



Article Info/Makale Bilgisi

✓Received/Geliş:30.03.2022 ✓Accepted/Kabul:11.04.2022

DOI:10.30794/pausbed.1095936

Review/Derleme Makalesi

Kılıç, A. F. (2022). "Açımlayıcı Faktör Analizinde Boyut Sayısına Karar Verme: Yöntemlere Kısa Bir Bakış", *Pamukkale Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 2022 Sayı 51: Özel sayı 1, Denizli, ss. 0305-0318.

## AÇIMLAYICI FAKTÖR ANALİZİNDE BOYUT SAYISINA KARAR VERME: YÖNTEMLERE KISA BİR BAKIŞ

Abdullah Faruk KILIÇ\*

### Öz

Açımlayıcı faktör analizi (AFA), bilimsel çalışma alanlarının birçoğunda (eğitim, sağlık, iktisat gibi) kendine yer bulmaktadır. Bu analizle ölçülen özelliğin doğası ve yapısı hakkında bilgi sahibi olunabilmektedir. Ölçülen özelliğin doğası hakkında bilgi sahibi olmak ise bu analizin gerekliliklerini yerine getirerek mümkündür. Açımlayıcı faktör analizinde boyut sayısına doğru bir şekilde karar verilmesi de araştırmacılar için zorlayıcı olabilmektedir. Bu nedenle bu çalışmada, açımlayıcı faktör analizinde boyut sayısına karar verirken kullanılabilir yöntemlerin hem teorik alt yapısına hem de bu yöntemlerin hangi yazılımlarda bulunduğuna yönelik bilgiler sunulmuştur. Dahası gerçekleştirilen çalışmalarda hangi yöntemin daha uygun sonuçlar verdiği ve hangi yöntemlerin güncel çalışmalarda kullanılabilmesine yer verilmiştir. Sonuç olarak geleneksel yöntemlerden optimal paralel analiz, karşılaştırmalı veriler ya da kısmi korelasyonların ortalaması yöntemleriyle boyut sayısına karar verilebileceği gibi literatürde kendine daha yeni kullanım alanı bulmuş makine öğrenmesi yöntemlerinden de (rastgele orman ya da aşırı gradyan artırma) yararlanılması AFA gerçekleştirecek araştırmacılara önerilebilir.

**Anahtar Kelimeler:** *Paralel analiz, Kısmi korelasyonların ortalaması, Açımlayıcı grafik analizi, Rastgele orman, Xgboost.*

## DECIDING THE NUMBER OF DIMENSIONS IN EXPLANATORY FACTOR ANALYSIS: A BRIEF OVERVIEW OF THE METHODS

### Abstract

Exploratory factor analysis (EFA) finds its place in many scientific fields (e.g. education, health science or economics). With this analysis, information about the nature and structure of the measured feature can be obtained. It is possible to have information about the nature of the measured feature by fulfilling the requirements of this analysis. Correctly deciding on the number of dimensions in EFA can also be challenging for researchers. For this reason, this study presents information on the theoretical background of the factor retention methods used when deciding on the number of dimensions in EFA. In addition, it has been given information about which software is available for these methods. Moreover, there is information about which method gives more accurate results in the simulation studies. As a result, the number of dimensions can be decided by using traditional methods such as optimal parallel analysis, comparative data, or minimum average partial, as well as making use of machine learning methods (random forest or extreme gradient augmentation), which have found new uses in the literature, to researchers who will perform EFA.

**Keywords:** *Parallel analysis, Minimum average partial, Exploratory graph analysis, Random forest, Xgboost.*

\*Arş. Gör. Dr., Adıyaman Üniversitesi, Eğitim Fakültesi Eğitim Bilimleri Bölümü ADIYAMAN.  
e-posta: abduhfarukkilic@gmail.com, (<https://orcid.org/0000-0003-3129-1763>)

## **GİRİŞ**

Ölçek geliştirme sürecinde açımlayıcı faktör analizi (AFA) kullanılması ve bu süreçte ölçme aracının boyutluluğunun incelenmesi tüm ölçek geliştirme sürecini etkileyebilecek aşamadır. Erkuş (2019) ölçek geliştirme çalışmalarında açımlayıcı faktör analizine mutlaka başvurulması gerektiğini belirtmiştir. Ölçek geliştirme çalışmaları; eğitim, sosyal ya da sağlık bilimleri alanında olabileceği gibi gizil bir özelliğin ölçüldüğü diğer bilimsel alanlarda (iktisat, ziraat bilimleri gibi) da olabilmektedir. Ölçek geliştirme sürecinde öncelikle aday maddeler hazırlanmaktadır. Daha sonra bu maddeler deneme uygulamasında bir grup bireye uygulanmaktadır. Böylece maddelerin ölçtüğü altta yatan gizil yapı ortaya çıkarılmaya çalışılmaktadır.

Literatürde faktör (factor), boyut (dimension), gizil yapı (latent construct), yapı (construct), gizil yetenek (latent traits) gibi kavramların hepsi aynı kavrama işaret etmektedir. Bu kavram da değişkenlerin birbiriyle ilişkili olmasını sağlayan ortak bir neden (common factor) değişkenidir. Bu değişken doğrudan gözlenemeyen ancak var olduğunu bildiğimiz insana ait birtakım özelliklerdir. Cronbach ve Meehl (1955) yapıyı; insanlarda var olduğu kabul edilen ve test performansına yansıyan özellikler olarak tanımlamıştır. Buradaki test sadece başarı testleri anlamında olmayıp diğer ölçek türlerini de (tutum, ilgi, yetenek, beceri ya da zekâ gibi) kapsamaktadır. Tutum, ilgi, zekâ, yetenek, başarı, Covid-19'a yakalanma korkusu, ölçme ve değerlendirmeye karşı tutum, psikolojik iyi oluş ve akademik yılmazlık yapı kavramına örnek olarak verilebilir. Yapıların ölçülmesi için araştırmacılar öncelikle bunları tanımlamakta, daha sonra yapılan bu tanıma göre bir ölçme aracı geliştirmekte (halihazırda var ise seçmekte) ya da başka bir kültür için geliştirilmiş ölçme araçlarını kendi kültürlerine uyarlamaktadırlar. Bu süreçlerin tamamında da faktör analizi kullanılarak kararlar alınmaktadır. Faktör analizi temelde açımlayıcı ve doğrulayıcı olarak ikiye ayrılmaktadır (Brown, 2015; Thompson, 2004).

Doğrulayıcı faktör analizi (DFA) ölçülen yapı hakkında bilgi sahibi olunup hangi maddenin hangi boyutu ölçtüğü bilindiğinde bu bilginin doğru olup olmadığının sınındığı (doğrulandığı) bir analiz yöntemidir (Brown, 2015). Açımlayıcı faktör analizi (AFA), psikolojik ölçümlerin kalbinde yer alan (Nunnally ve Bernstein, 1994), ölçülen özelliğin doğasının keşfedilmesinde kullanılan aynı zamanda ölçülen özelliğin operasyonel tanımının yapılmasını sağlayan çok değişkenli bir analiz yöntemidir. AFA daha çok maddelerin hangi gizil yapıları ölçtüğünün bilinmediği durumlarda maddelerin ölçtüğü yapıyı keşfetme amacıyla kullanılmaktadır (Fabrigar ve Wegener, 2012). AFA gerçekleştirilirken, DFA'dan farklı olarak, araştırmacılar birçok konuda karar vermektedir. Bu kararlardan biri de faktör sayısına karar vermektir. Bu karar, kendisinden sonraki uygulamaları da etkileyeceği için oldukça önemlidir. Örneğin, ölçeğin tek boyutlu olduğu sonucuna ulaşırsa faktör döndürme yapılmazken ölçeğin iki boyutlu olduğu sonucuna ulaşılması durumunda faktörlerin döndürülüp döndürülmeyeceği, döndürmede hangi yöntemin kullanılacağı (dik ya da eğik döndürme yöntemleri), hangi sonucun daha uygun olduğu gibi daha başka birçok karar almayı gerektirmektedir. Bu nedenle faktör sayısına doğru bir şekilde karar vermek, yapının kavramsallaşması açısından önem taşıdığı gibi analizin diğer adımlarını etkilemesi açısından önem arz etmektedir. Bu nedenle mevcut çalışmanın literatüre üç açıdan katkı sağlayacağı düşünülmektedir: i) sadece sosyal bilimler değil diğer bilimsel alanlarda da AFA kullanan araştırmacılara yol göstereceğinden yaygın etkisinin yüksek olması, ii) AFA gerçekleştirecek araştırmacılara boyut sayısına karar verirken hangi yöntemi seçmesi gerektiği noktasında yardımcı olması, iii) sadece geleneksel değil, aynı zamanda güncel literatürde de boyut sayısını belirleme yöntemlerinin gelişimini araştırmacılara sunması nedeniyle mevcut çalışmanın önemli olduğu düşünülmektedir.

