

Temel Bileşenler Analizi ve Yapay Sinir Ağı Modellerinin Ölçek Geliştirme Sürecinde Kullanılabilirliğinin İncelenmesi*

An Investigation on Usability of Principal Component Analysis and Artificial Neural Network Models in The Process of Scale Development

Esin TEZBAŞARAN**, Selahattin GELBAL***

Öz: Bu araştırmanın amacı, yapı geçerliği çalışmalarında kullanılan temel bileşenler analizi yerine bu amaçla geliştirilen yapay sinir ağı modellerinin kullanılabilir olup olmadığını tespit etmektir. Veri indirgeme amacıyla geliştirilen Genelleştirilmiş Hebb Algoritması kullanan yapay sinir ağı modeli ve Kendini Düzenleyen Haritalama olarak adlandırılan diğer yapay sinir ağı modeli bu araştırmanın temel konusudur. Yapı geçerliği çalışması yapmak için 30 maddeden oluşan denemelik Öğretmenlere Yönelik Tutum Ölçeği hazırlanmış ve bu ölçek 400 öğretmen adayına uygulanmıştır. Elde edilen veriler temel bileşenler analizi ve yapay sinir ağı modelleri kullanılarak analiz edilmiştir. Kullanılan farklı yöntemlerden elde edilen ölçek yapılarından hangisinin daha uygun olduğuna karar vermek amacıyla, farklı 400 kişilik bir diğer öğretmen adayı grubundan tekrar veri toplanmış ve bu verilere doğrulayıcı faktör analizi uygulanmıştır. Temel bileşenler analizi ile yapay sinir ağı modellerine dayanarak yapılan doğrulayıcı faktör analizi sonuçları model uyum ve hata indekslerine göre karşılaştırılmıştır. Uyum indekslerine bakıldığında, bu yapılar uyum ve hata indekslerinin çoğu açısından uyumlu yapılarıdır. Sonuçta, 5x5 nöron üzerinden haritalanan kendini düzenleyen haritalama modelinin, RMSEA indeksi hariç, daha uyumlu sonuçlar verdiği söylenebilir.

Anahtar Kelimeler: Yapay sinir ağı, temel bileşenler analizi

Abstract: The aim of the research is to find out /to determine whether the artificial neural network models are usable instead of principal component analysis used in the construct validity studies. With the aim of data mining, the artificial neural network model which uses Generalized Hebb Algorithm developed and the other artificial neural network model called as Self Organizing Mapping are the focus of this research. For this reason, trial version of an attitude scale towards teachers with 30 items have been prepared, and it has been implemented on 400 teacher candidates from different faculties who joined the Pedagogical Formation Programme. The data obtained have been analysed via the principal component analysis and the artificial neural network models. To decide on the reasonable one among the scale constructs revealed by different methods, trial version of scale has been given to another group of 400 teacher candidates joining the same programme and the confirmatory factor analysis has been done based on the data gathered second time. Then the constructs revealed by principal component analysis and artificial neural network models have been compared based on the results of the confirmatory factor analysis using model fit and error indexes. When the model fit and error indexes are reviewed, it is seen that these constructs are fitting ones in terms of most fit and error indexes. As a result, the construct obtained from Self Organizing Mapping on 5x5 neuron have a more fitting one in terms of the model fit indexes excluding RMSEA index.

Keywords: Artificial neural network, principal component analysis

Giriş

Tüm bilimsel problemlerin çözüme kavuşturulabilmesi, mutlaka veri toplanması ve veri analizini gerektirir. Veri toplamak için gerekli olan araçlardan biri ölçme araçlarıdır. Özellikle doğrudan yapılamayan ölçmeler için çeşitli ölçme araçları ya da yöntemlerinin geliştirilmesine

*Bu makale ilk yazarın doktora tezinden oluşturulmuştur.

**Dr., İstanbul Üniversitesi Hasan Ali Yücel Eğitim Fakültesi, İstanbul-Türkiye, e-posta: tezbasaranesin@gmail.com

***Prof. Dr., Hacettepe Üniversitesi Eğitim Fakültesi, Ankara-Türkiye, e-posta: sgelbal@gmail.com

ihtiyaç duyulmaktadır. Eğitimde ele alınan problemler, fiziksel ölçüm sonuçlarına göre incelenebilecek problemler gibi değildir. Bu nedenle eğitimde ölçme ve değerlendirme alanının en çok yer kaplayan sorunlarından birisi, güvenilir ve geçerli sonuçlar veren ölçme araçlarının nasıl geliştirilebileceğine yönelik yaklaşım ve yöntemlerin belirlenebilmesidir.

Eğitimde araştırma problemlerinin ilgilendiği başarı, kaygı, tutum gibi temel değişkenler için, dolaylı ölçme yöntemi vasıtası ile ölçme araçları ya da yöntemleri geliştirilerek ölçümler elde edilir. İlgili değişkene ait geliştirilen ölçme araçları ya da yöntemlerinin güvenilirlik, geçerlik ve kullanılabilirlik gibi niteliklerinin sağlanması gerekir.

Eğitimde ve psikolojide sıklıkla incelenen yapılardan biri olan tutumlar için ölçek geliştirme çalışmasında, özenle takip edilmesi gereken bir yol haritası vardır. Öncelikle, tutum değişkeninin kuramsal tanımı ortaya konur. Ölçülmek istenen tutumun kuramsal tanımı çerçevesinde, gözlenmek istenen tepkileri uyuracağı düşünülen durumların tasarlanması ve kullanılan ölçekleme tekniğine uygun olarak ifade edilmesi gerekir (Tezbaşaran, 1997a). Böylesi araçlar geliştirilirken genellikle izlenen yolun birinci adımı, ölçülecek yapıya ilişkin gözlenebilir ve ölçülebilir bir tepki evreninden, denemelik bir tepki örneklemini oluşturmaktır. Daha sonra seçilen örneklemden tepkileri uyandıracak varsayılan uyarıcılar takımı (ölçek maddeleri) hazırlanır. Hazırlanan bu maddeler temsilci bir örnekleme (norm grubuna) uygulanarak, elde edilen veriler analitik yöntemlerle incelenir. Bu incelemede her bir maddenin, hedeflenen tepkiyi yeterince uyandırması beklenir. Amaca uygun istatistiksel analiz teknikleri kullanılarak uyarıcı özelliği taşıyan maddeler seçilir ve nihai bir ölçek hazırlanmış olur. Tezbaşaran (1997b), nihai ölçeğe doğru giden bu sürecin ilk adımını denemelik ölçeğin hazırlanması ve uygulanması olarak belirtir ve maddeler halinde aşamalandırır:

- Bir psikolojik obje ya da nesne durumuna yönelik tutumu tanımlama
- Belirlenen obje ya da duruma özgü tutumu temsil eden ifadeleri belirleme
- Bu ifadeleri denemelik ölçekte bir araya getirme ve ifadelere verilen cevapları toplama

Sürecin ikinci aşamasında ise bu cevapların analizi ve ifadelerden oluşan maddelerin seçimi ile nihai testin oluşturulması yer alır (Tezbaşaran, 1997b). Hazırlanan ölçekler, ölçülmek istenen yapıyı temsil etme gücü, güvenilir ve geçerli ölçme sonuçları verme derecesi gibi psikometrik özellikleri açısından incelenir. Ölçme araçlarında aranan önemli niteliklerden birisi güvenilirlik bir diğeri geçerliktir. Geçerli sonuçlar elde etmek için ölçümlerin güvenilir olmasına ihtiyaç duyulur ancak, geçerli olmayan güvenilir ölçümler yapılabilir. Bir başka deyişle ölçümler tutarlı olsa da, yanlış bilgiler ve doğru olmayan çıkarımlara neden olabilir. Bu nedenle güvenilirlik, geçerlik için gereklidir ancak, yeterli değildir (Miller, Linn ve Gronlund, 2009).

Ölçme aracı geliştirilirken kullanılan istatistiksel analizlerin amacı, bireylere yöneltilen ve bireyde ölçmek istediğimiz değişkene ait olduğu düşünülen yazılı ya da sözlü uyarıcılara (sorular, cümleler) değişik formatta verilen tepkiler üzerinden, ölçme aracının sağlıklı bir araç olup olmadığını tespit etmek ve ideal ölçme aracı haline getirmektir. Bu durumda yapılan iş, özetle, henüz ölçme aracı olduğu kanıtlanmamış bir araçtan veri toplayarak ve bu verileri analiz ederek ondan güvenilir ve geçerli bir ölçme aracı oluşturmak şeklinde tanımlanabilir. Bu nedenle ölçme aracı geliştirmede kullanılan istatistiksel analizlerin, istenen amaca hizmet etmesi oldukça önemlidir.

İstatistiksel analiz yöntemlerinin kullanımında bazı kısıtlayıcı durumlar vardır. Bunlar genel olarak parametrik analize izin vermeyen ölçek türleri, değişkenlere ait toplanan verilerde normal olmayan dağılımlar, değişkenler arası doğrusal olmayan ilişkiler olarak sıralanabilir. Özellikle bu bağlamda ve daha ötesi, verilerden elde edilecek daha sağlam sonuçların alınabilmesinin mümkün olup olmadığının bilimsel olarak incelendiği bir alan olan yapay sinir ağı modelleri dikkati çekmektedir. İstatistiksel analiz yöntemleri dışında yapay sinir ağı modellerinin, özellikle mühendislik ve iktisat alanında, yaygın olarak kullanıldığı görülmektedir. Ayrıca, yapay sinir ağlarının veri analizinde nispeten kullanışlı olabileceğini ortaya koyan kuramsal ve uygulamalı çalışmalar da vardır.

Eğitim ve psikoloji alanında ise ölçek geliştirme çalışmalarında kullanılan analizlerden biri temel bileşenler analizidir (TBA). Bu analiz üzerine odaklanıldığında, bunun yerine kullanılabilir olan yapay sinir ağı modelleri geliştirildiğine yönelik, alan yazında temel

araştırmalar ve farklı alanlara yönelik veri setleri üzerinden karşılaştırmalı çalışmalar mevcuttur. Bu ağ modellerinden biri, TBA yerine geliştirilen Genelleştirilmiş Hebb Algoritması (GHA) kullanan yapay sinir ağı modeli, diğeri ise faktör analizi yerine kullanılan Kendini Düzenleyen Haritalama (KDH) olarak bilinen yapay sinir ağı modelidir.

Bu araştırmanın temel problemi, eğitim ve psikolojide kullanılan tutum ölçeklerinin yapı geçerliğini belirlemek amacıyla kullanılan TBA yerine, yapay sinir ağları kullanarak daha optimum çözümlere ulaşılabilirliğinin incelenmesidir.

Araştırmanın amacı

Bu çalışmanın temel amacı, teorik ve uygulamalı çalışmalarda ortaya konan, veri indirgeme ve boyut belirleme amacıyla TBA'ne alternatif olan yapay sinir ağı modellerinin, eğitim araştırmalarında kullanılabilirliğini uygulamalı olarak incelemektir. Bu çalışmada, özellikle psikolojik yapılara ait ölçme araçlarının geliştirilmesinde kullanılan TBA sonuçlarını, yapay sinir ağı modellerinden çıkan sonuçlarla karşılaştırılması ve elde edilen yapıların uygunluğunun, uyum ve hata indeksleri açısından değerlendirilmesi amaçlanmaktadır.

Bu çalışmada ölçek yapısının incelenmesinde, TBA yerine GHA ve KDH ile modellenen yapay sinir ağlarının kullanılabilir olup olmadığına yönelik bir çalışma planlanmıştır. Bunun için, hazırlanan denemelik Öğretmenlere Yönelik Tutum Ölçeği (ÖYTÖ) ve bu ölçek üzerinden elde edilen verilere analizler uygulanmıştır. Analizlerden ortaya çıkan yapılar ve bunun üzerine yapılan karşılaştırmaları içeren araştırmanın problemi ve alt problemleri şu şekilde kurgulanmıştır:

Denemelik ÖYTÖ'nin TBA'ne göre elde edilen yapısı ile yapay sinir ağı modellerinden elde edilen yapısı nasıldır?

1. Denemelik ÖYTÖ'nin yapısı, TBA sonuçlarına göre nasıldır?
2. Denemelik ÖYTÖ'nin yapısı, GHA kullanan yapay sinir ağı modeli sonuçlarına göre nasıldır?
3. Denemelik ÖYTÖ'nin yapısı, KDH kullanan yapay sinir ağı modeli sonuçlarına göre nasıldır?
4. Denemelik ÖYTÖ için farklı yöntemlerle elde edilen yapıların, doğrulayıcı faktör analizinden elde edilen uyum ve hata indeksleri açısından sonuçları nasıldır?
 - 4.a. TBA'nde döndürme öncesi ortaya çıkan denemelik ÖYTÖ'nin yapısı ile GHA kullanan yapay sinir ağı modeli sonucu ortaya çıkan yapının uyum ve hata indeksleri nasıldır?
 - 4.b. TBA'nde döndürme sonrası ortaya çıkan denemelik ÖYTÖ'nin yapısı ile KDH kullanan yapay sinir ağı modeli sonucu ortaya çıkan yapının uyum ve hata indeksleri nasıldır?

Sayıtlar

Bu çalışmada temel iki sayıtlı vardır. Bunlardan birincisi, uygulamada bireylerin denemelik ÖYTÖ maddelerine içtenlikle cevap verdikleri kabul edilir. İkincisi ise Likert tipi ölçek maddelerinin tepki kategorilerinin sürekli olduğu kabulüdür.

