

T.C.
Mersin Üniversitesi
Eđitim Bilimleri Enstitüsü
Eđitim Bilimleri Anabilim Dalı
Eđitimde Ölçme ve Deđerlendirme Bilim Dalı

TEMEL BİLEŐENLER ANALİZİ VE YAPAY SİNİR AđI
MODELLERİNİN ÖLÇEK GELİŐTİRME SÜRECİNDE
KULLANILABİLİRLİĐİNİN İNCELENMESİ

DOKTORA TEZİ

Esin TEZBAŐARAN

Danıőman

Prof. Dr. Selahattin GELBAL

Mersin, 2016

KABUL VE ONAY

Eđitim Bilimleri Enstitüsü M¼d¼rl¼đ¼'ne,

Bu alıřma j¼rimiz tarafından Eđitim Bilimleri Anabilim Dalı Eđitimde ¼lme ve Deęerlendirme Bilim Dalında DOKTORA TEZİ olarak kabul edilmiřtir.

Başkan

Prof. Dr. M¼lyá KELECİ ¼GLU

¼ye.....

Prof. Dr. Selahattin GELBAL (Danıřman)

¼ye.....

Prof. Dr. Tuęba YELKEN

¼ye.....

Do. Dr. Mehmet Hakan G¼NDOęDU

¼ye.....

Do. Dr. Devrim ALICI

Onay

Yukarıdaki imzaların, adı geen ¼đretim ¼yelerine ait olduęunu onaylarım.



TEŐEKKÜR

Bu alıőmanın kapsamını oluőturan yapay sinir ađları ile tanışmamı sađlayan, süreçte beni cesaretlendiren ve alıőmanın her aşamasında bilgi ve yönlendirmeleri ile katkı sađlayan deđerli Hocam ve Danıőmanım Prof. Dr. Selahattin GELBAL'a teőekkürü bir bor bilirim.

Yapay sinir ađları ile ilgili öğrenme yolculuđumda yardımlarını esirgemeyen Prof. Dr. Fatoő YARMAN VURAL'a teőekkür ederim.

Doktora eđitimim süresince sabır gösteren ve alıőmayı tamamlamam için beni destekleyen ođlum Sezer'e, yaőamım boyunca hep arkamda olan anneme ve babama sonsuz teőekkürlerimi sunarım.

ÖZET

TEMEL BİLEŞENLER ANALİZİ VE YAPAY SİNİR AĞI MODELLERİNİN ÖLÇEK GELİŞTİRME SÜRECİNDE KULLANILABİLİRLİĞİNİN İNCELENMESİ

Esin TEZBAŞARAN

Doktora Tezi

Eğitim Bilimleri Enstitüsü

Prof. Dr. Selahattin GELBAL (Danışman)

Ocak, 2016

127 Sayfa

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.

Bu amaçla 30 maddeden oluşan denemelik Öğretmenlere Yönelik Tutum Ölçeği hazırlanmış ve bu ölçek çeşitli fakültelerden mezun olan ve öğretmenlik formasyon eğitimine katılan 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, ölçeklerin geliştirildiği örnekleme benzer ancak, farklı bireylerden oluşan 400 kişilik bir örneklemden 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.

Döndürme öncesi temel bileşenler analizinden çıkan ölçek yapısı ile Genelleştirilmiş Hebb Algoritması sonucu karşılaştırılmıştır. Çünkü bu algoritma döndürme öncesi bileşen yapısı ortaya koymaktadır. İki analizden çıkan ölçek yapılarının birbirine oldukça yakın bir yapı ortaya koyduğu ve her ikisinin de beş bileşenli bir yapıda olduğu gözlenmiştir. Aynı zamanda her iki yapının doğrulayıcı faktör analizi sonucunda ortaya çıkan uyum ve hata indekslerinin de birbirine çok yakın olduğu görülmüştür.

Döndürme sonrası temel bileşenler analizinden çıkan ölçek yapısı ile Kendini Düzenleyen Haritalamadan çıkan ölçek yapısı ise birbirlerinden oldukça farklıdır. Temel bileşenler analizi 5 bileşenli bir yapı ortaya koyarken, Kendini Düzenleyen Haritalama daha az madde ile iki bileşenli bir yapı ortaya koymuştur. Uyum indekslerine bakıldığında, bu yapılar uyum indekslerinin çoğu açısından uyumlu yapılardır. RMSEA dışındaki uyum indekslerine göre, 5x5 nöron üzerinden haritalanan yapay sinir ağı modelinin ortaya koyduğu yapının daha uyumlu olduğu söylenebilir.

Anahtar Kelimeler: Genelleştirilmiş Hebb Algoritması, Kendini Düzenleyen Haritalama, Temel Bileşenler Analizi

ABSTRACT

AN INVESTIGATION ON USABILITY OF PRINCIPAL COMPONENT ANALYSIS AND ARTIFICIAL NEURAL NETWORK MODELS IN THE PROCESS OF SCALE DEVELOPMENT

Esin TEZBAŞARAN

Doctorate Thesis

Graduate School of Educational Science

Prof. Dr. Selahattin GELBAL (Advisor)

January, 2016

127 pages

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.

The result of the Generalized Hebbian Algorithm related with the scale construct has been compared with the unrotated result of the principal component analysis. 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 as a result of the confirmatory factor analysis.

After the rotation, the scale construct obtained from the principal component analysis is quite different from the scale construct obtained from self organizing mapping. While principal component analysis puts forward a construct with 5 components, self organizing mapping reveals a construct with 2 components. 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. It can also be said that 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.

Key Words: Generalized Hebbian Algorithm, Self Organizing Mapping, Principal Component Analysis

Prof. Dr. A. Ata Tezbaşaran'a

İÇİNDEKİLER

KABUL VE ONAY	i
TEŞEKKÜR	ii
ÖZET	iii
ABSTRACT	v
İTHAF	vii
İÇİNDEKİLER	viii
TABLolar DİZİNİ	xi
ŞEKİLLER DİZİNİ	xiii
KISALTMALAR	xv
BÖLÜM I	1
GİRİŞ	1
1.1. Problem Durumu	1
1.2. Problem Cümlesi	4
1.3. Araştırmanın Amacı	5
1.4. Araştırmanın Önemi	5
1.5. Sayıtlar	6
1.6. Sınırlılıklar	6
1.7. Tanımlar	6
BÖLÜM II	8
KURAMSAL YAPI VE LİTERATÜR	8
2.1. Ölçmede Yapı Geçerliği	8
2.2. Faktör Analizi ve Temel Bileşenler Analizi	15
2.3. Yapay Sinir Ağları	22
2.3.1 Aktivasyon Fonksiyonları	26
2.3.2 Yapay Sinir Ağları Gelişiminde Kilometre Taşları	27