## **AÇIMLAYICI FAKTÖR ANALİZİNDE BOYUT SAYISINA KARAR VERME**

Araştırmacılar açımlayıcı faktör analizi gerçekleştirirken boyut sayısına karar vermektedir. Bu karar gerçek boyut sayısına yaklaşma ya da tekrar edilebilir çözümler elde etme şeklinde olabilir (Preacher vd., 2013). Diğer bir deyişle faktör sayısına karar verilirken gerçek faktör sayısına daha uygun olduğu için karmaşık bir yapı ortaya çıkarılabileceği gibi, AFA sonuçlarının başka örneklerde de tekrar edilebilirliği göz önüne alınarak daha tutumlu (parsimonious) modeller tercih edilebilir. Araştırmacılar, ampirik olarak elde ettikleri veri setinin gerçek faktör yapısını doğal olarak bilmemektedir. Bu nedenle bazı durumlarda ampirik olarak elde edilen veri setinde gerçekleştirilen AFA sonucunda karmaşık modeller (hiyerarşik faktörler ya da bi-faktör modeller gibi) ortaya çıkabilmektedir. Ancak bu durumda geliştirilmiş ölçeği kullanacak araştırmacılar benzer bir örnekte veri topladıklarında AFA ile ortaya konulan yapıyı DFA ile doğrulayamamaktadır. Bu nedenle AFA için boyut

sayısına karar verirken bu çalışmada sunulan yöntemler göz önünde bulundurulabilir. Bu yöntemlerden elde edilen sonuçların yanında AFA için tekrar edilebilirlik (replicability) çalışması yapılarak ortaya çıkacak yapının AFA ile tanımlanan yapıyla benzer olup olmadığı araştırılabilir (son bölümde tekrar edilebilirlik çalışmasından bahsedilmiştir).

AFA'da doğru faktör sayısının belirlenmesinde gerçek faktör sayısına yaklaşmaya çalışmak yerine diğer bazı ölçütler göz önüne alınabilir (Fabrigar ve Wegener, 2012; Preacher vd., 2013). Çünkü ampirik olarak elde edilen veri setinin gerçekte kaç boyutlu olduğu bilinmemektedir. Bu nedenle bilinmeyen bu gerçek değere yaklaşmak ya da ulaşmak da mümkün olmamaktadır. Ulaşılsa bile bundan emin olmak güçtür. Bu nedenle veri setine hangi faktör sayısının daha uygun olduğuna karar verirken bazı kanıtlar kullanılabilir. Örneğin, Fabrigar ve Wegener (2012) bir veri setinde faktör sayısına karar verirken göz önünde bulundurulacak durumları şu şekilde özetlemiştir: Düşünülen faktör sayısı; i) maddeler arasındaki korelasyonları yeterli oranda açıklıyorsa, ii) bir azaltıldığında açıklanan varyans oranı önemli ölçüde azalıyorsa, iii) bir artırıldığında açıklanan varyans oranı önemli düzeyde artmıyorsa ve iv) teorik olarak kullanışlı ve yorumlanabilir ise bu durumda doğru faktör sayısına ulaşıldığı düşünülebilir. Preacher vd. (2013) de benzer şekilde gerçek faktör sayısı (correct, true) kavramının yanlış bir kavram olduğu bunun yerine optimal faktör sayısı kavramının kullanılması gerektiğini belirtmiştir.

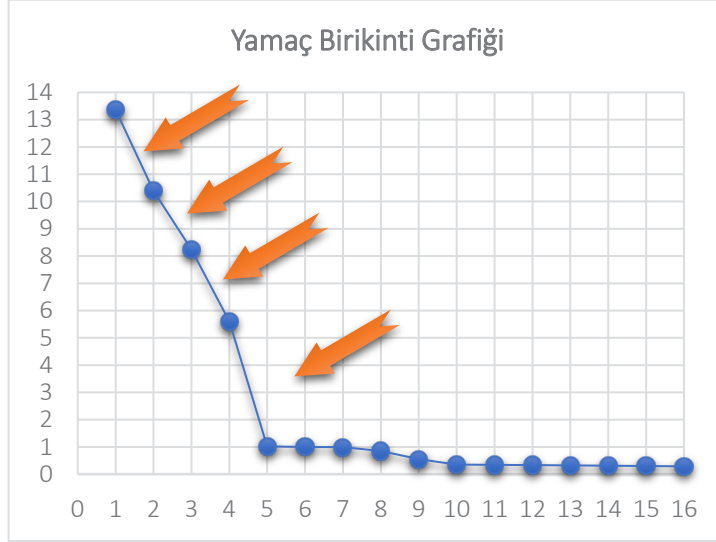
Gerçek faktör sayısı düşünülerek faktör sayısına karar verilmese de araştırmacılar AFA gerçekleştirirken bir faktör sayısı belirlemek durumundadır. Bu sayı belirlenirken de bazı yöntemlerin kullanılması, araştırmacıların karar vermesine yardımcı olabilmektedir. Ancak bu yöntemlerin önerdiği faktör sayısı doğrudan kullanılmamalı bunun yerine Fabrigar ve Wegener (2012) tarafından önerilen yaklaşımla birlikte değerlendirilmelidir. Diğer taraftan faktör sayısına karar verirken hiçbir yöntem kullanılmadığında, kararlar tamamen araştırmacıların yorumlarına ve öznel görüşlerine dayanabilir. Bu durumda gelecekte yapılacak çalışmalarda da yanıltıcı sonuçlara neden olabilir. AFA yapısı gereği araştırmacı kararlarıyla ilerlediği için bu süreci biraz daha objektif hale getirmek için gösterilen çabaların da önemli olduğu düşünülmektedir. Nitekim bu alanda çalışan bir çok araştırmacı (Golino, Shi, vd., 2020; Golino ve Epskamp, 2017; A. F. Kılıç ve Uysal, 2019, 2021; Yang ve Xia, 2015) faktör sayısına karar verme yöntemlerinin performanslarını karşılaştırarak hangilerinin daha uygun sonuçlar verdiğini incelemiştir. Bu nedenle faktör sayısına karar vermek için kullanılan yöntemler bu bölümde ele alınmıştır.

#### **K1 Kuralı**

Kaiser (1960) tarafından önerildiği için K1 kuralı olarak anılan bu yöntemde özdeğeri 1'den büyük olan faktörler önemli faktörler olarak değerlendirilmektedir. Buradaki mantık, bir faktörün tek bir maddenin açıkladığı varyanstan daha fazla varyans açıklamasının beklenmesidir. Ancak bu yöntem temel bileşenler analizi için geliştirilmiş olup, faktör çıkarma yöntemi olarak temel bileşenler kullanılmadığında (örneğin temel eksenler ya da en çok olabilirlik kullanıldığında) her bir maddenin varyansının 1'den küçük olduğu varsayılmaktadır (Kahn, 2006). Bu nedenle de K1 kuralının ortak faktör analizi için (common factor analysis) kullanılması çok uygun olmamaktadır. Başka bir deyişle temel bileşenler analizi gerçekleştirildiğinde özdeğerlerin toplamı madde sayısına eşitken, ortak faktör analizi kullanıldığında özdeğerlerin toplamı madde sayısına eşit olmamaktadır. Diğer taraftan bu yöntem birçok istatistik programında varsayılan olarak bulunduğu ve anlaşılması kolay bir yöntem olduğundan literatürde sıklıkla kullanılmaktadır. Ancak simülasyon çalışmaları incelendiğinde, bu yöntemin diğer yöntemlere nazaran daha yanlış kestirimlerde bulunduğu ve faktör sayısını olduğundan daha büyük önerdiği gösterilmiştir (Fabrigar vd., 1999; Lance vd., 2006; Velicer vd., 2000; Zwick ve Velicer, 1986). Bu nedenle K1 kuralı varsayılan olarak istatistik programlarında hâlihazırda yer aldığından özdeğeri 1'den büyük olan faktörler incelenebilir. Ancak 1'den büyük özdeğeri olan faktörler, faktör sayısı olarak kabul edilirken diğer objektif yöntemler de dikkate alınmalıdır. K1 kullanışlı olabilir. Diğer bir deyişle 1'den büyük özdeğere sahip faktörler önemli faktör sayısı olmayabilir ancak 1'den küçük özdeğere sahip faktörlerin bir faktör olarak değerlendirilmesine gerek yoktur. Örneğin bir veri setinin analizi sonucunda özdeğeri 1'den büyük 2 faktör varsa bu durumda veri setinin bir ya da iki boyutlu olabileceği düşünülüp bu iki seçenek değerlendirilebilir. Veri setinde çok büyük ihtimalle iki faktörden daha fazla faktör çıkmayacaktır. Ancak yine de K1 kuralının tek başına faktör sayısını belirlemede kullanılması önerilmemektedir (Ledesma ve Valero-Mora, 2007).

### Yamaç-Birikinti Grafiği (Scree Plot)

K1 kuralına benzer şekilde bu yöntem de özdeğerleri kullanarak faktör sayısına karar vermektedir. Özdeğerlerle oluşturulan grafik incelenerek iki özdeğer arasındaki farkın azaldığı (grafikğin plato yaptığı) veya 1'den küçük özdeğerlere geçildiği noktanın üzerindeki kırılımlar önemli faktör sayısı olarak ele alınmaktadır (Cattell, 1966). Bu yöntemde dikkat edilmesi gereken nokta, kırılımların sayılması gerektiğidir (bknz Şekil 1). Ancak bazı araştırmacılar kırılımlar yerine noktaları saymaktadır (Nelson vd., 2011). Bu durumda tek boyutlu olan yapılar bile tek boyutlu çıkmayacaktır. Çünkü iki özdeğer arasında çizilen grafikte (doğru parçası) iki nokta bulunmaktadır. Bu nedenle noktalar sayıldığında her yapı en az iki boyutlu çıkacaktır. Şekil 1'de örnek bir yamaç birikinti grafiği sunulmuştur.



