

Açıklayıcı Grafik Analizi: EGAnet R paketiyle Bir Uygulama

Çiğdem Akın Arıkan*^{ID}

Sinem Demirkol**^{ID}

Öz

Amaç: Faktör sayısının belirlenmesinde her tekniğin kendine göre sınırlılıkları mevcuttur. Bu durum doğru tahminler sağlayabilecek yeni faktör belirleme yöntemlerine ihtiyaç duyulmasına neden olmuştur. Bu araştırmanın amacı faktör belirleme yöntemlerine alternatif bir yaklaşım olan açıklayıcı grafik analiz yöntemi ve bu yöntemin analizleri için kullanılan R programlama dilindeki EGAnet paketi tanıtmaktır.

Yöntem: Bu çalışmada, pakette yer alan ölçek geliştirme çalışmalarında kullanılan fonksiyonların göstermesi amaçlanmıştır. Bu amaçla, verinin analiz için hazırlanması, geleneksel ve bootstrap açıklayıcı grafik analiz ile faktör belirleme, madde ve boyutlara ilişkin istatistiklerin elde edilmesi, yapısal tutarlılık, doğrulayıcı faktör analizi ve ölçme değişmezliği gibi uygulamaların nasıl kullanılabileceği gösterilmiştir. EGAnet paketinin işlevselliğini göstermek için gerçek veri seti üzerinden analizler yapılmıştır. Bunun için Çevrimiçi Oyun Oynama Motivasyon Ölçeği'nden elde edilen veriler ile açıklamalı R kodları gösterilmiştir.

Sonuç: Bu araştırma sonucunda, geleneksel ve bootstrap açıklayıcı grafik analiz sonuçlarıyla doğrulayıcı faktör analizi sonuçlarının aynı olduğu elde edilmiştir. Ayrıca cinsiyete göre yapılan ölçme değişmezliği sonucunda kısmi metrik değişmezlik sağlanmıştır.


Özgünlük: Bu çalışmanın ölçek geliştirme sürecinde ölçeğin bütünsel olarak incelenmesi ve faktör belirleme konularında araştırmacılara yol göstereceği düşünülmektedir.

Anahtar sözcükler: Faktör belirleme, Keşifsel grafik analizi, EGAnet, ağ analizi.

* Psikometrist, İngiltere ve Galler Ulusal Eğitim Araştırmaları Vakfı, akincgdm@gmail.com

** Dr. Öğr. Üyesi, Ordu Üniversitesi, Eğitim Fakültesi, Eğitimde Ölçme ve Değerlendirme Anabilim Dalı, sinemdemirkol@odu.edu.tr

Exploratory Graphic Analysis: An Application with the EGAnet R Package

Çiğdem Akın-Arıkan*

Sinem Demirkol**

Abstract

Purpose: Each technique has its own limitations in determining the number of dimensions. This situation has led to the need for new factor determination methods that can provide accurate predictions. The aim of this research is to introduce the explanatory graphical analysis method, which is an alternative approach to factor determination methods, and the EGAnet package in the R programming language used for the analysis of this method.

Method: The article aims to show the functions used in the scale development studies in the package. For this purpose, it has been shown how applications such as preparation of data for analysis, dimension determination with traditional and bootstrapping explanatory graphic analysis, obtaining statistics regarding items and dimensions, structural consistency, confirmatory factor analysis and measurement invariance can be used. To demonstrate the functionality of the EGAnet package, analyzes are performed on the real data set. For this purpose, R codes are shown using data obtained from the Online Game Playing Motivation Scale.

Conclusion: As a result of this research, it is found that the results of traditional and bootstrapping explanatory graphic analysis and confirmatory factor analysis are same. In addition, partial metric invariance is achieved as a result of measurement invariance based on gender.

Originality: It is thought that this study will guide researchers in holistic examination of the scale and dimension determination during the scale development process.

Key words: Exploratory graph analysis, EGAnet, network analysis, factor numbers.

* Psychometrician, The National Foundation for Educational Research in England and Wales, The Mere, Upton Park, Slough, Berkshire SL1 2DQ, UK, akincgdm@gmail.com

** Assist. Prof., Ordu University, Faculty of Education, Department of Educational Measurement and Evaluation, sinemdemirkol@odu.edu.tr

Giriş

Psikoloji ve eğitimde kullanılan ölçme araçlarının faktör sayısını belirlemek psikometride uzun süredir devam eden bir sorundur (Velicer ve Jackson, 1990). Çok değişkenli verilerden yola çıkarak altta yatan gizli boyutların veya faktörlerin doğru bir şekilde belirlenmesi ölçme araçlarının oluşturulması ve doğrulanmasında önemli bir husustur (Timmerman ve Lorenzo-Seva, 2011). Ayrıca gözlenen değişkenlerden elde edilen çıkarımlara dayanarak hipotezler üretildiğinden faktörlerin doğru bir şekilde belirlenmesi psikolojik değişkenleri ölçmek için elde edilen verilerin analizindeki ilk adımlardan biridir (Lubbe, 2019). Faktör sayısının belirlenmesi psikolojik teorilerin oluşturulmasıyla da ilgilidir. Özellikle kişilik, zekâ vb. gibi alanlarda var olan yapıyı ortaya çıkarmak büyük ölçüde gizil yapıların tanımlanmasına bağlıdır (Garcia-Garzon, Abad ve Garrido, 2019).

Gizil yapıların ortaya konulmasında sıklıkla faktör analizi kullanılmaktadır. Faktör analizi insan davranışları ve yetenekleri altında yatan yapıları keşfetmek için kullanılan temel yöntemlerden biridir (Spearman, 1904). Bu yöntemde amaç değişkenler arasındaki ilişkileri belirlemek, doğrudan gözlemlenemeyen temel faktörleri ortaya çıkarmak (açımlayıcı faktör analizi) veya belirli bir teori altında varsayılan faktör yapısını doğrulamaktır (doğrulayıcı faktör analizi) (Cohen, Manion ve Morrison, 2005). Faktör, bir dizi değişken arasındaki ilişkilerin yoğunlaştırılmış halini açıklayabilen bir boyut veya yapıdır (Kline, 1994). Aynı zamanda değişkenlerin faktörle olan korelasyonu (faktör yükü) işlevsel olarak tanımlanan bir yapı şeklinde de ifade edilebilir (Roche, 1963). Faktörler gözlenen korelasyon matrisindeki korelasyon örüntülerini özetleyebilir veya gözlenen korelasyon matrisini tekrar üretmek için kullanılabilirler (Tabachnick ve Fidell, 2013).

Faktör sayısının belirlenmesinde farklı yöntemler bulunmaktadır. Bu yöntemlerin bazılarında belirli bir durdurma kuralına dayalı olarak faktör sayısı belirlenir. Bu yöntemin en bilinen örnekleri K1 yöntemi (Guttman, 1954; Kaiser, 1960) ve Horn'un paralel analizidir (PA) (Horn, 1965). K1 yönteminde özdeğerlerin birden büyük olması kuralı uygulama kolaylığı açısından sıklıkla tercih edilmesini sağlamıştır (Bandalos ve Boehm-Kaufman, 2009). Horn (1965) tarafından geliştirilen paralel analiz (PA) yöntemi ise K1 yönteminin uyarlaması olup bileşen belirsizliği sorununu azaltmak için önerilmiştir. Faktör sayısını belirlemek için model uyum indekslerini kullanan yöntemlerin en bilinen örnekleri ise Minimum Ortalama Kısmi Korelasyon (Minimum Average Partial, MAP) (Velicer, 1976), Bayesian Bilgi Kriteri (BIC) (Schwarz, 1978) ve Genişletilmiş Bayesian Bilgi Kriteri (EBIC) (Chen ve Chen, 2008) yöntemleridir. Bu yöntemlerde uyum indeksleri farklı sayıda faktör içeren modellerin yapısal uyumunu karşılaştırmak için kullanılır. Faktör sayısını belirlemede sıklıkla kullanılan

bir başka yöntem ise yamaç grafiği (Scree Plot; Cattell, 1966) yöntemidir. Bu yöntemde faktörler özdeğer büyüklüğüne göre bir grafik oluşturur ve grafikte eğimin azaldığı kırılma noktası faktör sayısını belirlemek için kullanılır (Gorsuch, 1983). Yamaç grafiği yönteminin bazı eksikliklerini gidermek için de grafiksel olmayan çözümler sunan hızlanma faktörü (acceleration factor, AF) ve optimal koordinatlar (optimal coordinates, OC) yöntemleri (Raiche, Riopel ve Blais, 2006; Raiche, 2010) geliştirilmiştir. Tüm bu yöntemlere ek olarak basitleştirilmiş bir model matrisi tarafından korelasyon matrisinin yeniden üretilip üretilmeyeceğini değerlendiren Çok Basit Yapı (Very Simple Structure, VSS; Revelle ve Rocklin, 1979) yöntemi gibi alternatif yöntemler de faktör sayısını belirlemek için kullanılabilir.

Literatürde farklı faktör belirleme yöntemlerinin değişen koşullar altında performanslarını inceleyen veya karşılaştıran çalışmalar mevcuttur. Örneğin, K1 yönteminin büyük örneklerde ve değişken sayısının fazla olduğu durumlarda faktör sayısını fazla tahmin ettiği (Velicer, Eaton ve Fava, 2000; Zwick ve Velicer, 1986); BIC yönteminin küçük örneklerde daha iyi performans gösterdiği ve büyük veri setlerinde faktör sayısını olduğundan fazla tahmin etme eğiliminde olduğu (Preacher, Zhang, Kim ve Mels, 2013); paralel analiz yönteminin faktör analizi ve temel bileşenler analizlerinde faktör sayısını belirlemek için kullanılabilir en iyi yöntem olduğu (Velicer ve diğerleri, 2000) belirtilmiştir. Ayrıca paralel analiz ve MAP'ın karşılaştırıldığı çalışmalarda, hem PA'nın hem MAP'ın özellikle faktörler arasındaki korelasyon yüksek (0,70) ve faktörler altında yer alan değişken sayısı düşük olduğunda boyut sayısını eksik tahmin etme eğiliminde olduğunu (Keith, Caemmerer ve Reynolds, 2016); faktörler arasında düşük veya orta düzeyde bir korelasyon olduğunda, örneklem büyüklüğü 500 veya üstü ve faktör yükleri orta ila yüksek olduğunda hem PA hem de MAP'ın iyi çalıştığını gösteren araştırmalar da mevcuttur (Velicer ve diğerleri, 2000; Crawford ve diğerleri, 2010; Garrido, Abad ve Ponsoda, 2011; Timmerman ve Lorenzo-Seva, 2011). Tüm bu çalışmalar faktör sayısının belirlenmesinde tek bir doğru yaklaşımın olmadığı, uygun yöntemin örneklem sayısı, bir faktör altında yer alan değişken/madde sayısı, faktör yükleri, faktörler arası korelasyon düzeyi gibi değişkenliklerin göz önüne alınarak belirlenebileceğini göstermektedir. Bu bağlamda bu çalışmanın amaçlarından biri gerçek bir araştırma senaryosundan elde edilen veri setini kullanarak son yıllarda alternatif faktör belirleme yöntemleri arasında yer alan Açıklayıcı Grafik Analizi yöntemini tanıtmak ve uygulamasını göstermektir.

