düzeltilmesi talep edilmiştir. Fakat öncelikle ML ile yapılan sonuçlara bakılmış ardından Bootstrap ML sonuçları değerlendirilmiştir. Elde edilen bulgular şunlar olmuştur:

**Tablo 4. ML Tahminleri ve Standart Hatalar (Regresyon Ağırlıkları)**


			Estimate	S.E.	C.R.	P
F1	<---	Fomo	1,000			
F2	<---	Fomo	1,582	,259	6,118	***
F3	<---	Fomo	2,788	,625	4,459	***
F4	<---	Fomo	2,798	,630	4,442	***
F5	<---	Fomo	1,753	,460	3,809	***
F6	<---	Fomo	1,328	,407	3,264	,001
F7	<---	Fomo	1,952	,504	3,871	***
F8	<---	Fomo	,951	,371	2,565	,010
F9	<---	Fomo	1,304	,404	3,226	,001
F10	<---	Fomo	1,418	,421	3,372	***

Tablo 4’de ölçeğe ait tüm gözlenen değişkenlerin anlamlı bir yapıda olduğu gözlemlenmektedir. Standartlaştırılmış faktör yükleri ise Tablo 5’de yer almaktadır.

**Tablo 5. Standartlaştırılmış Regresyon Ağırlıklarının Tahminleri**

			Estimate
F1	<---	Fomo	,324
F2	<---	Fomo	,511
F3	<---	Fomo	,719
F4	<---	Fomo	,692
F5	<---	Fomo	,407
F6	<---	Fomo	,299
F7	<---	Fomo	,424
F8	<---	Fomo	,209
F9	<---	Fomo	,295
F10	<---	Fomo	,317

Standardize edilmiş tahmin değerleri sonuçlarına bakıldığında 0,209 ile 0,719 arasında değişen bir faktör yüklenimlerinin olduğu gözlemlenmektedir. DFA modelinin path diyagramı ve model uyumu hakkındaki bulgular ise şu şekildedir:



Şekil 1. Fomo Ölçeğine ait DFA

Model uyumunda CMIN/DF 1,247, GFI 0,971, AGFI 0,949, CFI 0,985, RMSEA 0,030 ve SRMR ise 0,047 olarak elde edilmiştir. Bu haliyle DFA sonuçlarının oldukça iyi olduğu görülmektedir (Tabachnick ve Fidell, 2007: 720). Yalnız bu sonuçlara bakarak raporlama işlemini yapmak normalliği ihlal etmek anlamına gelir ki bu sonuçların güvenilirliği tartışma konusudur. Bu yüzden Bootstrap ML ile standart hatalarının yanlışlıkların düzeltilerek tahminler için güven aralıklarının incelenmesi gereklidir.

Tablo 6. Önyükleme Standart Hataları (Standartlaştırılmış Regresyon Ağırlıkları)



			SE	SE-SE	Mean	Bias	SE-Bias
F1	<---	Fomo	,075	,002	,322	-,002	,003
F2	<---	Fomo	,068	,002	,510	,000	,003
F3	<---	Fomo	,059	,002	,721	,002	,003
F4	<---	Fomo	,056	,002	,685	-,007	,003
F5	<---	Fomo	,057	,002	,409	,002	,003
F6	<---	Fomo	,070	,002	,300	,001	,003
F7	<---	Fomo	,058	,002	,426	,002	,003
F8	<---	Fomo	,077	,002	,209	,000	,003
F9	<---	Fomo	,068	,002	,298	,002	,003
F10	<---	Fomo	,074	,002	,318	,001	,003

Tablo

6'daki ilk SE sütunu bootstrapped standard hatalarını veren sütundur. Bu sütun değerleri 500 önyükleme örneğinden hesaplanan parametre tahmin değerlerinden elde edilenlerdir. Tablodaki ikinci sütun değerleri, bootstrapped standard hataları ile ML ile yapılan tahminlemeden elde edilen standart hataların farkını vermektedir. Bu sütunda görüleceği üzere fark değerleri oldukça küçüktür. Eğer bootstrapped standard hataları ML standart hatalarından büyük olsa idiler fark ciddi anlamda açılacaktır ki bu durumda, veride aykırı değerlerin varlığını ve önemli basıklığın olduğu söylenebilirdi. Üçüncü sütun 500 önyüklemekten elde edilen tahmin değerlerini vermektedir. Bu değerler ML ile yapılan tahmin değerlerinden farklı olması oldukça doğaldır. Tablodaki dördüncü sütun ise "yanlılık" sütunu olup önyükleme ile yapılan tahmin değerlerinin ML ile yapılan tahmin değerlerinden farklarını vermektedir. Bu tahmin değerleri arasındaki fark eğer pozitif ise önyükleme ile yapılan tahmin değerlerinin ML ile yapılan tahmin değerlerinden büyük olduğuna işaret edecektir. Son sütun değerleri ise yanlılığın standart hatasını vermektedir (Byrne, 2016: 383- 388).