**Şekil 1. Yamaç-Birikinti Grafiği**

Şekil 1 incelendiğinde 5. maddeden itibaren özdeğerlerin 1'in altına indiği görülmektedir. İlk özdeğer 13'ün üzerindeyken ikinci ve sonrasındaki özdeğerlerde grafikğin eğimi yüksek şekilde azalmaktadır. Diğer bir deyişle ani düşüşler bulunmaktadır. Şekil 1'de de görülebileceği üzere, ani düşüş yaşanan doğru parçası sayısı 4'tür. Buna göre veri seti yamaç birikinti grafiğine göre 4 boyutludur diyebiliriz. Ancak 5. faktörden sonra plato yaptığı için veri seti 5 boyutlu olarak değerlendirilmemelidir. Yamaç grafikğinin mantığı özdeğerlerdeki sayısal değışimleri görselleştirerek önemli faktör sayısının belirlenmesini sağlamaktır. Bu mantıkla bakınca grafikte tek bir ani düşüş yaşanmış, sonrasında grafik plato yapmış ise tek boyutlu bir yapının olabileceği düşünölmelidir. Ancak sadece yamaç-birikinti grafikğinin sonuçlarına göre boyut sayısına kadar vermek araştırmacılar tarafından önerilmemektedir. Çünkü bu grafikte açık bir şekilde plato oluşmayabilir. Bunun yerine Ruscio ve Roche (2012) tarafından yamaç-birikinti grafikğinin grafiksel olmayan bir çözümü önerilmiştir. Ancak bu yöntemler K1 kuralından iyi çalışsalar da boyut sayısını olduğundan düşük kestirme eğiliminde olduğu belirtilmektedir (Auerswald ve Moshagen, 2019; Ruscio ve Roche, 2012).

### Paralel Analiz

Horn (1965) tarafından geliştirilen Paralel analiz (PA), temel bileşenler analizini temele almaktadır. Bu yöntemde, boyutluluğu araştırılan veri setinde gerçekleştirilen temel bileşenler analizinden elde edilen özdeğerler ile bu veri setine benzer özellikte (aynı madde sayısı ve aynı örneklem büyüklüğü) ancak rassal olarak üretilmiş veri setinde gerçekleştirilen temel bileşenler analizinden elde edilen özdeğerler karşılaştırılmaktadır. Rassal veri setinden elde edilen özdeğerin büyük olduğu değer hangi sıradaysa bir eksiği boyut sayısı olarak belirlenmektedir (Lorenzo-Seva vd., 2011).

PA, araştırmalarda bir açılımlayıcı faktör analizi faktör çıkarma metodu gibi raporlanabilmektedir. Ancak paralel analiz, diğer faktör sayısını belirleme yöntemleri gibi yalnızca veri setinin boyutluluğu hakkında bilgi vermektedir.

Bir faktör çıkarma yöntemi (temel eksenler, ağırlıklandırılmamış en küçük kareler gibi) değildir. Paralel analizde, boyutluluğu araştırılan veri setine benzer rassal veri seti üretildiği için üretilen veri seti sayısı da önemlidir. Örneğin, bir adet rassal veri seti üretilse, bu analize dayalı olarak verilecek kararın yanlı olacağı söylenebilir. Çünkü rassal üretilen veri seti, rassal olmanın doğası gereği gerçek boyut sayısına yakın ya da uzak olabilir. Bu nedenle de değişkenlerin kategori sayısı ve kullanılan korelasyon matrisine göre rassal üretilen veri seti sayısı önemlidir (A. F. Kılıç ve Uysal, 2018). Çok sayıda rassal veri seti üretildiğinde gerçek veri setinden elde edilen özdeğerler ile karşılaştırmanın yapılabilmesi için rassal veri setlerinden elde edilen özdeğerlerin bir temsilcisinin seçilmesi gerekmektedir. Bu temsilci, ortalama özdeğerler, özdeğerlerin %95 ve %99'luk kısımları olabilmektedir. Yapılan çalışmalarda ortalama özdeğerlerin olduğundan daha fazla faktör önerdiği (Glorfeld, 1995), bunun yerine %95'lik özdeğerlerin tercih edilmesi önerilmektedir (Crawford vd., 2010; Lorenzo-Seva vd., 2011; Timmerman ve Lorenzo-Seva, 2011).

Horn (1965) tarafından geliştirilen paralel analiz, temel bileşenler analiziyle (TBA) gerçekleştirildiğinden ortak faktör modeline uygun olacak şekilde modifikasyonlar geliştirilmiştir. Bunlardan biri TBA yerine faktör sayısını belirlemek için ortak faktör modeline dayanan temel eksenler faktör çıkarma yöntemiyle gerçekleştirilen paralel analizdir (Humphreys ve Ilgen, 1969). Bu yöntemde özdeğerler indirgenmiş korelasyon (reduced korelasyon) matrisinden elde edilmektedir. Ancak TBA kullanıldığında veri setindeki değişkenler arasındaki korelasyon matrisi (orijinal korelasyon matrisi) doğrudan analiz edilmektedir. Ancak indirgenmiş korelasyon matrisinde köşegenlerde ortaklık (communalities) değerleri köşegen altında ise değişkenler arasındaki korelasyonlar bulunmaktadır. İndirgenmiş korelasyon matrisiyle PA gerçekleştirildiğinde önerilen faktör sayısının orijinal korelasyon matrisiyle gerçekleştirilene nazaran daha fazla olduğu belirtilmektedir (Timmerman ve Lorenzo-Seva, 2011).

Timmerman ve Lorenzo-Seva (2011), temel eksenler yöntemiyle özdeğerlerin elde edildiği PA yönteminin teorik olarak uygun olmadığını belirtmiştir. Çünkü temel eksenler yöntemiyle PA gerçekleştirildiğinde özdeğerler korelasyon matrisinin bir oranı şeklinde (indirgenmiş korelasyon matrisi kullanıldığı için) ifade edilememektedir. Ancak temel bileşenler yöntemiyle gerçekleştirildiğinde orijinal korelasyon matrisi (indirgenmemiş korelasyon matrisi) kullanıldığı için özdeğerler korelasyon matrisinin oranı şeklinde ifade edilebilmektedir. Bu nedenle de temel eksenler yöntemine alternatif olarak en küçük sıra faktör analizi (minimum rank factor analysis [MRFA]) yöntemini önermişlerdir. Bu yöntemde faktör çıkarma yöntemi olarak MRFA kullanılmakta olup gerçek ve rassal üretilen korelasyon matrislerinden elde edilen özdeğerler yerine açıklanan ortak varyanslar (explained common variance) karşılaştırılmaktadır. Buradaki mantık da Horn'un (1965) önerdiği paralel analize benzemektedir. Sadece özdeğerler yerine açıklanan ortak varyans değerleri karşılaştırılmaktadır. İndirgenmiş korelasyon matrisi kullanıldığı için temel eksenler faktör çıkarma yönteminde açıklanan ortak varyans değerinin hesaplanamamaktadır (Timmerman ve Lorenzo-Seva, 2011). Bu nedenle temel eksenler yerine en küçük sıra yöntemi tercih edilmiştir.

Özdeğerler kullanılarak gerçekleştirilen PA'da rassal olarak üretilen veri setleri çok değişkenli normal dağılım kullanılarak üretilmektedir (Horn, 1965). Ancak özdeğerler farklı dağılımlar (uniform, multinominal gibi) gösterecek şekilde belirlenebilir. Dinno (2009), gerçekleştirdiği simülasyon çalışmasında 10 farklı dağılıma uygun olacak şekilde özdeğerleri üretmiş ve çalışma sonucunda PA'nın performansına dağılımların etki etmediğini belirtmiştir. Timmerman ve Lorenzo-Seva (2011) tarafından gerçekleştirilen simülasyon çalışmasında ise temel eksenler yöntemiyle gerçekleştirilen PA'nın, Horn'un önerdiği PA ile MRFA yöntemiyle gerçekleştirilen PA'dan daha fazla faktör çıkarma eğiliminde olduğu raporlanmıştır. Bu çalışmada permütasyona dayalı örnekleme yapılması, polikorik korelasyon matrisinin kullanılması ve faktör çıkarma yöntemi olarak MRFA'nın kullanılması önerilmiştir (bu yöntem optimal paralel analiz ismini vermişlerdir). A. F. Kılıç ve Uysal (2021) tarafından gerçekleştirilen simülasyon çalışmasında ise faktör çıkarma yöntemlerinden en küçük kalıntı, temel bileşenler, temel eksenler, en çok olabilirlik, ağırlıklandırılmamış en küçük kareler, en küçük ki- kare ve optimal paralel analizde uygulanan en küçük sıra faktör çıkarma yöntemleri karşılaştırılmıştır. Araştırma sonucunda iki kategorili veri setlerinde optimal paralel analiz yönteminin daha uygun sonuçlar verdiği raporlanmıştır. Ayrıca tetrakorik veya polikorik korelasyon matrisiyle analizler gerçekleştirildiğinde yakınsama sağlanamazsa (heywood vakası ortaya çıkarsa) bu durumda da Pearson korelasyon matrisiyle temel bileşenler analizine dayalı olarak PA gerçekleştirilmesi önerilmiştir. Bu çalışmaların yanında PA yönteminin geliştirilmesi için öneriler de mevcuttur. Örneğin Green vd. (2012) revize edilmiş PA (R-PA) yöntemini önermiştir.



Sonuç olarak paralel analiz (PA), boyutluluk konusunda en sık kullanılan ve önerilen (Kahn, 2006; A. F. Kılıç ve Uysal, 2019, 2021; Lance vd., 2006; Lorenzo-Seva vd., 2011; Worthington ve Whittaker, 2006) bir yöntemdir. PA gerçekleştirilirken optimal paralel analiz (Timmerman ve Lorenzo-Seva, 2011) gerçekleştirilmesi önerilebilir. Eğer optimal paralel analiz gerçekleştirilemiyorsa bu durumda Horn (1965) tarafından önerilen paralel analizin ilk hali gerçekleştirilebilir. Simülasyon ile elde edilen özdeğerlerin, ortalamasını almak yerine %95'ine karşılık gelen özdeğerler gerçek veri setinden elde edilen özdeğerler ile karşılaştırmak için kullanılabilir.