Açıklayıcı Grafik Analizi

Faktör sayısının belirlenmesine yönelik yapılan çalışmalardan anlaşıldığı üzere her tekniğin kendine göre sınırlılıkları mevcuttur. Bu durum doğru tahminler sağlayabilecek yeni faktör belirleme yöntemlerine ihtiyaç duyulmasına neden olmuştur. Golino ve Epskamp (2017) ağ psikometrisini kullanarak faktör belirleme yöntemlerine alternatif bir yaklaşım olarak

Açıklayıcı Grafik Analiz (Exploratory Graph Analysis, EGA) yöntemini önermişlerdir. Ağ psikometrisi, psikolojik yapıları incelemek için ağ modelleme tekniğini uygulayan ve psikometri alanına yeni eklenen bir kavramdır (Epskamp, Maris, Waldorp ve Borsboom, 2017). Ağ modellerinde düğümler rastgele değişkenleri (ör. test maddeleri) kenarlar ise iki değişken arasındaki kısmi korelasyon katsayılarını belirtir (Epskamp ve Fried, 2018). Genel olarak düğümler dairelerle, daireleri birbirine bağlayan kenarlar ise çizgiyle temsil edilir.

Bir ağ modelinde düğümler arasında herhangi bir kenar yok ise değişkenlere ait kısmi korelasyon katsayısının sıfır olduğu, başka bir ifadeyle değişkenlerin koşullu olarak bağımsız olduğu anlaşılır. Fakat bu noktadaki temel sorunlardan biri örnekleme varyansından dolayı iki değişkenin koşullu olarak bağımsız olsa bile kısmi korelasyon katsayısının sıfır olarak kestirilmemesidir (Epskamp ve Fried, 2016). Bu durum ağ modelinde değişkenler arasında olmayan ilişkilerin görülmesini dolayısıyla modelin daha karmaşık hale gelmesine sebep olur. Bu soruna çözüm olarak değişkenler arasındaki sahte bağları engelleyen En Az Mutlak Küçültme ve Seçim Operatörü (Least Absolute Shrinkage and Selection Operatör, LASSO) kullanılabilir (Epskamp ve Fried, 2016; Golino ve Epskamp, 2016; Kossakowski ve diğerleri, 2015; Tibshirani, 1996). Bu teknik ile değişkenler arasındaki küçük korelasyonlar sıfır olarak ayarlanır ve ağ modelinde kovaryansı açıklamak için daha az bağlantı ortaya çıkar. Böylelikle ağ modeli daha sade hale gelerek (daha az kenar olduğundan) yorumlanabilirliği kolaylaştırır (Epskamp ve Fried, 2016). EGA modellerinde LASSO'nun grafiksel uzantısı kullanılır ve GLASSO olarak adlandırılır. EGA analizinde GLASSO'ya alternatif olarak Üçgenlenmiş Maksimum Filtrelenmiş Grafik (TMFG) yöntemi de mevcuttur. Bu yaklaşım, puan fonksiyonunun maksimize edilmesini sağlayan bir üçgenleme oluşturur. Bu sayede veriler anlamlı bir yapıda organize edilerek modellenebilir. Ayrıntılı açıklamalar ve formülasyonlar için Massara, Di Matteo ve Aste (2016) incelenebilir.

Ağ modellerini kullanan EGA'da gözlenen değişkenler herhangi bir faktörün nedenleri olarak modellenmek yerine gözlemlenen değişkenler arasındaki doğrudan ilişkilere dayanarak kümelenir. Birçok düğümün birbirine bağlı olduğu bölüme küme denir ve faktör analizindeki boyutlara denk gelir. EGA'da faktör sayısı Walktrap algoritması yardımıyla belirlenir (Pons ve Latapy, 2006). Walktrap algoritması, ağdaki içeriği ve faktör sayısını tanımlamak için Rastgele Yürüyüşler (Random Walks) kullanır. Rastgele yürüyüşler, ağdaki bir düğümden diğerine adımlar veya atlayışlardır. Bu algoritma grafikteki topluluk/küme yapısını ortaya çıkarabilen rastgele yürüyüşlere dayalı olarak düğümler arasındaki benzerliklerin bir ölçümünü sağlar ve veri kümesindeki değişkenleri kümeleyerek boyutları çıkarır (Pons ve Latapy, 2006).

EGA genel hatlarıyla şu şekilde çalışmaktadır. Öncelikle gözlenen değişkenler arasındaki kısmi korelasyon değerleri hesaplanır. Daha sonra GLASSO operatörü kullanılarak küçük kısmi korelasyonlar sıfıra ayarlanır. Son olarak da Walktrap algoritmasıyla kısmi korelasyon matrisinden yoğun alt grafiklerin sayısı (faktörler, topluluklar veya kümeler) belirlenir. Alt grafikler kümelerdeki yönlendirilmemiş ağırlıklı ağlardan oluşmaktadır. Bu ağların yönlendirilmemiş olmaları değişkenler arasındaki ilişki hakkında bilgi verirken neden sonuç ilişkisi hakkında herhangi bir bilgi vermez. Bu sürecin sonunda ilgilenilen örtük özelliğin altında yatan faktör sayısı ve her bir maddenin diğer maddelerle olan ilişkisi kestirilir. Ayrıca değişkenlere ait bu kestirimler düğümler ve kenarlardan oluşan bir grafikte sunulur.

Golino ve Epskamp (2017), EGA'nın boyut sayısını tahmin etmedeki performansını VSS, MAP, BIC, EBIC, K1 ve PA yöntemleriyle karşılaştırmış ve özellikle faktör sayısı (4 faktör) ve faktörler arası korelasyon değerleri (0,70) büyük olduğunda diğer yöntemlere göre daha iyi performans gösterdiği görülmüştür. Yine Golino ve Demetriou (2017)'nin yürüttüğü bir çalışmada EGA'nın diğer faktör analizi yöntemleriyle karşılaştırılabilir veya daha doğru boyut belirleme performansına sahip olduğu saptanmıştır. Koyuncu ve Kılıç (2021), maddelerin boyutlara göre sınıflandırılmasında EGA ve makine öğrenmesi yöntemlerini karşılaştırmışlardır. Faktör yükleri, örneklem büyüklüğü, boyut altında yer alan madde sayısı gibi koşulları değiştirerek oluşturdukları veri setlerinde makine öğrenmesi yöntemleri ile EGA'nın karşılaştırılabilir sonuçlar verdiği ve her iki yöntemde maddeleri boyutlarına göre doğru sınıflandırmada yüksek performans gösterdiğini belirtmişlerdir. Avcu (2021) çok kategorili yanıtlanan maddelerle oluşturulan tek boyutlu veri setlerinde EGA'yı geleneksel faktör belirleme yöntemleriyle karşılaştırmıştır. Yapılan simülasyon çalışması sonucu EGA'nın özellikle GLASSO algoritması ile birlikte kullanıldığında diğer faktör belirleme yöntemleriyle karşılaştırılabilir sonuçlar verdiğini belirtmiştir.

Yürütülen çalışmalar EGA yöntemin diğer faktör belirleme yöntemlerine göre değişen koşullardan daha az etkilendiğini göstermiştir (Golino ve Epskamp, 2017; Golino ve Demetriou, 2017). Bu sonucun ortaya çıkmasındaki ana sebeplerden biri EGA'nın tüm değişkenler arasında paylaşılan varyanstan çok değişkenler arasındaki varyansa odaklanmasıdır (Golino ve Epskamp, 2017). Ayrıca EGA yöntemi boyut sayısını belirlerken aynı zamanda her bir boyutta hangi maddelerin olduğunu da kestirir. Dolayısıyla boyutların içeriği ve sayısı maddelerin tek tek faktör yüklerini yorumlamaya gerek kalmadan belirlenebilir. Fakat yine de belirlenen boyutların teorik yapıyı doğrulaması gerektiği belirtilmiştir. Bunlarla beraber EGA'nın faktör analizi bulgularını desteklemede (Bell ve O'Driscoll, 2018) ve yapıların yeni boyutlarını keşfetmede (Christensen, Gross, Golino, Silvia ve Kwapil, 2019) de etkili olduğu görülmüştür.

EGA yönteminin özellikle incelenen yapının altında yatan faktör örüntüsünün keşfedilmesinde ve değişkenler arasındaki ilişkileri görselleştirilmesinde araştırmacılara fayda sağlayacağı düşünülmektedir. Ayrıca değişkenlerin otomatik olarak hangi boyutta yer aldığı kestirilmesi faktörlerle ilişkili olan değişkenlerin belirlenmesini kolaylaştıracaktır. Belirtilen bu gerekçelerle bu çalışmanın amacı geliştirilecek veya var olan teoriler altındaki boyutları anlamada araştırmacılara yardımcı olacağı düşünülen EGA yöntemini tanıtmaktır. Bu yöntemin R programlama dilinde nasıl uygulanacağına dair kod örnekleri paylaşmak ve kullanımını teşvik etmektir. Bu doğrultuda, EGA, Bootstrap EGA ve ölçme değişmezliği uygulamaları, gerçek bir veri seti üzerinde gerçekleştirilmiş ve bu veri seti üzerinden yöntemin işleyişi gösterilmiştir

Yöntem

Çalışma Grubu

Bu araştırmanın çalışma grubunun %65,3'ünü (n=534) erkekler, %34,1'ini (n=279) kadınlar, %0,6'sını (n=5) ise diğer olmak üzere toplam 818 üniversite öğrencisi oluşturmaktadır. Öğrencilerin yaşları 17 ile 28 arasında değişmektedir (Ortalama=22,919; SS= 4,352). Sınıf düzeyine göre bakıldığında ise katılımcıların %21,1'i birinci sınıf, %20,3'ü ikinci sınıf, %16,5'i üçüncü sınıf, %20,1'i dördüncü sınıf ve %21,8'i ise diğer (hazırlık, beşinci sınıf ve üstü) düzeyindedir.

Veri Toplama Aracı

Bu çalışmada Evren, Evren, Dalbudak, Topçu ve Kutlu (2020) tarafından Türkçe'ye uyarlanan Çevrimiçi Oyun Oynama Motivasyon Ölçeği (ÇOOMÖ) kullanılmıştır. Ölçek 27 maddeden oluşmaktadır. Ölçeğin uyarlama çalışması kapsamında yapılan açıklayıcı faktör analizi (AFA) sonucunda ölçeğin 6 faktör ve 26 maddeden oluştuğu görülmüştür. 18 nolu madde ölçekten çıkarılmıştır. Ancak bu maddenin ileride yapılacak araştırmalarda kontrol edilmesi önerilmiştir. Altı faktörlü bu yapı, doğrulayıcı faktör analizi (DFA) ile sınanmış ve ölçeğin iyi uyum indekslerine ($\chi^2/df=710,5/251=2,83$; GFI=0,929, CFI=0,971, TLI=0,962, and RMSEA=0,049) sahip olduğu elde edilmiştir. Ölçeğin güvenilirlik çalışması kapsamında Cronbach Alpha iç tutarlılık katsayısı hesaplanmış ve ölçeğin boyutlarına ait katsayıların 0.92 ile 0.87 arasında değiştiği görülmüştür (Evren ve diğerleri, 2020). Bu çalışmada ölçeğin iç tutarlılık güvenilirlik katsayısı başatme/kaçış boyutu için 0.905, eğlenme boyutu için 0.867, fantezi boyutu için 0.854, beceri geliştirme boyutu için 0.858, sosyalleşme boyutu için 0.833 ve rekabet boyutu için 0.860 olarak bulunmuştur.