Bootstrap ML ile verilen son bilgilendirici çıktı, yanlılıkların düzeltilmesi ile elde edilen güven aralıklarıdır. Hem standartlaştırılmış hem de standartlaştırılmamış faktör yük tahminleri için güven aralıkları program sayesinde Tablo 7'de verilmiştir.

**Tablo 7. Yanlılıkları Düzeltilmiş Güven Aralıkları (Standartlaştırılmış Regresyon Ağırlıkları)**

			Estimate	Lower	Upper	P
F1	<---	Fomo	,324	,169	,454	,004
F2	<---	Fomo	,511	,354	,623	,006
F3	<---	Fomo	,719	,588	,821	,006
F4	<---	Fomo	,692	,568	,798	,002
F5	<---	Fomo	,407	,277	,508	,006
F6	<---	Fomo	,299	,155	,443	,005
F7	<---	Fomo	,424	,306	,535	,005
F8	<---	Fomo	,209	,045	,342	,014
F9	<---	Fomo	,295	,154	,432	,005
F10	<---	Fomo	,317	,160	,451	,005

Tablo 7'de yanlılıkları düzeltilmiş (standartlaştırılmış) faktör yük değerlerine ait %95 güven aralıkları yer almaktadır. Bu güven aralıkları, sıradan bir okunuşa sahiptir. Güven aralıklarının sıfırı içermemesi istenilen bir durumdur. Tablo 7'de hiçbir güven aralığı sıfırı içermemektedir. Bu sonuç gösterge değişkenlerinin faktör yüklerinin sıfıra eşit olduğu hipotezini reddeder. Aksi bir durumda faktör yüklerinin anlamlı olmadığı sonucu ortaya çıkar. Tablo 7'de görülen son sütun p değerleri şunu ifade etmektedir: Sıfırı içerecek bir güven aralığı elde etmek için güven seviyesinin ne kadar küçük olması gerektiğini gösterir. Örneğin F1 gösterge değişkeninin güven aralığının [,169 - ,454] sıfırı içermesi için güven seviyesinin %99.6 olması (p= ,004) gerektiğini bildirir (Byrne, 2016: 388).

Buraya kadar olan analiz ve bulgular verilerin normallik varsayımını sağlamadığını ve Bootstrap ML sonuçlarında ise tahminlemede herhangi bir olumsuz durum olmadığını belirtmektedir. Yalnız halen

model uyumu konusunda kesin bir şey söylenemez. Çünkü Bootstrap, bağımsız model parametreleri için standart hataların yanlışlıkların düzeltilme işlemini sağlar. Ancak daha önce bahsedildiği gibi çok değişkenli normallik ihlali ki- kare değerinde abartılmış bir sonuç elde edilmesini sağlayarak iyi bir modelin gereksiz yere reddedilmesini yol açar. Bu yüzden önyükleme birçok durumda iyi çalışabilse de bazı koşullar altında iyi bir performans gösterememektedir. Bollen- Stine (1993) bu durumu ele alarak model uyumu için önyüklemeli bir p değeri geliştirmişlerdir. Bollen- Stine önyükleme p değeri, gözlemlenen veriler ile elde edilen ki-kare değerinin önyükleme yoluyla elde edilen ki-kare değerinden kaç kez geride kaldığını, yani kötü uyumu, değerlendiren bir ölçüttür. Bu ölçüt sayesinde modelin kötü uyumu değerlendirilir. p değeri  $<0,05$  ise modelin veriye uygun olmadığı sonucuna varılır. Aksi durumda yani  $p > 0,05$  ise mevcut model uyumu sağlanır (Byrne, 2016: 389). Program vasıtasıyla elde edilen Bollen- Stine Bootstrap sonuçları Tablo 8’de verilmiştir.