2.3.3	Yapay Sinir Ağlarının Uygulama Alanları	28
2.3.4.	Yapay Sinir Ağlarının Topolojisi	29
2.3.5	Yapay Sinir Ağlarının Öğrenme Yöntemleri	31
2.3.6.	Yapay Sinir Ağlarının Mimari Yapısı	34
2.3.7.	Yapay Sinir Ağlarında Öğrenme Kuralları	38
2.3.8	Veri İndirgemedeki Kullanılan Yapay Sinir Ağı Modelleri	46
2.3.8.1.	Genelleştirilmiş Hebb Algoritması	46
2.3.8.2.	Kendini Düzenleyen Haritalama	48
2.4.	İlgili Araştırmalar	49
BÖLÜM III	59
YÖNTEM	59
3.1.	Araştırmanın Türü	59
3.2	Araştırma Grubu	59
3.3.	Veri Toplama Aracı	61
3.4.	Verilerin Analizi	62
BÖLÜM IV	77
BULGULAR	77
4.1.	Birinci Alt Probleme İlişkin Bulgular	77
4.2.	İkinci Alt Probleme İlişkin Bulgular	82
4.3.	Üçüncü Alt Probleme İlişkin Bulgular	86
4.4.	Dördüncü Alt Probleme İlişkin Bulgular	91
BÖLÜM V	99
TARTIŞMA VE YORUM	99
KAYNAKLAR	107

EKLER	116
Ek 1. Aktivasyon Fonksiyonları ve Grafik Gösterimi	116
Ek 2. Denemelik Öğretmenlere Yönelik Tutum Ölçeği	118
Ek 3. GHA İçin Kullanılan MATLAB Komut Dosyası	121
Ek 4. GHA Sonuçları için Kullanılan Veri Matrisleri	124

TABLolar DİZİNİ

Tablo 1.	Biyolojik ve Yapay Sinir Ağı Elemanları	25
Tablo 2.	Lisans Alanlarına Göre TBA, GHA ve KDH İçin Kullanılan Çalışma Grubunun Frekans ve Yüzde Dağılımı	60
Tablo 3.	Lisans alanlarına Göre DFA İçin Kullanılan Çalışma Grubunun Frekans ve Yüzde Dağılımı	61
Tablo 4.	TBA, GHA ve KDH İçin kullanılan Veri Seti Üzerinden Denemelik ÖYTÖ Maddeleri İçin Bazı İstatistikler	63
Tablo 5.	DFA İçin kullanılan Veri Seti Üzerinden Denemelik ÖYTÖ Maddeleri İçin Bazı İstatistikler	70
Tablo 6.	TBA Sonucunda Bileşenlerce Açıklanan Toplam Varyans	78
Tablo 7.	Döndürme Öncesi TBA Sonucu Maddelerin Bileşenlere Verdiği Faktör Yükleri	79
Tablo 8.	Dik Döndürme Sonrası TBA Sonucu Maddelerin Bileşenlere Verdiği Faktör Yükleri	81
Tablo 9.	GHA Sonucunda Bileşenlerce Açıklanan Toplam Varyans	84
Tablo 10.	GHA Sonucu Maddelerin Bileşenlere Verdiği Faktör Yükleri	85
Tablo 11.	5x5 Nöron Üzerinden KDH Çıktısında Maddelerin Norönlara Dağılımı	88
Tablo 12.	4x4 Nöron Üzerinden KDH Çıktısında Maddelerin Norönlara Dağılımı	90
Tablo 13.	Analiz Sonuçlarına Göre Ölçek Yapıları	91

Tablo 14.	Döndürme Öncesi TBA ve GHA Sonuçlarında Maddelerin Bileşenlere Dağılımı	92
Tablo 15.	Döndürme Öncesi TBA ve GHA'dan Ortaya Çıkan ÖYTÖ Yapısının DFA Uyum ve Hata İndeksleri.....	93
Tablo 16.	Döndürme Sonrası TBA ve KDH Sonuçlarına Göre Maddelerin Bileşenlere Dağılımı.....	94
Tablo 17.	Döndürme Sonrası TBA ve KDH'dan Ortaya Çıkan ÖYTÖ Yapısının DFA Uyum ve Hata İndeksleri	98
Tablo 18.	GHA Sonucu Elde Edilen Özvektörler Matrisi (30x30)	124
Tablo 19.	GHA Sonucu Elde Edilen Özdeğerler Matrisi (30x30)	125
Tablo 20.	Madde-Madde Korelasyon Matrisi (30x30)	126
Tablo 21.	GHA Sonucu Elde Edilen Faktör Yükleri (30x30) (>0,45)	127

ŞEKİLLER DİZİNİ

Şekil 1.	Dik Döndürme Yönteminin Geometrik Gösterimi	19
Şekil 2.	Eğik Döndürme Yönteminin Geometrik Gösterimi	20
Şekil 3.	Biyolojik Sinir Ağı Yapısı	23
Şekil 4.	Yapay Sinir Ağı Yapısı	25
Şekil 5.	Tek Katmanlı İleri Beslemeli Yapay Sinir Ağı	30
Şekil 6.	Tek Katmanlı Geri Beslemeli Yapay Sinir Ağı	31
Şekil 7.	İki Girdili Tek Katmanlı Algılayıcıların Geometrik Gösterimi ..	36
Şekil 8.	Çok Katmanlı Nöronların Ağ Mimarisi	37
Şekil 9.	İki Boyutlu Girdi Uzayının Üç katmanlı Algılayıcılar Tarafından Çözümüne Ait Geometrik Gösterim	38
Şekil 10.	Yarışmacı Öğrenme Kuralının Geometrik Yorumu	44
Şekil 11.	KDH ile Yapılan 10x15 nöronlu Semantik Harita	49
Şekil 12.	Faktör Analizi Sonucunun Şematik Gösterimi	53
Şekil 13.	Bir Gizli Katmanda Tek Nöronlu Yapay Sinir Ağı Modelinin Şematik Gösterimi	53
Şekil 14.	EQS Yapısal Eşitlik Modeli	72
Şekil 15.	DFA’da Bir Model Örneği	73
Şekil 16.	5x5 Nöron Üzerinden KDH Çıktısında Sınıflandırılan Madde Sayıları	87

Şekil 17.	4x4 Nöron Üzerinden KDH Çıktısında Sınıflandırılan Madde Sayıları	89
Şekil 18.	Döndürme Sonrası TBA Sonucunda Ortaya Çıkan ÖYTÖ Yapısının Yön Diyagramı	95
Şekil 19.	KDH Modelinde 5x5 Nöron Üzerinden Ortaya Çıkan ÖYTÖ Yapısının Yön Diyagramı	96
Şekil 20.	KDH Modelinde 4x4 Nöron Üzerinden Ortaya Çıkan ÖYTÖ Yapısının Yön Diyagramı	97