Sınırlılıklar

Bu çalışmanın sınırlılıkları, veri toplama aracı, çalışma grubu ve veri analizi bölümü ile ilgilidir.

- Yapılan tüm analiz sonuçları denemelik ölçek için hazırlanan maddeler ile sınırlıdır.
- Yapılan tüm analiz sonuçları çalışma grubuna dâhil edilen bireylerle sınırlı ve yalnızca bu gruba ait olacaktır.
- Temel bileşenleri belirleme için yapay sinir ağlarında kullanılan modellerden yalnızca GHA kullanan yapay sinir ağı modeli ile sınırlandırılmıştır.
- Faktör belirleme için yapay sinir ağlarında kullanılan modellerden yalnızca KDH yapan yapay sinir ağı modeli ile sınırlandırılmıştır.

Faktör analizi ve temel bileşenler analizi

Faktör analizi, açıklayıcı faktör analizi ve doğrulayıcı faktör analizi (DFA) olmak üzere ikiye ayrılır. Açıklayıcı faktör analizi teori geliştirmek üzere kullanılırken, DFA teorisini test etmek üzere kullanılır. Bu tezin kapsamı, açıklayıcı faktör analizi ile ilgili olduğundan burada yalnızca açıklayıcı faktör analizine yer verilmiştir.

Faktör analizi, test puanlarının bir takım faktörlere bağlı olduğunu varsayar ve bu faktörlerin bazıları birden fazla test maddesi ya da değişken için ortaktır. Maddeler ya da değişkenler arası korelasyon analizi, her bir maddeden gelen puanın ne kadarının varsayımsal/farazi faktörlere bağlı olduğunu (daha sonra faktör yükleri olarak tanımlanacaktır) tahmin etmek için kullanılır. Eğer madde ya da değişkenler ile faktörler arasında bir başlangıç sayıltısı (faktör yükü tahmini) yok ise bu analiz açıklayıcı faktör analizi olarak tanımlanır (Kane, 2006). Açıklayıcı faktör analizi ile ortaya çıkan faktörlerin tümevarımsal örtük özellikler olduğu söylenebilir (Kane, 2006).

Örtük özelliklerin ortaya çıkarılmasında faktör analizi ve TBA'ne matematiksel işlem açısından yaklaşılacak olursa, kullanılan analizlerdeki farklılıkların, ortaya çıkan boyutlara farklı bir yorum getirdiği görülmektedir. TBA'nde, gözlenen maddelerdeki/değişkenlerdeki tüm varyans üzerinden analiz yapılırken, faktör analizinde ortak varyans analiz edilerek hata varyansı dışta tutulur. Bu nedenle sonuçta yapıya ait boyutların adı birinde "bileşenler" diğeri "faktörler" olarak adlandırılır.

Faktör analizinde önemli olan, bir yapıya ait olduğu düşünülen her bir değişkenin faktörlerce açıklanan ortak varyansıdır (communalıty). Faktörler tarafından açıklanamayan varyans ise hata varyansı olarak adlandırılır. Faktör yükleri, değişken ile faktörler arasındaki ilişki katsayısıdır. Değişkenin faktör yüklerinin kareleri toplamı ise değişkenin faktörlerce açıklanan toplam varyansını yüzde olarak verir.

TBA'nin genel amacı, veri azaltma ve yorumlamadır (Johnson ve Wichern, 1982). Çok sayıdaki değişkeni, bilgi kaybına uğratmadan daha az sayıda değişkene indirger ve yorum yapabilme gücünü artırır. TBA doğrusal bir analizdir. Cebirsel olarak temel bileşenler p adet rasgele değişkenin (x_1, x_2, \dots, x_p) doğrusal kombinasyonu olarak ifade edilirken, geometrik olarak doğrusal kombinasyonlar orijinal eksenlerin döndürülmesi ile yeni bir koordinat sistemini ortaya koyar. Yeni eksenler, en yüksek değişkenliğin yönlerini temsil eder (Johnson ve Wichern, 1982). Döndürme işlemi, TBA ile bileşenlerin ortaya çıkarılmasından sonra yapılır. Döndürme işlemi yapılmasındaki amaç, faktörler tarafından yapının daha iyi yorumlanabilmesi sağlayabilmektir. Faktör ya da bileşenlerin ortaya çıkarılmasında hangi yöntem kullanılırsa kullanılsın iyi bir veri seti ile benzer sonuçlar elde edildiği gibi, korelasyonların oldukça belirgin olduğu durumlarda farklı döndürme yöntemleri de benzer sonuçlar vermeye eğilimlidir (Tabachnick ve Fidell, 2001). İki döndürme yönteminden uygun olan kullanılarak ortaya çıkan yapılar artık anlamlandırılabilir. Bu döndürme yöntemlerinden birisi dik döndürme diğeri eğik döndürmedir. Dik döndürme faktörler arası bağımsızlık ilişkisini koruyarak, geometrik ifade ile eksenler arası 90 derecelik açıyı koruyarak yapılan döndürmedir. Faktörler arası korelasyonun manidar olduğu durumlarda eğik döndürme tercih edilir. Bu döndürme yönteminde artık eksenler arasındaki açı 90 derece değildir ve yine özellikle psikolojik yapılara ait faktörlerin birbiri ile ilişkisi olduğu durumlarda kullanılabilir.

Yapay sinir ağları

Yapay sinir ağı modeli, 1943 yılında McCulloch ve Pitts tarafından ortaya atılmış ve bu konudaki ilerleme daha çok bilgisayar ve robotik teknolojinin gelişiminde kendini göstermiştir. Yapay sinir ağları üzerinde oluşturulan yeni ağ modelleri ve farklı öğrenme kuralları ile bu yöntem, farklı alanlardaki (endüstri, haberleşme, savunma sanayi, gibi) verilerin analiz edilmesi amacıyla da kullanılmaya başlamıştır.

Yapay sinir ağları, beyindeki sinir ağlarının yapısından esinlenerek ortaya atılmış ve yapay olarak tasarlanmış bir ağ sistemidir. Bu ağlar, deneyimle elde ettiği bilgileri daha sonra kullanabilmek ve bu bilgileri depolamak için basit işlemci elemanlardan (nöron) ve birbirleri arasında paralel bağlantılardan (sinaps) oluşan bir sistemdir. Yapay sinir ağı modelleri, paralel

dağıtımli bağlaşımcı (connectionist) işleme modelleri olarak da bilinir (Kulkarni, 1994). Sinir ağları düzenlenebilir bağlantı ağırlıkları ile birbirlerine bağlanmış birimlerden oluşan bir dolaşım olarak görülebilir (Baldi ve Hornik, 1989).

Yapay sinir ağları, beyine iki açıdan benzer: Birincisi, her ikisi de bilginin çevreden alınıp bir öğrenme sürecinden geçirilerek elde edilmesine dayanır. İkinci benzerlik ise, sinaptik bağlar olarak bilinen nöronlar arasındaki bağlantı gücünün, bu bilgilerin depolanmasında kullanılmasıdır (Haykin, 1999).

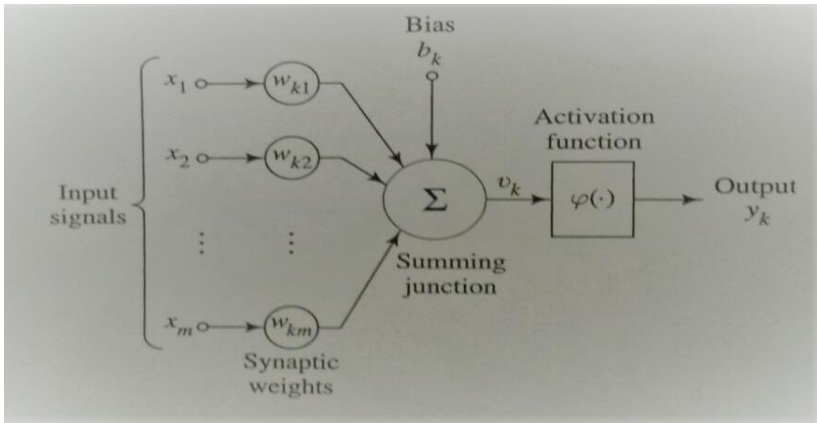
Biyolojik açıdan bir sinir ağının dentrit, soma, akson ve sinaps adı verilen yapıları ve görevleri incelenerek, yapay sinir ağlarının yapısı kurgulanmıştır. Yapay sinir hücresi, gerçek bir biyolojik hücreyle aynı ilkelere göre temellendirilmeye çalışılmıştır (Fausett, 1994 aktaran Neural Network Fundamentals, t.y.).

Yapay sinir ağı, McCulloch ve Pitts (aktaran Yurtoğlu, 2005) tarafından tanımlanan, biyolojik nöronun basit matematiksel modelinin gösterimi olarak da düşünülebilir. Biyolojik sinir ağlarındaki elemanlara karşılık gelen yapay sinir ağlarının elemanları Tablo 1'de gösterilmektedir (Baş, 2006).

Tablo 1
Biyolojik ve Yapay Sinir Ağı Elemanları

Biyolojik Sinir Ağı	Yapay Sinir Ağı
Sinir Sistemi	Sinirsel Hesaplama Sistemi
Sinir Hücresi (Nöron)	İşlemci Eleman (Yapay Sinir Hücresi, Nöron)
Sinaps	İşlemci Elemanlar Arası Bağlantı Ağırlıkları
Dentrit	Toplama Fonksiyonu
Akson	İşlemci Eleman Çıkışı

McCulloch-Pitts modeli incelendiğinde (Şekil 2), toplama fonksiyonu olarak doğrusal bir fonksiyon ve transfer fonksiyonu olarak birim adım fonksiyonu kullanılmış olduğu görülmektedir. Temelde biyolojik nörona benzer bir şekilde, işlem elemanı çıktıyı, toplama fonksiyonu sonucunun belirli bir eşik değerinin altında veya üstünde olmasına göre, iki olasılık arasından seçerek oluşturmaktadır.



Şekil 1. Yapay Sinir Ağı Yapısı

Kaynak: Haykin, S. (1999). *A Neural Networks A Comprehensive Foundation*, Prentice Hall, (s.11). kaynağından aynen aktarılmıştır.

Yapay hücre modelindeki ağırlıklandırılmış girdiler (u_k) ve yanlılık değeri (b_k), eklenerek toplam girdi değeri (v_k) aktivasyon fonksiyonundan geçerek ağın çıktısını belirler (y_k).

$$u_k = \sum_{j=1}^n x_j w_{kj}$$

$$b_k = X_0 W_0$$
$$v_k = u_k + b_k$$
$$y_k = F(v_k)$$

- x_j : Girdi nöronu
 w_{kj} : j girdi nöronundan k nöronuna giden bağlantı ağırlığı (+ ya da - olabilir)
 b_k : Yanlılık
 X_0 : Yanlılık girdisi 1 değerini alır.
 W_0 : Yanlılık girdisinin bağlantı ağırlığı
 $F(.)$: v girdisini çıktıya dönüştüren aktivasyon fonksiyonu
 y_k : k nöronunun çıktı değeri

Aktivasyon fonksiyonları, ağırlıklandırılmış girdiler toplamını, belirli bir nöron için seçilmiş bir işleme fonksiyonudur. Bu işlemi sağlayan ve McCulloch-Pitts tarafından önerilen birim adım fonksiyonu, sinyal fonksiyonudur (Sengupta, 2009). Aktivasyon fonksiyonları adım fonksiyonları, doğrusal fonksiyonlar ya da doğrusal olmayan fonksiyonlardan oluşabilir. Krenker, Bestër ve Kos (2011), doğrusal olmayan fonksiyonlardan en çok kullanılan fonksiyonun, sigmoid fonksiyonu olduğunu belirtir. Fonksiyonun ağırlığa göre türevinin alınabilmesi, yapay sinir ağlarında ağırlıkların güncellenebilmesi ve böylece beklenen çıktı ile gözlenen çıktı arasındaki fark ile ortaya çıkan hatayı azaltmayı sağlamak açısından önemlidir.

Yapay sinir ağlarının uygulama alanları

Yapay sinir ağları, eksik bilgilerle çalışabilme ve normal olmayan verilere çözüm getirebilme yeteneklerinden dolayı pek çok alanda kullanılmaktadır. Bu nedenle mühendislik alanında teknolojik gelişmelerde önemli rol oynamaktadır. Savunma sanayiindeki radar ve sonar cihazları, mayın detektörleri, haberleşme alanındaki gürültü filtreleme, iletişim kanallarında trafik yoğunluğunu kontrol etme, endüstrideki ürün analizi, tasarım ve kontrolü, otomasyondaki uçakların otomatik pilot sistemi, robotik sistemlerin ve hareket mekanizmalarının kontrolü gibi uygulamalar, yapay sinir ağlarının kullanıldığı alanlara örnek olarak verilebilir (Bayır, 2006).

Ancak eğitimde uygulama alanlarını görebilmek için yapay sinir ağlarının, hangi problem durumlarına çözüm ürettiğini incelemek gerekir. Özetmel'in aktarımına göre Geliştirilen ağ modelleri şu işlevleri yerine getirmede başarı göstermektedir (aktaran Bayır, 2006): Olasılık fonksiyon kestirim yakınsamaları, sınıflandırma, veri ilişkilendirme, desen eşleştirme, tanıma, kavramlaştırma / kümeleme, zaman serileri analizleri, sinyal filtreleme, veri sıkıştırma, doğrusal olmayan sinyal işleme, doğrusal olmayan sistem modelleme, optimizasyon, akıllı doğrusal olmayan kontrol.