### **Karşılaştırmalı Veriler (Comparison Data) Yöntemi**

Karşılaştırmalı veriler yöntemi, PA'ya benzer bir mantıkla PA'nın iki zayıf noktasını gidermek için Ruscio ve Roche (2012) tarafından geliştirilmiştir. Bu zayıflıklardan ilki, karşılaştırılacak özdeğerlerin seçiminde ortalama kullanıldığında faktör sayısını olduğundan yüksek kestirmesidir. Bunun için %95 ve %99 özdeğerlerin kullanımı önerilmiştir; ancak yine de bu sorunu tam olarak çözmektedir. İkinci zayıflık ise gerçek veri setinden elde edilen özdeğerin simülasyondan elde edilen özdeğerden biraz daha küçük olduğu durumda fazla faktör çıkarılmasıdır. Bu gibi durumlarda araştırmacıların objektif tekniklere daha çok güvendiği, ancak PA'nın hatalı sonuçlar verebildiği belirtilmektedir (Ruscio ve Roche, 2012). Karşılaştırmalı veriler yönteminde ise ampirik olarak elde edilen korelasyon matrisine farklı faktör çözümleri denenerek bunlardan elde edilen sonuçlar karşılaştırılmaktadır (Ruscio ve Roche, 2012).

Karşılaştırmalı veriler yönteminde analizler 5 adımda gerçekleşmektedir. i) rassal veriler madde sayısı ya da (madde sayısı +1) faktör olacak şekilde üretilmekte ve her bir veri seti için özdeğerler elde edilmektedir, ii) elde edilen özdeğerlerin gerçek veri setinden elde edilenle karşılaştırılması için hata ortalamalarının kare kökü hesaplanmaktadır ( $RMSE = \sqrt{\sum_{i=1}^p (\lambda_{gerçek} - \lambda_{simi})^2}$ , p = madde sayısı, i = özdeğerler), ii) birinci ve ikinci adım bir çok kez tekrar edilmektedir (örneğin 500 ya da 1000), iv) iki modelden elde edilen RMSE (örneğin tek faktörlü ve iki faktörlü) değerleri Wilcoxon işaretli sıralar testiyle karşılaştırılmaktadır, v) eğer bu karşılaştırma sonucu istatistiksel olarak anlamlı değilse, bu durumda karşılaştırmalı veriler yöntemi az olan faktör sayısını önermektedir. Eğer bu karşılaştırma sonucu istatistiksel olarak anlamlı bulunursa, bu durumda faktör sayısı bir artırılarak 1-4 adımları tekrarlanmaktadır. İşlem RMSE farkının istatistiksel olarak anlamlı bulunmadığı sayıya kadar devam etmektedir (Auerswald ve Moshagen, 2019). Özet olarak, rassal üretilen tek faktörlü veri setiyle, gerçek veri setine tek faktörlü model uygulandığında elde edilen uyum karşılaştırılarak karar verilmektedir. İki boyutlu model ile bir boyutlu modelden elde edilen sonuçlar karşılaştırıldığında eğer iki faktörlü model daha iyi uyum gösterdiyse üç boyutlu model ile iki boyutlu model karşılaştırılmaktadır. Bu şekilde karşılaştırılarak boyut sayısına karar verilmektedir. Diğer faktör sayısını belirleme yöntemleriyle kıyaslandığında daha iyi sonuçlar verebildiği koşulların bulunduğu belirtilmiş (Ruscio ve Roche, 2012) dahası en az paralel analiz kadar iyi çalıştığı vurgulanmıştır (Bandalos ve Finney, 2019).

### **Açımlayıcı Grafik Analizi (Exploratory Graph Analysis)**

Açımlayıcı grafik analizi (AGA), psikometrik ağlar (network psychometrics) üzerine temellendirilmiş hem boyut sayısını hem de maddelerin bu boyutlara nasıl dağıldığının incelenmesine imkân veren bir tekniktir. Psikometrik ağlar yaklaşımı, ortak faktör modelinden farklı olarak gözlenen değişkenler arasındaki ilişkileri doğrudan modellemektedir (Golino ve Epskamp, 2017). Ortak faktör modelinde ise gözlenen değişkenler arasındaki ilişkilerden bunları etkileyen ortak faktörler oluşturulmaktadır. AGA ise psikometrik ağların altında yer alan Gaussian grafik modelini temele almaktadır. Bu modelde, kovaryans matrisinin tersi kullanılarak ağlar kestirilmektedir. Bunun için "walktrap" ismi verilen bir algoritma kullanılmaktadır (Golino, Moulder vd., 2020). AGA kestirimi sonucunda, düğümler (nodes) ve bu düğümleri birbirine bağlayan kenarlar (edge) elde edilmektedir. Faktör analizine karşılık olacak şekilde düşünüldüğünde düğümler maddelere, kenarlar faktör yüklerine karşılık gelmektedir (Golino ve Epskamp, 2017). AGA'nın diğer faktör sayısını belirleme yöntemlerinden farkı, boyut sayısını önerirken maddelerin faktörlere dağılımını da göstermesidir (Golino ve Epskamp, 2017). Buradan hareketle AGA'nın maddeleri boyutlara yerleştirme performansı makine öğrenmesi yöntemleriyle karşılaştırılmış ve araştırma sonucunda örneklemin küçük olduğu koşullarda makine öğrenmesi yöntemlerinin AGA'dan daha doğru sonuçlar verdiği bulunmuştur (Koyuncu ve Kılıç, 2021). Diğer taraftan boyut sayısını belirleme performansını simülatif verilerde karşılaştıran çalışmalarda büyük örneklemlerde boyutlar arası korelasyonun 0.70 olduğu

koşullarda diğer boyut sayısını belirleme yöntemlerinden daha iyi sonuçlar verdiği belirlenmiştir (Golino, Shi, vd., 2020; Golino ve Epskamp, 2017). Cosemans vd. (2021) ise sürekli ve iki kategorili (normal ve çarpık dağılan) değişkenleri kullanarak gerçekleştirdikleri simülasyon çalışmasında AGA'nın çoğu simülasyon koşulunda diğer geleneksel yöntemlerden (paralel analiz, revize edilmiş paralel analiz, kısmî korelasyonların ortalaması gibi) daha iyi sonuçlar verdiğini belirtmiştir. AGA koşulların tümü değerlendirildiğinde diğer yöntemlerden daha iyi sonuçlar verse de boyutlar arası korelasyon ve değişkenler arasındaki ortaklık (communality) değerleri yüksekse revize edilmiş paralel analizin küçük örneklerde diğer yöntemlerden daha iyi sonuçlar verdiği bulunmuştur.

### **Kısmî Korelasyonların Ortalaması (MAP) Yöntemi**

Velicer (1976) tarafından geliştirilen Kısmî Korelasyonların Ortalaması (minimum average partial correlation [MAP]) yöntemi temel bileşen analizini temele almaktadır. MAP yönteminde öncelikle korelasyon matrisinden kısmi kovaryans matrisi oluşturulmakta, daha sonra bu kovaryans matrisi üzerinden kısmi korelasyon matrisi oluşturulmaktadır (Garrido vd., 2011). İlk aşamada ilk temel bileşen, veri setindeki değişkenlerden elde edilen korelasyon matrisinden ayrılır. Korelasyon matrisinde köşegen haricindeki elemanların kareleri hesaplanarak kısmî korelasyon matrisi oluşturulur. İkinci aşamada ilk iki temel bileşen veri setinden elde edilen korelasyon matrisinden ayrılır. Korelasyon matrisindeki köşegen dışındaki elemanların kareleri hesaplanarak yine kısmî korelasyon matrisi oluşturulur. Bu işlem değişken sayısının bir eksiğine kadar tekrar edilir. Bu adımlardan elde edilen kısmî korelasyonların karelerinin ortalamaları sıraya dizilir. Sıraya dizilen bu değerlerin en küçüğü kaçınıcı sıradaysa o sayı, boyut sayısı olarak tanımlanır (Ledesma ve Valero-Mora, 2007; O'connor, 2000; Velicer, 1976). Zwick ve Velicer (1986) MAP analizinde her bir faktör için en az iki değişkenin faktör yükünün yüksek olması gerektiğini belirtmiştir.

Velicer vd. (2000) MAP yönteminde, kısmî korelasyonların karesi yerine dördüncü kuvvetinin alınmasını gerektiren bir modifikasyon önermiştir. Bu modifikasyonun biraz daha iyi sonuçlar verdiğini, gerçekleştirdikleri simülasyon çalışmasında göstermişlerdir. A. F. Kılıç ve Uysal (2019) tarafından gerçekleştirilen simülasyon çalışmasında da MAP analizinin diğer yöntemlere göre daha uygun sonuçlar verdiği raporlanmıştır. Garrido vd. (2011) MAP analizinin karşılaştırılan yöntemler içinde gerçek faktör sayısına daha yakın sonuçlar verdiğini belirtmiştir. Zwick ve Velicer (1986) de gerçekleştirdikleri simülasyon çalışmasında, PA ve MAP yöntemlerinin gerçek faktör sayısını belirlemede daha uygun yöntemler olduğu raporlamıştır.