KISALTMALAR

AGFI	: Uyumlaştırılmış Uyum İyiliği İndeksi
CFI	: Karşılaştırmalı Uyum İndeksi
DFA	: Doğrulayıcı Faktör Analizi
GFI	: Uyum İyiliği İndeksi
GHA	: Genelleştirilmiş Hebb Algoritması
KDH	: Kendini Düzenleyen Haritalama
LMS	: En Az Ortalama Kareler
NFI	: Normlaştırılmış Uyum İndeksi
NNFI	: Normlaştırılmamış Uyum İndeksi
RMSEA	: Ortalama Karekök Hata Tahmini
TBA	: Temel Bileşenler Analizi

BÖLÜM I

GİRİŞ

1.1. Problem Durumu

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 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 olarak 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 örnekleme oluşturmaktır. Daha sonra seçilen örnekleme 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 herbir 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 ölçüğe doğru giden bu sürecin ilk adımını denemelik ölçüğün 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 uygulanan yöntem, bireylere yöneltilen ve bireyde ölçmek istediğimiz değişkene ait olduğu düşünülen yazılı ya da sözlü uyarıcılara (sorular, cümleler) değişik formatta verilen tepkilerin üzerinden yapılan istatistiksel analizlerle veri toplama aracının sağlıklı bir araç olup olmadığını tespit etmek ve ideal ölçme aracı haline getirmek için bu analiz sonuçlarından yararlanmaktadır. 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 analizlerin, istenen amaca hizmet etmesi oldukça önemlidir.

İstatistiksel analiz yöntemlerinin kullanımında bazı kısıtlayıcı durumlar vardır. Bunlar genel olarak ölçek türleri, değişkenlere ilişkin normal olmayan dağılımlar, değişkenler arası doğrusal olmayan ilişkiler olarak sıralanabilir. İstatistiksel analiz yöntemleri dışında yapay sinir ağları modelleri de kullanılabilir. Özellikle, yapay sinir ağlarının veri analizinde nispeten kullanışlı olabileceğini ortaya koyan kuramsal ve uygulamalı çalışmalar vardır.

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

Ölçek geliştirme çalışmalarında kullanılan analizlerden biri temel bileşenler analizidir (TBA). Bu analiz üzerine odaklanıldığında, bunun yerine kullanılabilir olan yapay sinir ağı modelleri geliştirildiğine yönelik literatürde 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 tezin temel problemi, eğitimde kullanılan tutum ölçeklerinin birimlerini oluşturacak olan uyarıcıları seçmek ve ölçülmek istenen değişkenin yapısını ortaya koyan boyutları belirlemek amacıyla kullanılan TBA yerine yapay sinir ağları kullanarak, daha optimal çözümlere ulaşılabilirliğinin incelenmesidir.

1.2. Problem Cümlesi

Bu araştırmada 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 yapan 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 yapısının uyum ve hata indeksleri nasıldır?

- 4.b. TBA'nde döndürme sonrası ortaya çıkan denemelik ÖYTÖ'nin yapısı ile KDH yapan yapay sinir ağı modeli sonucu ortaya çıkan yapısının uyum ve hata indeksleri nasıldır?

1.3. 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.

1.4. Araştırmanın Önemi

Yapay sinir ağı modelleri genellikle eğitim ve psikolojik araştırmalar dışında yaygın olarak kullanılmaktadır. Bu çalışma yapay sinir ağı modellerinin eğitim verileri üzerinde incelenmesiyle, eğitim alanına kazandırılması açısından önemlidir. Yapılan incelemelerde, Türkiye'de eğitim verileri üzerinde yapay sinir ağları ve lojistik regresyon analizi karşılaştırma çalışmasının, ilk olarak Tepehan (2011) tarafından yapıldığı görülmektedir. Ancak Türkiye'de eğitim verileri üzerinde yapay sinir ağı modellerinin, TBA ile karşılaştırılması çalışmasına, yapılan incelemeler sonucu literatürde karşılaşılmamıştır.

Diğer yandan, yapay sinir ağı modelleri ile istatistiksel analiz yöntemlerinin uygulamalı olarak karşılaştırılması önem taşımaktadır. İstatistiksel analiz yöntemlerinin kullanımında bazı önkoşullar vardır. Bu koşullara göre seçilen parametrik ve parametrik olmayan analizlerin getirdiği sınırlamaların yapay sinir ağı modelleri ile aşılabileceğinin belirlenmesi ve eğitim araştırmalarında en uygun sonuçlara ulaştırabilecek bir analiz yöntemi

sunulabilmesi bu çalışmanın alana getirebileceği bir katkı olarak düşünülmektedir. Bu nedenle veri indirgeme ve boyut belirleme amacıyla kullanılan istatistiksel analizlerde karşılaşılan bazı problemlere karşın yapay sinir ağı modellerinin kullanılabilirliğini incelemek anlamlı olabilir.

1.5. Sayıtlar

Bu araştırmada 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.

1.6. 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.
- 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.

1.7. Tanımlar

Genelleştirilmiş Hebb Algoritması (GHA): GHA kullanan yapay sinir ağının topolojisi ileri beslemeli, mimarı yapısı tek katmanlı ve öğrenme yöntemi ise denetimsiz öğrenme yöntemidir. Öğrenme kuralı olarak Hebb öğrenme kuralını uygular. Bu ağın temel amacı, veri indirgeme ve temel bileşenleri ortaya çıkarmadır. Bu nedenle literatürde, bu algoritmanın temel bileşenler analizi yerine kullanıldığı çalışmalar mevcuttur.

Kendini Düzenleyen Haritalama (KDH): Kendini düzenleyen bir haritalama yapan yapay sinir ağının amacı, dış dünyadan gelen sinyallere göre girdilerin özelliklerinin haritasını çıkarmaktır. Kohonen tarafından geliştirilen bu model, Kohonen Ağı olarak da adlandırılır. Bu ağ tek katmanlı mimari yapıda, ileri beslemeli, denetimsiz öğrenme yöntemine sahip bir ağ modelidir. Yarışmacı öğrenme kuralı kullanan ağ yapısı ile, girdilerin özelliklerini göz önüne alarak kümelemesi temel işlevidir ve literatürde faktör analizi amacıyla kullanıldığı çalışmalar vardır.

Temel Bileşenler Analizi (TBA): Parametrik bir istatistiksel analiz olan TBA'nin amacı, veri indirgemedir. Bu analiz tekniği, çok sayıda değişkeni, bilgi kaybına uğratmadan daha az sayıda değişkene indirger ve özellikle psikolojide örtük değişkenlerin yapılarını ortaya çıkarmada kullanılır. TBA, faktör analizi yönteminin bir altında bir teknik olarak düşünülebilir. Değişkenlerdeki hata varyansını göz ardı ederek tüm değişkenlik üzerinden faktörleme yaptığı için analiz sonucunda çıkan örtük yapılar “bileşen” olarak adlandırılır.