Verilerin Analizi

Bu çalışmada verilerin analizi için Golino ve Christensen (2020) tarafından geliştirilen "EGAnet" paketi kullanılmıştır. Paket R programında mevcuttur

(R Core Team, 2019). *EGAnet* paketinin birçok işlevi bulunmaktadır, ancak bu çalışmada ölçme araçlarının boyutluluğunu belirlemek için pakette yer alan geleneksel EGA, bootsrapt EGA, DFA ve ölçme değişmezliği fonksiyonları gösterilmiştir.

Psikometrik ağ modelleri Gauss grafik modelini (GGM: Lauritzen, 1996) kullanır ve bu model varyans-kovaryans matrisinin tersi modellenerek rastgele/gözlenen değişkenlerin ortak dağılımları tarafından oluşturulur (Epskamp ve diğerleri, 2017). Fakat GGM'lerin bu tahmini küçük veri setlerinde aşırı uyumdan dolayı büyük standart hatalara ve kararsız parametre tahminlerine yol açabilir. Bu soruna çözüm olarak GLASSO operatörünün kullanılması önerilmiştir. Bu operatör yardımıyla değişkenler arasındaki küçük kısmi korelasyonlar sıfır olarak kestirilir. GLASSO tahminini kullanırken, ortaya çıkan ağ yapısının seyrekliğini kontrol eden bir ayarlama parametresinin ayarlanması gerekir. Bu ayar parametresini ayarlamamanın tipik bir yolu 100 farklı ayar parametresi üzerinden bir model tahmin etmek ve bazı kriterleri en aza indiren değeri seçmektir. GGM tahmini için, genişletilmiş Bayesian bilgi kriterinin (EBIC) en aza indirilmesinin gerçek ağ yapısının elde edilmesinde iyi çalıştığı gösterilmiştir (Foygel ve Drton, 2010). Bu çalışmada da *EGAnet* paketiyle ölçme araçlarının boyut sayısı EBIC'e göre ayarlanan uyum parametresi ile GLASSO tarafından belirlenmiştir. Ayrıca ağdaki içeriği ve boyut sayısını tanımlamak için *Rastgele Yürüyüşler (Random Walks)* algoritması kullanılmıştır. Ayarlanan uyum parametresi için *EGAnet* paketinde varsayılan olarak belirlenmiş olan 0,5 değeri kullanılmıştır. Ortaya çıkan boyutluluk ağında ağın geri kalanıyla bağlantısı kesilen bir düğüm olursa uyum parametresi değeri değiştirilebilir.

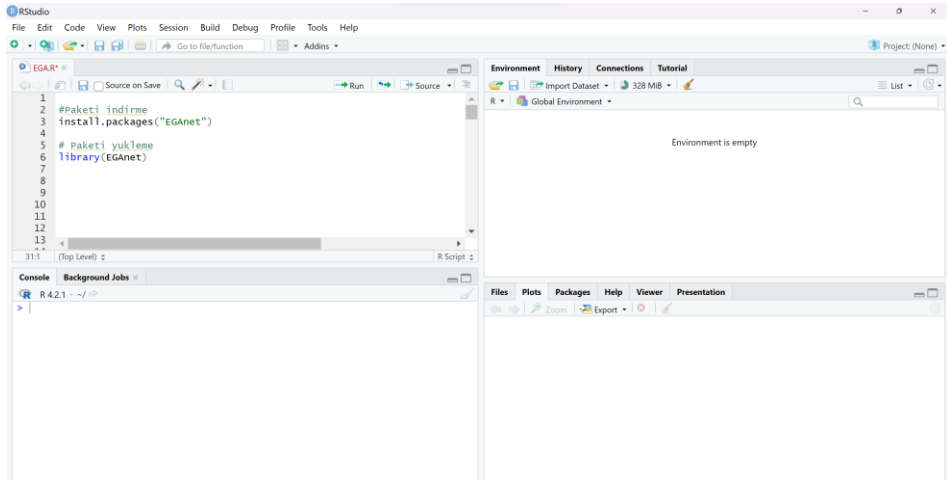
Bu çalışmada kullanılan *EGAnet* paketindeki işlemler sırayla verilmiştir.

- İlk olarak ağırlık matrisi elde edilmiştir.
- Geleneksel EGA fonksiyonu ile ölçmeğe ait ağ modeli oluşturulmuştur. Ağ modeli ile 6 boyutlu yapı elde edildikten sonra, ağ yükleri (standardize edilmiş düğüm güçleri veya faktör yükleri) elde edilmiştir.
- Bootstrap yöntemine dayalı olarak tahmin edilen ağ yapısını elde etmek için "bootEGA" fonksiyonu kullanılmıştır. Bootstrap modeli elde edildikten sonra, ölçmeğin güvenilirliğini gösteren madde kararlılık istatistikleri elde edilmiştir. Ayrıca boyut tutarlılığı ve bazı betimsel istatistikler hesaplanmıştır.
- Geleneksel EGA ve bootstrap EGA ağ modelleri karşılaştırılmıştır.
- Ayrıca EGA fonksiyonu ile oluşturulan sonucu (EGA nesnesini) kullanarak lavaan (Rosseel, 2012) paketi ile DFA yapılmıştır.
- Son olarak cinsiyete göre değişmezlik incelenmiştir.

Bulgular

Bu araştırmada hem tek boyutlu hem de çok boyutlu yapılarda kullanılan EGA algoritmasının (geleneksel EGA ve bootstrap EGA) nasıl kullanılacağı gerçek bir veri seti üzerinden adımlarıyla gösterilmiştir. İlk olarak bilgisayarımıza R programı (windows için: <https://cran.r-project.org/bin/windows/base/>), daha sonra R Studio'nun ücretsiz sürümü web adresinden indirilmelidir. EGA'nın R uygulaması için *EGAnet* paketine erişim sağlanmalıdır. R'daki *install.packages("EGAnet")* işlevi çalıştırılarak gerekli olan paket indirilebilir. Daha sonra *library(EGAnet)* komutu yazılarak bu paket çalıştırılmalıdır.

Şekil 1: R Studio ekranı ve EGA paket yükleme



SPSS dosyasında olan veri setlerini okutmak için *haven* (Wickham, Miller ve Smith, 2023) R paketine ihtiyaç bulunmaktadır. Bunun için R Studio'da ilk önce paketin indirilmesi daha sonra yüklenmesi gerekmektedir (Bknz Şekil 2).

Şekil 2: Haven paketinin yüklenmesi ve verinin okunması

```
#Paketi indirme
install.packages("haven")
# Paketi yükleme
library(haven)
#Datayı okuma
data1 <- read_sav("C:/Users/akinc/OneDrive/Masaüstü/EGA/EGAGaming.sav")
```

Haven paketi indirildikten sonra *ÇOOMÖ*'ne ait veriler *read_sav* fonksiyonu ile okutulmuştur. Veride ID, cinsiyet ve *ÇOOMÖ*'ne ait 27 madde yer almaktadır. Veriyi incelemek ve doğru olarak aktarılıp aktarılmadığını kontrol etmek için bazı fonksiyonlar kullanılabilir. Verideki ilk satırlardaki

verileri görmek için *head(data1)* komutu, son satırlardaki verileri görmek için ise *tail(data1)* komutu kullanılabilir. Ayrıca eğer verideki sütun isimleri kontrol etmek isteniyorsa *colnames(data1)* komutu ile bütün sütun isimleri yazdırılabilir (Şekil 3).

Şekil 3: Veri setinin incelenmesi

```
#Datadaki ilk 6 satırı görmek için
head(data1)
#Datadaki sütun isimleri
colnames(data1)
> head(data1)
# A tibble: 6 × 29
  ID cinsiyet  OG1  OG2  OG3  OG4  OG5  OG6  OG7  OG8  OG9  OG10  OG11  OG12
  <dbl> <chr>    <dbl> <dbl> <dbl> <dbl> <dbl> <dbl> <dbl> <dbl> <dbl> <dbl> <dbl>
1 1 1 5 5 5 5 5 5 5 5 2 5 5
2 2 1 5 5 5 5 4 4 4 5 5 5 5
3 3 2 4 5 5 5 5 5 5 5 5 5 5
4 4 2 4 5 5 5 5 5 5 5 5 5 5
5 5 1 5 5 5 5 5 5 5 5 3 5 5
6 6 2 4 5 3 5 5 4 5 5 5 5 3
# ... with 15 more variables: OG13 <dbl>, OG14 <dbl>, OG15 <dbl>, OG16 <dbl>, OG17 <dbl>,
# OG18 <dbl>, OG19 <dbl>, OG20 <dbl>, OG21 <dbl>, OG22 <dbl>, OG23 <dbl>, OG24 <dbl>,
# OG25 <dbl>, OG26 <dbl>, OG27 <dbl>
# İ Use `colnames()` to see all variable names
> colnames(data1)
[1] "ID" "cinsiyet" "OG1" "OG2" "OG3" "OG4" "OG5"
[8] "OG6" "OG7" "OG8" "OG9" "OG10" "OG11" "OG12"
[15] "OG13" "OG14" "OG15" "OG16" "OG17" "OG18" "OG19"
[22] "OG20" "OG21" "OG22" "OG23" "OG24" "OG25" "OG26"
[29] "OG27"
```

ÇOOMÖ'ne ait data1 dosyasında ID ve cinsiyet sütunlarını veriden çıkarmak için Şekil 4'deki komut yardımıyla data2 adında yeni bir very oluşturulur.

Şekil 4: Maddelerin seçilmesi

```
#sadece ölçek maddelerin olduğu data
data2 <- data1[, 3:29]
```

EGA analizlerine geçmeden önce ölçekte yer alan maddeler arası korelasyon matrisini elde etmek için pakette yer alan '*auto.correlate*' komutu kullanılır. Bunun için sadece maddelerin yer aldığı data2 verisi için *auto.correlate(data2)* komutu çalıştırılmalıdır. Komut ve örnek gösterim için sadece ilk 10 maddeye ait matris Şekil 5'te verilmiştir.