Genelleştirilmiş Hebb Algoritması

Oja (1982) tarafından Hebb öğrenme kuralı üstüne oluşturulan ve TBA görevi görececek bir öğrenme kuralı geliştirilmiştir. Oja tarafından temeli atılan bu kural üzerine, Sagner (1989), Genelleştirilmiş Hebb Algoritması (Generalized Hebbian Algorithm-GHA) adı verilen bir yapay sinir ağı modeli ile temel bileşenleri belirleme çalışması yapar.

Diyelim ki bir nörona x_1, x_2, \dots, x_n gibi skalar değerleri olan girdiler ulaşsın. Bu girdi değerleri nöron ile bağlantılarını w_1, w_2, \dots, w_n ağırlıklarına göre yapmakta ve bu ağırlıklar nörona girdi değerlerini belirlemektedir. Buna göre y çıktı değeri ağırlıklandırılmış girdilerin toplamıdır.

$$y = \sum_{i=1}^n w_i x_i$$

Hebb kuralına göre, ağırlıkları zaman içinde değişkenlik gösterir. Nörona giren ve nörondan çıkan bağlantılar kuvvetli olduğunda, bir sonraki girdi ve çıktı bağlantıları daha kuvvetli olur. Ancak Oja (1982), girdi vektörleri $[x_1(t), x_2(t), \dots, x_n(t)]^T$ $t=1, 2, \dots$ gibi her zaman dilimi içinde değişen ağırlık değerleri bir stokastik süreç olarak ele alınacak olursa, oluşturulan yapay sinir ağı modelinin bir temel bileşen analizi işlevi göreceğini belirtir.

Oja öğrenme kuralında ($w_i(t+1)$), her bir ağırlık $w_i(t)$, kendi girdisine $x_i(t)$ göre büyüyecek fakat bu büyüme nörondaki iç dönütün kontrolü altında olacaktır ($-y(t)w_i(t)$). Bu terim öğrenme kuralında zayıflama ya da unutma terimi olarak adlandırılır.

$$w_i(t+1) - w_i(t) = \eta y(t)[x_i(t) - y(t)w_i(t)]$$

Oja öğrenme kuralı, tek bir çıktı üzerinde birinci temel bileşeni ortaya koyan bir algoritma tasarlar. Ancak bu algoritma genişletilirse diğer temel bileşenler de elde edilebilir (Sagner, 1989). Sagner'in (1989), Oja öğrenme kuralı ile Gram-Schmidt ortogonalizasyon işlemi birleştirilerek geliştirdiği algoritmaya Genelleştirilmiş Hebb Algoritması (GHA) denir. Bu çalışma ile Sagner (1989), GHA'nın öz vektör çözümlemesinin yapay sinir ağlarına uygulanabilirliğini ve eğitilen ağın gücünü ispatlar. Bu şekilde eğitilmiş bir ağdan çıkan her bir çıktı, öz değerleri azalan sırada olmak üzere dizilir. Böylece tasarlanan yapay sinir ağı, minimum ortalama hata kare ile başlangıç girdilerin yeniden doğrusal olarak yapılanmasına izin verir. Sonuçta çıktı sayısının girdi sayısından daha az olması koşulu altında çıktıda mümkün olduğunca yüksek bilgiyi barındırması beklenir (Sagner,1989). Bunun için oluşturulan ağ, tek katmanlı doğrusal ileri beslemeli bir ağıdır. Girdi sayısı çıktı sayısından az olmak koşulu ile minimum ortalama hata karesi ile girdi değerlerindeki bilgiyi koruyan daha az sayıda çıktı değerleri üretilebilir. Diyelim ki tek katmanlı bir ağa n boyutlu bir girdi verilsin ve $m < n$ olmak üzere çıktı sayısı m boyutlu bir y vektörü olsun. Bu durumda $m \times n$ boyutlu ağırlık düzeltme değerini (Δw_{ij}) belirleyen Genelleştirilmiş Hebb öğrenme kuralı ortaya çıkar.

$$w_{ij}(t+1) - w_{ij}(t) = \eta [y_j(t)x_i(t) - y_j(t) \sum_{k=1}^j w_{ik} y_k]$$

Sagner'in geliştirdiği GHA'yı Local GHA olarak tanımlayan Diamantaras (2002), en önemli özelliğinden birisinin istenilen sayıda boyut çıkarabilmesi olduğunu belirtir. GHA kullanan yapay sinir ağı çıktı katmanındaki ilk nöronundan birim-uzunluk öz vektörü (e_1) elde edilir. Birinci öz vektörün belirlenmesinin ardından girdi olan x vektörü, e_1 vektörü tarafından yeniden oluşturulur ve böylece girdi vektörünün yoğunluğu azalır (deflated data x). Çıktı katmanının ikinci nöronundan çıkan öz vektör e_2 ise e_1 vektörü yüzünden yoğunluğu azalmış olan x verisinin birinci temel bileşenidir. Çıktı katmanının üçüncü nöronundan çıkan öz vektör e_3 ise e_1 ve e_2 vektörleri yüzünden yoğunluğu tekrar azalmış olan x vektörünün birinci temel bileşenidir ve bu böylece devam eder (Diamantaras, 2002).

Kendini düzenleyen haritalama

Kohonen (1982), kendi kendini düzenleyerek bir haritalama yapan ağı temel prensibini, gözlenen olayların özelliklerine göre, geometrik düzlemde gerçeğe uygun haritalarını, otomatik olarak düzenlemesi olarak tanımlar. KDH (Self-Organizing Mapping-SOM), dış dünyadan gelen sinyallere göre, girdilerin özelliklerinin haritasını çıkaran bir ağ modelidir. Kohonen tarafından geliştirilen bu model Kohonen Ağı olarak da adlandırılır. KDH, özellikle kümeleme problemlerinde verileri benzerliklerine göre gruplayabilir. KDH aynı zamanda çok boyutlu bir yapıya sahip olan veri setinin boyut sayısını indirgeyerek, genellikle iki boyutlu bir haritada görselleştirir. KDH, çok boyutlu girdi sinyallerini işleyerek, iki boyutlu düzlemde soyut bilgiyi ortaya koyabilen bir ağ yapısıdır (Kohonen,1990).

KDH için kullanılan öğrenme yöntemi denetimsiz öğrenme yöntemidir. Beklenen çıktı değeri yoktur. O yüzden ölçüt, genelde verinin elde edildiği değişkenlerin ait olduğu nesne ya da olguların doğasında gizlidir. Öğrenme kuralı olarak yarışmacı öğrenme kuralı kullanılır. Buna göre algoritmada eğitim girdi vektörlerinin (x_i), c kümelerine sınıflandırılması için ağırlık güncellemesi, koşullu olarak formüllendirilir:

$$w_c(t+1) = w_c(t) + \alpha(t)[x_i(t) - w_c(t)] \quad \text{Eğer } x \text{ doğru sınıflandırılmış ise,}$$

$$w_c(t+1) = w_c(t) - \alpha(t)[x_i(t) - w_c(t)] \quad \text{Eğer } x \text{ yanlış sınıflandırılmış ise,}$$

$$w_i(t+1) = w_i(t) \quad \text{Eğer } i \neq c$$

$\alpha(t)$, her adımda monoton olarak azalan skaler bir değerdir. Genellikle $\alpha(t)=0,01$ ya da $0,02$ başlangıç değeridir.

Yöntem

Araştırmanın türü

Bu tez kapsamında yapılan araştırmanın türü temel araştırmadır. Temel araştırmalar, var olan bilgiye yenilerini katan araştırmalardır (Karasar, 1998). Bu araştırmalar tarafından üretilen bilgiler pratikte hemen uygulanabilir bilgiler değildir ancak, uygulamaya dönük çalışmalar için gerekli bilgi kaynağını ya da altyapısını oluştururlar (Elmes, Kantowitz ve Roediger III, 1992; Bogden ve Biklen, 1998). Bu çalışma, ölçek geliştirme sürecinde kullanılan TBA'nın yerine, yeni bir analiz yaklaşımı ve yöntemi olan yapay sinir ağlarının kullanılabilirliğini açıklamayı amaçlamakta ve uygulama araştırmalarında kullanılmak üzere bir bilgi üretme niteliği taşımaktadır.

Araştırma grubu

Araştırma grubu olarak İstanbul Üniversitesi Hasan Ali Yücel Eğitim Fakültesi tarafından 2014-15 güz döneminde verilen pedagojik formasyon eğitimine katılan öğrenciler olarak tanımlanmıştır. Bu öğrenciler eğitim fakültesi dışında ağırlıklı olarak fen ve edebiyat fakültelerinde okuyan ya da mezun olmuş branş öğretmen adaylarıdır. Bu öğrencilerden ilk olarak 400 öğrenciye veri toplama aracı uygulanmıştır. Bu veri seti, TBA ve yapay sinir ağları üzerinden elde edilen bulguları ortaya koymak üzere kullanılmıştır. Daha sonra yine aynı gruptan aynı sayıda ancak, ilk çalışma grubu dışında başka bir 400 kişiye ölçme aracı tekrar uygulanmıştır. İkinci gruba ait veri ise, ilk uygulamada ortaya çıkan ölçek yapılarının karşılaştırılabilirliği amacıyla yapılan DFA'da kullanılmıştır.

Araştırma problemlerinin cevaplanabilmesinde kullanılan ilk gruptan, bölümünü belirten 391 katılımcının bölümlerine göre dağılımı Tablo 2'de verilmiştir. Farklı analiz sonuçlarından ortaya çıkan ölçek yapılarının karşılaştırılmasında kullanılacak olan DFA analizi için, verisi toplanan diğer 400 kişilik grubun, bölüm bilgisini veren 380 katılımcının, bölümlerine göre dağılımı ise Tablo 3'de verilmiştir. Buna göre birinci gruba göre ikinci grupta bölüm çeşitliliği daha fazladır. Ancak öğretmenlere yönelik tutumlar açısından katılımcıların bölümlerinin farklılık göstermesinin, DFA sonuçlarının karşılaştırılmasında bir sakınca doğurmayacağı varsayılmaktadır.

Tablo 2

Lisans Alanlarına Göre TBA ve GHA ve KDH İçin Kullanılan Çalışma Grubunun Frekans ve Yüzde Dağılımı

Bölüm	Frekans	Yüzde (%)
Psikoloji	14	3,6
Arap D. ve E.	18	4,6
Sosyoloji	19	4,9
İlahiyat	27	6,9
Fizik	28	7,2
Coğrafya	40	10,2
Felsefe	48	12,3
Türk D. ve E.	61	15,6
Tarih	64	16,4
Biyoloji	72	18,4
Toplam	391	100,0

Tablo 3
Lisans Alanlarına Göre DFA İçin Kullanılan Çalışma Grubunun Frekans ve Yüzde Dağılımı

Bölüm	Frekans	Yüzde (%)
Turizm Rehberlik	1	,3
Tiyatro	1	,3
Radyo Sinema	1	,3
Arkeoloji	1	,3
İletişim	4	1,1
Sanat Tarihi	4	1,1
Gazetecilik	6	1,6
Sosyoloji	7	1,8
Sağlık Öğ.	7	1,8
Ebelik	9	2,4
Halkla İlişkiler	10	2,6
Psikoloji	12	3,2
Türk Dili ve Ed.	19	5,0
Felsefe	25	6,6
Beden Eğitimi	30	7,9
Tarih	41	10,8
Biyoloji	42	11,1
Fizik	47	12,4
Coğrafya	53	13,9
Hemşirelik	60	15,8
Toplam	380	100,0

Veri toplama aracı

Analizde kullanılan veriler denemelik olarak hazırlanan “Öğretmenlere Yönelik Tutum Ölçeği-ÖYTÖ” maddeleri üzerinden elde edilmiştir. Bu ölçek 5’li likert tipinde bir ölçektir. Denemelik maddeler hazırlandıktan sonra iki Eğitimde Ölçme ve Değerlendirme Uzmanı ve bir Rehberlik ve Psikolojik Danışmanlık Uzmanı olmak üzere üç uzmanın görüşlerine başvurulmuştur. Elde edilen dönütlere göre maddeler yeniden düzenlenerek 30 maddeden oluşan denemelik ölçek formu hazırlanmıştır (Ek 1). Maddelerin 11’i olumsuz 19’u olumlu tutum ifadeleridir. Demografik verilerin bulunduğu bir anket ile birlikte ÖYTÖ, farklı bölümden mezun ya da henüz okuyan ve pedagojik formasyon eğitimine devam eden bireylere uygulanarak, araştırmanın verileri elde edilmiştir.

Verilerin analizi

Birinci araştırma sorusu için denemelik ÖYTÖ ile çalışma grubu üzerinden toplanan veriler üzerinden SPSS 21.0 paket programı kullanılarak TBA yapılmıştır. Bileşen miktarını belirlemek için, SPSS Kaiser Ölçütünü kullanır (öz değerlerin 1’den büyük olması). Ayrıca, bu çalışmada 0,45 değeri, faktör yükü için ölçüt olarak seçilmiştir. Comrey ve Lee (aktaran Tabachnick ve Fidell, 2001) tarafından verilen ölçütlere göre, faktör yükleri 0,71 üzerinde olması mükemmel, 0,63 üzerinde olması çok iyi, 0,55 üzeri iyi ve 0,45 üzeri orta ve 0,32 üzeri zayıf olarak tanımlanır.