BÖLÜM II

KURAMSAL YAPI VE LİTERATÜR

2.1. Ölçmede Yapı Geçerliği

Eğitim ve psikolojide geliştirilen ölçme araçlarının güvenirlik ve geçerliği çalışmaları oldukça önemlidir. Klasik test kuramı çerçevesinde, güvenirlik ve geçerlik kavramları açık bir biçimde kuramsal ve uygulama boyutuyla tanımlanırlar.

Güvenirlik, ölçülmek istenen değişkenin miktarının değişmemesi koşulu altında, tekrarlı yapılan ölçümler sonucu her birinin bir diğeri ile tutarlılık göstermesi durumudur (Zeller, 1988). Teoride, X gözlenen puanlar, T gerçek puanlar ise gözlenen ve gerçek puanlar arasındaki fark puanları, hata puanları E olarak belirlenir ve gözlenen puanlar gerçek ve hata puanlarının toplamından oluşur (1).

$$X = T + E \quad (1)$$

Test puanlarındaki değişkenliği açıklamada kullanılan istatistik, varyanstır. Bu durumda gerçek farklılıklardan oluşan değişkenliğe gerçek varyans (σ_T^2), puanlara karışan hata kaynaklı değişkenliğe hata varyansı (σ_E^2) ve gözlenen puanlardaki değişkenlik ise gözlenen varyans (σ^2) olmak üzere; gözlenen varyans, gerçek ve hata varyansları toplamından oluşmaktadır (2).

$$\sigma^2 = \sigma_T^2 + \sigma_E^2 \quad (2)$$

Güvenirlik kavramı, (2) nolu eşitlik çerçevesinde açıklanacak olursa, gerçek varyansın gözlenen varyansa oranıdır. Toplam varyans içinde gerçek varyansın oranı ne kadar büyük olursa testin güvenilirliği de o derece büyük olur (Cohen, Montague, Nathanson ve Swerdlik, 1988). Cohen ve diğerleri (1988, s:101) hata varyansının kaynaklarını, test geliştirme sürecinde madde seçimi, test uygulama süreci ve test puanlama ve yorumlama süreçlerinden gelen hatalar olarak tanımlamaktadır.

Geçerlik kavramı ise ölçme aracının ölçülmek istenen değişkeni ne kadar isabetli olarak ölçebildiği ile ilgilidir. Aslında daha ayrıntıda bakılacak olursa geçerlik, test puanlarından elde edilen çıkarımların uygunluğuna ilişkin kanıtların bir değerlendirmesidir (Cohen ve diğ., 1988). Temel olarak puanları geçerliği, ölçme sonuçlarının anlamını deneysel olarak değerlendirmedir ve geçerlik çalışması, puanların kullanımını ve yorumlarını doğrulamak ya da yanlışlamak için mantıksal yollarla bilimsel olarak incelemektir (Messick, 1994).

Geçerliğin değerlendirilmesinde, “geçerliğin dört yüzü” olarak da adlandırılan dört farklı kategori vardır (Murphy ve Davidshofer, 2001):

1. Kapsam Geçerliği
2. Yapı Geçerliği
3. Yordama Geçerliği
4. Uyum Geçerliği

Uzun yıllar, farklı geçerlilik türlerinin farklı amaçlar için uygun olduğu düşünülmüştür. Örneğin eğitimde kullanılan testler için kapsam geçerliği, bireysel testler için yordama geçerliğinin uygun olabileceği benimsendi (Murphy ve Davidshofer, 2001). Murphy ve Davidshofer (2001), artık araştırmacıların geçerlik inceleme stratejilerini geniş bir yapı geçerliği başlığı altında gruplandırdıklarını belirtmektedir.

Geçerlik, değerlendirme sonuçlarına getirilen yorumları desteklemek ya da reddetmek üzere sunulan kanıtlara karşılık gelir (Downing, 2003). Geçerliğe her zaman bir hipotez olarak yaklaşılr. Öyleki; ilkin değerlendirmeye yönelik bir hipotez kurulur, veri toplanır ve geçerliğe ilişkin hipotez desteklenir ya da reddedilir. Kanıt olabilecek kaynaklar, ölçümlerle ilgili tüm anlamlandırma ve yorumlamaların gerektirdiği mantıksal bir bakış açısıyla önerilir. Bu geçerlik çalışmaları Messick tarafından 1989'da yapı geçerliği çerçevesi içinde tanımlanır ve Eğitim ve Psikolojide Ölçme Standartları olarak vücut bulur (Downing, 2003).

Amerikan Eğitim Araştırmaları Derneği, Amerikan Psikoloji Derneği ve Eğitimde Ölçme Ulusal Kurulunun yayınladığı Eğitim ve Psikolojide Ölçme Standartları'na göre (1999; akt. Downing, 2003) geçerlik, testin amacına yönelik kullanımın gerektirdiği test puanları yorumlarını destekleyen teori ve kanıtlara ne derece ulaşılabilirdiği bilgisini verir.

Standartlar, beş farklı geçerlik kanıtı olabilecek kaynakları açıklar ve bunlar kapsam, cevaplama dayalı süreç, iç yapı, diğer değişkenlerle ilişki, sonuçların etkisi olmak üzere beş başlık altında toplanır. Downing (2003), bu başlıkların içini başarı testi kapsamında şöyle açıklar:

Kapsama ait kanıtlar

Detaylı sınav planı ana hatları ile belirlenir. Sınavın içeriğinin, ölçülmek istenen başarıya ait değişkenin öğrenme hedefleri ile ilişkisi kurulur. Test planında içeriğin alt kategorileri, soruların bilişsel boyuttaki düzeyleri ve oranı açıkça belirtilir. Test sorularının her bir öğrenme hedefi ile doğrudan ilişkisi gösterilir. Test sorularının kalitesine ilişkin kanıtlar ortaya konur. Bunları da şöyle sıralamak mümkündür: Soru yazarlarının alan uzmanlarından oluşması, soruların kapsamı temsil gücüne sahip olması, test sorularının açıklığı ve anlaşılır olması, yazım kurallarına uygunluğu, soruların kültürel hassasiyetleri açısından gözden geçirilmesi.