Şekil 5: ÇOOMÖ maddelere ait korelasyon matrisi

```
#Maddeler arasındaki korelasyonu elde etmek için
korelasyon <- auto.correlate(data2)
#İlk 10 maddeye ait korelasyon matrisi
```

	OG1	OG2	OG3	OG4	OG5	OG6	OG7	OG8	OG9	OG10
OG1	1.0000000	0.3639631	0.2679735	0.3779565	0.4076686	0.3562862	0.2984262	0.8417507	0.2913132	0.2396036
OG2	0.3639631	1.0000000	0.3141308	0.6255849	0.4854892	0.4418409	0.4626920	0.3342948	0.7636319	0.2547735
OG3	0.2679735	0.3141308	1.0000000	0.4415680	0.3883175	0.2641959	0.4198460	0.3056972	0.1851988	0.7208237
OG4	0.3779565	0.6255849	0.4415680	1.0000000	0.5889581	0.3959329	0.6636379	0.3917692	0.4861617	0.3452812
OG5	0.4076686	0.4854892	0.3883175	0.5889581	1.0000000	0.4583167	0.4731930	0.4275226	0.4340446	0.3790591
OG6	0.3562862	0.4418409	0.2641959	0.3959329	0.4583167	1.0000000	0.3687050	0.3512910	0.4663116	0.2462747
OG7	0.2984262	0.4626920	0.4198460	0.6636379	0.4731930	0.3687050	1.0000000	0.3357389	0.3830053	0.4174346
OG8	0.8417507	0.3342948	0.3056972	0.3917692	0.4275226	0.3512910	0.3357389	1.0000000	0.3057594	0.2744272
OG9	0.2913132	0.7636319	0.1851988	0.4861617	0.4340446	0.4663116	0.3830053	0.3057594	1.0000000	0.2385149
OG10	0.2396036	0.2547735	0.7208237	0.3452812	0.3790591	0.2462747	0.4174346	0.2744272	0.2385149	1.0000000

Literatürde yaygın olarak uygulanan ağ tahmin yöntemi GLASSO operatörü kenarların, ağdaki diğer tüm düğümler göz önüne alındığında, iki düğüm arasındaki kısmi korelasyon olduğu bir Gauss Grafik Modeli'ni tahmin eder (Christensen ve Golino, 2021). EGA süreci öncelikle düğümler arasındaki kenarların ağırlık matrislerinin hesaplanmasıyla başlar. Ağırlık matrisinin elde edilmesi için "*EGA.estimate*" fonksiyonu kullanılır. Ağırlık matrisini görmek için Şekil 6'da yer alan komut kullanılmıştır ve maddeler arası ağ ağırlık değerleri verilmiştir. Şekil 6 incelendiğinde en yüksek kenar ağırlığı değerlerinin madde 1 - madde 8 ve madde19 - madde 26 çiftleri arasında olduğu görülmektedir. Bu sonuç bu madde çiftleri arasında diğer madde çiftlerine oranla daha yüksek ilişki olduğu anlamına gelir. Eğer madde çiftleri arasındaki değerler sıfır ise bu madde çiftleri arasında bağlantı olmadığı anlamına gelir. Örnek olarak, 27 nolu maddenin 1, 2, 3, 4, 7, 10, 12, 14, 15, 17, 18, 19, 21, 24 ve 26. maddelerle bağlantısı yoktur.

Şekil 6: GLASSO kullanılarak tahmin edilen simetrik ağ kenarı ağırlıkları

```

ega.est <- EGA.estimate(data = data2)
ega.est[["network"]]

```

	OG1	OG2	OG3	OG4	OG5	OG6	OG7	OG8	OG9	OG10	OG11	OG12	OG13	OG14	OG15	OG16	OG17	OG18	OG19	OG20	OG21	OG22	OG23	OG24	OG25	OG26	OG27
OG1	-																										
OG2	0.02	-																									
OG3	0.00	0.00	-																								
OG4	0.02	0.17	0.08	-																							
OG5	0.03	0.03	0.02	0.21	-																						
OG6	0.02	0.00	0.00	0.00	0.09	-																					
OG7	0.00	0.00	0.03	0.24	0.03	0.02	-																				
OG8	0.57	0.00	0.00	0.00	0.03	0.00	0.00	-																			
OG9	0.00	0.25	0.00	0.00	0.00	0.00	0.00	0.00	-																		
OG10	0.00	0.00	0.34	0.00	0.00	0.00	0.01	0.00	0.00	-																	
OG11	0.00	0.11	0.00	0.14	0.00	0.00	0.08	0.00	0.12	0.00	-																
OG12	0.00	0.00	0.03	0.00	0.10	0.00	0.00	0.03	0.00	0.10	0.03	-															
OG13	0.01	0.00	0.00	0.00	0.10	0.00	0.05	-0.03	0.00	0.00	0.00	0.00	-														
OG14	0.00	0.00	0.03	0.01	0.00	0.00	0.34	0.00	0.00	0.04	0.00	-0.01	-														
OG15	0.02	0.00	0.00	0.00	0.00	0.00	0.07	0.15	0.00	0.00	0.12	0.00	0.12	-													
OG16	0.00	0.15	0.00	0.00	0.00	0.02	0.00	0.00	0.40	0.00	0.00	-0.01	0.08	0.00	0.00	-											
OG17	0.00	0.00	0.03	0.00	0.00	0.08	0.00	0.00	0.12	0.00	0.00	0.08	0.00	0.00	0.00	-											
OG18	0.00	0.00	0.00	0.00	0.09	0.12	0.00	0.00	0.00	0.00	0.00	0.00	0.05	-0.02	0.00	0.00	0.04	-									
OG19	0.00	0.00	0.01	0.00	0.14	0.00	0.00	0.00	0.00	0.00	0.20	0.00	0.00	0.04	0.00	0.00	0.08	-									
OG20	0.00	0.00	0.00	0.00	0.15	0.00	0.00	0.00	0.00	0.00	0.49	-0.02	0.00	0.06	0.09	0.15	0.01	-									
OG21	0.00	0.00	0.00	0.00	0.00	0.27	0.00	0.00	0.06	0.00	0.00	0.46	0.02	0.00	0.00	0.00	0.00	0.00	-								
OG22	0.19	0.00	0.00	0.00	0.01	0.00	0.00	0.30	0.00	0.00	0.07	0.00	0.09	0.00	0.03	0.04	0.00	0.01	0.00	-							
OG23	0.00	0.22	0.00	0.00	0.02	0.03	0.00	0.11	0.00	0.04	0.00	0.00	0.00	0.22	0.00	0.07	0.00	0.00	0.01	-							
OG24	0.00	0.00	0.21	0.00	0.00	0.00	0.00	0.37	0.00	0.00	0.00	0.00	0.00	0.38	0.05	0.00	0.01	0.01	0.01	-							
OG25	0.00	0.01	0.00	0.10	0.00	0.00	0.02	0.00	0.00	0.35	0.00	0.00	0.00	0.00	0.00	0.00	0.07	0.02	0.22	0.00	-						
OG26	0.00	0.00	0.00	0.00	0.05	0.00	0.00	0.00	0.00	0.36	0.00	0.00	0.06	0.00	0.00	0.44	0.01	0.06	0.00	0.04	0.07	-					
OG27	0.00	0.00	0.00	0.00	0.01	0.15	0.00	0.01	0.06	0.00	0.02	0.00	0.10	0.00	0.00	0.09	0.00	0.00	0.27	0.00	0.06	0.08	0.00	0.05	0.00	-	

Ağırlık matrisi elde edildikten sonra geleneksel EGA yöntemi uygulanmıştır. Bunun için pakette yer alan *EGA* fonksiyonu kullanılmıştır. EGA fonksiyonunda önemli argümanlardan biri “corr”dur. Bu argümanda 3 seçenek bulunmaktadır: auto, pearson ve spearman. Pearson, sürekli veriler için; Spearman ise sıralı veriler için tercih edilmelidir. Varsayılan olarak pakette ‘auto’ belirlenmiştir ve ‘auto’ veriler için uygun korelasyonları otomatik olarak hesaplar. EGA sonuçlarını grafik ile görmek için *plot.EGA = TRUE* olarak yazılmalıdır. Aşağıda yer alan fonksiyonda EGA paketindeki varsayılan (default) argümanlar kullanılmıştır. GLASSO ağ tahmin yöntemi Walktrap topluluk tespit algoritması ile birlikte kullanılmıştır (Detaylı bilgi için EGAnet paketi incelenebilir).

Şekil 7: Geleneksel EGA uygulaması

```

## EGA
egadata <- EGA(data2, uni.method = "LE", corr = "auto", model = "glasso", algorithm = "walktrap", plot.EGA = TRUE, plot.type = "qgraph")


```

EGA ağ modeli, düğümler (daireler) ve düğümler arasındaki kısmi korelasyonları temsil eden kenarlardan (çizgiler) oluşmaktadır. EGA ile ÇOOMÖ’yü temsil eden altı küme ortaya çıkmıştır (Şekil 8) ve bu yapı Evren ve diğerleri (2020) tarafından belirlenen faktör sayısı ile uyumludur. Ancak iki madde farklı boyutlarda yer almıştır. Bu maddelerden biri ilgili çalışmada da başatme boyutunda olması beklenen ancak iki faktöre yük veren ve ölçekten çıkarılan 18 numaralı maddedir. Bu madde, fantezi boyutuyla ilişkili bulunmuştur. Diğer madde ise sosyal boyutta olan ancak beceri geliştirme boyutu ile yüksek ilişkili çıkan 15 nolu maddedir. Boyut 1, sosyal boyutu ile (OG1,OG8,OG22); boyut 2 başatme boyutu ile (OG2, OG4, OG9, OG11, OG16, OG23, OG25); boyut 3 yarışma boyutu ile (OG3, OG10,OG17,OG24);

boyut 4 beceri geliştirme boyutu ile (OG5, OG12, OG15, OG19,OG26); boyut 5 fantezi boyutu ile (OG6, OG13, OG18, OG20, OG27) ve boyut 6 eğlenme boyutu ile (OG7, OG14, OG21) uyumludur.

Şekil 8'den de görüldüğü üzere, düğümlerin renkleri farklı faktörleri temsil ederken, maddeler arasındaki bağlantıların (yeşil renkli) kalınlığı veya inceliği maddeler arasındaki ilişkinin gücünü göstermektedir. Kalın çizgiler daha yüksek ilişki olduğu anlamına gelmektedir. Ayrıca maddeler arasında negatif korelasyon varsa ağ grafiğinde maddeler arasında çizgiler kırmızı renk ile gösterilmektedir. Ortaya çıkan ağ incelendiğinde, fantezi boyutunda yer alan maddeler arasındaki kısmi korelasyonların diğer boyutlara göre daha yüksek olduğu söylenebilir. Aynı zamanda, ağ grafiği; eğlence boyutundaki 4. madde ile yarışma boyutundaki 7. madde ve beceri geliştirme boyutundaki 5. madde arasında ilişkiler olduğunu göstermektedir. Ayrıca 4. maddenin kendi boyutunda yer alan 11 ve 2. maddeler ile çizgilerin daha ince olmasından dolayı görece olarak daha az ilişkili olduğu görülmektedir. Bu durum, her ne kadar bu 3 madde farklı boyutlarda olsa da ilişkilerinin görece daha yüksek olduğu anlamına gelmektedir.

Şekil 8: EGA'ya göre ÇOOMÖ'ne ait boyutluluk sonuçları



EGA'da madde kararlılık değerlerini incelemek için ise *net.load* fonksiyonundan yararlanılır. Bu fonksiyon her bir düğümün her bir boyuttaki gücünü hesaplayarak faktör yüklerine benzer bir denklik sağlar. Bununla birlikte, maddelerin kararlı olarak tanımlanabilmesi için ortalama ağ yüklerinin yalnızca tek bir boyutta yer alması ve bu değer 0,15'ten yüksek olması gerekir (Christensen ve Golino, 2021). Eğer birden fazla boyutta 0,15 ve üstünde bir yük değeri varsa o madde binişik maddedir ve ölçekten

çıkartılarak analizler tekrar edilmelidir. ÇOOMÖ maddelerine ait ağ yüklerinin elde edilmesine yönelik kod Şekil 9'da ve sonuçlar ise Tablo 1'de verilmiştir.