### **Ampirik Kaiser Kriteri**

Braeken ve van Assen (2017) tarafından önerilen bu yöntem özdeğerlere dayanmaktadır. Ancak Ampirik Kaiser Kriteri (AKK) Green vd. (2012) ile Ruscio ve Roche (2012) tarafından önerilen yöntemlerde ihtiyaç duyulan simülatif veri setlerine ihtiyaç duymamaktadır. AKK, üç girdi ile faktör sayısını kestirebilmektedir. Birincisi boş model altında örneklemden elde edilecek en büyük özdeğer olan  $l_{mak} = (1 + \sqrt{\gamma})^2$  değeridir. Bu değer için ilk referans özdeğer olarak alınmaktadır. Burada  $\gamma$  değişken sayısının örneklem büyüklüğüne oranı  $\gamma = \frac{j}{n}$  ile elde edilmektedir. İkinci olarak bu özdeğerlerin düzenli olarak azalmasını sağlayacak düzeltme formülünün belirlenmesidir. Bunun için  $l_{mak}$  değeri  $l_j^{Referans} = \frac{j - \sum_{j=0}^{j-1} l_j}{j - j + 1}$  değeri ile çarpılarak elde edilmekte ve diğer özdeğerlerin bir önceki özdeğerden küçük olması sağlanmaktadır. Üçüncü olarak da AKK için gözlenen özdeğerlerin 1'i aşması gerekmektedir. Bu sınırlamanın getirilmesinin 3 nedeni vardır: i) güvenilirliğin pozitif olabilmesi için özdeğerlerin 1'den büyük olmasının gerekmesi, ii) kalıntılar (residual) arası korelasyonların ve tekil faktörlerin önüne geçilmesi iii) evren düzeyi için AKK'nın K1 kuralı ile aynı sonucu vermesini sağlamaktır.

Auerswald ve Moshagen (2019) tarafından gerçekleştirilen simülasyon çalışmasında AKK yönteminin, tek boyutlu ve ilişkisiz faktörlerin bulunduğu yapılarda küçük örneklem büyüklüğünde bile iyi sonuçlar verdiği belirlenmiştir. Li vd. (2020) de gerçekleştirdikleri simülasyon çalışması sonucunda AKK'nin faktör sayısını belirleme performansının çapraz yüklerden çok az etkilendiği belirlenmiştir.

### **Hull Yöntemi**

Lorenzo-Seva vd. (2011) tarafından geliştirilen Hull (kabuk) yöntemi yamaç grafiğine benzer şekilde grafik incelemesiyle faktör sayısını önermektedir. Ancak Hull yöntemi yamaç grafiğinden farklı olarak özdeğer ile değil uyum indekslerini kullanarak faktör sayısını önermektedir. Bu yöntemde, önerilen modelin serbestlik derecesine

dayalı olarak faktör sayısı kestirilmeye çalışılmaktadır. Yöntemde ilk olarak; uyum iyiliği indeksi (karşılaştırmalı uyum iyiliği [comparative fit index-CFI] ya da açıklanan ortak bölümler indeksi [common part accounted for-CAF]) ve serbestlik dereceleri farklı modeller (faktör sayısı maksimum faktör sayısına kadar sürekli 1 artırılarak) için hesaplanmaktadır. Daha sonra uyum iyiliği indeksinden elde edilen değerler ile serbestlik dereceleri iki boyutlu bir grafikte gösterilmektedir (Auerswald ve Moshagen, 2019). Bu yöntem uyum iyiliği indeksiyle serbestlik derecesi arasındaki optimal dengeyi oluşturarak faktör sayısı önermektedir (Liu ve Wang, 2016).

Liu ve Wang (2016) tarafından gerçekleştirilen simülasyon çalışmasında Hull yöntemi, iki kategorili değişkenlerden oluşan tek boyutlu veri setlerinde simülasyon koşullarının neredeyse tamamında boyut sayısını doğru belirlemiştir. Ancak iki ve üç boyutlu yapılar için sadece boyutlar arası korelasyonun düşük olduğu koşullarda faktör sayısını doğru tahmin etmiştir. Boyutlar arası korelasyon arttıkça boyut sayısını tahmin başarısının düştüğü de bu çalışma sonucunda belirlenmiştir. Auerswald ve Moshagen (2019) tarafından gerçekleştirilen simülasyon çalışmasında ise Liu ve Wang'a (2016) benzer şekilde tek boyutlu veya çok boyutlu ancak boyutlar arası korelasyonun düşük olduğu koşullarda Hull yönteminin faktör sayısını doğru önerdiği belirlenmiştir.

### **Rastgele Orman (Random Forest) ve Aşırı Gradyan Arttırma (Extreme Gradient Boosting) Yöntemi**

Bir makine öğrenmesi olan rastgele orman yönteminde gerçek veriden yeniden örnekleme yöntemiyle (bootstrap) n tane örneklem oluşturulmaktadır. Daha sonra her bir örnekleme regresyon ya da sınıflama ağaçları kullanılarak tahmin/sınıflama yapılmaktadır. Bu büyüme süreci gözlemler için belirlenen en küçük eşik değerine ulaşıldığında sonlandırılmaktadır. Algoritma her bir düğümde rassal olarak seçtiği m tane değişkeni kullanarak en iyi bölünmeyi gerçekleştiren değişkeni seçmektedir (Breiman, 2001; Goretzko ve Bühner, 2020). Burada m, genellikle değişken sayısının üçte biri ya da kare kökü olarak kullanılmaktadır ( $m = \frac{p}{3} \sqrt{p}$ , p = değişken sayısı) (Goretzko ve Bühner, 2020).

Aşırı gradyan arttırma (Extreme Gradient Boosting [XGboost]) yöntemi, zayıf sınıflandırıcıların sınıflandırma gücünü arttırmak için bu sınıflandırıcılardan elde edilen sonuçlarının birleştirilmesine dayalı bir yöntemdir. Bu yöntem "boosting" denilmektedir (Friedman vd., 2000). Bu yöntemde rastgele orman yönteminin aksine yeniden örnekleme yapılmamaktadır. Önceki karar ağaçlarının sonuçlarını içeren tamamlanmış modelden elde edilen kalıntılar kullanılarak belirlenen sayıda karar ağacı oluşturulmaktadır. Büzülme (shrinkage;  $\lambda$ ) parametresi adı verilen bir parametre ile öğrenme hızı düzenlenmektedir (Goretzko ve Bühner, 2020).

Goretzko ve Bühner (2020) rastgele orman ve aşırı gradyan arttırma yöntemlerinin faktör sayısını doğru belirleme performanslarını 3204 simülasyon koşulunda diğer faktör sayısını belirleme yöntemlerinden (paralel analiz, karşılaştırmalı veriler ve AKK) elde edilen sonuçlarla karşılaştırmıştır. Çalışma sonucunda en iyi sonucun aşırı gradyan arttırma yönteminden elde edildiği, rastgele orman yönteminin de benzer şekilde iyi sonuçlar verdiği ve bu yöntemlerin geleneksel olarak kullanılan paralel analiz, karşılaştırmalı veriler ve AKK yöntemlerinden daha doğru sonuçlar verdiği belirlenmiştir.

### **Açıklanan Varyans Oranı**

Boyut sayısına karar verirken araştırmacılara fikir verebilecek yöntemlerden biri de açıklanan varyans oranıdır. Diğer yöntemlerden farklı olarak doğrudan boyut sayısı önerilmemesine rağmen araştırmacılar tarafından boyut sayısına karar verirken kullanılabilir (Howard, 2016). Açıklanan varyans oranının ne kadar olması gerektiği ise çalışma alanına göre değişmekle birlikte farklı yazarların farklı önerileri mevcuttur. Genellikle %75-%80 civarında olması önerilirken (Pett vd., 2003; Widaman, 2012) %90'a (Hair vd., 2009) çıkarılan ya da %50'ye (Beavers vd., 2013) kadar düşüren araştırmacılar da mevcuttur. Büyüköztürk (2020) sosyal bilimlerde tek boyutlu yapılarda %30'a kadar düşürülebileceğini ifade ederken Reckase (1979) ise ilk faktörün en az %20 oranında varyans açıklaması gerektiğini belirtmiştir. Buna göre açıklanan varyans oranının ölçülen özelliklerin doğasına göre değiştiği, bu nedenle çalışma alanlarına göre açıklanması beklenen varyans oranlarının da değişeceği söylenebilir. Örneğin, fen bilimlerinde güçlü ölçme araçları kullanılarak oran düzeyinde ölçmeler elde edilerek sürekli veri setleri oluşturulabilir. Bu gibi durumlarda açıklanan varyans oranının artması beklenebilir. Çünkü bu tip ölçümlerde (örneğin bir maddenin miktarının ölçümü gibi) ölçme sonuçlarına karışan hata miktarı sosyal bilimlerdeki ölçümlere nazaran daha az olacaktır. Ancak sosyal bilimlerde tanımlanması ve özelliklerinin



ölçülmesinin daha güç olduğu alanlarda ölçme sonuçlarına karışan hata miktarı daha fazla olabileceği için açıklanan varyans oranının da azalması beklenilebilir.

Açıklanan varyans oranına göre faktör sayısına karar verirken eklenecek yeni faktörün açıklayacağı varyansın önemli düzeyde olması gerekmektedir. Örneğin, yeni faktör eklendiğinde açıklanan varyans oranının %3 artması faktör eklenmesine değmeyecektir. Çünkü eklenen faktör yapıyı daha karmaşık hale getirecektir. Bunun için açıklanan varyans oranının en az %10 artırması bir kriter olarak ele alınabilir. Aynı zamanda teorik olarak da anlamlı yapılar oluşması gerektiği göz ardı edilmemelidir.

### **Tekrar Edilebilirlik Çalışması**

Burada bahsedilen yöntemlerin dışında açılıyıcı faktör analizinin tekrar edilebilirlik çalışması ile de faktör sayısı hakkında fikir edinilebilir. AFA sonuçlarının tekrar edilebilirliğinin incelenmesi için iki yol bulunmaktadır. Bunlardan biri AFA'nın gerçekleştirildiği örneklem rassal olarak ikiye bölünerek iki örneklemde de aynı AFA özellikleriyle (faktör çıkarma, faktör döndürme yöntemleriyle faktör sayısı aynı olacak şekilde) analizler gerçekleştirilip sonuçların karşılaştırılmasıdır. Diğer yöntem ise aynı evrenden gelen başka bir örneklemde yeniden veri toplayarak ilk örneklemdeki AFA gerçekleştirme özellikleri korunarak (faktör sayısı, faktör çıkarma yöntemi gibi) iki örneklemde elde edilen sonuçların karşılaştırılmasıdır (Osborne ve Fitzpatrick, 2012). Bu uygulama kararlı faktörlerin belirlenmesi için de kullanılabilir.