Cevaplama süreci

Testin uygulamasından doğacak hata kaynağı olarak sonuçlara etki eden tüm durumların kontrol altına alınması ya da maksimum oranda dışta tutulmasına yönelik çalışmalar, cevaplama sürecine ait geçerlik kanıtı olarak tanımlanabilir. Bu süreç puanlamanın nasıl yapıldığı, değerlendirmelerin nasıl olacağı, puanlamalara yönelik ölçütlerin ne olacağı, sonuçların nasıl, ne zaman raporlanacağı ve nasıl yorumlanması gerektiğine ilişkin tüm detaylı bilgilerin sağlanması ve yönergelerin titizlikle hazırlanıp cevaplayıcılara sunulmasına ait tüm dokümanların hazırlanmasını barındırır. Ayrıca puan anahtarının doğruluğu, zayıf soruların puanlamadan çıkarılması gibi puanlamaya ait kalite kontrolleri ve varsa bileşik puanlamanın mantığı gibi tüm detaylar da bu sürece dahildir.

İç yapı

Madde analizini kapsayan madde güçlük ve ayırd edicilik analizleri, madde karakteristik eğrisi, madde-madde korelasyonları, madde-toplam korelasyonları ve testin güvenilirliği iç yapıya ait önemli bilgiler sunan kanıtlar olarak belirlenir. Özellikle performans dayalı sınavlarda güvenirlüğün özel bir hali olan ve genellenebilirlik teorisinden türetilen güvenirlilik, iç yapıya ait önemli bir kanıt olarak bulundurulmalıdır. Ayrıca, ölçmenin standart hatası, genellenebilirlik, boyutluluk, faktör analizi, yanlılık analizi olarak diferansiyel madde fonksiyonu gibi çalışmalar testin iç yapısına dönük geçerlik kanıtları olarak sunulabilir.

Diğer değişkenlerle ilişki

Bu tür geçerlik kanıtları, test sonuçlarının yapısal özellikleri iyi bilinen ölçümlerle olan ilişkisinin incelendiği kanıtlardır. Aynı özelliğin ölçüldüğü bilinen sonuçlar ya da yapılan değerlendirmeler ile yakınsaklık bilgisi veren ilişkiler ya da farklı ölçümlerle olan ve ırsaklık bilgisi veren ilişkiler, bu kapsamda geçerlik

kanıtı olarak sunulabilir. Ayrıca genellenebilirlik meselesi ve verilerin yorumlanmasına ilişkin sınırlamalarda bu kapsamda toplanabilecek kanıtlardır.

Sonuçların etkisi

Ölçme sonuçlarına göre verilen kararların cevaplayıcılar üzerinde doğuracağı etki ve değerlendirmelerin eğitim-öğretim açısından etkilerinin incelenmesini içeren çalışmalar bu kapsamda yer alır. Test sonuçlarının öğrenciye ya da topluma olan etkisi, gelecek öğrenme yaşantılarına etkisi, olumlu doğurgular ile olumsuz doğurguların belirlenip ağır gelenin tespiti, ölçüt puanının belirlenmesindeki mantık, sınıflama doğruluğu, kesme puanında ölçmenin koşullu standart hatası ve eğitsel sonuçlar açısından inceleme ve analizlerin raporları geçerlik kanıtı olarak sunulabilir.

Geçerlik türlerinden birisi olan yapı geçerliği başarı, yetenek, bireysel ve sosyal gelişimleri ölçmek amacıyla geliştirilen tüm ölçme ve değerlendirme türleri için önemlidir (Miller, Linn ve Gronlund, 2009). Yapı geçerliği, psikolojik bir yapıyı ya da özelliği, ölçme aracının ne derecede ortaya koyabildiği ile ilgilidir (Anastasi, 1988). Araştırmacılar, ölçme aracı ya da içindeki maddelerden daha çok, ölçülmek istenen değişkenin yapısı ile ilgilenir. Ölçme aracının maddeleri ise, yapının değerlendirilmesine dönük bir araçlar takımıdır. Çünkü, değişkene ait yapı doğrudan gözlenemez (De Vellis, 2003).

Yapı denilen kavram, gözlenen durumları organize edebilmenin bir yoludur (Cronbach, 1984). Murphy ve Davidshofer (2001), yapıların iki özelliği olduğunu belirtir. Birincisi yapılar, doğadaki bazı düzenli durumların, soyut olarak ifade edilebilen özetleridir. Diğer özelliği ise, onlar somut, gözlenebilir olaylarla bağlantılıdır. Psikolojik yapıların ölçülmesi de somut ve gözlenebilir davranışları temel alan bir işlemdir. Bu durumda psikolojik ölçme araçları, gözlenebilir davranışlar takımı olarak tanımlanabilir. O halde soyut olan psikolojik yapı ile

gözlenebilir, somut davranışların ilişkisini ortaya koyma durumu, yapı geçerliğini belirlemede temel anahtardır (Murphy ve Davidshofer, 2001).

Bir ölçme aracının yapı geçerliğini incelemek için farklı yöntemler vardır. Bu yöntemler yapı geçerliğine birer kanıt sağlayabilir (Cohenve diğ., 1988):

Homojenlik

Bir ölçme aracının tek bir bağlamda ölçümleri elde edebilme derecesini belirleyen homojenlik, ölçme aracının iç tutarlılığını ifade eder. Ölçek maddeleri ile ölçek puanları arasındaki korelasyonun varlığı, yapının homojen olarak ölçülebilirliğinin bir göstergesi olarak kabul edilebilir.

Yaşa göre değişkenlik

Bazı psikolojik yapıların doğası gereği bireylerde ölçülmek istenen yapının zaman içinde değişime uğraması beklenir. Bir yapıya ait puanların yaşlar büyüdükçe belli bir fonksiyona göre artış göstermesi gibi bir beklenti var ise, ölçme aracı farklı yaş gruplarına ait puanlardaki artışı gösterebilmelidir. Ancak, bu türlü bir kanıt, homojenlikte olduğu gibi, yapının diğer yapılarla ilişkisi hakkında bilgi vermez.

Öntest-sontest

DeneySEL bir bakış açısıyla elde edilen bu kanıt, yapıya ilişkin değişime dayalı deneyim öncesi ve sonrası elde edilen ölçek puanlarının bu değişimi yansıtabilmesi ile ilgilidir. Bu deneyim ölçek puanlarındaki değişimin nedeni olacak şekilde düzenlenmelidir.

Farklı gruplardan elde edilen sonuçlar

Eğer bir ölçme aracı istenen yapıyı geçerli bir biçimde ölçüyor ise, ölçme aracı ölçülmek istenen yapı açısından belirgin olarak farklı olduğu bilinen grupları, ölçüm sonucu üzerinden ayırabilmelidir.

Yakınsaklık

Bu tür bir kanıt eğer o yapıyı ölçen bir ölçme aracı ya da yapıya ilişkin farklı kaynaklar ya da göstergeler mevcut ise ortaya çıkarılabilir. Ölçme aracından elde edilen puanlar, yapıyı ölçtüğü bilinen aracın puanlar ya da göstergeler ile ilişkili olduğu müddetçe yakınsaklık kanıtı elde edilebilir.