**Tablo 8. Bollen-Stine Bootstrap**

The model fit better in 357 bootstrap samples.  
It fit about equally well in 0 bootstrap samples.  
It fit worse or failed to fit in 143 bootstrap samples.  
Testing the null hypothesis that the model is correct, Bollen-Stine bootstrap  $p = ,287$

Tablo 8’den elde edilen önemli bilgiler şunlardır: 357 önyükleme örneği modele daha iyi uyum sağlamaktadır. Modelin doğru olduğunu test eden sıfır hipotezi kabul edilmiştir. Yani model veri uyumu sağlanmıştır. Bu durumda mevcut model ve veriler, farklı model çalışmalarında ya da alternatif analizlerde kullanılabilir.

Tüm analiz ve bulgular neticesinde çok değişkenli normal olmayan Fomo ölçeği verisi ve model yapısının artık kullanılabilir olduğu Bootstrap ML ve Bollen- Stine Bootstrap ile sağlanmıştır. Bu noktada elde edilen bulguları, Bayesci yaklaşım ile tahminleme işlemi yaparak destekleyici bir sonuç araştırılmasına gidilmiştir. Bayesci yaklaşım için yine aynı program kullanılmış olup elde edilen bulgular şunlar olmuştur:

**Tablo 9. Standartlaştırılmış Regresyon Ağırlıklarınının Bayesci Tahminleri**

			Estimate
F1	<---	Fomo	,322
F2	<---	Fomo	,536
F3	<---	Fomo	,704
F4	<---	Fomo	,693
F5	<---	Fomo	,408
F6	<---	Fomo	,287
F7	<---	Fomo	,416
F8	<---	Fomo	,198
F9	<---	Fomo	,273
F10	<---	Fomo	,318

Tablo 9’deki tahmin değerleri incelendiğinde Bootstrap ML ile yapılan tahmin değerlerine oldukça yakın olduğu görülmektedir. Bayesci yaklaşımda model uyumu değerlendirmesi sonsal tahmin kontrolü- ppp (Posterior Predictive p value- ppp) ölçütü ile gerçekleştirilmiştir. AMOS programı bu çıktıyı sağlamaktadır. Sonsal tahmin kontrolü, teorik model için veri türetme işlemini sağlayarak mevcut gözlem veriler ile türetme verileri arasındaki farkı inceler. Bu fark ya da sapma model uyumu için oldukça düşük olması beklenir. Eğer bu fark fazla ise bu durum, olası model hatalarına işaret eder. Bu ölçüt temelde modelin kalitesini değerlendirir (Kaplan ve Depaoli, 2012: 654). Sonsal tahmine dayalı kontrol sadece tek bir modelin uyum iyiliğini değerlendirmek için kullanılır. Farklı modelleri karşılaştırmak için kullanılmaz (Lee, 2007: 129). Değerlendirme ölçütü olarak 0 ve 1’e yakınlık model uyumunun kötü olduğuna işaret etmektedir. 0,05’e yakın bir değer (Gelman vd., 2014; Fong ve Ho, 2013) ise mükemmel model uyumu olduğunu gösterir. Muthen ve Asparouhov (2012), 0,1, 0,05 ve 0,01

gibi sonsal tahmine dayalı p değerlerinin makul model uyumuna işaret ettiğini belirtmişlerdir. Bu sonuçlar model uyumunu değerlendirmede sonsal tahmine dayalı p değerleri için daha fazla araştırma yapılmasına ayrıca işaret etmektedir (Harindranath ve Jacob, 2018: 1259). Uygulama modelinden elde edilen ppp değeri 0,40'tır. Bu sonuç iyi bir model uyumunu vermektedir.