GHA üzerinden faktör yapısını belirlemek üzere, genelleştirilmiş Hebb öğrenme kuralına göre denetimsiz öğrenmeli tek katmanlı ileri beslemeli yapay sinir ağı modeli, MATLAB_R2014a üzerinden uygulanmıştır. GHA için kullanılan ve MATLAB için hazırlanmış olan yazılım Yu Hen Hu (2001) tarafından geliştirilmiştir. GHA üzerinden temel bileşen tahmini yapan komut dosyası incelendiğinde bir ana komut dosyası ve içerisinde iki fonksiyon dosyası vardır. Ana komut dosyasında bazı değerler başlangıçta belirlenmiş değerlerdir. Bunlardan birisi iterasyon sayısıdır ve bu çalışmada 500’lük bir iterasyon yapılmıştır. Ağ için önemli diğer bir değer eta katsayısıdır. Bu katsayı ağın öğrenme hızını

belirleyen bir değerdir. Komut dosyasında tanımlanan eta değeri üzerinden analiz yapıldığında ağ çıktı vermemiştir. Bu nedenle bu araştırmaya özgün, deneme yolu ile yeni bir eta değeri belirlenmiştir. Yazılımda kullanılan eta öğrenme hızı 0,005 değerinden 0,001 değerine düşürülerek bir düzenleme yapılmıştır.

GHA kullanan yapay sinir ağından, temel bileşenlerin ortaya çıkarıldığı bir öz vektörler matrisi elde edilmektedir. Ancak çıktıyı değerlendirebilmek için verilerin standartlaştırılması gerekmektedir. Ağdan elde edilen öz vektör matrisi ile (V) madde-madde korelasyonları matrisi (C) kullanılarak öz değerler matrisi (L) ($L= V'CV$) elde edilmiştir. Faktör yüklerinin (A) hesaplanması için ise, yine ağdan çıkan öz vektörler matrisi ile ve bu matristen elde edilen öz değerler matrisi ($A=VL^{1/2}$) kullanılarak hesaplanmıştır. TBA sonuçları ile karşılaştırabilmek için TBA'da kullanılan öz değer sınırlaması (Kaiser ölçütü: >1) ve faktör yükleri için 0,45 ölçütü kullanılmıştır.

KDH kullanan ağ modeli için, MATLAB R2014a üzerinden ANN araç kutusu kullanılarak veriler işlenmiştir. Burada kullanılan ağ, tek katmanlı ileri beslemeli ve yarışmacı öğrenme kuralına sahip bir ağıdır. Bu kural, girdileri iki boyutlu topoloji üzerinden sınıflandırarak kümeler. Küme sayısı ağ için önceden belirlenen nöron sayısına göre değişiklik gösterebilir. Küme sayıları, oluşan faktörler olarak değerlendirilmektedir. Bu araştırmada 5x5 ve 4x4 nöronlardan oluşan iki boyutlu topoloji üzerinden çıktılar elde edilmiştir. Bulgular iki farklı nöron sayısı üzerinden elde edilerek değerlendirilmiştir.

Her üç araştırma sorusuna ait bulgular çerçevesinde oluşan ölçek boyutları, LISREL9.2 paket programı aracılığıyla yapılan DFA ile incelenerek karşılaştırılmıştır. Ortaya çıkan yapılar, yol analizi sonuçlarındaki hata ve uyum indeksleri karşılaştırılarak yorumlanmıştır.

Bulgular

Temel bileşenler analizine göre ölçek yapısı

TBA'ne başlamadan önce maddelere ait verilerin incelenmesi söz konusudur. Yine yapay sinir ağı modelleri için kullanılan girdi matrisinde kayıp verinin bulunmaması, ağın çalışması açısından önemlidir. Her madde de bulunan kayıp veriler tutum ölçeği tepki kategorilerinden "kararsızım" tepkisine karşılık gelen 3 değeri işlenmiştir. Ayrıca maddeler normallik açısından incelendiğinde, dört madde dışında (madde 1, 2, 10 ve 15), maddelerin çarpıklık değerleri -1 ve 0 aralığında, beş maddenin (madde 1, 2, 10, 15 ve 26) ise diğerlerine göre normalden daha sivri bir dağılıma sahip olduğu görülmektedir. Ancak tüm maddelerin basıklık ve çarpıklık değerlerinin ± 3 aralığında olduğu görülmüştür. Uygulamada Fisher basıklık ve çarpıklık değeri ± 3 aralığında ise ilgili değişken normal kabul edilmektedir (Kalaycı, 2014; s. 209). Ayrıca bilinmektedir ki, eğer sonuçlar üzerinden bir genelleme yapılmayacaksa, normallik sayıltısı karşılansa da, veriler kullanılabilir (Tabachnick ve Fidell, 2001). 400 adet verinin, bu çalışmanın amacı olan analiz tekniklerinin karşılaştırmasına yönelik olarak, kullanılabilir olduğu kabul edilmiştir.

TBA öncesi, denemelik ÖYTÖ'nin 30 maddesi üzerinden hesaplanan ve iç tutarlık açısından güvenilirlik bilgisi veren Cronbach alfa katsayısı 0,94'tür. TBA'nin ilk aşamasında, madde-madde korelasyonları bir ön inceleme amacıyla kullanılabilir. Maddelerin birbirleri ile ilişkisiz olup olmadıkları ya da çok yüksek ilişki gösterip göstermedikleri, madde-madde korelasyon matrisinden tespit edilebilir. Tek yönlü olarak önem düzeylerine göre diğer maddelerle ilişkisiz olan maddeler atılmalıdır (Field, 2009). Buna göre 29 madde incelendiğinde, 1. maddenin birden çok madde (8 madde) ile ilişkisizlik gösterdiği görülmüştür ($p>0,01$). Bu nedenle, 1. madde analizden çıkarılmıştır. Böylece TBA 29 madde ile gerçekleştirilmiştir.

TBA aşamasında, örneklem büyüklüğünün analiz için yeterliliği KMO testi sonucu uygun bulunmuştur (KMO=0,951). Ayrıca madde-madde korelasyonu incelendiğinde maddeler arası düşük ilişki olmadığı ve matrisin birim matris özelliği taşımadığı Barlett testi ile ortaya konmuştur ($X^2(406)=5019, p<,000$).

Maddeler arasında yüksek ilişki görülmesi, bir başka deyişle, değişkenin tekrarı olabilecek ikinci bir değişken olması durumunu önlemek için madde-madde korelasyon matrisinin determinantı incelenmiş ve birbirinin tekrarı sayılabilecek maddelerin bulunmadığı görülmüştür ($|R| > ,00001$). Tablo 4'e göre denemelik ölçekteki 29 madde üzerinden 5 bileşenli bir yapı ortaya çıktığı görülmektedir. Kaiser ölçütüne göre öz değerleri 1'in üzerinde olan 5 bileşenin açıkladığı varyans %55,11'dir.

Tablo 4
TBA Sonucunda Bileşenlerce Açıklanan Toplam Varyans

Bileşen	Başlangıç öz değerleri			İndirgeme Sonrası öz değerler		
	Toplam	Varyans Yüzdesi	Yığılmalı Varyans Yüzdesi	Toplam	Varyans Yüzdesi	Yığılmalı Varyans Yüzdesi
1	10,971	37,832	37,832	10,971	37,832	37,832
2	1,580	5,448	43,280	1,580	5,448	43,280
3	1,306	4,504	47,784	1,306	4,504	47,784
4	1,120	3,863	51,647	1,120	3,863	51,647
5	1,004	3,462	55,110	1,004	3,462	55,110
6	,896	3,091	58,201			
7	,875	3,017	61,218			
8	,858	2,959	64,176			
9	,823	2,838	67,014			
10	,746	2,573	69,587			
11	,689	2,376	71,963			
12	,677	2,336	74,299			
13	,605	2,085	76,384			
14	,597	2,057	78,442			
15	,567	1,954	80,395			
16	,553	1,908	82,303			
17	,528	1,821	84,125			
18	,486	1,676	85,801			
19	,475	1,640	87,440			
20	,435	1,498	88,939			
21	,426	1,467	90,406			
22	,424	1,461	91,867			
23	,402	1,386	93,253			
24	,377	1,301	94,555			
25	,356	1,227	95,782			
26	,352	1,215	96,997			
27	,317	1,094	98,091			
28	,291	1,005	99,096			
29	,262	,904	100,000			

Denemelik ÖYTÖ maddelerinden ilk aşamada ortaya çıkan 5 bileşenli yapının maddelere göre dağılımı Tablo 5'de görülmektedir. Bileşenler ve maddeler arasındaki ilişkiyi veren faktör yükleri için ölçüt '>0,45' (ortak değişkenlik %20) kullanılmıştır. Buna göre 2. maddenin hiç bir bileşene yük vermediği ve 26 maddenin ise 1. bileşene yük verdiği görülmektedir. Diğer bileşenlerde ise yalnızca bir madde olduğu görülmektedir.

Tablo 5
Döndürme Öncesi TBA Sonucu Maddelerin Bileşenlere Verdiği Faktör Yükleri

	Bileşen				
	1	2	3	4	5
Madde2					
Madde3		,538			
Madde4	,562		,487		
Madde5	,569				
Madde6				,575	
Madde7	,634				
Madde8	,587				
Madde9	,683				
Madde10	,569				
Madde11	,668				
Madde12	,718				
Madde13	,630				
Madde14	,697				
Madde15	,642				
Madde16	,669				
Madde17	,592				
Madde18	,667				
Madde19	,658				
Madde20	,678				
Madde21	,458				-,498
Madde22	,575				
Madde23	,617				
Madde24	,550				
Madde25	,703				
Madde26	,642				
Madde27	,662				
Madde28	,694				
Madde29	,588				
Madde30	,695				

TBA'nin önemli aşamalarından birisi döndürme işlemidir. Döndürme işlemi ile örtük yapıyı ortaya çıkaran bileşenlerin birbirleri ile olan ilişkisi ve onları gözlenebilir kılan maddelerin netleşmesi için gereklidir. İki tür döndürme işlemi yapılabilir. Bunlardan biri dik döndürme, diğer bir deyişle bileşenler arası ilişkisizlik kuralına göre gerçekleştirilen dik döndürme ve diğeri ise, bileşenler arası ilişkiler göz önüne alınarak yapılan eğik döndürmedir.

Denemelik ÖYTÖ için ortaya çıkan 5 bileşenli yapıya iki tür döndürme işlemi uygulanmıştır. Bu sonuçlar karşılaştırıldığında, dik döndürme işlemi maddeleri bileşenlere dağıtırken, faktör yüklerinin bir bileşende yoğunlaşmasını sağladığı için eğik döndürmeye göre daha kararlı bir yapı ortaya çıkardığı görülmüştür. Buna göre varimax tekniği ile yapılan dik döndürme sonuçlarına göre analiz sonuçlandırılmıştır.

Tablo 6'ya bakıldığında, maddelerin bileşenlere verdiği yükler görülmektedir. Buna göre 20., 24. ve 27. maddelerin hiç bir bileşene yük vermediği görülmektedir. Diğer maddeler bileşenlere dağılmıştır. Buna göre, 29 maddeden 3 maddenin daha atılması sonucunda, 5 bileşenli 26 maddeli bir ölçek yapısının ortaya çıktığı görülmektedir.

Tablo 6
Dik Döndürme Sonrası TBA Sonucu Maddelerin Bileşenlere Verdiği Faktör Yükleri

	Bileşen				
	1	2	3	4	5
Madde2		,505			
Madde3			,801		
Madde4		,700			
Madde5		,577			
Madde6					,706
Madde7		,487			
Madde8		,464			
Madde9			,484		
Madde10					,495
Madde11		,643			
Madde12		,636			
Madde13	,622				
Madde14		,562			
Madde15	,646				
Madde16	,687				
Madde17			,639		
Madde18	,571				
Madde19	,501				
Madde20					
Madde21				,797	
Madde22				,602	
Madde23	,691				
Madde24					
Madde25	,502				
Madde26	,636				
Madde27					
Madde28	,711				
Madde29	,517				
Madde30			,451		

Genelleştirilmiş Hebb Algoritmasına göre ölçek yapısı

Genelleştirilmiş Hebb öğrenme kuralına göre denetimsiz öğrenmeli tek katmanlı ileri beslemeli yapay sinir ağı modeli için kullanılan ve MATLAB’da hazırlanmış yazılım, Yu Hen Hu (2001) tarafından geliştirilmiştir. Bu yazılım ana komut dosyası ve iki fonksiyon dosyası içermektedir. Ana komut dosyasında ağın öğrenme hızını belirleyen eta değeri 0,005 olarak belirlenmiştir. Ancak yazılımın madde sayısı arttıkça, diğer bir deyişle, girdi vektör büyüdükçe yakınsamanın gerçekleşmediği ve optimum sonuca ulaşamadığı görülmüştür.

Yapılan deneme çalışmasında madde sayısının eta değerinin 0,005 iken maksimum 17 adet madde için sonuç bulduğu gözlenmiştir. Madde sayısı artırıldığında ÖYTÖ verisine yapılan GHA yazılımı, NaN (Not a Number) olarak çıktı vermektedir. Bu tarz bir sonuç tanımsız sayılar ile yapılan matematiksel işlemler ile ortaya çıkabilir (0x∞, 0/0, ∞/∞ gibi). Bunun üzerine eta öğrenme hızı 0,001 olarak değiştirilmiştir. Bu durum öğrenme hızının düşmesi ile birlikte optimum değere ulaşılmasını sağlamıştır.