İraksaklık

Yakınsaklığın tersine, farklı yapıları ölçtüğü bilinen puan ya da göstergeler ile ölçmek istediğimiz yapıya ait ölçme aracından elde edilen puanlar arasındaki korelasyonun olmaması iraksaklık kanıtı olarak kabul edilir. Birbiri ile ilişkisiz olduğu bilinen bu iki yapı, ölçümler üzerinden de ilişki göstermemelidir.

Faktör Analizi

Veri indirgeme amacıyla kullanılan bu matematiksel işlem ile birbiriyle yakın ilişkide olan maddeler bir araya gelir ve ilgili yapıya ait faktörler ortaya çıkarılır. Yapı geçerliğinin yakınsaklık ve iraksaklık kanıtları, faktör analizi ile elde edilebilir. Bunun için yapı içindeki örtük değişkenler arasında ilişkinin yüksek olmaması iraksaklık, değişkenlerin faktör yüklerinin yüksek olması yakınsaklık açısından geçerlik bilgisi verebilir.

Bir başarı testi ya da bir psikomotor becerinin ölçülmesi için kullanılan aracın ölçülmek isteneni ölçüp ölçmediğine dair kanıt elde etmek daha görgül ve net sonuçlar elde etmek anlamına gelebilir. Guilford (1954), bu durumu başarı testleri için öğrenme hedefleri/kazanımlar temelinde testin geçerliğinin değerlendirilebileceğini, psikomotor bir beceri için, örneğin uçak kullanmayı öğrenen bir bireyin, uçağı ne kadar iyi kullandığına dair performansı, ölçme aracının geçerliğine ilişkin soruyu cevaplama için yeterli bir ölçüt olabileceğini belirtir. Ancak örtük yapıları ölçmek üzere hazırlanan araçların geçerlik çalışmaları bu kadar açık ölçütler bulunmaması nedeni ile bir çok kanıt elde etmek

zorunluluğunu ortaya çıkarır. Ölçme aracındaki maddeler, ölçülmek istenen örtük yapıyı ölçüyor mu? Guilford (1954, s.399) faktör analizini, bu soruyu cevaplandıracak bir kapı olarak nitelendirir.

2.2. 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 teoriyi 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 ortakdır. 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 sayılışı (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).

Faktör analizi ve TBA'ne matematiksel işlem açısından yaklaşılacak olursa, kullanılan analizlerdeki farklılıkların ortaya çıkan boyutlara farklı bir yorum getirdiği görülmektedir.

TBA'nde, gözlenen 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” diğesinde “faktörler” olarak adlandırılır.

TBA Modeli:

$$Y = XB$$

Y: Gözlenen deęişken matrisi

X: Bileşen matrisindeki puanlar

B: Özdeęerler matrisi (aęırlıklar)

Faktör Analizi Modeli:

$$Y = XB + E$$

Y: Gözlenen deęişken matrisi

X: Ortak faktörler matrisi

B: Faktör yükleri matrisi (aęırlıklar)

E: Tek (Unique) faktör matrisi (Hata varyansı)

Faktör analizinde önemli olan, bir yapıya ait olduęu düşünölen her bir deęişkenin faktörlerce açıklanan ortak varyansıdır (communality). Faktörler tarafından açıklanamayan varyans ise hata varyansı olarak adlandırılır. Faktör yükleri, deęişken ile faktörler arasındaki ilişki katsayısıdır. Deęişkenin faktör yüklerinin kareleri toplamı ise deęişkenin faktörlerce açıklanan toplam varyansını yüzde olarak verir (3).

$$d^2 = 1 - \text{faktör yükleri kareleri toplamı} = \text{Bir deęişkenin faktörlerce açıklanamayan deęişkenlięi (\%)} \quad (3)$$

Faktör analizi ve TBA, açıklanan ortak varyansı tahmin etmede birbirinden farklılık gösterirler (Field, 2009). TBA'nde açıklanan toplam varyans, ne kadar büyük olursa, iki analiz sonucunda oluşan bileşenler ve faktörler aynı olacaktır. Temel bileşenler ve faktörlerin eşitlięini etkileyen iki durum vardır (Thompson, 2005). Birincisi, ölçme aracının güvenilirlięi ile ilgilidir. Analiz edilen puanların güvenilirlięi ne kadar yüksek olursa açıklanan ortak varyans da

yükselecek ve %100'e yaklaşacaktır. Çünkü TBA korelasyon matrisindeki diagonal değerlerini '1' olarak kullanır. İkincisi ise ölçme aracındaki değişken sayısı ile ilgilidir. Örneğin 8 değişken bulunan bir korelasyon matrisinde 64 adet değer bulunacaktır. Bu durumda matristeki diagonalın oranı $8/64=12,5$ olacaktır. 100 değişken üzerinden bu oran %1 olacaktır. Değişken sayısı arttıkça toplam açıklanan varyans artacaktır. Böylece faktör analizi, TBA ile aynı sonucu verecektir (Ogasawara, 2000; akt. Thompson, 2005).

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, geometriksel olarak doğrusal kombinasyonlar orjinal eksenlerin döndürülmesi ile yeni bir koordinat sistemini ortaya koyar. Yeni eksenler en yüksek değişkenliğin yönlerini temsil eder (Johnson ve Wichern, 1982).

Rasgele değişkenlerden oluşan vektörün $(\mathbf{x}^t = (x_1, x_2, \dots, x_p))$ kovaryans matrisi (C) özvektör ve özdeğer çiftlerine (e_i, λ_i) sahip olsun. Özdeğerler sıfırdan büyük olmak koşulu ile sıralanır $(\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_p)$. Buna göre cebirsel olarak doğrusal kombinasyonlar kurulur ve temel bileşenler (y_i) oluşturulur (4). \mathbf{x} vektörünün özvektörler ile çarpımından oluşan dönüşümüne, Karhunen–Loève dönüşümü denir (Diamantaras, 2002).

$$\begin{aligned}
 y_1 &= e_{11}^t x_1 + e_{21}^t x_2 + \dots + e_{p1}^t x_p = e_1^t \mathbf{x} \\
 y_2 &= e_{12}^t x_1 + e_{22}^t x_2 + \dots + e_{p2}^t x_p = e_2^t \mathbf{x} \\
 &: \\
 y_p &= e_{1p}^t x_1 + e_{2p}^t x_2 + \dots + e_{pp}^t x_p = e_p^t \mathbf{x}
 \end{aligned}
 \tag{4}$$

Özdeğerler her bir temel bileşenin değişkenliğini gösterir (5) ve her bir temel bileşen bir diğerinden bağımsızdır (6).