### SONUÇ

Bu araştırmanın birincil amacı, YEM çalışmalarında çok değişkenli normallik ihlalinin değerlendirilmesi ve yönetimini AMOS programı vasıtasıyla yapmaktır. Araştırmanın ikincil amacı, çok değişkenli normallik ihlaline karşı tavsiye edilen Bootstrap ML ve Bayesci yaklaşımların karşılaştırmasını yaparak bir değerlendirme bulmaktır. Araştırmada günümüzün önemli sorunlarından birini oluşturan ve sosyal medya bağımlılığına yönelten “Gelişmeleri Kaçırma Korkusu” ölçeği üzerinden çalışmanın amacı gerçekleştirilmek istenmiştir. Üniversite öğrencilerine yöneltilen anketler vasıtasıyla çalışma verisi elde edilmiş olup ölçeğe ait verilerin normallik değerlendirme işlemi ilgili literatürün göstermiş olduğu adımlarla sağlanmıştır. Model verisinin çok değişkenli normallik ihlali gösterdiği (Mardia'nın çok değişkenli basıklık ölçüsü 15,541 kritik oran değeri ise 8,318) tespit edilmiştir (Byrne, 2016: 373). Bu noktada araştırmacıların belirli bir strateji izlemeleri gerekmektedir. Çünkü YEM çalışması için oldukça önemli bir kriter olan normalliğin göz ardı edilemeyecek sonuçları vardır. Bu sonuçlar hakkında West vd., (1995) açıklayıcı çalışmaları ile bu konuda literatüre öncü olmuşlardır. Normallik ihlalinin en tehlikeli sonuçlarından biri, ki-kare değerinde aşırı bir artışa sebebiyet vererek gerçekte doğru olan bir modelin gereksiz yere reddedilmesidir. İkincisi, standart hataların yanlışlığının hafife alınmasıdır. Bu durumda model parametrelerinin testinde yanlış çıkarımlara sebebiyet vermektedir (Byrne, 2016: 366- 367). Bu sonuçlar bir model çalışmasının her yönünü ele aldığından araştırmacının bu konuyu göz ardı etmesi neredeyse imkânsızdır. Bu yüzden araştırmacı ya mevcut veriler yerine başka veriler elde etme işlemi yapacak ya da var olan bu koşul için çözüm stratejileri izlemesi gerekecektir.

Uygulamada çok değişkenli normalliğin sağlanamaması sonucunda Bootstrap ML stratejisi izlenerek mevcut model ve veri ile analize devam edilip edilmeyeceği belirlenmeye çalışılmıştır. Bootstrap, bağımsız model parametreleri için standart hataların yanlışlıkların düzeltilme işlemi sağlar. Bu sayede model parametrelerini test etmede güvenilir sonuçlar kazanılmıştır. Fakat çok değişkenli normallik ihlali ki- kare değerinde abartılmış bir sonuç elde edilmesini sağlayarak doğru bir modelin gereksiz yere reddedilmesini yol açar. Bu yüzden önyükleme birçok durumda iyi çalışabilse de bazı koşullar altında iyi bir performans gösterememektedir. Bollen- Stine (1993) bu durumu ele alarak model uyumu için önyüklemeli bir p değeri geliştirmişlerdir. Bollen- Stine önyükleme p değeri uygulamada  $0,287 > 0,05$  olarak bulunmuştur. Bu sonuç mevcut modelin veri ile uyumunun olduğuna işaret etmektedir (Ievers-Landis vd., 2011: 624). Tüm bulgular normal dağılmayan bir model çalışması için gerekli araştırmalar ile kullanılabilir olduğu göstermiştir. Fakat normalliğin ihlali ile bir diğer çekici strateji Bayesci yaklaşımdır. Bayesci yaklaşım, büyük örneklem teorisine dayanmaz ve sonsal dağılımdan normal olduğuna bakmadan tüm dağılımlardan tahminleme işlemi yapar (Muthen ve Asparouhov, 2012: 314). Bu nedenle mevcut model Bayesci yaklaşım ile değerlendirilmiştir. Elde edilen bulgular her iki yöntemde de oldukça yakın sonuçlara sahiptir. Son olarak Bayesci yaklaşım için model uyumu, sonsal tahmin kontrolü- ppp değeri incelenmiş olup 0,40 olarak elde edilmiştir. Bu sonuç model uyumunun iyi olduğuna işaret etmektedir (Harindranath ve Jacob, 2018: 1259). Normallik ihlali sonucunda hem Bootstrap ML hem de Bayesci yaklaşım aynı sonuçları vermesi ile mevcut model ve verilerin diğer çalışmalarda kullanılabilir olduğu saptanmıştır.

Gelecek araştırmalarda, simülasyon çalışmaları kullanarak farklı örneklem hacimlerinde bu iki stratejinin karşılaştırması literature önemli katkılar sağlayacaktır. Ayrıca mevcut model formu yerine iç içe geçmiş model yapıları ve normalliğin sağlandığı küçük örneklem hacimleri üzerinden bir değerlendirme ile bu iki stratejiden hangisinin daha doğru sonuçlara ulaştırdığı konusu da oldukça önemli kazanımların yolunu açacaktır.