Şekil 9: Ağ yüklerini elde etme

Ag_yükü <- net.loads(egadata)
Ag_yükü

Tablo 1: ÇOOMÖ maddelerine ait ağ yükleri

Maddeler	1	2	3	4	5	6
OG8	0.514			0.101		
OG1	0.449					
OG22	0.286					
OG2		0.353				
OG9		0.336				
OG23		0.311				
OG16		0.295			0.112	
OG11		0.294				
OG25		0.263				
OG4		0.161				0.141
OG24			0.495			
OG10			0.432			
OG3			0.301			
OG17			0.275		0.136	
OG26				0.426		
OG19				0.386		
OG12				0.370		
OG5		0.103		0.139		
OG15	0.157			0.107		0.123
OG20					0.488	
OG13					0.341	
OG6					0.242	
OG27		0.116			0.240	
OG18					0.145	
OG14						0.458
OG21						0.421
OG7		0.13				0.347

Not: Ölçek verisinden çıkarılan maddeler koyu ve italik olarak yazılmıştır.

Tablodaki ortalama ağ yükleri (network loadings) incelendiğinde, ölçeğin uyarılama çalışmasında iki boyuta yük verdiği için (bir boyuta negatif, diğer boyuta pozitif) çıkarılan ve bu çalışmada orjinal boyutundan farklı bir boyutta çıkan 18. madde, madde ağ yük değerleri 0,15'in altında olan 5. madde ve farklı bir boyut ile daha yüksek ağ yük değeri veren 15. madde ölçekten çıkarılmış ve EGA fonksiyonu yardımıyla (Şekil 10) analizler tekrarlanmıştır.

Şekil 10: Maddeler çıkarılarak EGA'nın tekrar uygulanması

```
#18, 15 ve 5 nolu maddelerin datadan çıkarılması
data3 <- data2[-c(18,15,5)]
## EGA with glasso
egadata<- EGA(data3, uni.method = "LE", corr = "auto", model = "glasso", algorithm = "walktrap", plot.EGA =
TRUE, plot.type = "qgraph")
```

Maddeler çıkarıldıktan sonra elde edilen standardize edilmiş yük değerleri Tablo 2'de verilmiştir. Buna göre, düğüm gücü değerleri sosyal boyutu için 0,306 ile 0,544 arasında, başatme boyutu için 0,176 ile 0,256 arasında, yarışma boyutu için 0,281 ile 0,497 arasında, fantezi boyutu için 0,226 ile 0,487 arasında, eğlenme boyutu için 0,362 ile 0,479 arasında ve beceri geliştirme boyutu için 0,365 ile 0,510 arasında değişmektedir. Öte yandan, yük değerleri incelendiğinde maddelerin diğer boyutlardaki yük değerlerinin daha düşük olduğu elde edilmiştir.

Tablo 2: ÇOOMÖ'ne ait standartlaştırılmış yük değerleri

Maddeler	Sosyal	Başatme	Yarışma	Fantezi	Eğlenme	Beceri geliştirme
OG8	0.544					
OG1	0.467					
OG22	0.306					
OG2		0.365				
OG9		0.338				
OG23		0.318				
OG16		0.296		0.123		
OG11		0.296				
OG25		0.268				
OG4		0.176			0.142	
OG24			0.497			
OG10			0.430			
OG3			0.304			
OG17			0.281	0.143*		
OG20				0.487		
OG13				0.363		
OG27		0.117		0.271		
OG6				0.226		
OG14					0.479	
OG21					0.433	
OG7		0.135			0.362	
OG26						0.510
OG19						0.419

Not: Standartlaştırılmış ağı yük değerleri 0.10'un altında olanlar verilmemiştir.

Bootstrap EGA:

Araştırmalar incelendiğinde, ölçeklerdeki maddelerin faktör yüklerinin bazen farklı örneklemlerde/uygulamalarda kritik değerden düşük çıktığı bir başka ifadeyle bazı maddelerin bazı örnekleme gruplarında çalışmadığı görülmektedir. Her ne kadar amacımız boyutluluğu yorumlamak olsa da bu boyutların farklı örneklemlerde yeniden doğrulanıp doğrulanmayacağını bilmek de önemlidir. Bunun için ise *EGAnet* paketinde yer alan *bootEGA* fonksiyonu kullanılmaktadır. Bootstrap yöntemi olarak "*parametric*" ve "*resampling*" olarak iki tür bulunmaktadır. Parametrik yöntemde orijinal veri kümesine dayalı olarak (çok değişkenli normal rastgele dağılımlardan) yinelenen yeni veri kümeleri oluştururken, resampling de orijinal verilerin rastgele alt örneklerinden yeni veri kümeleri oluşturur. Parametrik yaklaşım verilerden bir GLASSO ağı tahmin ederek ve bir kovaryans matrisi üretmek için ağı tersini alarak başlar. Bu kovaryans matrisi daha sonra çok değişkenli bir normal dağılımdan gelen orijinal verilerle aynı sayıda bireye sahip verileri simüle etmek için kullanılır (Christensen ve diğerleri, 2019). Bununla birlikte önemli noktalardan biri de iterasyon sayısıdır. Golino ve Christensen (2020) iterasyon sayısını 500 olarak önerdiklerinden bu çalışmada da 500 olarak alınmıştır. İlgili kodlar Şekil 11'de verilmiştir. İlk olarak 18,15 ve 5. maddeler çıkarılmadan Bootstrap EGA yapılmıştır.

Şekil 11: Bootstrap EGA uygulaması

```
bootstrap EGA
gaming_bootegea <- bootEGA(
  data2 # verilerin olduğu data
  type = "parametric", # bootstrap turu
  iter = 500, # iterasyon sayısı
  seed= 1234 )
Not: Eğer seed değeri yazılmaz ise sonuçlar tekrarlanabilir olmayacaktır.
```

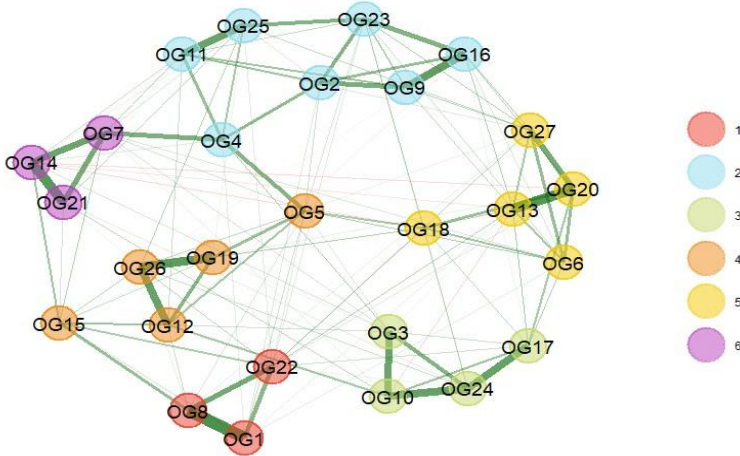
Eğer korelasyon matrisi kullanılmak isteniyorsa fonksiyona veri seti yerine korelasyon matrisi eklenmeli ve örneklem büyüklüğü belirtilmelidir (Şekil 12).

Şekil 12: Korelasyon matrisi kullanılarak Bootstrap EGA uygulaması

```
bootstrap EGA
gaming_bootegea <- bootEGA(
  datacor, # korelasyon matrisi
  n=818, #örneklem sayısı
  type = "parametric", # bootstrap turu
  iter = 500 # iterasyon sayısı)
```


Parametrik bootstrap ile elde edilen ağ yapısı Şekil 13'te verilmiştir. Elde edilen ağ yapısının Şekil 8'de elde edilen geleneksel EGA ile aynı olduğu ve beş boyutun ortaya çıktığı görülmektedir.

Şekil 13: Parametrik bootstrap EGA'ya göre ÇOOMÖ'ne ait boyutluluk sonuçları



Ölçeğe ilişkin ağ yapısı elde edildikten sonra boyutların kararlılığı incelenmiştir. İlk olarak betimsel istatistikler incelenmiştir. *EGAnet* paketinde yer alan *summary.table* komutu kullanılarak (Şekil 14) betimsel istatistikler elde edilir. Sonuçlar Tablo 3'te verilmiştir.

Şekil 14: Betimsel istatistiklerin elde edilmesi

```
# Betimsel istatistikler
gaming_bootege$summary.table
```

Tablo 3: ÇOOMÖ'nin Bootstrap EGA betimsel istatistik sonuçları

Bootstra sayısı	Medyan	S.H	% 95 GA- Düşük	%95 GA- Yüksek	Alt. Kuantil	Üst. Kuantil
500	6	0.0894	5.824	6.175	6	6

Tablo 3 incelendiğinde medyan değerinin altı boyutlu olduğu elde edilmiştir. Medyan değerine ait güven aralığı değerlerinin de dar bir aralıkta olduğu elde edilmiştir. Betimsel istatistiklere ek olarak her bir boyut çözümünün frekans değerleri de incelenebilir. Bunun için *frequency* komutundan yararlanılır (Şekil 15). Fonksiyon değerlerine ilişkin bilgiler Tablo 4'de verilmiştir.

Şekil 15: Frekansların elde edilmesi

```
#boyutluluk frekans değerleri
gaming_bootega$frequency
```

Frekanslara ilişkin Tablo 4 incelendiğinde ölçeğin boyut sayısının 500 bootstrap örneğinin 496'sında, yani %99'unda altı boyut olarak ortaya çıktığı görülmektedir. Elde edilen sonuçlar altı boyutlu yapının istikrarlı olduğunu göstermektedir.

Tablo 4: ÇOOMÖ'nin Bootstrap EGA boyutluluk frekans değerleri

Faktör sayısı	Frekans
5	0.006
6	0.992
7	0.002

Hangi boyutların veya maddelerin kararsız olduğunu belirlemek için yapısal tutarlılık incelenmelidir. Yapısal tutarlılık, maddelerin iterasyonlar boyunca doğru boyutlarda yer alma oranını göstermektedir. Bunun için *dimensionStability* fonksiyonundan yararlanılır (Şekil 16). Bu fonksiyon yardımıyla boyut tutarlılığı ile ilgili sonuçlar Tablo 5'te madde bazındaki sonuçlar ise Şekil 17'de verilmiştir.


Şekil 16: Yapısal tutarlılık değerlerinin elde edilmesi

```
# yapısal tutarlılık
yapısal <- dimensionStability(gaming_bootega)
```


Tablo 5: Bootstrap EGA boyutların yapısal tutarlılık sonuçları


Boyutlar	Boyutluluk Tutarlılığı
1	0.996
2	0.994
3	1
4	0.712
5	0.926
6	0.998

Yapısal tutarlılık sonucu, 4. boyutun en düşük tutarlılığa sahip olduğu ve diğer boyutların yeterli tutarlılığa sahip olduğu elde edilmiştir. 4. boyutta hangi maddelerin tutarlılığı düşürdüğünü bulmak için madde bazında inceleme yapılmıştır. Şekil 17 incelendiğinde 5 ve 15 nolu maddelerin diğer maddelere göre daha kararsız olduğu görülmektedir. 15 nolu madde ölçeğin orijinalinde sosyal boyutta iken EGA ve bootEGA sonucunda beceri geliştirme boyutunda çıkmıştır. Maddelerin kararlı olarak tanımlanabilmesi için 0,70'den yüksek olması istenir.

Şekil 17: ÇOOMÖ'nin madde kararlılığı sonuçları


18., 15. ve 5. maddeler çıkarıldıktan sonra *EGA* ve *bootEGA* fonksiyonları ile elde edilen boyutluluk grafikleri Şekil 18'de verilmiştir. Ayrıca maddeler çıkarıldıktan sonra *bootEGA* ile elde edilen betimsel istatistikler incelendiğinde (*summary.table* and *frequency* komutları kullanılarak) 500 örneklemin tamamında ölçek 6 boyutlu çıkmıştır. Maddelerin tutarlılığına ilişkin elde edilen sonuçlar Şekil 19'da verilmiştir.