Amacı TBA’nin görevini yapmak olan GHA yapay sinir ağı modeli için kullanılan yazılım, öz vektörler matris çıktısı vermektedir. Öz vektörler matrisinin boyutları madde sayısı olan 30 olarak belirlenmiştir. Bu aynı zamanda çıktıda gözlenebilecek temel bileşen sayısıdır. Burada dikkat edilmesi gereken nokta ise GHA kullanan yapay sinir ağı modeli çıktıları döndürmesiz sonuçlardır. Çünkü TBA amaçlı geliştirilen sinir ağı modeli döndürme işlemi

uygulamamaktadır. Dolayısıyla, GHA ve TBA karşılaştırmalarının döndürme öncesi bulgular üzerinden olması gerekir.

GHA için kullanılan yazılımda dikkat edilmesi gereken nokta, verilerin standartlaştırıldıktan sonra ağı girdi olarak verilmesidir. Normalde Likert tipi bir ölçekten elde edilen ham veriler için TBA yapılırken SPSS korelasyon matrisi kullanır ve bu matristen öz vektör ve öz değerler elde edilir. İki değişken arasındaki bir korelasyon katsayısı aslında iki değişkenin birlikte değişimini veren standartlaştırılmış bir kovaryans katsayısıdır (Field, 2009). Standartlaştırılmış veri seti üzerinden elde edilen ve ağıdan çıkan öz vektör matrisi (V) ve devrik hali (V'), standartlaştırılmamış ham veri seti kullanılarak SPSS üzerinden elde edilen korelasyon matrisi (C) ile çarpılarak öz değerler matrisi (L) elde edilmiştir ($L = V'CV$). Daha sonra faktör yüklerinin (A) hesaplanması için öz vektör matrisi, öz değerler matrisinin karekökü ile çarpılmıştır ($A = V\sqrt{L}$). TBA sonuçları ile karşılaştırabilmek için TBA'da kullanılan özdeğer sınırlaması (Kaiser ölçütü: >1) ve faktör yükleri için 0,45 ölçütü kullanılmıştır. Sonuç olarak 30 madde üzerinden model ortaya çıkarılmıştır.

Tablo 7.

GHA Sonucunda Bileşenlerce Açıklanan Toplam Varyans

Bileşen	Başlangıç öz değerler			İndirgeme Sonrası öz değerler		
	Toplam	Varyansın Yüzdesi	Yığılmalı Varyansın Yüzdesi	Toplam	Varyansın Yüzdesi	Yığılmalı Varyansın Yüzdesi
1	11,10	36,673	36,673	11,10	36,673	36,673
2	1,73	5,728	42,401	1,73	5,728	42,401
3	1,35	4,473	46,873	1,35	4,473	46,873
4	1,17	3,859	50,732	1,17	3,859	50,732
5	1,09	3,589	54,321	1,09	3,589	54,321
6	0,96	3,178	57,499			
7	0,89	2,938	60,438			
8	0,87	2,876	63,314			
9	0,83	2,745	66,059			
10	0,77	2,556	68,615			
11	0,72	2,369	70,984			
12	0,69	2,284	73,268			
13	0,63	2,091	75,359			
14	0,60	1,998	77,357			
15	0,59	1,958	79,315			
16	0,57	1,872	81,187			
17	0,55	1,810	82,997			
18	0,53	1,757	84,754			
19	0,47	1,567	86,321			
20	0,49	1,615	87,936			
21	0,44	1,450	89,386			
22	0,43	1,421	90,807			
23	0,43	1,407	92,214			
24	0,39	1,303	93,517			
25	0,37	1,236	94,753			
26	0,36	1,177	95,930			
27	0,35	1,162	97,092			
28	0,32	1,058	98,150			
29	0,29	0,974	99,124			
30	0,27	0,876	100,000			

Tablo 7’de görüldüğü üzere GHA algoritması kullanan yapay sinir ağı modeli ile yapılan analiz sonucunda denemelik ÖYTÖ’nin yapısı 5 bileşenli olarak belirlenmiştir. Bu bileşenlerce açıklanan toplam varyans %54,32’dir.

Maddelere bileşenlere verilen faktör yüklerine bakıldığında, 1. maddenin hiç bir bileşene yük vermediği görülmektedir (Tablo 8). 1. bileşene 29 madde yük verirken diğer bileşenlerde bir madde görülmektedir. Bu maddeler de 1. bileşen ile ortak yük vermektedir. Sonuç olarak ortaya çıkan yapı, 29 maddelik 5 bileşenli bir yapıdır.

Tablo 8
GHA Sonucu Maddelerin Bileşenlere Verdiği Faktör Yükleri

	Bileşen				
	1	2	3	4	5
Madde1					
Madde2	0,473				
Madde3	0,493	0,498			
Madde4	0,779		0,549		
Madde5	0,527				
Madde6	0,453			0,625	
Madde7	0,514				
Madde8	1,019				
Madde9	0,543				
Madde10	0,546				
Madde11	0,715				
Madde12	0,780				
Madde13	0,566				
Madde14	0,612				
Madde15	0,583				
Madde16	0,713				
Madde17	0,514				
Madde18	0,750				
Madde19	0,583				
Madde20	0,658				
Madde21	0,498				0,475
Madde22	0,830				
Madde23	0,686				
Madde24	0,615				
Madde25	0,526				
Madde26	0,569				
Madde27	0,679				
Madde28	0,653				
Madde29	0,521				
Madde30	0,550				


Tablo 9’da görüldüğü gibi 8. madde ile 1. bileşenin ilişkisini veren faktör yükü 1’den büyük çıkmıştır (1,019). Ağıdan çıkan öz vektör matrisi ile SPSS’den çıkan korelasyon matrisi kullanılarak hesaplanan öz değerler matrisinin diyagonal olmayan birimleri 0’dan büyük çıkabilmektedir. Böylece faktör yüküne ait değerler hesaplandığında, 1’den büyük değerde olmaması gereken ilişki miktarı bir miktar yükselerek 1’i geçebilir. GHA öğrenmeli bir yapay sinir ağından çıkan sonuç, bir öz vektör matrisi olmakla birlikte, Sagner (1989), GHA’dan çıkan öz vektörlerin tam değil, yaklaşık değerler olduğunu belirtir.

Kendini düzenleyen haritalama modeline göre ölçek yapısı

KDH modeli ortaya koyan MATLAB programında çıktı iki boyutludur. Nöron sayıları ağa önceden girilir. İlk olarak, iki boyutlu 5x5 nöron çıktısı üzerinden daha sonra 4x4 nöron çıktısı üzerinden veriler analiz edilmiştir.

KDH çıktısından biri olan ve girdi vektöründeki birimleri nöronlara dağıtarak sınıflandıran şekil (Plotsomhits), her bir nöronda kaç adet birim olduğunu gösterir. Ayrıca, şekildeki altıgen olarak sembolize edilmiş nöronlardaki renklendirilmiş alan, nöron sayısı arttıkça genişler. Nöron numaraları sağ alttaki nöron 1 nolu nöron olmak üzere, sağ üst köşedeki 25 nolu nöron ile son bulur.

İlk olarak nöron sayısı 5x5 olarak belirlenen çıktı nöronlarında 30 madde girdi olarak KDH üzerinden işlenmiştir. Şekil 2’de görüldüğü üzere, iki küme oluşmuştur. Bu durumda maddelerin özelliklerine göre bir kümede 6 adet madde yine özelliklerine göre görece uzakta bulunan diğer bir nöronda 2 madde kümelendiği görülmüştür.



Şekil 2. 5x5 Nöron Üzerinden KDH Çıktısında Sınıflandırılan Madde Sayıları

30 maddenin 8'inin iki nöronda gruplanmasını sağlayan, 400 adet girdi vektörü değerleridir. 400 adet eğitim örneği sayesinde, ağdaki ağırlıkların yeniden güncellenmesi sağlanır ve sonuçta maddeler birbirine yaklaşır veya uzaklaşır. Tablo 9'a bakıldığında 11 nolu nöronda 1. ve 2. maddeler, 24 nolu nöronda ise 9., 22., 25., 26., 27. ve 30. maddeler bulunmaktadır. Buna göre 5x5 SOM üzerinden yapılan yapay sinir ağı ÖYTÖ yapısını, TBA terminolojisi üzerinden, 8 maddeli iki bileşenli bir yapı olarak ortaya koymuştur.


Tablo 9

5x5 Nöron Üzerinden KDH Çıktısında Maddelerin Nöronlara Dağılımı

Nöron No	Maddeler
1	□
2	□
3	□
4	□
5	□
6	□
7	M7
8	M8
9	M24
10	□
11	M1, M2
12	M16
13	M4
14	M11
15	M18

16	M15
17	M29
18	M21
19	M14
20	M5
21	M23
22	M13
23	M28
24	M9, M22, M25, M26, M27, M30
25	M12

KDH için belirlenen nöron sayısı 4x4 yapılarak azaltıldığında ÖYTÖ yapısı için ortaya çıkan kümelene ve madde sayısı Şekil 3'de görülmektedir. Buna göre nöron sayısı azalınca maddelerin özelliklerinin daha az hassas olarak gruplandırıldığı söylenebilir. Yine iki küme ortaya çıkmış ve 1. kümede 2 maddenin, 2. kümede ise 5x5 nöron dağılımından farklı olarak 14 maddenin bir araya geldiği görülmektedir.



Şekil 3. 4x4 Nöron Üzerinden KDH Çıktısında Sınıflandırılan Madde Sayıları

Tablo 10'a bakıldığında 9 nolu nöronda 5x5 nöron modelinde olduğu gibi 1. ve 2. maddeler, 11 nolu nöronda ise 5x5 nöron modelindeki 6 maddeye görece yakın özelliğe sahip 8 madde daha eklendiği görülmektedir. Buna göre 4x4 SOM üzerinden yapılan yapay sinir ağı ÖYTÖ yapısını, TBA terminolojisi üzerinden, 16 maddeli iki bileşenli bir yapı olarak ortaya koymuştur.

Nöron sayılarının değişmesine rağmen, KDH'dan kararlı iki bileşenli yapı ortaya çıktığı görülmektedir. 1. ve 2. maddeler ayrı olarak durmaktadır. Bu maddeler incelendiğinde (Ek 1), tutum ifadelerinin öğretmenlere değil ancak öğretmenlik mesleğine yönelik tutum ifadeleri olduğu görülmektedir.

Tablo 10
4x4 Nöron Üzerinden KDH Çıktısında Maddelerin Nöronlara Dağılımı

Nöron No	Maddeler
1	M7
2	M29
3	M21
4	M3
5	M6
6	M8
7	M4
8	M18
9	M1, M2

10	M26
11	M9, M10, M11, M12, M13, M16, M17, M19, M20, M22, M23, M25, M27, M30
12	M14
13	M15
14	M28
15	M24
16	M5

Analiz sonuçlarına göre ortaya çıkan ölçek yapılarının bileşen ve madde sayıları üzerinden karşılaştırma yapılacak olursa KDH'nın ortaya koyduğu ölçek yapısının hem bileşen sayısı hem de madde sayısı diğer sonuçlara göre daha azdır (Tablo 11). KDH kendi içinde nöron sayısı arttıkça bileşen sayısı aynı ancak madde sayısının azalmış olduğu görülmektedir. TBA döndürme öncesi ve sonrası bileşen sayıları, TBA yerine kullanılan yapay sinir ağı modeli olan GHA ile aynıdır. GHA sonucuna göre madde sayısı ise döndürme öncesi ve sonrası TBA sonuçlarına göre daha fazladır. Denemelik ölçekteki 30 maddeden sadece bir tanesi (1. madde) dışta tutulmuştur. Döndürme öncesi TBA sonucu ölçek yapısında ise 2 madde (1. ve 2. madde) dışta tutulmuştur. Döndürme öncesi TBA sonucu ile GHA sonucunun ortak bir noktası da maddelerin 1. bileşende toplanması, diğer bileşenlerde birer maddenin yer almasıdır.

Tablo 11
Analiz Sonuçlarına Göre Ölçek Yapıları

Analiz	Bileşen Sayısı	Madde Sayısı
TBA Döndürme Öncesi	5	28
TBA Döndürme Sonrası	5	26
GHA	5	29
KDH 4x4	2	16
KDH 5x5	2	8

Doğrulayıcı faktör analizi sonuçlarına göre ölçek yapılarının karşılaştırması

Farklı analizler sonucunda ortaya çıkan yapılar üzerinde değerlendirme yapabilmek için bileşenlerin bağlamsal olarak yorumlanabilmesinin (adlandırılması) yanında, ortaya çıkan yapıların uyum ve hata istatistikleri üzerinden karşılaştırılması anlamlı olabilir. Bu nedenle DFA sonuçlarından yararlanılmıştır.

TBA, GHA ve KDH için kullanılan veri setinin dışında, DFA sonuçlarının incelenmesi için aynı gruptan elde edilen diğer 400'lük veri seti ile ÖYTÖ maddeleri, ilk grup veri setinde yapıldığı gibi kayıp veriler '3' olarak kodlanmış ve normallik sayıltısı açısından incelenmiştir. Bu veri seti üzerinden elde edilen maddelerin dağılımı 1, 2 ve 3 numaralı araştırma problemlerinde kullanılan veri seti üzerinden elde edilen sonuçlarla benzerlik göstermiştir. Ölçek değerleri evrene genellenmeyeceği için ayrıca, maddelerin çarpıklık ve basıklık değerleri ± 3 değerleri arasında olduğu için veri setinin DFA'nde kullanımının uygun olduğu kabul edilmiştir.