## KAYNAKÇA

- Byrne, B. M. (2010). *Structural equation modeling with AMOS: Basic concepts, applications, and programming*. 2nd Edition. Routledge Taylor & Francis Group.
- Byrne, B. M. (2016). *Structural Equation Modeling With AMOS*. New York: Routledge.
- Doğan, M. (2017). *Bayesci Yapısal Eşitlik Modeli: Teknoloji Kabul Modeli Uygulaması*. Eskişehir Osmangazi Üniversitesi, Fen Bilimleri Enstitüsü, İstatistik Anabilim Dalı, Doktora Tezi.
- Dossey, L. (2014). FOMO, digital dementia, and our dangerous experiment. *Explore: The Journal of Science and Healing*, 10(2), 69-73.
- Durak, İ. (2021). Yapısal eşitlik modellemesinin işletme araştırmalarında kullanımı: Modele genel bakış ve yapılan uygulamaların sistematik incelemesi. Akay- Ünvan, Y.(Ed.), *İşletme ve iktisadi bilimler araştırması* (sy. 82- 111). Livre de Lyon.
- Efron, B. (1979). “Bootstrap Methods: Another Look at the Jackknife”. *Annals of Statistics*. 7(1): 1-26.
- Gökler, M. E., Aydın, R., Ünal, E., & Metintaş, S. (2016). Sosyal ortamlarda gelişmeleri kaçırma korkusu ölçeğinin Türkçe sürümünün geçerlilik ve güvenilirliğinin değerlendirilmesi. *Anadolu Psikiyatri Dergisi*, 17(1), 52-59.
- Hair Joseph F., Black William C. & Babin Barry J. (2014). *Multivariate Data Analysis* (Seventh Edition). USA. Pearson Education.
- Harindranath, R. M., & Jacob, J. (2018). Bayesian structural equation modelling tutorial for novice management researchers. *Management Research Review*, 41(11), 1254-1270.
- Ichikawa, M. & Konishi, S. (1995). “Application of the Bootstrap Methods in Factor Analysis”. *Psychometrika*. 60: 77-93.
- Ievers-Landis, C. E., Burant, C. J., & Hazen, R. (2011). The concept of bootstrapping of structural equation models with smaller samples: An illustration using mealtime rituals in diabetes management. *Journal of Developmental & Behavioral Pediatrics*, 32(8), 619-626.
- Kaplan, D., & Depaoli, S. (2012). Bayesian structural equation modeling. In R. H. Hoyle (Ed.), *Handbook of structural equation modeling* (pp. 650–673). The Guilford Press.
- Kline, R. B. (2005). *Principles and Practice of Structural Equation Modelling*. New York: Guilford Press.
- Kline, R. B. (2011). *Principles and Practice of Structural Equation Modeling*. New York: Guilford Press.
- Lee, S. Y. (2007). *Structural equation modeling: A Bayesian approach*. John Wiley & Sons.
- Lee, S. Y., & Song, X. Y. (2004). Evaluation of the Bayesian and maximum likelihood approaches in analyzing structural equation models with small sample sizes. *Multivariate behavioral research*, 39(4), 653-686.
- Liang, X. (2014). *Estimation and Specification Search of Structural Equation Modeling Using Frequentist and Bayesian Methods*, Florida State University, Collage of Education, Phdthesis.
- Matsueda, R. L. (2012). Key advances in the history of structural equation modeling. In R. H. Hoyle (Ed.), *Handbook of structural equation modeling* (pp. 17–42). The Guilford Press.
- Muthén, B. & Asparouhov, T. (2012). “Bayesian structural equation modeling: A more Flexible Representation of Substantive Theory”. *Psychological Methods*. 17(3): 313-335.
- Ozechowski, T. J. (2014). Empirical Bayes MCMC estimation for modeling treatment processes, mechanisms of change, and clinical outcomes in small samples. *Journal of Consulting and Clinical Psychology*, 82(5), 854–867.