Şekil 18: ÇOOMÖ'nin EGA ve BootEGA ile Boyutluluk Sonuçları



Şekil 19 madde kararlılık değerlerinin tamamının 1 olduğunu göstermekte ve EGA ile tahmin edilen boyutsallık çözümünün sağlamlığını ortaya koymaktadır.

Şekil 19: ÇOOMÖ'nin tutarsız maddeler atıldıktan sonra madde tutarlılığı sonuçları



DFA

EGA yöntemine göre elde edilen boyutluluğun literatürde en sık kullanılan yöntem olan DFA sonuçlarıyla uyumlu olup olmadığı da incelenmiştir. Bunun için *EGAnet* paketinde yer alan *CFA* fonksiyonundan yararlanılmıştır. CFA


fonksiyonunda ordinal veriler için WLSMV ve eşit aralıklı/sürekli veriler için ise ML veya WLS kestirim yöntemleri bulunmaktadır. Bu çalışmada ML kestirim yöntemi kullanılmıştır. Ayrıca uyum indeksleri de elde edilmektedir (Şekil 20). Şekil 18 deki EGA grafik ağı ile Şekil 21'deki DFA sonuçları karşılaştırıldığında boyutluluk sonuçlarının aynı olduğu elde edilmiştir. DFA ile elde edilen uyum indekslerinin (CFI=0.986, TLI=0.984, RMSEA=0.080, SRMR=0.070) kabul edilebilir olduğu görülmüştür (Hu ve Bentler, 1999).

Şekil 20: DFA kodları

```
#DFA sonuçları
oyun_dfa <- CFA(ega.obj=egadata2, estimator="ML", data=data3)

#uyum indeksleri
lavaan::fitMeasures(oyun_dfa$fit, fit.measures = c("cfi", "tli", "rmsea", "srmr"))
```

Şekil 21: ÇOOMÖ'nin DFA sonuçları



Ölçme Değişmezliği

Geçerli bir karşılaştırma yapabilmek için, ölçme aracının farklı gruplar arasında aynı yapıyla aynı kavramları ölçmesi gerekmektedir. Bu durum ölçme değişmezliğinin sağlandığı anlamına gelir. DFA’da yapılan ölçme değişmezliği dört aşamalı olarak, daha esnek yapılardan daha katı yapılara doğru sıralı testlerle gerçekleştirilir. Biçimsel değişmezlik en temel düzeydir. Ölçme aracının bu düzeyde faktör yapısının, metrik değişmezlikte faktör yüklerinin, ölçek değişmezliğinde regresyon denklemlerindeki sabit sayının ve katı değişmezlikte hata terimlerinin gruplar arasındaki değişmezliği test edilir. Değişmezlik aşamalarından biri sağlanmazsa sonraki aşamaya geçilmez. Modelin uyum düzeyinin önceki aşamadaki modelle karşılaştırılmasıyla ölçme değişmezliği aşamaları değerlendirilir. Ölçme değişmezliği ağ analizinde de aynıdır. Ancak, *EGAnet* paketinde şu anda yalnızca biçimsel ve metrik değişmezlik test edilebilir. Ayrıca ağ analizinde değişmezlik testleri şu anda sadece iki grubun karşılaştırılmasına izin vermektedir.

EGA çerçevesindeki biçimsel değişmezlik, aynı topluluk yapısının gruplar arasında geri kazanılıp kazanılmadığını değerlendirmek için Walktrap algoritması kullanılarak ağ modellerinin ayrı gruplarda tahmin edilmesiyle değerlendirilir (Jamison ve diğerleri, 2021). Biçimsel değişmezliği sağlamak için gruplara ait veriler birleştirilir ve *bootEGA* ve *itemStability* komutları kullanılarak ortak bir örneklem yapısı oluşturulur. Eğer maddeler ait oldukları boyutta 0,70’den daha düşük bir değere sahip ise madde kararsız yapıya sahip olduğundan veriden çıkarılır ve bu işlem tüm maddeler kararlı olana kadar bir başka ifadeyle 0,70’den daha büyük bir değere sahip oluncaya kadar tekrarlanır (Christensen ve Golino, 2021; Golino ve Christensen, 2020). Eğer herhangi bir madde veriden çıkarılmışsa kısmi biçimsel değişmezliğin sağlandığı söylenebilir.

Biçimsel değişmezlik sağlandıktan sonra metrik değişmezlik aşamasına geçilir. Metrik değişmezlik aşamalı olarak gerçekleşir. İlk olarak her grup atanan topluluk üyeliklerini kullanarak ağ yüklerini hesaplayan bir ağ oluşturur. Gruplar arasındaki yüklemeler arasındaki fark ampirik değerleri verir. Daha sonra, grup üyelikleri permütasyona tabi tutulur ve ağlar yinelemeli olarak tahmin edilir. Yüklemelerdeki farklılıklar boş bir dağılım oluşturur. Ampirik farklılıklar daha büyük ve daha küçük boş dağılım farklılıklarını hesaba katan iki kuyruklu bir p-değeri kullanılarak bu dağılımla karşılaştırılır. Analiz sonuç, hem düzeltilmemiş p-değerlerini hem de Benjamini-Hochberg (B-H procedure; Benjamini ve Hochberg, 1995) çoklu karşılaştırma prosedürünü kullanarak düzeltilmiş p-değerlerini verir (Jamison, Christensen ve Golino, 2021).

Değişmezliğin test edilebilmesi için *invariance* fonksiyonundan yararlanılır. Bunun için ilk olarak sadece maddelerden oluşan verinin ve iki

kategorili olan grup değişkeninin tanımlanması gerekmektedir. Şekil 10'da görüldüğü üzere kararsız olan 3 madde çıkarılmış ve data3 oluşturulmuştur. Değişmezliğe geçmeden önce her bir grup üzerinde ayrı ayrı EGA yeniden çalıştırılmalı ve ortaya çıkan ağ yapısının gruplarda geçerli olup olmadığı kontrol edilmelidir. Cinsiyet değişkenini oluşturulurken erkekler 1, kadınlar 2 olarak kodlanmıştır. İlgili kodlar Şekil 22'de verilmiştir.

Şekil 22: Cinsiyete göre EGA kodları


```
# datayı çağırma
data3

# Cinsiyet değişkeni data1 datasında yer aldığı için data1'den cinsiyet değişkenini seçmemiz gerekiyor. Ayrıca eğer
grup değişkeni list formatında ise as.data.frame fonksiyonu yardımıyla dönüştürme yapılması gerekmektedir. Grup
değişkeninin hangi formatta olduğu typeof (grup) ile incelenebilir.


grup <- as.data.frame(data1[,2])

#ilk olarak sadece maddelerin olduğu data3 ile grup değişkeni birleştirilerek yeni bir data oluşturulur.
datagrup <- cbind(data3, grup)
#Erkekler için
ega.erkek <- EGA( datagrup[datagrup$Cinsiyet == 1, 1:24],model = "glasso", algorithm = "walktrap", plot.ega =
FALSE)
plot(ega.erkek, title = "Erkek")
#Kadınlar için
ega.kadin <- EGA(datagrup[datagrup$Cinsiyet == 2, 1:24], model = "glasso", algorithm = "walktrap", plot.ega =
FALSE)
plot(ega.kadin, title = "Kadin")
# Gruplarda ortaya çıkan ağ yapısını EGA analizindeki wc nesnesini karşılaştırmalıdır. wc, ağdaki her düğümün
topluluk (boyut) üyelikliğini temsil eden vektördür.
ega.kadin$wc
ega.erkek$wc
```

Şekil 23: ÇOOMÖ'nden kararsız öğeler çıkarıldıktan sonra erkek ve kadınlar için EGA grafikleri



Kadin



Ağ grafikleri incelendiğinde kadınlar ve erkekler için yapının 6 faktörden oluştuğu ve her faktörde aynı maddelerin olduğu görülmektedir. Ayrıca bu sonuçların Şekil 18 ile aynı olduğu görülmektedir.

Ağ grafiklerini kontrol edildikten sonra değişmezlik aşamasına geçilmiştir. İlk olarak biçimsel değişmezlik test edilir. Bunun için *wc* nesneleri arasındaki normalleştirilmiş ortak bilgi hesaplanır ve eğer sonuç 1 ise daha sonraki aşamaya geçilir. İlgili kodlar Şekil 24’te verilmiştir. *Invariance* fonksiyonundaki pakette varsayılan olarak belirtilenler kullanılmıştır.

Şekil 24: Değişmezlik kodları

```
# Değişmezlik
#Biçimsel değişmezlik
igraph::compare(ega.kadin$wc, ega.erkek$wc, method = "nmi")
#Metrik degismezlik
set.seed(1234)
degismezlik <- invariance(data3, grup, ncores = 2)
plot(degismezlik)
#sonuçlar
results[["results"]]
```

Tüm *wc*'ler aynı olduğundan (sonuç 1 olduğundan), biçimsel değişmezliği sağladığını söyleyebiliriz. Ayrıca *invariance* fonksiyonunu çalıştırıldığında “*Configural invariance was found with 24 variables*” (ölçekte 24 madde olduğu için) uyarısı bize biçimsel değişmezliğin tüm maddelerde sağladığını göstermektedir.

Metrik değişmezlik için hem gruplardaki fark hem de düzeltilmiş ve düzeltilmemiş *p* değerlerini görmek için `results[["results"]]` komutu

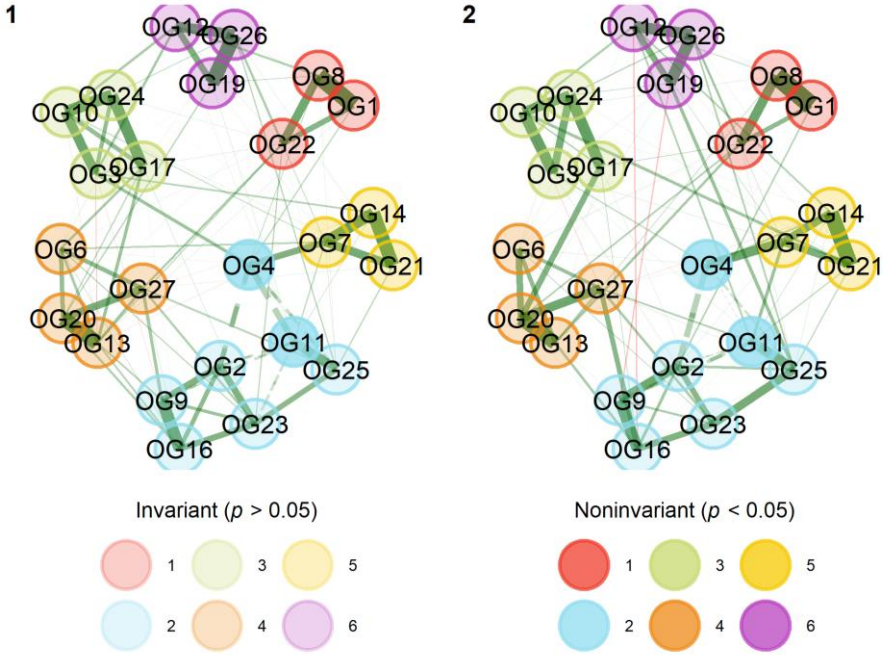
kullanılır. Jamison ve diğerleri (2021), bir madde hem düzeltilmemiş hem de düzeltilmiş p değerleri ile değişmez olarak tanımlandığında değişmez olarak kabul edilmesi gerektiğini belirtmişlerdir. Elde edilen sonuçlar Tablo 6'da verilmiştir.