Öncelikle, GHA kullanan yapay sinir ağı modelinden çıkan ÖYTÖ'nin yapısı, TBA işlemi sonucu döndürme öncesinde ortaya çıkan ÖYTÖ yapısı karşılaştırılacak olursa, her iki yapının birbiri ile oldukça benzer olduğu söylenebilir (Tablo 12 ve Tablo 13). Her ikisinde de ağırlıklı olarak tek bileşenli bir yapı görülmektedir. Diğer bileşenlerde birer madde gözlenmektedir. GHA'dan çıkan sonuçta 1. madde dışarıda kalmıştır, 29 madde 1. bileşende olduğu gözlenirken, 4 madde diğer bileşenlerce ortak paylaşılmıştır. TBA'da gerçekleşen döndürme öncesi sonuçta ise 1. madde diğer maddelerle ilişki vermediği için analizin başında çıkarılmıştır. Analiz sonucunda 2. maddenin hiç bir bileşene yük vermediği gözlenmiştir. 26 madde ise 1. bileşene yük vermektedir. Diğer bileşenlerde ise 1 madde bulunmaktadır ve bunlardan ikisininin (4. ve 21. madde) 1. bileşenle ortak maddeler olduğu görülmektedir. Bu durumda iki yapının benzer olduğu GHA yapay sinir ağı modelinden çıkan yapının 29 maddelik

tek bileşenli; döndürme öncesi TBA'dan ortaya çıkan yapının, 26 maddelik tek bileşenli bir yapı olduğu söylenebilir.

Tablo 12
TBA'de Döndürme Öncesi 28 Maddenin Bileşenlere Dağılımı

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

Tablo 13
GHA Sonucu 29 Maddenin Bileşenlere Dağılımı

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

İki sonucun verdiği yapı, DFA uyum istatistikleri üzerinden karşılaştırıldığında da birbirine yakın değerler verdiği görülmektedir (Tablo 14). Uyum ve hata istatistiklerinde ortaya çıkan yapıların karşılaştırılması aynı örneklem üzerinden olduğu için örneklem büyüklüğünden kaynaklı etki göz ardı edilebilir. Maddelerin dağılımlarında farklılık olabileceği dikkate alındığında, X_M^2 uyum istatistiğinin olasılık düzeyi bu durumdan etkilendiği için karşılaştırmaların bu istatistiğin serbestlik derecesine bölümü sonucu ortaya çıkan değer üzerinden yapılması daha uygun olacağı söylenebilir.

LISREL üzerinden elde edilen DFA sonuçlarında, her iki yapı için yakınsamanın gerçekleşmediği uyarısı görülmüştür. Bunun birçok nedeni olabilir. Heywood vakaları olarak geçen bazı durumlar, gözlenen verilerden oluşan örnek kovaryans matrisi ile parametre tahminlerinin oluşturduğu modele ait evren kovaryans matrisini birbirine yaklaşmasına engel olur. Heywood vakaları negatif hata varyansı ya da faktör ile gösterge arasındaki korelasyonun 1'den büyük çıkması gibi durumlardır. Bu vakaları oluşturan sebepler, tanımlanmamış modeller, sonucu çarpıtacak uç değerlerin varlığı, küçük örnek sayısı ile birlikte ölçme modelinde faktör başına sadece iki göstergenin bulunması, kötü başlangıç değerleri, aşırı düşük ya da yüksek evren korelasyon değerleri gibi durumlar sayılabilir (Kline, 2005).

Döndürme öncesi TBA ölçek yapısı ve GHA ölçek yapısı olarak ortaya çıkan modelde dört bileşende sadece 1 adet madde bulunması ve hatta bu maddelerin diğer başka bileşenle ortak olması, Heywood vakalarını yaratmış olabilir. Yine de karşılaştırma açısından uyum indekslerini incelemek gerekirse, her iki analizden ortaya çıkan yapıya ait uyum istatistiklerinin birbirine oldukça yakın çıktığı görülmektedir. Üstelik GFI ve AGFI indeksleri dışında diğer uyum indekslerinin, uyumun olduğunu gösteren değerlerde olduğu görülmektedir. Döndürme öncesi TBA sonucu ortaya çıkan yapının, GHA sonucu ortaya çıkan yapıya göre X_M^2 / sd ve NFI değerleri, küçük farkla da olsa daha iyi görünmektedir (sırasıyla 2,71 ve 0,96) (Tablo 16). RMSEA değeri açısından ise yine küçük farkla GHA'dan çıkan yapının daha az uyumsuzluk gösterdiği söylenebilir (0,071). Ancak karşılaştırmada uyum indekslerinin her iki yapı için çok yakın ya da aynı çıktığı ve aralarında tercihe yönelik bir öncelik bulunmadığı söylenebilir.

Tablo 14

Döndürme Öncesi TBA ve GHA'dan Ortaya Çıkan ÖYTÖ Yapısının DFA Uyum ve Hata İndeksleri

Uyum İndeksleri	TBA Modeli Döndürme Öncesi (30 madde üzerinden 28 maddelik 5 bileşenli model)	GHA Modeli (30 Madde üzerinden 29 maddelik 5 bileşenli model)
X_M^2 / sd	915,31/338=2,71	993/363=2,74
RMSEA	0,072	0,071
GFI	0,84	0,84
AGFI	0,81	0,81
NFI	0,96	0,95
NNFI	0,97	0,97
CFI	0,97	0,97

Döndürmeli TBA'den çıkan ölçek yapısı 5 bileşenli bir yapıdır (Tablo 15). Ancak KDH'dan çıkan 4x4 ve 5x5 nöron üzerinde görünen yapılar kararlı olarak iki bileşenli yapı olduğu ve daha az maddeler üzerinden ölçek yapısını ortaya koyduğu görülmektedir.

Tablo 15

Döndürme Sonrası TBA'de Sonucunda 26 Maddenin Bileşenlere Dağılımı

Bileşen	Maddeler
1. Bileşen	13, 15, 16, 18, 19, 23, 25, 26, 28, 29
2. Bileşen	2, 4, 5, 7, 8, 11, 12, 14
3. Bileşen	3, 9, 17, 30
4. Bileşen	21, 22
5. Bileşen	6, 10

KDH modelinde nöron sayısı azaldığında, 1. bileşenin madde sayısı artmıştır (Tablo 16 ve Tablo 17). Sonuçta KDH'dan çıkan ölçek yapıları, döndürmeli TBA'nden çıkan yapıya göre daha basittir. Kendi içinde KDH nöron sayılarına göre bileşen sayısı iki olarak kalmış ancak madde sayısı 5x5 nöronluk haritada oldukça azalmış 2. bileşendeki iki madde aynı ancak 1. bileşendeki maddelerden 9 madde dışta kalmış farklı bir madde (M26) bileşene eklenmiş ve bileşen 6 maddeden oluşmuştur.

Tablo 16

KDH Modelinde 5x5 Nöron Üzerinden 8 Maddenin Bileşenlere Dağılımı

Bileşen	Maddeler
1. Bileşen	9, 22, 25, 26, 27, 30
2. Bileşen	1, 2

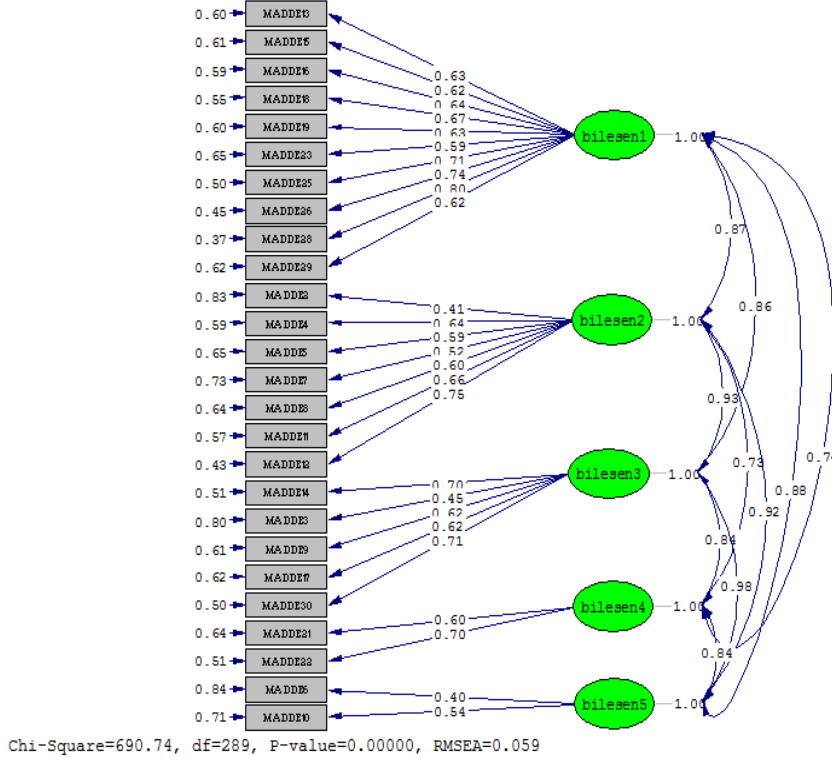
Tablo 17

KDH Modelinde 4x4 Nöron Üzerinden 16 Maddenin Bileşenlere Dağılımı

Bileşen	Maddeler
1. Bileşen	9, 10, 11, 12, 13, 16, 17, 19, 20, 22, 23, 25, 27, 30
2. Bileşen	1, 2

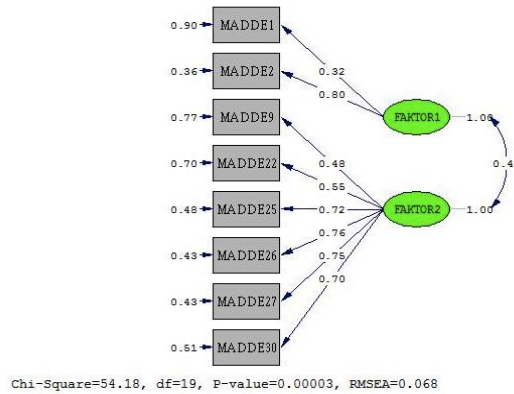
Analizlerin yön diyagramları incelenecek olursa, Döndürme sonrası TBA sonucu çıkan yapıda bileşenlerde ortak maddeler bulunmamaktadır. Ancak Şekil 4'de görüldüğü üzere, faktörler arası korelasyon oldukça yüksek bu da iraksaklık açısından yapı geçerliğinin düşük olduğu anlamına gelebilir. Değişkenlerin çoğunun faktör yüklerinin ise çok yüksek olmadığı ancak 0,60'ın üzerinde olduğu görülmektedir. Kline (2005), yüksek kalitede psikometrik özelliklerin ortaya konulabilmesi için faktör yüklerinin 0,60'dan yüksek olması gerektiğini

belirtir. Faktör yüklerinin düşük olması yakınsaklık açısından yapı geçerliğinin düşük olduğunu göstermektedir. Buna göre 1. faktörün diğerlerine göre daha iyi bir yapı ortaya koyduğu söylenebilir. 4. bileşenin ise faktör yükleri ölçütün üzerinde olmakla birlikte iki maddeli bir bileşen olduğu için zayıf bir yapıdır.



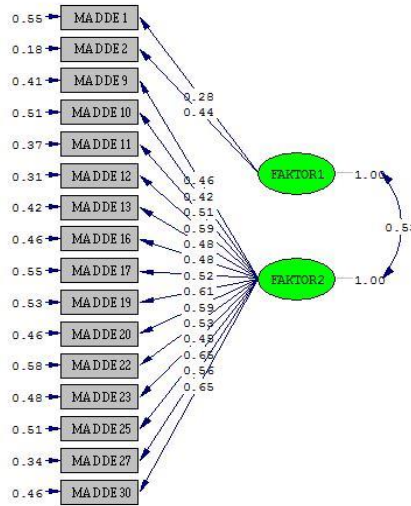
Şekil 4. Döndürme Sonrası TBA Sonucunda Ortaya Çıkan ÖYTÖ Yapısının Yön Diyagramı

İki bileşenli 8 maddeden oluşan 5x5 nöronlu KDH modeli sonucunda çıkan ölçek yapısı için yön diyagramı incelendiğinde, ıraksaklık açısından yapı geçerliğinin faktörler arası korelasyonun 0,45 olması nedeni ile kabul edilebilir olduğu söylenebilir (Şekil 5). Yakınsaklık açısından 2. faktörde 6 maddeden ikisi ölçütün altında kalmıştır. Ancak, iki maddelik faktörün zayıf ve bağlamsal olarak farklı bir yapı olduğu söylenebilir. Bağlamsal olarak bu maddeler, öğretmenlere ilişkin tutum maddeleri yerine öğretmenlik mesleğine ilişkin tutum maddeleri olmaları bu iki maddenin atılması durumunu desteklemektedir. Dolayısıyla bu maddelerin yapıdan çıkarılması uygun olabilir.



Şekil 5. KDH Modelinde 5x5 Nöron Üzerinden Ortaya Çıkan ÖYTÖ Yapısının Yön Diyagramı

4x4 nöronlu KDH modeli sonucunda çıkan ölçek yapısı için yön diyagramı incelendiğinde (Şekil 6), ıraksaklık açısından yapı geçerliğinin faktörler arası korelasyonu, 5x5 nöronlu KDH sonucu ile karşılaştırıldığında biraz artarak 0,53 olduğu görülmektedir. 5x5 nöronlu KDH sonucu için iki maddelik faktör yorumu burada da geçerlidir. Hem 4x4 hem 5x5 nöronlu KDH sonuçlarında 6'lı ya da 14'lü bileşen yapısında faktör yüklerinin tümü ölçüt değeri olan 0,60'ın üzerine çıkamamış, bunun da yakınsaklığı düşüren bir sonuç olduğu söylenebilir.