$$\lambda_i = \text{var}(y_i) = e_i^t C e_i \quad i = 1, 2, \dots, p \quad (5)$$

$$\text{cov}(y_i, y_k) = e_i^t C e_k = 0 \quad i \neq k \quad (6)$$

Toplam varyansın (7) en büyük kısmını açıklayan k. temel bileşen (8) birinci temel bileşen, ikinci büyük kısmını açıklayan temel bileşen, ikinci temel bileşen olarak tanımlanır ve bu şekilde devam eder. Toplam varyansın büyük kısmının açıklanması durumunda (yaklaşık %80-90 arası), diğer temel bileşenler dışta tutulur ve ağırlıklı toplam varyansı açıklayan temel bileşenler p adet orjinal değişkenin yerine kullanılır (Johnson ve Wichern, 1982). Kaiser (1960; akt. Field, 2009), özdeğeri 1'den büyük olanların temel bileşen olarak tanımlanmasını önerir.

$$\sigma_{11} + \sigma_{22} + \dots + \sigma_{pp} = \sum_{i=1}^p \text{var}(x_i) = \lambda_1 + \lambda_2 + \dots + \lambda_p = \sum_{i=1}^p \text{var}(y_i) \quad (7)$$

k. temel bileşenin


$$\text{toplam varyansa oranı} = \frac{\lambda_k}{\lambda_1 + \lambda_2 + \dots + \lambda_p} \quad k = 1, 2, \dots, p \quad (8)$$

Faktör döndürme işlemi, TBA ile bileşenlerin ortaya çıkarılmasından sonra yapılır. Döndürme işlemi yapılmasındaki amaç, faktörler tarafından yapının daha iyi yorumlanabilmesi sağlayabilmektir. Faktör yada 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 biri kullanılarak ortaya çıkan yapılar anlamlandırılabilir. Bunlardan birisi dik döndürme, diğeri eğik döndürmedir.

Dik döndürme faktörler arası bağımsızlık ilişkisini koruyarak, geometriksel ifade ile, eksenler arası 90 derecelik açıyı ile yapılan döndürmedir (Şekil 1). Dik döndürmede genel olarak üç farklı teknik kullanılabilir.

Varimax tekniğinin amacı, faktör yüklerin belirginleştirmektir. Bu döndürme tekniği, bir faktörün tüm değişkenler üzerindeki yüklerin varyansını maksimize eder. Bu durumda bir faktörün değişkenler üzerinde olan yükü, yüksek olanlarda daha çok artarken, düşük olanlar da daha düşük hale gelir. Böylece faktörler daha belirginleşir. Böylece yapılar basitleşerek, daha açık hale gelir ve yorumlanması daha kolay olur (Tabachnick ve Fidell, 2001).


Quartimax tekniği ise varimax tekniğinin faktörler üzerine yaptığını, değişkenler için yapar. Bir değişkenin faktörlere olan yüklerindeki dağılımını maksimize eder. Bu durumda değişkenler basitleştirilmiş olur. Ancak çalışmalarda varimax tekniği daha çok tercih edilir. Çünkü, genelde faktörlerin belirgin hale gelmesi amaçlanır. Bir de Equamax tekniğinden bahsedilir. Bu teknik önceki iki tekniğin bir karışımı denilebilir; hem faktör hem de değişkenleri basitleştirme birarada bu teknikte kullanılır (Tabachnick ve Fidell, 2001).



Şekil 1. Dik Döndürme Yönteminin Geometrik Gösterimi

Faktörler arası korelasyonun manidar olduğu durumlarda eğik döndürme tercih edilir (Şekil 2). Bu döndürme yönteminde artık eksenler arasındaki açı 90 derece değildir ve yine özellikle psikolojik yapılara ait faktörlerin birbiri ile ilişkisi olduğu durumlarda kullanılabilir. Bu yöntem için kullanımda olan iki teknik

mevcuttur. Direkt Oblimin tekniđi, faktörler arası korelasyonun miktarının ne kadar olduđuna bađlı olarak seğıilmelidir. Bunu belirleyen delta deđeridir. Delta deđerı (SPSS için), 0'dan büyük deđilse -ki büyük olması faktörler arası korelasyonun çok büyük olması durumunda ortaya çıkar- direkt oblmin kullanılabilir. Diđer teknik olan Promax, çok büyük veri setleri için tasarlanmış hızlı iřlem yapan bir tekniktir (Field, 2009).



řekil 2. Eđiđ Döndürme Yönteminin Geometrik Gösterimi

Veri indirgeme amacıyla kullanılan tekniklerden TBA'nin kullanımı için bazı sayıtların karşılanması gerekir. Field (2009), bu sayıtları řu şekilde açıklar:

- Deđiřkenin sürekli olması (deđilse tetrakorik korelasyon matrisi oluşturulmalıdır)
- Doğrusal iliřki üzerine kurulması
- Deđiřkenin normal dađılım göstermesi (sonuçların genellenebilmesi için gereklidir)

Bunun dıřında, analizin kendi içinde bazı kořullarının yerine getirilmiř olması gerekir (Field, 2009).

- Determinant testi: Değişkenlerin çoklu bağlantı (multicollinearity) göstermemesi beklenir. Bu test, aralarında çok yüksek korelasyonlu değişkenlerin bulunup bulunmadığını test eder.
- KMO: Güvenilir faktörler için örnek büyüklüğünü test eder.
- Barlet testi: Değişkenler arasında ilişkisizlik istenmeyen bir durumdur. Bu test, değişkenler arası korelasyonun çok düşük olup olmadığını test eder.

Genelde istatistiksel analiz yöntemlerinin bazı kullanım koşulları vardır. Bu koşullar sağlandığı takdirde parametrik denilen analiz yöntemleri kullanılabilir. TBA ve faktör analizi de bir parametrik yöntemdir.

Sonuç olarak her iki yöntemin benzerlikleri ve ortak amaçları olmakla birlikte işlemsel ve yorumlama boyutunda bazı farklılıkları vardır. Sosyal ve psikolojik kavramların ölçümünde kullanılan faktör analizinde eğer faktör ve gözlenen değişkenler arasında yüksek ilişki varsa, bu değişkenler arasında da yüksek ilişki gözlenir. Diyelimki, faktör ve iki değişken arasında yüksek ilişki olsun ve bir üçüncü değişken ile düşük ilişki gösterebilir. Bu aynı zamanda faktörle yüksek ilişki gösteren iki değişkenin kendi aralarında yüksek ilişki, diğer değişkenle aralarında düşük ilişki bulunması demektir. Bir başka deyişle faktör analizi, gözlenen değişkenler sayesinde faktör tahmini yapma işlemidir ve bu tahmin, gözlenen değişkenlerin doğrusal kombinasyonları üzerinden yapılır (Francis, 2001). TBA de bu açıdan aynı özelliklere sahiptir. Korelasyon matrisinin çözümlenmesi ile, bir çok değişkenden daha az sayıda bileşenlere indirgeme işlemi yapılır. Ancak TBA’nde ortaya çıkan bileşenler arası ilişki nedensel bir ilişki değildir (Francis, 2001). Bu nedenden ötürü ortaya çıkan yapılardan birine “faktör” diğerine “bileşen” adı verildiği söylenebilir.