Tablo 6: Metrik değişmezlik sonuçları

Boyut	Maddeler	Fark	p	p_BH	sig	Yön
Sosyal	OG1	-0.02	0.620	0.783		
	OG8	-0.058	0.174	0.534		
	OG22	0.007	0.856	0.936		
	OG2	-0.021	0.498	0.780		
	OG4	0.072	0.036	0.432	*	1 > 2
Başetme	OG9	-0.019	0.570	0.783		
	OG11	0.091	0.036	0.432	*	1 > 2
	OG16	0.016	0.604	0.783		
	OG23	0.029	0.372	0.720		
	OG25	-0.061	0.122	0.534		
Yarışma	OG3	-0.068	0.122	0.534		
	OG10	0.051	0.280	0.672		
	OG17	0.053	0.178	0.534		
	OG24	-0.03	0.520	0.780		
Beceri Geliştirme	OG6	-0.056	0.230	0.613		
	OG13	-0.001	0.982	0.992		
	OG20	-0.043	0.420	0.720		
Fantezi	OG27	0.014	0.772	0.926		
	OG7	0.095	0.086	0.534		
	OG14	0.047	0.396	0.720		
Eğlenme	OG21	0	0.992	0.992		
	OG12	-0.009	0.858	0.936		
	OG19	0.066	0.146	0.534		
	OG26	0.043	0.380	0.720		

Tablodaki sonuçlar alt örneklemeler arasında daha yüksek farklılıklara sahip değişmez olmayan yüklerin başetme boyutunda olan 4. ve 11. maddelere karşılık geldiğini göstermektedir. Bir başka ifadeyle, bu maddelerin değişmezliği sağlamadığı görülmüş, bu da kısmi metrik değişmezliğin sağlandığı anlamına gelmektedir. Ancak bu sonuçlar sadece düzeltilmemiş p değerleri için elde edilmiş, düzeltilmiş p değerlerinde tüm maddelerin değişmezliği sağlamıştır. Tablodaki sonuçlar görsel olarak incelendiğinde, metrik değişmezliğe sahip maddeler daha açık düğümlerle gösterilmişken metrik değişmezliğe sahip olmayan maddeler daha koyu gölgeli olarak gösterilmiştir.

Şekil 25: Metrik Değişmezlik Grafığı



Tartışma

Bu çalışmada geleneksel faktör belirleme yöntemlerine alternatif olarak geliştirilmiş EGA yönteminin gerçek bir uygulama verisiyle tanıtılması amaçlanmıştır. Çalışma dört aşamadan oluşmaktadır. Birinci aşamada geleneksel EGA yöntemi ile faktör sayısının belirlenmesi, ikinci aşamada araştırmacıların ölçeklerin yapısal bütünlüğünü psikometrik ağ perspektifinden değerlendirilmeleri için bootstrapEGA uygulaması, üçüncü aşamada EGA yöntemi ile belirlenen faktör sayısının DFA ile uyumunu karşılaştırılması ve dördüncü aşamada cinsiyet değişkenine göre ölçek değişmezliği uygulaması *EGAnet* paketi aracılığıyla tanıtılmıştır. Uygulamalar araştırmacıların faktör sayısını belirlemede karşılaştıkları sorunlara daha gerçekçi çözüm yolları sunmak adına bir ölçek uygulama çalışmasında elde edilen veriler üzerinden yürütülmüştür.

ÇOOMÖ'nün boyutları ortaya çıkarmak için yaptığımız bu çalışmada, EGA, bootstrap EGA ve DFA sonuçlarının benzer olduğu bulunmuştur. Bu bulgu, Golino ve Demetriou (2017)'in EGA'nın DFA'ya yakın sonuçlar verdiği çalışması ile uyumludur. Bununla birlikte, her ne kadar bu çalışmanın konusu olmasa bile DFA'nın başarısız olduğu koşullarda da (yüksek faktör korelasyonu, düşük faktör yükü gibi) EGA'nın daha iyi sonuçlar ortaya koyduğunu belirtmişlerdir.

Bu çalışmada gösterilen bir diğer uygulama ölçme değişmezliğidir. Ölçme değişmezliğinin sağlanması, gruplar arası karşılaştırmaları için ön koşul niteliğindedir. *EGAnet* paketinin geliştirilmesine devam edilmektedir, şu anda sadece yapısal ve metrik değişmezliği test edilmesine imkan tanımaktadır. Bu nedenle bu çalışmada EGA çerçevesindeki ağ yükleri üzerinde sadece yapısal ve metrik değişmezlik uygulaması gösterilmiştir. ÇOOMÖ maddelerinin yapısal ve metrik değişmezliği sağladığı görülmüştür. Metrik değişmezliğin sağlanması ölçekte yer alan her bir maddenin gizil yapıya gruplar arasında benzer derecede katkıda bulunduğu anlamına gelmektedir. Jamison ve diğerleri (2021)'nin yaptığı çalışmada faktör analizine dayalı ölçme değişmezliği ile ağ psikometrisi yönteminin benzer sonuçlar verdiği bulunmuştur. Bu nedenle faktör analizine dayalı ölçme değişmezliğine alternatif olarak ağ psikometrisine dayalı yöntem tercih edilebilir.

EGA doğası gereği keşfedicidir ve yapıların herhangi bir varsayıma dayanmadan incelenmesi veya yeniden değerlendirmesi için ideal bir yöntemdir (Christensen ve diğerleri, 2019). AFA veya diğer faktör belirleme yöntemleriyle birlikte EGA'nın kullanılması boyut sayısı için verilen kararlara dayanak sağlayacaktır. Elde edilen sonuçlar EGA'nın geleneksel faktör analizi yöntemleriyle karşılaştırılabilir veya daha iyi boyut belirleme doğruluğuna sahip olduğunu düşüncesini desteklemektedir (Golino ve Demetriou, 2017; Golino ve Epskamp, 2017). Ağ psikometrisini kullanan EGA'da araştırmacıların herhangi bir yönlendirmesi olmaksızın boyutların ve boyutları oluşturan maddelerin belirlenmesi araştırmacılara kolaylık sağlayacaktır. Ancak yine de ortaya çıkan yapının teorik tutarlılığının incelenmesi gerektiği unutulmamalıdır. Ayrıca EGA yöntemiyle değişkenler arasındaki ilişkinin görselleştirilmesi geleneksel boyut sayısı belirleme yöntemlerine göre daha avantajlı olabilir.

Psikolojik yapıların ortaya çıkışı, ortak nedenlere sahip olmalarından ziyade bir arada var olmaları ve birbirleriyle etkileşime girmeleri sebebiyle meydana gelir. Örneğin uyku sorunları yaşayan bir insan odaklanma sorunları veya yeni bir işe başlamada isteksizlik yaşayabilir. Bu belirtilerin ortaya çıkması gizil bir sebepten değil diğer belirtilerin varlığından kaynaklanabilir. Özellikle psikopatoloji (Borsboom ve Cramer, 2013; Isvoranu, Borsboom, van Os ve Guloksuz, 2016), gelişim psikolojisi (van der Maas ve diğerleri, 2006) ve bilişsel nörobilim (Smith Bassett ve Bullmore, 2006) gibi çeşitli araştırma alanlarında bu tarz yapılarla daha sık karşılaşılmaktadır. Bu yapıları oluşturan boyutların belirlenmesinde psikolojik ağlardan faydalanan ve ağ modellerini davranışların altında yatan yapıları tanımlamak için kullanan EGA ile daha doğru sonuçlar sağlanacaktır (Epskamp ve diğerleri, 2017).

Araştırmanın bazı sınırlılıkları vardır. Çalışmada sadece geniş örnekleme sahip bir ölçek uygulaması gösterilmiştir. Daha küçük

örneklemelerde sonuçların DFA ile benzerliğini karşılaştıran çalışmalar yapılabilir. Araştırmada ters puanlanan maddenin olmadığı bir ölçek uygulaması yapılmıştır. İleride yapılacak olan çalışmalarda ters puanlanan maddelerin olduğu benzer araştırmalar yapılabilir. *EGAnet* paketinde farklı birçok fonksiyon bulunmaktadır. Bundan sonra yapılacak olan çalışmalarda diğer fonksiyonlar tanımlanabilir. Bu bağlamda ölçme araçları için ağ analizi çalışmalarının artırılmasının ölçek geliştirme ve boyut belirleme alanyazına katkı sağlayacağı düşünülmektedir.

Kaynakça

- Avcu, A. (2021). Investigating the performance of exploratory graph analysis when the data are unidimensional and polytomous. *Journal of Measurement and Evaluation in Education and Psychology*, 12(1), 1-14. doi: 10.21031/epod.784128
- Bandalos, D. L., ve Boehm-Kaufman, M. R. (2009). Four common misconceptions in exploratory factor analysis. In C. E. Lance & R. J. Vandenberg (Eds.), *Statistical and methodological myths and urban legends: Doctrine, verity and fable in the organizational and social sciences* (ss. 61–87). Routledge/Taylor & Francis Group.
- Bell, V. ve O'Driscoll, C. (2018). The network structure of paranoia in the general population. *Soc Psychiatry Psychiatr Epidemiol*, 53, 737–744. <https://doi.org/10.1007/s00127-018-1487-0>.
- Borsboom, D., ve Cramer, A. O. (2013). Network analysis: An integrative approach to the structure of psychopathology. *Annual Review of Clinical Psychology*, 9, 91–121. doi: 10.1146/annurev-clinpsy-050212-185608.
- 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.
- Chen, J. ve Chen, Z. (2008) Extended Bayesian information criteria for model selection with large model spaces. *Biometrika*. 95(3), 759–71. <https://www.jstor.org/stable/20441500>
- Christensen, A. P. ve Golino, H. (2021). On the equivalency of factor and network loadings. *Behavior research methods*, 53, 1563–1580. <https://orcid.org/10.3758/s13428-020-01500-6>
- Christensen, A.P., Gross, G.M., Golino, H.F., Silvia, P.J. ve Kwapil, T.R. (2019). Exploratory graph analysis of the multidimensional schizotypy scale. *Schizophr. Res.* 206, 43–51. doi: 10.1016/j.schres.2018.12.018