Bazı durumlarda, özellikle sosyal bilimlerde, faktör yükleri çok güçlü olmayan maddeler de ölçeklerde yer alabilmektedir. Bu gibi durumlarda elde edilen veri setine en çok uyan faktör sayısı yerine sonraki araştırmalarda da kullanılacak faktör sayısını belirlemek önemli olabilir. Özellikle ölçek geliştirme çalışmalarında bir amaç da geliştirilen ölçeğin sonraki çalışmalarda kullanılmasına imkân vermektir. Bu nedenle geliştirilen ölçeğin hedeflediği evren için benzer sonuçlar vermesi daha sonra bu ölçeği kullanacak araştırmacılar için de oldukça önemlidir. Bu nedenle tekrar edilebilirlik çalışması gerçekleştirerek her iki örneklemde de benzer yapılar veren modellerdeki faktör sayısı önemli faktör sayısı olarak ele alınabilir. Örneğin, bir ölçek geliştirme çalışması sonucunda elde edilen veri setinde 5 boyutlu (bazı boyutlarda 3 ya da 4 madde olan) ve bir ikincil düzey boyuta sahip bir yapı keşfedilmiş olsun. Bu durumda bu yapının benzer bir örneklemde de ortaya çıkıp çıkmadığı incelenebilir. Bu inceleme sonucunda iki örneklemde de benzer şekilde sonuçlar alınan modeldeki faktör sayısı önemli faktör sayısı olarak kabul edilebilir. Tekrar edilebilirlik çalışmasında iki örneklemde ilişkili 3 faktörlü bir yapı elde edildiyse bu durumda yapının teorik olarak da anlamlandırılabilir olup olmadığı göz önünde bulundurularak ilişkili üç faktörlü bir yapı tanımlanabilir. Çünkü bazı durumlarda veriye aşırı uyum gösteren modeller genellenebilir sonuçlar elde edilmesini engelleyebilmektedir.

### **AFA'da BOYUT SAYISINA KARAR VERİRKEN KULLANILABİLECEK YAZILIMLAR**

AFA'da boyut sayısına karar verirken kullanılacak yöntemler yukarıda belirtilmiştir. Bir araştırmacı için bu yöntemlerin bilgisinin yanında anılan yöntemlerin hangi yazılımlarda yer aldığı bilinmesi de önemlidir. Bu nedenle yöntemlerin teorik bilgilerinin yanı sıra bu bölümde hangi yazılımlarda analizlerin gerçekleştirilebileceğine yer verilmiştir.

K1 kuralı ile yamaç birikinti grafiğinin oluşturulması için bir yazılıma ihtiyaç yoktur. Ancak Sosyal Bilimler için İstatistik paketinde (Statistical Package for the Social Sciences [SPSS]) yamaç-birikinti grafiği AFA sonucunda otomatik olarak çizdirilebilmektedir. Diğer taraftan örneğin Factor (Lorenzo-Seva ve Ferrando, 2021) yazılımıyla gerçekleştirilen AFA sonucunda özdeğerler kullanılarak Excel yazılımında da grafik çizdirilebilir. K1 kuralı için 1'den büyük özdeğerler incelenmektedir. Tüm AFA gerçekleştirilen yazılımlar özdeğerleri de raporlayabildiğinden bu kural için tüm yazılımlarda inceleme yapılabilmektedir.

Paralel analiz için Factor (Lorenzo-Seva ve Ferrando, 2021) yazılımı kullanılabilir gibi R yazılımında (R Core Team, 2021) bulunan *psych* (Revelle, 2021) paketi de kullanılabilir. *Psych* paketinde Horn (1965) tarafından önerilen PA gerçekleştirilirken *EFA.MRFA* (Navarro-Gonzalez ve Lorenzo-Seva, 2020) paketinde en küçük sıra faktör çıkarma yöntemine dayalı olarak (minimum rank factor analysis) PA gerçekleştirilebilmektedir. Timmerman ve Lorenzo-Seva (2011) tarafından önerilen bu yöntem optimal PA adı verilmekte ve geleneksel PA'dan daha iyi sonuçlar verdiği belirtilmektedir.

Karşılaştırmalı veriler yöntemi için R yazılımında bulunan *EFAtools* (Steiner ve Grieder, 2020) paketi kullanılabilir. Ayrıca bu pakette birçok faktör sayısı belirleme yöntemi yer almaktadır. Karşılaştırmalı veriler yönteminin yanında *N\_FACTORS()* fonksiyonunda ampirik Kaiser kriteri, Hull yöntemi, paralel analiz, yamaç grafiği gibi yöntemler de yer almaktadır. Hull yöntemi için istenirse Factor yazılımı ya da *EFAtools* (Steiner ve Grieder, 2020) paketi de kullanılabilir.

Açımlayıcı grafik analizi için R yazılımında bulunan *EGAnet* (Golino ve Christensen, 2020) paketi kullanılabilir. MAP analizi için Factor yazılımı kullanılabilir gibi *EFA.dimensions* (O'Connor, 2022) paketi de kullanılabilir. *EFA.dimensions* paketinde MAP analizinin yanında yamaç grafiği, paralel analiz, ampirik Kaiser kriteri gibi yöntemler de bulunmaktadır. Aşırı gradyan artırma (*xgboost*) yöntemi için R yazılımında bulunan *xgboost* (Chen vd., 2022) paketi kullanılabilir. Rastgele orman yöntemi için de R yazılımında bulunan *ranger* paketi (Wright ve Ziegler, 2017) kullanılabilir. Bu yöntemler haricinde bu çalışmada bahsedilen açıklanan varyans oranı ve tekrar edilebilirlik çalışması için özel olarak bir yazılım bulunmamaktadır. Açıklanan varyans oranı zaten AFA gerçekleştirilen yazılımlar tarafından (SPSS, R ya da Factor yazılımı gibi) raporlanmaktadır. Tekrar edilebilirlik çalışması için seçilen yöntemlere göre (yeniden veri toplama ya da örnekleme ikiye bölme) işlemler gerçekleştirilmektedir. Factor yazılımı örneklem büyüklüğü 400 ve üzerinde olduğunda örnekleme Lorenzo-Seva (2021) tarafından geliştirilen SOLOMON yöntemiyle iki denk örnekleme ayırmaktadır. Bu şekilde iki örneklem üzerinde AFA gerçekleştirilerek sonuçlar karşılaştırılabilir. Diğer bir alternatif olarak R ya da SPSS yazılımlarında veri seti rassal olarak ikiye bölünerek her iki örnekleme de AFA gerçekleştirilebilir.

## **SONUÇ**

Açımlayıcı faktör analizi, hem yapı geçerliğine kanıt arama sürecinde (Guilford, 1946; Nunnally ve Bernstein, 1994; Thompson, 2004) hem de değişkenlerin ölçtüğü gizil yapıyı açığa çıkarırken sıklıkla kullanılmaktadır (Erkuş, 2019). AFA'nın kullanıldığı çalışmalarda boyut sayısına karar verme yöntemlerinin kullanımı konusunda bazı sınırlılıklar olabilmektedir. AFA'da elde edilen yapıların geçerli olabilmesi için araştırmacıların boyut sayısı konusunda verdikleri kararların doğru olması gerekir. Bu kararların doğru olması ise seçilen yöntemin verdiği sonuçların doğru olmasına bağlıdır. Örneğin, boyut sayısına karar verirken K1 kuralının kullanımı boyut sayısını olduğundan daha yüksek belirleyebilecekken (Fabrigar vd., 1999; Lance vd., 2006; Velicer vd., 2000; Zwick ve Velicer, 1986) yamaç-birikinti grafiğinin kullanımının boyut sayısını olduğundan daha düşük belirleyebilecektir (Auerswald ve Moshagen, 2019; Ruscio ve Roche, 2012). Ancak günümüzde yapılan çalışmalarda boyut sayısına karar verirken sadece bir yöntemin (çoğunlukla yamaç-birikinti grafiği) kullanıldığı araştırmalara rastlamak mümkündür (A. E. Kılıç ve Yılmaz, 2021; Konan ve Mermer, 2021; Okçu ve Deviren, 2021; Tellioğlu, 2021; Usta vd., 2020).