Chi-Square=278.65, df=103, p-value=0.00000, RMSEA=0.065

Şekil 6. KDH Modelinde 4x4 Nöron Üzerinden Ortaya Çıkan ÖYTÖ Yapısının Yön Diyagramı

Tablo 18 incelendiğinde, modellere ait uyum indekslerine bakıldığında bazı uyum indekslerine göre 5x5 nöronlu KDH modeli, diğerlerine göre daha iyi uyum göstermekte (GFI=0,97, AGFI=0,94); bazı indekslere göre ise daha iyi değer vermektedir ($X_M^2 / sd=2,25$, RMSEA=0,057, NNFI=0,98). Ancak RMSEA dışındaki tüm indeksler, 5x5 nöronlu KDH modelinin, genel olarak ölçütlerinin oldukça üstünde daha kabul edilebilir bir yapı ortaya çıkardığını göstermektedir.

Tablo 18.

Döndürme Sonrası TBA ve KDH'dan Ortaya Çıkan ÖYTÖ Yapısının DFA Uyum ve Hata İndeksleri

Uyum İndeksleri	TBA Modeli Dik Döndürme Sonrası (30 Madde üzerinden 26 Maddelik 5 bileşenli model)	SOM 5x5 Modeli (30 Madde üzerinden 8 maddelik 2 faktörlü model)	SOM 4x4 Modeli (30 Madde üzerinden 16 maddelik 2 faktörlü model)
X_M^2 / sd	649,69/289=2,25	52,43/19=2,76	256,32/103=2,49
RMSEA	0,057	0,068	0,065
GFI	0,89	0,97	0,92
AGFI	0,86	0,94	0,89
NFI	0,96	0,96	0,96
NNFI	0,98	0,96	0,97
CFI	0,98	0,98	0,97

Tartışma

Bu araştırmanın temel amacı, tutum ölçeği geliştirme çalışmalarında kullanılan istatistiksel analiz yöntemlerinden biri olan TBA ile veri indirgeme/boyut belirleme için kullanılan yapay sinir ağı modellerinden ortaya çıkan sonuçları karşılaştırarak, uygulamada hangisinden daha doğru sonuçlar elde edildiği ve hangisinin daha kullanışlı olduğunu tespit etmektir. Bu amaçla geliştirilen ve detaylandırılan araştırma problemi ve alt problemlerinden elde edilen sonuçlar, karşılaştırmalı olarak, bu çalışmada verilmektedir.

Yapılan analizler sonucu elde edilen bulgulara göre, TBA ölçek yapısı beş bileşenli olmakla birlikte aslında, 26 maddenin 1. bileşende kaldığı; 28 maddeden oluşan ve diğer iki bileşende bir adet maddenin, öteki iki bileşende 1. bileşenle ortak birer maddenin bulunduğu bir yapı ortaya çıkmıştır. Bu sonucun karşılaştırılacağı ikinci alt problem olan GHA modeli sonuçları aynı şekilde beş bileşenli bir ölçek yapısı ortaya çıkarmıştır. Döndürme öncesi TBA sonucundan farklı olarak 1. bileşende 29 madde bulunmaktadır. Diğer bileşenlerdeki maddeler ise TBA sonuçları ile aynıdır. Yine ortak olarak, 1. madde her iki analizden çıkan yapıda da yoktur.

Döndürme öncesi TBA sonuçlarına ve GHA sonuçlarına göre ortaya çıkan bu iki yapıya ait DFA uyum istatistikleri, birbirine oldukça benzerdir. Ancak her ikisinin de bir bileşen dışında diğer bileşenlerinde bir madde bulunması ve bunların da diğer bir bileşenle ortak olması durumu hata varyansının negatif çıkması ve bileşenler arası kovaryansın hesaplanamaması gibi sonuçlar doğurmuştur. Karşılaştırma açısından incelendiğinde, döndürme öncesi TBA ve GHA sonuçlarına göre her iki model için elde edilen uyum istatistikleri, GFI ve AGFI hariç, modelin uyumlu bir sonuç çıkardığını göstermektedir.

GHA işlemleri sürecinde ortaya çıkan önemli bir takım bulgular söz konusudur. Bunlardan birincisi, GHA öğrenme algoritması için kullanılan ve Hu (2001) tarafından yazılan komut dosyasında, değişken sayısı ya da girdi boyutu arttığında eta öğrenme hızının düşürülmesi gerektiğidir. Diğer önemli bir nokta ise, ağına ortaya çıkardığı sonuç bir öz vektör matrisidir. Dolayısıyla GHA, pratik olarak, öz değerleri ve bileşen-madde ilişkisini (faktör yükleri) vermediğinden ötürü öz değerlerin, açıklanan varyansın ve bileşen-madde ilişkilerinin hesaplanması ve TBA sonuçları ile karşılaştırılabilir hale getirilmesidir. Diamantaras (2002) veriler sonlu ve az boyutlu ise ayrıca kovaryans matrisi elde edilebiliyor ise klasik özdeğer çözümlenmesinin, eğer veriler stokastik durumlardan ötürü devamlılık gösteriyor ve/veya veri boyutu çok büyük ise (1000 gibi), bu durumda TBA yapan yapay sinir ağı modellerinin avantajlı olduğunu vurgular.

GHA işlemlerinin sonuç verebilmesi için dikkat edilmesi gereken nokta, ölçekten elde edilen ham verilerin standartlaştırılmış olması gerekmektedir. Çünkü bu çalışmada öz vektörleri elde etmek için korelasyon matrisi kullanılmıştır. Ham verilerin bileşen analizi için standartlaştırılmış kovaryans matrisi olan korelasyon matrisinden çıkan öz vektör sonuçları, ancak standartlaştırılmış verileri işleyen ağ çıktısı ile aynı sonucu vermektedir. Bu durum Sagner (1989, s. 463) tarafından da belirtilmiş ve optimum düzeyi anlatırken, x girdisini, korelasyon matrisi bulunan, 0 ortalamalı bir veri seti şeklinde tanımlamıştır.

GHA sonuçlarında ortaya çıkan bir sorun vardır. GHA'ndan ortaya çıkan öz vektör matrisi (V) ile elde edilen öz değerler matrisindeki ($L=V'CV$) diyagonal olmayan birimler 0'dan büyük çıkabilmektedir. Bu nedenle faktör yüküne ait değerler de ($A=V\sqrt{L}$), birden büyük çıkabilmektedir. Sagner (1989), gerçek uygulamada sonlu eğitim süreci için GHA'nın öz vektörlere yaklaşık sonuçlar verebileceğini ve ilk birkaç öz vektörün bulunmasındaki hata, geri kalan öz vektörleri hesaplamadaki hata miktarını artıracaklarını vurgular. Bu nedenle tam doğru sonuçlar isteniyorsa, klasik matris tekniklerinin daha uygun olacağını belirtir. Ayrıca Sagner (1989), girdi verileri yüksek boyutta ve ilk bir kaç öz vektöre ihtiyaç duyuluyorsa, GHA'nın daha kolay ve hızlı hesaplama açısından bir alternatif olabileceğini belirtir.

GHA modeline ait elde edilen bulgulardan ortaya çıkan sonuç ölçek geliştirmede döndürme öncesi TBA ile benzer sonuçlar verse de, kullanılabilirlik açısından ve faktör yüklerinin beklenenin üstünde çıkma eğilimi, GHA modelinin üzerinde daha çok araştırma ve inceleme

yapılması gerektiğini düşündürmektedir. Ancak amaca göre birbirlerine olan üstünlükleri de söz konusudur. Rizk (2006), yüz tanımada GHA'nın TBA'ya göre daha iyi, görüntü sıkıştırma ise TBA'nın GHA'ya göre daha iyi sonuç verdiğini belirtir.

Araştırmanın diğer bir parçası ise bir yapay sinir ağı modeli olan KDH sonuçlarının, döndürme sonrası TBA sonuçları ile karşılaştırılmasıdır. TBA analizi dik döndürme işlemi ile sonlandırıldıktan sonra ortaya çıkan ölçek yapısı, 26 maddeli ve 5 bileşenli bir yapıdır. Bu sonuç, KDH modeli sonuçları ile karşılaştırılmaktadır. Çünkü KDH, veri indirgemedi sonuca götüren bir öğrenme algoritmasına sahiptir.

KDH analizi yapabilmek için, sonucun kaç nöronluk bir katmanda haritalamak istenildiğine karar verilmesi gerekmektedir. Çünkü bu bilgi analizin başlangıcında tanımlanması gereken bir bilgidir. Bu durumda iki farklı çapta nöron sayısı üzerinden ağ çıktısı alınmıştır. Birincisi 5x5 boyutlarında 25 adet nöron üzerinden 30 maddenin haritası çıkarılmıştır. Buna göre iki farklı nöron üzerinde maddeler benzerliklerine göre gruplanmıştır. Birinci nöronda 2 madde, diğer nöronda ise 6 madde bulunmaktadır. TBA terminolojisi kullanılacak olursa, ağdan iki boyutlu 8 maddeden oluşan bir ölçek yapısı ortaya çıkmıştır.

Bir sonraki aşamada, KDH analizi nöron sayısı değiştirilerek tekrarlanmıştır. Bu aşamada, nöron sayısı 16 olarak belirlenmiş ve çıktı, 4x4 boyutunda elde edilmiştir. Elde edilen ölçek yapısı, bir öncekine göre pek fazla değişiklik göstermemiştir. Yine iki nöronda maddeler toplanmış, birinci nöronda yine aynı iki madde görülmekte diğer nöronda ise aynı 6 maddenin üzerine 8 madde daha eklenerek, madde sayısının 6'dan 14'e çıktığı gözlenmiştir.

Döndürmeli TBA sonuçları ile KDH sonuçlarının bu durumda oldukça farklı iki yapı ortaya koydukları görülmektedir. Döndürmeli TBA madde sayısını 30'dan ancak 26'ya indirgeyebilmiş ve beş boyutlu bir ölçek yapısı ortaya çıkarmıştır. KDH ise hem madde sayısı hem de boyut sayısı açısından oldukça kullanışlı bir yapı ortaya koymuştur.

KDH sonuçları açısından kendi içinde önemli bir bulgu ortaya çıkmıştır. Bu bilgi, nöron sayıları ile ortaya çıkan yapının boyutu ve madde sayısı ilişkisidir. Bu çalışmada iki farklı nöron sayısında haritalama yapılmıştır. Buna göre daha az sayıda nöron üzerinden (4x4) elde edilen çıktıda bileşen sayısı aynı kalmakla birlikte madde sayısının arttığı görülmüştür.

Döndürmeli TBA, 4x4'lük ve 5x5'lik KDH çıktılarında elde edilen ölçek yapılarının DFA sonucunda elde edilen uyum istatistikleri açısından karşılaştırılmıştır. Buna göre KDH'dan elde edilen her iki yapının da, RMSEA değerleri hariç, oldukça yüksek uyum gösterdikleri ancak, 5x5 nöron haritasından çıkan iki bileşenli 8 maddeli ölçek yapısının uyum indeksi değerlerinin 4x4'lük KDH yapısına göre daha iyi sonuç verdiği görülmektedir. Döndürmeli TBA sonucu ortaya çıkan 5 bileşenli yapının GFI ve AGFI değerleri dışındaki diğer değerlerinin yüksek uyuma işaret ettiği görülmektedir. Her üç farklı yapının uyum indeksleri, genel olarak birbirine yakın olmakla birlikte, az sayıda faktör sayısı, daha az madde ile örtük yapıyı ortaya çıkarması ve en önemli noktalardan biri olan analiz için gerekli sayıların bulunmaması gibi açılardan, KDH'nın veri indirgeme ve örtük yapıyı ortaya çıkarmada oldukça etkili bir yöntem olduğu söylenebilir. Kiang ve Kumar'ın (2001) çalışmasında KDH ağının, özellikle çarpık dağılımlı verilerde, döndürme öncesi faktör analizi sonuçlarından daha üstün olduğu ve örtük küme yapısını daha doğru ortaya koyduğu gözlenmiştir. Bu çalışmada KDH'nın yine çarpık dağılımlarda döndürme sonrası TBA sonuçlarına göre daha kullanışlı olduğu ortaya çıkmıştır.

Bunun yanı sıra ortaya çıkan örtük yapıların tanımlanması ve adlandırılmasında KDH'dan çıkan yapılar daha kolaylık sağlamaktadır ve böylelikle bağlamsal olarak daha anlaşılabilir bir yapı ortaya konmuştur. Döndürmeli TBA'dan çıkan yapıda, bileşenlerdeki maddelere bakarak 5 bileşenin adlandırılması mümkün olmamaktadır. Ancak KDH'dan çıkan yapıda iki faktörden birisi oldukça kararlı olan 2 maddeli faktördeki ifadeler, diğer maddelerden bağlamsal açıdan net olarak ayrılmaktadır. Ölçeğin 1. ve 2. maddesi olan bu maddeler, öğretmenlik mesleğine yönelik tutum ifadeleridir. Hem 4x4'lük hem de 5x5'lik haritalamada çıkan diğer faktörde yer alan maddelerin ise öğretmenlere yönelik tutum ifadeleri olduğu söylenebilir. Bu durumda amaç öğretmenlere yönelik tutum ölçeği maddelerinin belirlenmesi olduğuna göre, 1. ve 2. maddenin öğretmenlik mesleğine yönelik maddeler olduğu için denemelik ölçekten çıkarılarak tek boyutlu 6 maddeli bir nihai ölçeğe ulaşıldığı söylenebilir.