- Özdamar, K., *Paket Programlar ile İstatistiksel Veri Analizi Cilt 1,2.* (9. Baskı). Ankara, Nisa Kitabevi, 2013.
- Przybylski, A. K., Murayama, K., DeHaan, C. R., & Gladwell, V. (2013). Motivational, emotional, and behavioral correlates of fear of missing out. *Computers in Human Behavior*, 29(4), 1841–1848.
- Scheines, R., Hoijtink, H., & Boomsma, A. (1999). Bayesian estimation and testing of structural equation models. *Psychometrika*, 64, 37-52.
- Tabachnick, B. G., & Fidell, L. S. (2007). *Using multivariate statistics* (5th ed.). Allyn & Bacon/Pearson Education.
- Tarka, P. (2018). “An Overview of Structural Equation Modeling: Its Beginnings, Historical Development, Usefulness and Controversies in the Social Sciences”. *Quality & Quantity: International Journal of Methodology*. 52(1): 313– 354.



### EXTENDED ABSTRACT

Two basic assumptions must be known and satisfied before conducting any structural equation modeling (SEM) study. These are conceptual and statistical assumptions. Conceptual assumption deals with issues related to correctly establishing cause and effect relationships based on theory, ensuring that the sample represents the population, and obtaining data from the appropriate measurement level (Dogan, 2017: 17; Tarka, 2017: 4). Statistical assumption, on the other hand, is also considered as distributional assumptions since it is directly related to forecasting techniques. For this reason, this assumption requires the assumption of multivariate normality due to the data being independent and identically distributed, as well as the estimation techniques chosen using classical statistics (the frequently used Maximum Likelihood - ML) (Liang, 2014: 12).

After providing the conceptual and statistical assumptions for an SEM study to be carried out, the appropriate estimation technique for the model is selected. In structural equation modeling studies, classical statistics are often preferred; therefore, the data are expected to meet the assumption of multivariate normality.

The primary purpose of this research is to evaluate and manage multivariate normality violations in SEM studies through the AMOS program. The secondary aim of the research is to evaluate by comparing the recommended Bootstrap ML and Bayesian approaches against multivariate normality violation. The study aimed to achieve the aim of the study through the "Fear of Missing Out" scale, which constitutes one of today's critical problems and leads to social media addiction. Study data was obtained through surveys directed to university students, and the normality evaluation process of the scale data was provided with the steps shown in the relevant literature. It was determined that the model data violated multivariate normality (Mardia's multivariate kurtosis measure was 15.541, and the critical ratio value was 8.318) (Byrne, 2016: 373). At this point, researchers need to follow a particular strategy. Because normality, an essential criterion for SEM study, has consequences that cannot be ignored. West et al. (1995) pioneered the literature on this subject with their explanatory studies on these results. One of the most dangerous consequences of normality violation is the unnecessary rejection of a correct model, causing an excessive increase in the chi-square value. Second, the bias of standard errors is underestimated. In this case, it causes wrong inferences when testing the model parameters (Byrne, 2016: 366- 367). Since these results address every aspect of a model study, it is almost impossible for the researcher to ignore this issue. Therefore, the researcher will either need to obtain other data instead of the existing data or follow solution strategies for this condition.

As multivariate normality could not be achieved in practice, an attempt was made to determine whether to continue the analysis with the existing model and data by following the Bootstrap ML strategy. Bootstrap provides standard error correction for individual model parameters. In this way, reliable results were obtained in testing the model parameters. However, violation of multivariate normality results in an exaggerated chi-square value, leading to unnecessary rejection of an accurate model. So, although bootstrapping may work well in many situations, it may perform poorly under some conditions. Bollen-Stine (1993) addressed this situation and developed a bootstrapped p-value for model fit. Bollen-Stine bootstrap p-value was found to be  $0.287 > 0.05$  in practice. This result indicates that the current model is compatible with the data (Ievers-Landis et al., 2011: 624). All findings showed that a non-normally distributed model can be used with the necessary research to study. However, another attractive strategy with a violation of normality is the Bayesian approach. The Bayesian approach is not based on large sample theory and makes predictions from all distributions regardless of whether the posterior distribution is normal (Muthen and Asparouhov, 2012: 314). For this reason, the current model was evaluated with a Bayesian approach. The findings obtained from both methods have very similar results. Finally, the model fit and posterior prediction check-ppp value for the Bayesian approach was examined and obtained as 0.40. This result indicates that the model fit is good (Harindranath and Jacob, 2018: 1259). As a result of normality violation, both Bootstrap ML and Bayesian approaches gave the same results, and it was determined that the existing model and data could be used in other studies.

In future research, comparing these two strategies in different sample sizes using simulation studies will significantly contribute to the literature. In addition, evaluating nested model structures instead of the current model form and small sample volumes where normality is ensured will pave the way for significant gains regarding which of these two strategies produces more accurate results.