Açımlayıcı faktör analizinde boyut sayısına karar verirken bu çalışmada bahsedilen yöntemlerden en az ikisi ya da üçünden elde edilen sonuçlar incelenmelidir. Özellikle objektif olan yöntemlerden elde edilen sonuçların incelenmesi ve raporlanması önem arz etmektedir. Diğer bir deyişle doğrudan faktör sayısını öneren, faktör sayısını araştırmacıların incelemesine bırakmayan (örneğin paralel analiz gibi) yöntemlerin tercih edilmesi AFA gerçekleştirecek araştırmacılara önerilebilir. Boyut sayısına karar verdikten sonra özellikle AFA sonuçlarının tekrar edilebilirliği çalışması gerçekleştirilerek benzer örneklemlerde de aynı faktör sayısının uygun sonuçlar verip vermediği incelenmelidir. Böylece özellikle ölçek geliştirme çalışmalarında, geliştirilen ölçeği gelecekte kullanmak isteyen araştırmacılar için de fikir verebilecektir. Bunun yanında AFA'da objektif yöntemlerle boyut sayısına karar verirken yapının anlamlandırılmasına dikkat edilmelidir. Mantıksal/teorik/kavramsal olarak bir arada olması gereken maddelerin aynı faktöre yüklenip yüklenmediği incelenmelidir. Örneğin 5 maddeden oluşan bir faktörde 4 madde benzer bir özelliği ölçerken 5. madde bu dört maddenin ifade ettiği özellikten farklı (bu özellikle ilgisiz) bir özellik ölçüyorsa, bu durumda 5. madde gözden geçirilmeli ve gerekli durumda alan uzmanlarından da görüş alınarak analiz dışında bırakılmalıdır. AFA kolaylıkla, tek bir analizle (tek bir seferde) sonuçlandırılacak bir yöntem değildir. Sadece boyut sayısına karar vermek bile birkaç yöntemin birleştirilmesini, tekrar edilebilirlik çalışmasını ve ortaya çıkan yapının teorik olarak incelenmesini gerektirmektedir. Bu süreçlere önem verilmeden gerçekleştirilen çalışmalarda, benzer örneklemlerde farklı AFA sonuçları elde edilebilecektir. Bunun önüne geçmek için AFA süreci doğru bir şekilde gerçekleştirilmelidir. Bu sürecin doğru olması için boyut sayısına doğru karar vermek de önemlidir.

Bu çalışmada tüm boyut sayısına karar verme yöntemlerine yer verilmemiştir. Burada bahsedilen yöntemlerin haricinde onlarca yöntem bulunmaktadır. Ancak bu çalışmada sıklıkla kullanılan, performansları diğer yöntemlerle karşılaştırılmış, geleneksel olarak ifade edilebilecek yöntemlerin yanında literatürde yeni önerilen (makine öğrenmesi yöntemleri gibi) yöntemlere de yer verilerek araştırmacılara AFA'da boyut sayısına karar verme noktasında ışık tutulmaya çalışılmıştır. Bu çalışma sonucunda araştırmacılara, bu çalışma kapsamında bahsedilen yöntemlerden iki ya da üçünü kullanarak boyut sayısına karar vermeleri, daha çok objektif (boyut sayısını doğrudan öneren, araştırmacıların yorumlamasını gerektirmeyen) yöntemlere odaklanmaları önerilebilir.

#### KAYNAKÇA

- Auerswald, M., & Moshagen, M. (2019). How to determine the number of factors to retain in exploratory factor analysis: A comparison of extraction methods under realistic conditions. *Psychological Methods, 24*(4), 468–491. <https://doi.org/10.1037/met0000200>
- Bandalos, D. L., & Finney, S. J. (2019). Factor analysis: Exploratory and confirmatory. In G. R. Hancock & R. O. Mueller (Eds.), *The reviewers guide to quantitative methods in the social sciences* (2nd. ed.). Routledge.
- Beavers, A. S., Lounsbury, J. W., Richards, J. K., Huck, S. W., Skolits, G. J., & Esquivel, S. L. (2013). Practical considerations for using exploratory factor analysis in educational research. *Practical Assessment, Research & Evaluation, 18*(6), 1–13. <https://pareonline.net/pdf/v18n6.pdf>
- Braeken, J., & van Assen, M. A. L. M. (2017). An empirical Kaiser criterion. *Psychological Methods, 22*(3), 450–466. <https://doi.org/10.1037/met0000074>
- Breiman, L. (2001). Random forests. *Machine Learning, 45*, 5–32. <https://doi.org/10.1023/A:1010933404324>
- Brown, T. A. (2015). *Confirmatory factor analysis for applied research* (2nd ed.). The Guilford.
- Büyüköztürk, Ş. (2020). *Sosyal bilimler için veri analizi el kitabı: İstatistik, araştırma deseni, SPSS uygulamaları ve yorum* (28. Baskı). Pegem Akademi.
- Cattell, R. B. (1966). The scree test for the number of factors. *Multivariate Behavioral Research, 1*(2), 245–276. [https://doi.org/10.1207/s15327906mbr0102\\_10](https://doi.org/10.1207/s15327906mbr0102_10)
- Chen, T., He, T., Benesty, M., Khotilovich, V., Tang, Y., Cho, H., Chen, K., Mitchell, R., Cano, I., Zhou, T., Li, M., Xie, J., Lin, M., Geng, Y., Li, Y., & Yuan, J. (2022). *xgboost: Extreme Gradient Boosting* (1.5.2.1). <https://cran.r-project.org/package=xgboost>
- Cosemans, T., Rosseel, Y., & Gelper, S. (2021). Exploratory graph analysis for factor retention: Simulation results for continuous and binary data. *Educational and Psychological Measurement*. <https://doi.org/10.1177/00131644211059089>
- Crawford, A. V., Green, S. B., Levy, R., Lo, W.-J., Scott, L., Svetina, D., & Thompson, M. S. (2010). Evaluation of parallel analysis methods for determining the number of factors. *Educational and Psychological Measurement, 70*(6), 885–901. <https://doi.org/10.1177/0013164410379332>
- Cronbach, L. J., & Meehl, P. E. (1955). Construct validity in psychological tests. *Psychological Bulletin, 52*(4), 281–302. <https://doi.org/10.1037/h0040957>
- Dinno, A. (2009). Exploring the sensitivity of Horn's parallel analysis to the distributional form of random data. *Multivariate Behavioral Research, 44*(3), 362–388. <https://doi.org/10.1080/00273170902938969>
- Erkuş, A. (2019). *Psikolojide ölçme ve ölçek geliştirme-I: Temel kavramlar ve işlemler* (4nd ed.). Pegem Akademi.
- Fabrigar, L. R., & Wegener, D. T. (2012). *Exploratory factor analysis*. Oxford University.
- Fabrigar, L. R., Wegener, D. T., MacCallum, R. C., & Strahan, E. J. (1999). Evaluating the use of exploratory factor analysis in psychological research. *Psychological Methods, 4*(3), 272–299. <https://doi.org/10.1037/1082-989X.4.3.272>
- Friedman, J., Hastie, T., & Tibshirani, R. (2000). Additive logistic regression: a statistical view of boosting. *The Annals of Statistics, 28*(2). <https://doi.org/10.1214/aos/1016218223>
- Garrido, L. E., Abad, F. J., & Ponsoda, V. (2011). Performance of Velicer's minimum average partial factor retention method with categorical variables. *Educational and Psychological Measurement, 71*(3), 551–570. <https://doi.org/10.1177/0013164410389489>

- Glorfeld, L. W. (1995). An improvement on Horn's parallel analysis methodology for selecting the correct number of factors to retain. *Educational and Psychological Measurement, 55*(3), 377–393. <https://doi.org/10.1177/0013164495055003002>
- Golino, H. F., & Christensen, A. P. (2020). *EGAnet: Exploratory Graph Analysis -- A framework for estimating the number of dimensions in multivariate data using network psychometrics*.
- Golino, H. F., & Epskamp, S. (2017). Exploratory graph analysis: A new approach for estimating the number of dimensions in psychological research. *PLOS ONE, 12*(6), 1–26. <https://doi.org/10.1371/journal.pone.0174035>
- Golino, H. F., Moulder, R., Shi, D., Christensen, A. P., Garrido, L. E., Nieto, M. D., Nesselrode, J., Sadana, R., Thiyagarajan, J. A., & Boker, S. M. (2020). Entropy fit indices: New fit measures for assessing the structure and dimensionality of multiple latent variables. *Multivariate Behavioral Research, 1*–29. <https://doi.org/10.1080/00273171.2020.1779642>
- Golino, H. F., Shi, D., Christensen, A. P., Garrido, L. E., Nieto, M. D., Sadana, R., Thiyagarajan, J. A., & Martinez-Molina, A. (2020). Investigating the performance of exploratory graph analysis and traditional techniques to identify the number of latent factors: A simulation and tutorial. *Psychological Methods, 25*(3), 292–320. <https://doi.org/10.1037/met0000255>
- Goretzko, D., & Bühner, M. (2020). One model to rule them all? Using machine learning algorithms to determine the number of factors in exploratory factor analysis. *Psychological Methods, 25*(6), 776–786. <https://doi.org/10.1037/met0000262>
- Green, S. B., Levy, R., Thompson, M. S., Lu, M., & Lo, W.-J. (2012). A proposed solution to the problem with using completely random data to assess the number of factors with parallel analysis. *Educational and Psychological Measurement, 72*(3), 357–374. <https://doi.org/10.1177/0013164411422252>
- Guilford, J. P. (1946). New standards for test evaluation. *Educational and Psychological Measurement, 6*(4), 427–438. <https://doi.org/10.1177/001316444600600401>
- Hair, J. F., Black, W. C., Babin, B. J., & Anderson, R. E. (2009). *Multivariate data analysis* (7th ed.). Pearson.
- Horn, J. L. (1965). A rationale and test for the number of factors in factor analysis. *Psychometrika, 30*(2), 179–185. <https://doi.org/10.1007/BF02289447>
- Howard, M. C. (2016). A review of exploratory factor analysis decisions and overview of current practices: What we are doing and how can we improve? *International Journal of Human-Computer Interaction, 32*(1), 51–62. <https://doi.org/10.1080/10447318.2015.1087664>
- Humphreys, L. G., & Ilgen, D. R. (1969). Note on a criterion for the number of common factors. *Educational and Psychological Measurement, 29*(3), 571–578. <https://doi.org/10.1177/001316446902900303>
- Kahn, J. H. (2006). Factor analysis in counseling psychology research, training, practice: Principles, advances, and applications. *The Counseling Psychologist, 34*(5), 684–718. <https://doi.org/10.1177/0011000006286347>
- Kaiser, H. F. (1960). The application of electronic computers to factor analysis. *Educational and Psychological Measurement, 20*(1), 141–151. <https://doi.org/10.1177/001316446002000116>
- Kılıç, A. E., & Yılmaz, R. (2021). YouTube'un eğitsel amaçlı kabul durumunun incelenmesi. *Ahmet Keleşoğlu Eğitim Fakültesi Dergisi, 3*(1), 69–89. <https://doi.org/10.38151/akef.2021.10>
- Kılıç, A. F., & Uysal, İ. (2018). The effect of number of random generated correlation matrix on parallel analysis results. *27. Uluslararası Eğitim Bilimleri Kongresi*.
- Kılıç, A. F., & Uysal, İ. (2019). Comparison of factor retention methods on binary data: A simulation study. *Turkish Journal of Education, 8*(3), 160–179. <https://doi.org/10.19128/turje.518636>
- Kılıç, A. F., & Uysal, İ. (2021). Faktör çıkarma yöntemlerinin paralel analiz sonuçlarına etkisi. *Trakya Eğitim Dergisi, 11*(2), 926–942. <https://doi.org/10.24315/tred.747075>
- Konan, N., & Mermer, S. (2021). Quantum leadership scale: Validity and reliability study. *E-International Journal of Pedagogogy, 1*(1), 74–86. <https://doi.org/10.27579808/e-ijpa.13>
- Koyuncu, İ., & Kılıç, A. F. (2021). Classification of scale items with exploratory graph analysis and machine learning methods. *International Journal of Assessment Tools in Education, 8*(4), 928–947. <https://doi.org/10.21449/ijate.880914>