KDH ve TBA karşılaştırmalarında her iki analiz yönteminin kendi içinde avantajları olduğunu görülmektedir. Chattopadhyay, Dan ve Majumdar (2011), hücrel üretim araştırmalarında, TBA'da açıklanan varyansın yüksek olduğu ancak daha büyük boyutlu hücrel oluşumlarda KDH'nin daha iyi sonuç verdiğini ve görsel sınıflandırma sonuçları verebilmesi nedeni ile gelecek çalışmalar açısından önemli bir katkı sağladığını belirtir. Görsellik ile ilgili vurgu, Peeters ve Dassargues (2006) tarafından da ifade edilir ve KDH'nin görselliği nedeni ile sonuçları yorumlama gücünden bahsedilir. TBA'nın avantajının ise matematiksel olarak bileşenlerin tespiti ve ilişkilerin görülebilmesi olduğu belirtilir.

Kaynaklar

- Baldi, P. ve Hornik, K. (1989). Neural networks and principal component analysis: Learning from examples without local minima. *Neural Networks*, 2, 53-58.
- Baş, N. (2006). *Yapay sinir ağları yaklaşımı ve bir uygulama* (Yayımlanmamış yüksek lisans tezi). Mimar Sinan Güzel Sanatlar Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- Bayır, F. (2006). *Yapay sinir ağları ve tahmin modellemesi üzerine bir uygulama* (Yayımlanmamış yüksek lisans tezi). İstanbul Üniversitesi Sosyal Bilimler Enstitüsü, İstanbul.
- Bogden, R. C. ve Biklen, S. K. (1998). *Qualitative research for education*. Boston: Allyn and Bacon.
- Chattopadhyay, M., Dan, P. K. ve Majumdar, S. (2011). *Principal component analysis and self organizing map for visual clustering of machine-part cell formation cellular manufacturing system* [Abstract]. Erişim adresi: <http://arxiv.org/pdf/1201.5524.pdf>
- Diamantaras, K. I. (2002). Neural networks and principal component analysis. Y.-H. Hu ve J.-N. Hwang (Yay. haz.). *Handbook of neural networks for signal processing* içinde (s. 1-37). Boca Raton: CRC Press.
- Elmes, D. G., Kantowitz, B. H. ve Roediger III, H. L. (1992). *Research methods in psychology*. St. Paul: West Publishing Company.
- Field, A. (2009). *Discovering statistics using SPSS*. London: SAGE Publications Inc.
- Haykin, S. (1999). *Neural network-a comprehensive foundation*. New Jersey: Prentice Hall, Inc.
- Hu, Y. H. (2001). *Ghademo.m - generalized hebbian learning demonstration*. Erişim adresi: https://svn.ssec.wisc.edu/repos/willem.marais.msthesis/examples/Hebbian%20Learning/m_scripts/ghademo.m
- Johnson, R. A. ve Wichern, D. W. (1982). *Applied multivariate statistical analysis*. New Jersey: Prentice Hall, Inc.
- Kalaycı, Ş. (2014). *SPSS uygulamalı çok değişkenli istatistik teknikleri*. Ankara: Asil Yayın Dağıtım Ltd. Şti.
- Kane, M. T. (2006). Validation. R. L. Brennan (Yay. haz.). *Educational measurement* içinde (s. 17-64). USA: American Council on Education Praeger.
- Karasar, N. (1998). *Bilimsel araştırma yöntemi*. Ankara: Nobel Yayın Dağıtım.
- Kiang, M. Y. ve Kumar, A. (2001). An evaluation of self organizing map networks as a robust alternative to factor analysis in data mining applications. *Information Systems Research*, 12(2), 177-194.
- Kline, R. B. (2005). *Principles and practice of structural equation modeling*. New York: The Guilford Press
- Kohonen, T. (1982). Self-organized formation of topologically correct feature maps. *Biological Cybernetics*, 43, 59-69.
- Kohonen, T. (1990). The self-organizing map. *Proceedings of the IEEE*, 78(9), 1464-1480.
- Krenker, A., Bestır, J. ve Kos, A. (2011). Introduction to the artificial neural networks. K. Suzuki (Yay. haz.). *Artificial neural networks- methodological advances and biomedical applications* içinde (s. 3-18). Erişim adresi: http://cdn.intechopen.com/pdfs/14881/InTech-introduction_to_the_artificial_neural_networks.pdf
- Kulkarni, A. D. (1994). *Artificial neural networks for image understanding*. New York: Van Nostrand Reinhold.

- Miller, M. D., Linn, R. L. ve Gronlund, N. E. (2009). *Measurement and assessment in teaching*. New Jersey: Pearson Education.
- Neural Network Fundamentals. (t.y.). Erişim adresi: <http://ube.ege.edu.tr/~cinsdiki/UBI521/Chapter-1>.
- Oja, E. (1982). A simplified neuron model as a principal component analyzer. *Journal of Mathematical Biology*, 15, 267-273.
- Peeters, L. ve Dassargues, A. (2006). *Comparison of Kohonen's self organizing map algorithm and principal component analysis in the exploratory data analysis of a groundwater quality data set*. Erişim adresi: <http://ulg.ac.be/handle/2268/3388>
- Rizk, M. R. M. (2006). A comparison of principal component analysis and Generalized Hebbian Algorithm for image compressing and face recognition. *The 2006 International Conference on Computer Engineering and Systems* (s. 214-219). Cairo: IEEE.
- Sagner, T. D. (1989). Optimal unsupervised learning in a single-layer linear feedforward neural network. *Neural Networks*, 2, 459-473.
- Sengupta, S. (2009) Artificial neural networks: Ders notları. *Indian Institute of Technology*. Erişim adresi: www.youtube.com/playlist=PLi-bxY2I4hXxf7vZKF2EcanZzWr-I7Pm
- Tabachnick, B. G. ve Fidell, L. S. (2001). *Using multivariate statistics*. Boston: Allyn and Bacon.
- Tezbaşaran, A. A. (1997a). *Likert tipi ölçek geliştirme klavuzu*. Ankara: Türk Psikologlar Derneği Yayınları.
- Tezbaşaran, A. A. (1997b). Validity issues of Likert type scales (a case study). *Hacettepe Üniversitesi Eğitim Fakültesi Dergisi*, 13, 41-45.
- Yurtoğlu, H. (2005). *Yapay sinir ağları metodolojisi ile öngörü modellemesi: Bazı makroekonomik değişkenler için Türkiye örneği* (Uzmanlık tezi). Devlet Planlama Teşkilatı, Ankara. Erişim adresi: www3.kalkinma.gov.tr/DocObjects/Download/3222/ysa.pdf

Extended Abstract

Introduction

In a scale development process, some statistical analysis techniques are used to get the reliable and valid measurements from the scale in terms of what intends to measure. In general, to determine the magnitudes of a psychological variable on population, couples of stimuli-response are used via written items (questions-answers or statements) in a data collection form, which is called scale. The one of the stage in developing scale process, which starts from the operational description of the theoretical one of a variable intending to measure, is statistical analysis process. The responses getting from rating scale format are analysed statistically to determine the quality of and select the items that constitute an ideal scale. With this perspective, it can be said that statistical analysis is very important to serve the purpose in a scale development.

Parametric statistical approach has some limitations to use them directly. In general, these limitations result from scale type, normality, and linearity concepts. Concerning for those limitations, it can be valuable to investigate artificial neural networks instead of using statistical analysis techniques in scale development. From this perspective, there are many theoretical and applied research papers related usefulness of neural networks in comparison with the corresponding statistical techniques in literature.

Principal component analysis (PCA) is one of the most commonly used techniques in developing a scale to investigate the construct validity. When this analysis is taken into focus, some artificial neural network models exist in literature. One of them is neural network model having Generalized Hebbian learning rule algorithms (GHA), the other is Kohonen's self organizing mapping (SOM) which is used instead of factor analysis specifically.

The aim of the research is to find out whether GHA and SOM can be applicable instead of PCA used in the construct validity studies in the fields of psychology and education. In line with this aim, as data reduction and factor extraction method, GHA and SOM and PCA results

are compared with each other in terms of construct of scale concerning the confirmatory factor analysis results (model fit and error indexes) and contextual aspect.

Method

For this research, trial version of an attitude scale towards teachers with 30 items have been prepared, and it has been implemented on 400 teacher candidates from different faculties who joined the Pedagogical Formation Programme. The data obtained have been analysed using the PCA and the artificial neural network models. To decide on the reasonable one among the scale constructs revealed by different techniques, trial version of scale has been given to another group of 400 teacher candidates joining the same programme and the confirmatory factor analysis has been done based on the data gathered second time. Then the constructs revealed by PCA and artificial neural network models have been compared based on the results of the confirmatory factor analysis that are model fit and error indexes and contextual aspect.

Result and Discussion

According to the findings from the analysis, the result of GHA related with the scale construct has been compared with the unrotated result of PCA. Because the algorithm gives the unrotated solution. It has been observed that the results obtained from the two analysis offer a close construct to each other and both of them include five components as well. It has also been observed that model fit and error indexes are close to each other. There are 28 items in the scale revealed from unrotated PCA and first component includes 26 items. In similar way, 28 items are also included in the first component of the scale revealing from the GHA. However, GHA gives some extraordinary values in eigenvalue matrix, for instance, value greater than zero for some non-diagonal entries. This causes factor loadings having greater than one. It can result from approximate solution and error that GHA gives, when GHA produce eigenvector as literature mentioned. Moreover, the scale construct from GHA is not an optimal solution since GHA just gives unrotated component construct.

After the rotation, it can be observed that the scale construct obtained from PCA is quite different from the scale construct obtained from SOM. While PCA puts forward a construct with 5 components having 26 items, SOM reveals a construct with 2 factors for both two dimensional topographies with 4x4 and 5x5 map. When the model fit and error indexes are reviewed, it is seen that these constructs from SOM are fitting ones compared with the scale construct revealing from rotated PCA. It can also be said that the construct obtained from SOM on 5x5 map size have a more fitting scale construct with 2 factors having 8 items compared with scale construct with 2 factors having 16 items observed on the 4x4 map in terms of the model fit indexes excluding RMSEA index. While 6 items are observed on 5x5 map in one factor, 8 items are added to these 6 items on 4x4 map within the same factor. In the other factor, there are 2 items observed on both maps. When examined contextually, these items can be considered to belong to not attitude towards teachers but towards teaching profession. This means that the scale come from SOM have one dimensional construct. As a conclusion, SOM gives better results for construct validity in terms of confirmatory factor analysis indexes and determining closing items and removing ones from what intent to measure contextually. Therefore, it is recommended more researches should be focused on SOM for construct validity.

Ekler**Ek 1. Denemelik Öğretmenlere Yönelik Tutum Ölçeği**

Maddeler	Hiç katılmıyorum	Katılmıyorum	Kararsızım	Katılıyorum	Tamamen katılıyorum
1. Öğretmenler ülkenin geleceğini belirler.					
2. Öğretmenler saygıyı hak eder.					
3. Öğretmenler eğitimin kalitesini olumsuz etkiler.					
4. Öğretmenler mesleklerinde fedakârdırlar.					
5. Öğretmenler öğrencilerine eşit davranır.					
6. Öğretmenlerden toplum lideri olmaz.					
7. Öğretmenler eğitim işini hafife alır.					
8. Öğretmenler toplum sorunlarına karşı duyarlıdır.					
9. Öğretmenler işlerini özenle yapmaz.					
10. Öğretmenler iletişimi zor insanlardır.					
11. Öğretmenler mesleklerini severek yapar.					
12. Öğretmenler öğrencilerine sevgi dolu yaklaşır.					
13. Öğretmenler öğrencilerin derslere olan ilgisini artırır.					
14. Öğretmenler öğrencilerin sorunları ile yakından ilgilenir.					
15. Öğretmenler öğrencileri geleceğe hazırlar.					
16. Öğretmenler öğrencilerine çalışma disiplini aşılar.					
17. Öğretmenler öğrenmeyi zevksiz hale getirir.					
18. Öğretmenler öğrencilerin öğrenme güçlüklerini dikkate alır.					
19. Öğretmenler öğrencilerin başarılarını objektif olarak değerlendirir.					
20. Öğretmenler öğrencilerin sıkıntılarını görmezden gelir.					
21. Öğretmenler velileri, öğrenciler hakkında, eksik bilgilendirir.					
22. Öğretmenler öğrencileri ile ilişkilerinde resmiyet-samimiyet derecesini ayarlayamaz.					
23. Öğretmenler öğrenciler için iyi birer rol modelidir.					
24. Öğretmenler sınıfı ceza ile korkutarak yönetir.					
25. Öğretmenler mesleki açıdan kendilerini geliştirir.					
26. Öğretmenler öğrencilerini iyi davranışlara yönlendirir.					
27. Öğretmenler derslerine hazırlıklı gelir.					
28. Öğretmenler dersleri ilgi çekici kılar.					
29. Öğretmenler yetenekli öğrencileri keşfeder.					
30. Öğretmenler mesleklerinde yetersizdir.					