- Christensen, A. P., Golino, H. F., ve Silvia, P. (2019). A psychometric network perspective on the validity and validation of personality trait questionnaires. *PsyArXiv*. <https://doi.org/g/10.1002/per.2265>.
- Christensen, A. P. ve Golino, H. (2021b). Estimating the stability of psychological dimensions via bootstrap exploratory graph analysis: A monte carlo simulation and tutorial. *Psych*, 3(3), 479–500. <https://doi.org/10.3390/psych3030032>
- Cohen, L., Manion, L., & Morrison, K. (2005). *Research methods in education*. (5th Ed.). London: Routledge Falmer.
- Cohen, J. (1960). A coefficient of agreement for nominal scales. *Educational and Psychological Measurement*, 20(1), 37-46. <https://doi.org/10.3390/psych3030032>
- Crawford, A. V., Green, S. B., Levy, R., Lo, W. J., Scott, L., Svetina, D., ve Thompson, M. S. (2010). Evaluation of parallel analysis methods for determining the number of factors. *Educational and Psychological Measurement*, 70, 885–901. <https://doi.org/10.1177/00131644103793>
- Epskamp, S., Maris, G., Waldorp, L. J., ve Borsboom, D. (2017). *Network Psychometrics*. P. Irwing, D. Hughes, ve T. Booth (Ed.), *Handbook of psychometrics*. New York: Wiley.
- Epskamp, S. ve Fried, E. (2018). A tutorial on regularized partial correlation networks. *Psychological Methods*, 23(4), 617–634. <https://doi.org/10.1037/met0000167>
- Epskamp, S. ve Fried, E. I. (2016). A primer on estimating regularized psychological networks. *arXiv:Applications*. Available at: <http://arxiv.org/abs/1607.013677>.
- Evren, C., Evren, B., Dalbudak, E., Topçu, M. ve Kutlu, N. (2020). Psychometric validation of the Turkish motives for Online Gaming Questionnaire (MOGQ) across university students and video game players. *Addicta: The Turkish Journal on Addictions*, 7(2), 81-89. doi: 10.5152/ADDICTA.2020.19093.
- Foygel, R. ve Drton, M. (2010). Extended bayesian information criteria for gaussian graphical models. In *Proceedings of the 23rd international conference on neural information processing systems - volume 1* (Vol. 1, ss. 604–612). Vancouver, Canada.
- Garcia-Garzon, E., Abad, F. J. ve Garrido, L. E. (2019a). Improving bi-factor exploratory modelling: Empirical target rotation based on loading differences. *Methodology: European Journal of Research Methods for*

the Behavioral and Social Sciences, 15(2), 45–55.
<https://doi.org/10.1027/1614-2241/a000163>

- Garcia-Garzon, E., Abad, F. J. ve Garrido, L. E. (2019b). Searching for G: A new evaluation of SPM-LS dimensionality. *Journal of Intelligence*, 7(3), 14. <https://doi.org/10.3390/jintelligence7030014>.
- Garrido, L. E., Abad, F. J. ve Ponsoda, V. (2011). Performance of Velicer's minimum average partial factor retention method with categorical variables. *Educational and Psychological Measurement*, 71, 551–570. <https://doi.org/10.1177/00131644103894>
- Golino, H. ve Christensen, A. P. (2020). *EGAnet: Exploratory Graph Analysis - A framework for estimating the number of dimensions in multivariate data using network psychometrics*. R package version 0.9.4. <https://cran.r-project.org/web/packages/EGAnet/index.html>.
- Golino, H. F. ve Epskamp, S. (2016). Exploratory graph analysis: a new approach for estimating the number of dimensions in psychological research. *arXiv preprint*. Stat-Ap/ 1605.02231. Available at: <https://arxiv.org/abs/1605.02231>
- Golino, H. F. ve Epskamp, S. (2017). Exploratory graph analysis: A new approach for estimating the number of dimensions in psychological research. *PloS One*, 12(6), e0174035. <https://doi.org/10.1371/journal.pone.0174035>.
- Golino, H.F. ve Demetriou, A. (2017). Estimating the dimensionality of intelligence like data using Exploratory Graph Analysis. *Intelligence*. 62, 54–70. <https://doi.org/10.1016/j.intell.2017.02.007>.
- Golino, H., Shi, D., Christensen, A. P., Garrido, L. E., Nieto, M. D., Sadana, R., Thiyagarajan, J. A. ve 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>
- Gorsuch, R. L. (1983). *Factor Analysis*. Philadelphia: Saunders.
- Guttman L. (1954). Some necessary conditions for common-factor analysis. *Psychometrika*. 19(2), 149–61. <https://doi.org/10.1007/BF02289162>
- Horn, J. L.(1965). A rationale and test for the number of factors in factor analysis. *Psychometrika*, 30(2), 179–85. <https://doi.org/10.1007/BF02289447>
- Hu, L. T. ve Bentler, P. M. (1999). Cutoff criteria for fit indexes in covariance structure analysis: Conventional criteria versus new alternatives.

Structural Equation Modeling: A Multidisciplinary Journal, 6(1), 1-55.
<https://doi.org/10.1080/10705519909540118>

- Isvoranu, A.M., Borsboom, D., van Os, J., ve Guloksuz, S. (2016). A network approach to environmental impact in psychotic disorder: Brief theoretical framework. *Schizophr Bull*, 42, 870–873.
<https://doi.org/10.1093/schbul/sbw049>.
- Jamison, L., Christensen, A. P., ve Golino, H. (2021). Optimizing Walktrap’s Community Detection in Networks Using the Total Entropy Fit Index.
<https://doi.org/10.31234/osf.io/9pj2m>
- Kaiser, H. F. (1960). The application of electronic computers to factor analysis. *Educational And Psychological Measurement*. 20, 141–151.
<https://doi.org/10.1007/BF02289447>
- Keith, T.Z., Caemmerer, J.M. ve Reynolds, M.R. (2016). Comparison of methods for factor extraction for cognitive test-like data: Which overfactor, which underfactor? *Intelligence*, 54, 37–54.
<https://doi.org/10.1016/j.intell.2015.11.003>
- Kline, P. (1994). *An Easy Guide To Factor Analysis*. New York: Routledge.
- Kossakowski, J. J., Epskamp, S., Kieffer, J. M., van Borkulo, C. D., Rhemtulla, M., ve Borsboom, D. (2015). The application of a network approach to Health-Related Quality of Life (HRQoL): Introducing a new method for assessing HRQoL in healthy adults and cancer patients. *Qual Life Res*, 25, 781–792. <https://doi.org/10.1007/s11136-015-1127-z>
- Koyuncu, M. ve Kılıç, A.(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>.
- Lubbe, D. (2019). Parallel analysis with categorical variables: Impact of category probability proportions on dimensionality assessment accuracy. *Psychological Methods*, 24(3), 339–351.
<https://doi.org/http://dx.doi.org/10.1037/met0000171>.
- Massara, G. P., Di Matteo, T., ve Aste, T. (2016). Network filtering for big data: Triangulated maximally filtered graph. *Journal of Complex Networks*, 5(2), 161–178. <https://doi.org/10.48550/arXiv.1505.02445>
- Pons, P. ve Latapy, M. (2006). Computing communities in large networks using random walks. *J. Graph Algorithms and Applications*, 10, 191–218. <https://doi.org/10.7155/jgaa.00189>.

- Preacher, K. J., Zhang, G., Kim, C. ve 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 (2019). *R: A language and environment for statistical computing*. R Foundation for Statistical Computing, Vienna, Austria. URL <https://www.R-project.org/>
- Raiche, G. (2010). *nFactors: An R package for parallel analysis and non graphical solutions to the Cattell's scree test*. R package version 2.3.3. <https://cran.r-project.org/web/packages/nFactors/index.html>.
- Raiche, G., Riopel, M. ve Blais, J.G. (2006). *Non graphical solutions for the Cattell's scree test*. Paper presented at the International Annual Meeting of the Psychometric Society, Montreal.
- Revelle, W. ve Rocklin, T. (1979). Very simple structure: An alternative procedure for estimating the optimal number of interpretable factors. *Multivariate Behavioral Research*, 14(4), 403-414. doi: 10.1207/s15327906mbr1404_2.
- Rosseel, Y. (2012). lavaan: An R package for structural equation modeling. *Journal of Statistical Software*, 48(2), 1-36. <https://doi.org/10.18637/jss.v048.i02>
- Royce, J.R. (1963). *Factors as theoretical constructs*. D.N. Jackson ve S. Messick (Ed.), *Problems in Human Assessment*. New York: McGrawHill.
- Schwarz, G. (1978). Estimating the dimension of a model. *The annals of statistics*, 6(2), 461-4. <https://www.jstor.org/stable/2958889>
- Smith Bassett, D. S. ve Bullmore, E. (2006). Small-world brain networks. *Neuroscientist*, 12(6), 512-523. doi: 10.1177/1073858406293182.
- Spearman, C. (1904). "General intelligence," objectively determined and measured. *The American Journal of Psychology*, 15, 201-292. <https://doi.org/10.2307/1412107>
- Tabachnick, B. G. ve Fidell, L. S. (2013). *Using multivariate statistics* (6th ed.). Boston: Allyn and Bacon.
- Tibshirani, R. (1996). Regression shrinkage and selection via the lasso. *Journal of the Royal Statistical Society. Series B (Methodological)*, 58(1), 267-288. <https://www.jstor.org/stable/2346178>
- Timmerman, M. E. ve 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>.

- van der Maas, H. L., Dolan, C. V., Grasman, R. P., Wicherts, J. M., Huizenga, H. M., ve Raijmakers, M. E. (2006). A dynamical model of general intelligence: The positive manifold of intelligence by mutualism. *Psychological review*, 113(4), 842-861. doi: 10.1037/0033-295X.113.4.842
- Velicer, W.F. (1976). Determining the number of components from the matrix of partial correlations. *Psychometrika*, 41(3), 321-7. <https://doi.org/10.1007/BF02293557>
- Velicer, W. F., Eaton, C. A. ve 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*. Richard D. Goffin, ve Edward Helmes (Ed.), *Problems and solutions in human assessment* (s. 41-71). New York, NY: Springer.
- Velicer, W.F. ve Jackson, D. N. (1990). Component analysis versus common factor analysis: Some issues in selecting an appropriate procedure. *Multivariate Behavioral Research*, 25(1), 1-28. https://doi.org/10.1207/s15327906mbr2501_1 PMID: 26741964.
- Wickham, H., Miller, E. ve Smith, D. (2023). *haven: Import and Export 'SPSS', 'Stata' and 'SAS' Files*. R package version 2.5.4, <https://github.com/WizardMac/ReadStat>, <https://haven.tidyverse.org>.
- Zwick, W. R. ve Velicer, W. F. (1986). Comparison of five rules for determining the number of components to retain. *Psychological Bulletin*, 99(3), 432-442. <http://dx.doi.org/10.1037/0033-2909.99.3.432>.

Atf için:

Akın Arıkan, Ç. ve Demirkol, S. (2024). Açıklayıcı grafik analizi: EGAnet R paketiyle bir uygulama. *Çankırı Karatekin Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 15(2), 541-574. doi: 10.54558/jiss.1449101.

Etik Beyan:

Bu çalışmanın tüm hazırlanma süreçlerinde etik kurallara uyulduğunu yazarlar beyan eder. Aksi bir durumun tespiti halinde Çankırı Karatekin Üniversitesi Sosyal Bilimler Enstitüsü Dergisi'nin hiçbir sorumluluğu olmayıp, tüm sorumluluk çalışmanın yazarlarına aittir. İlgili çalışmada etik kurul izni gerekmemektedir.

Uyarı:

Yazar Çiğdem Akın Arıkan bu çalışmayı bağımsız olarak, yalnızca kendi araştırma, analiz ve yorumlarına dayanarak gerçekleştirmiştir. Bu çalışmada ifade edilen görüş ve fikirler yazarın şahsına aittir ve adı geçen kuruluşun resmi politikasını veya pozisyonunu yansıttığı düşünülmemelidir.

Yazar Katkıları:

“Açıklayıcı Grafik Analizi: EGAnet R paketiyle Bir Uygulama” başlıklı çalışmaya yazarlar eşit oranda katkı sağlamıştır.

Çıkar Beyanı: Yazarlar arasında çıkar çatışması yoktur.