- Lance, C. E., Butts, M. M., & Michels, L. C. (2006). The sources of four commonly reported cutoff criteria. *Organizational Research Methods, 9*(2), 202–220. <https://doi.org/10.1177/1094428105284919>
- Ledesma, R. D., & Valero-Mora, P. (2007). Determining the number of factors to retain in EFA: An easy-to-use computer program for carrying out parallel analysis. *Practical Assessment, Research & Evaluation, 12*(2), 2–11.
- Li, Y., Wen, Z., Hau, K.-T., Yuan, K.-H., & Peng, Y. (2020). Effects of cross-loadings on determining the number of factors to retain. *Structural Equation Modeling: A Multidisciplinary Journal, 27*(6), 841–863. <https://doi.org/10.1080/10705511.2020.1745075>
- Liu, C.-W., & Wang, W.-C. (2016). A comparison of methods for dimensionality assessment of categorical item responses. *Pacific Rim Objective Measurement Symposium (PROMS) 2015 Conference Proceeding*, 395–410. <https://doi.org/10.1007/978-3-642-37592-7>
- Lorenzo-Seva, U. (2021). SOLOMON: A method for splitting a sample into equivalent subsamples in factor analysis. *Behavior Research Methods*. <https://doi.org/10.3758/s13428-021-01750-y>
- Lorenzo-Seva, U., & Ferrando, P. J. (2021). *Factor (Version 12.01.02) [Computer software]*. Universitat Rovira i Virgili.
- Lorenzo-Seva, U., Timmerman, M. E., & Kiers, H. A. L. (2011). The Hull method for selecting the number of common factors. *Multivariate Behavioral Research, 46*(2), 340–364. <https://doi.org/10.1080/00273171.2011.564527>
- Navarro-Gonzalez, D., & Lorenzo-Seva, U. (2020). EFA.MRFA: Dimensionality assessment using minimum rank factor analysis. <https://cran.r-project.org/package=EFA.MRFA>
- Nelson, A. E., DeVellis, R. F., Renner, J. B., Schwartz, T. A., Conaghan, P. G., Kraus, V. B., & Jordan, J. M. (2011). Quantification of the whole-body burden of radiographic osteoarthritis using factor analysis. *Arthritis Research & Therapy, 13*(5), 1–9. <https://doi.org/10.1186/ar3501>
- Nunnally, J. C., & Bernstein, I. H. (1994). *Psychometric theory* (3rd. ed.). McGraw-Hill.
- O'Connor, B. P. (2000). SPSS and SAS programs for determining the number of components using parallel analysis and Velicer's MAP test. *Behavior Research Methods, Instruments, & Computers, 32*(3), 396–402. <https://doi.org/10.3758/BF03200807>
- O'Connor, B. P. (2022). EFA.dimensions: Exploratory factor analysis functions for assessing dimensionality. <https://cran.r-project.org/package=EFA.dimensions>
- Okçu, V., & Deviren, İ. (2021). Kapsayıcı liderlik ölçeğinin geliştirilmesi. *Elektronik Eğitim Bilimleri Dergisi, 10*(20), 321–333.
- Osborne, J. W., & Fitzpatrick, D. C. (2012). Replication analysis in exploratory factor analysis: What it is and why it makes your analysis better. *Practical Assessment, Research & Evaluation, 17*(15). <http://pareonline.net/getvn.asp?v=17&n=15>
- Pett, M. A., Lackey, N. R., & Sullivan, J. J. (2003). *Making sense of factor analysis: The use of factor analysis for instrument development in health care research*. Sage.
- Preacher, K. J., Zhang, G., Kim, C., & Mels, G. (2013). Choosing the optimal number of factors in exploratory factor analysis: A model selection perspective. *Multivariate Behavioral Research, 48*(1), 28–56. <https://doi.org/10.1080/00273171.2012.710386>
- R Core Team. (2021). *R: A Language and Environment for Statistical Computing*. <https://www.r-project.org/>
- Reckase, M. D. (1979). Unifactor latent trait models applied to multifactor tests: Results and implications. *Journal of Educational Statistics, 4*(3), 207. <https://doi.org/10.2307/1164671>
- Revelle, W. (2021). *psych: Procedures for psychological, psychometric, and personality research* (Version = 2.1.9). <https://cran.r-project.org/package=psych>
- Ruscio, J., & Roche, B. (2012). Determining the number of factors to retain in an exploratory factor analysis using comparison data of known factorial structure. *Psychological Assessment, 24*(2), 282–292. <https://doi.org/10.1037/a0025697>



- Steiner, M. D., & Grieder, S. (2020). EFAtools: An R package with fast and flexible implementations of exploratory factor analysis tools. *Journal of Open Source Software, 5*(53), 2521. <https://doi.org/10.21105/joss.02521>
- Telliöđlu, S. (2021). Türk ve Alman Turistleri Tatile İten ve Çeken Faktörlerin Analizi. *Alanya Akademik Bakış, 5*(1), 287–299. <https://doi.org/10.29023/alanyaakademik.814273>
- Thompson, B. (2004). *Exploratory and confirmatory factor analysis: Understanding concepts and applications*. APA.
- Timmerman, M. E., & Lorenzo-Seva, U. (2011). Dimensionality assessment of ordered polytomous items with parallel analysis. *Psychological Methods, 16*(2), 209–220. <https://doi.org/10.1037/a0023353>
- Usta, H., Nal, G., & Gıca, S. (2020). Turkish validity reliability of udvalg for kliniske undersøgelser side effect rating scale (UKU-SERS) in patients with chronic schizophrenia. *Yeni Symposium, 58*(3), 7–10. <https://doi.org/10.5455/NYS.20200621093100>
- Velicer, W. F. (1976). Determining the number of components from the matrix of partial correlations. *Psychometrika, 41*(3), 321–327. <https://doi.org/10.1007/BF02293557>
- Velicer, W. F., Eaton, C. A., & Fava, J. L. (2000). Construct explication through factor or component analysis: A review and evaluation of alternative procedures for determining the number of factors or components. In R. D. Goffin & E. Helmes (Eds.), *Problems and Solutions in Human Assessment* (pp. 41–71). Springer. [https://doi.org/10.1007/978-1-4615-4397-8\\_3](https://doi.org/10.1007/978-1-4615-4397-8_3)
- Widaman, K. F. (2012). Exploratory factor analysis and confirmatory factor analysis. In H. Cooper, P. M. Camic, D. L. Long, A. T. Panter, D. Rindskopf, & K. J. Sher (Eds.), *APA handbook of research methods in psychology, Vol 3: Data analysis and research publication*. (pp. 361–389). American Psychological Association. <https://doi.org/10.1037/13621-018>
- Worthington, R. L., & Whittaker, T. A. (2006). Scale development research: A content analysis and recommendations for best practices. *The Counseling Psychologist, 34*(6), 806–838. <https://doi.org/10.1177/0011000006288127>
- Wright, M. N., & Ziegler, A. (2017). ranger : A fast implementation of random forests for high dimensional data in C++ and R. *Journal of Statistical Software, 77*(1), 1–17. <https://doi.org/10.18637/jss.v077.i01>
- Yang, Y., & Xia, Y. (2015). On the number of factors to retain in exploratory factor analysis for ordered categorical data. *Behavior Research Methods, 47*(3), 756–772. <https://doi.org/10.3758/s13428-014-0499-2>
- Zwick, W. R., & Velicer, W. F. (1986). Comparison of five rules for determining the number of components to retain. *Psychological Bulletin, 99*(3), 432–442. <https://doi.org/10.1037/0033-2909.99.3.432>

#### **Beyan ve Açıklamalar (Disclosure Statements)**

1. Bu çalışmanın yazarları, araştırma ve yayın etiđi ilkelerine uyduklarını kabul etmektedirler (The authors of this article confirm that their work complies with the principles of research and publication ethics).
2. Yazarlar tarafından herhangi bir çıkar çatışması beyan edilmemiştir (No potential conflict of interest was reported by the authors).
3. Bu çalışma, intihal tarama programı kullanılarak intihal taramasından geçirilmiştir (This article was screened for potential plagiarism using a plagiarism screening program).