2.3. Yapay Sinir Ağları

Yapay sinir ağları 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 dağıtımlı 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, akt. Neural Network Fundamentals, t.y.).



Şekil 3. Biyolojik Sinir Ağı Yapısı

Şekil 3'te görülen sinir ağı yapısı ve elemanlarının görevleri şunlardır (Neural Network Fundamentals, t.y.):

Dentrit

Görevi diğer sinir hücrelerinden iletilen sinyalleri, sinir hücresinin çekirdeğine iletmektir. Bu yapı basit gibi görünse de, günümüzde dentritlerin görevlerinin daha karmaşık olduğu yolundaki düşünceler yaygınlık kazanmıştır. Hücrenin çekirdeği ile her bir dentrit arasında farklı bir iletişim söz konusudur. Bu sebeple bazı dentritlerin etkileşimde ağırlıklı pay sahibi, diğerlerinin de pasif olduğu düşünülmektedir. Bu ise, dışarıdan alınan sinyallerde seçicilik gibi önemli bir olgunun sinir hücresi tarafından gerçekleştirildiği anlamını taşımaktadır.

Soma

Dentritler yoluyla iletilen tüm sinyalleri alıp toplayan merkezdir ve biyolojik olarak hücre çekirdeğini bünyesinde barındırır. Çekirdek gelen

toplam sinyali değerlendirerek, diğer sinir hücrelerine göndermek üzere bilgiyi aksona iletir.

Akson

Hücre çekirdeğinden aldığı toplam bilgiyi bir sonraki sinir hücresine dağıtmakla görevlidir. Ancak akson, bu toplam sinyalin ön işlemden geçirilmeden diğer sinir hücresine aktarılmasına engel olur. Çünkü akson bilgiyi, ucunda yer alan ve sinaps denilen birimlere aktarır.

Sinaps


Aksondan gelen toplam bilgiyi ön işlemden geçirdikten sonra diğer sinir hücrelerinin dentritlerine iletmekle görevlidir. Sinapsın ön işlemle gerçekleştirdiği görev oldukça önemlidir. Bu ön işlem gelen toplam sinyalin, belli bir eşik değerine göre değiştirilmesinden ibarettir. Böylece toplam sinyal olduğu gibi değil, belli bir aralığa indirgenerek diğer sinir hücrelerine iletilmiş olur. Bu açıdan, her gelen toplam sinyal ile dentrite iletilen sinyal arasında bir korelasyon (ilişki) kurulur. Buradan yola çıkarak “öğrenme” işleminin sinapslarda gerçekleştiği fikri ortaya atılmış ve bu hipotez, günümüz yapay sinir ağı dünyası için teori haline dönüşmüştür. Yapay sinir ağı modelleri üzerinde “öğrenme”, bu teoriye dayanılarak, sinapslar ve dentritler arasında yer alan ağırlık katsayılarının güncellenmesi olarak tanımlanmaktadır.

Yapay sinir ağı, McCulloch ve Pitts (1943 akt. 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 Ağlıkları
Dentrit	Toplama Fonksiyonu
Akson	İşlemci Eleman Çıkışı

McCulloch-Pitts modeli incelendiğinde (Şekil 4), 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 ihtimal arasından seçerek oluşturmaktadır.



Şekil 4. Yapay Sinir Ağı Yapısı

Yapay hücre modelindeki ağırlıklandırılmış girdiler (9) ve yanlılık değeri (10), eklenerek toplam girdi değeri (11) aktivasyon fonksiyonundan geçerek ağın çıktısını belirler (12).

$$u_k = \sum_{j=1}^n x_j w_{kj} \quad (9)$$

$$b_k = x_0 w_0 \quad (10)$$

$$v_k = u_k + b_k \quad (11)$$

$$y_k = \varphi(v_k) \quad (12)$$

x_j : Girdi nöronu

w_{kj} =: j girdi nöronundan k neronuna giden bağlantı ağırlığı (+ ya da - olabilir)

b_k : Yanlılık

x_0 : Yanlılık girdisi 1 değerini alır.

w_0 : Yanlılık girdisinin bağlantı ağırlığı

$\varphi(v_k)$: v girdisini çıktıya dönüştüren aktivasyon fonksiyonu

y_k : k nöronunun çıktı değeri

2.3.1. Aktivasyon Fonksiyonları

Aktivasyon fonksiyonları, ağırlıklandırılmış girdiler toplamını, belirli bir nöron için seçilmiş, bir işleme fonksiyonudur. Bu işlemi sağlayan ve McCulloch-Pitts arafından önerilen birim adım fonksiyonu, sinyal (signal) fonksiyonudur (Sengupta, 2009). Aktivasyon fonksiyonları adım fonksiyonları, doğrusal fonksiyonlar ya da doğrusal olmayan fonksiyonlardan oluşabilir. Adım fonksiyonlarından sinyal ya da eşik fonksiyonu sıkça kullanılan fonksiyonlardır. Bu fonksiyonlar kullanıldığında, k nörona gelen girdi değeri (v_k) bir eşik ile karşılaşır, eğer eşik değerini aşarsa (\geq) beklenen değeri alır; değilse farklı bir değer alır. Bu tür aktivasyon fonksiyonu kullanan yapay sinir ağları, yapay sinir algılayıcı (artificial neuron perceptron) olarak adlandırılır. Algılayıcı (perceptron), sinir hücresinin basit bir modelidir (Kumar, Kumawat, Marwal ve Singh, 2013). Doğrusal dönüştürme fonksiyonları, basit olarak ağırlıklandırılmış girdilerin toplamına, yanlılık (biased) değerinin (b_k) eklenmesi ile oluşan bir fonksiyondur. Matematiksel olarak b_k , doğrunun y eksenini ile yaptığı kesişimin değerini verir.

Krenker, Bestır 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. Bu matematiksel modellerin grafik gösterimi ve diğer doğrusal olmayan fonksiyonları Ek 1'de verilmiştir.

2.3.2. Yapay Sinir Ağı Gelişiminde Kilometre Taşları

Yapay sinir ağları alanında gelişmeler 1943 yılında başlamış ve günümüzde gelişimini yeni teoriler ve alt sınıflandırmalar üzerinden devam ettirmektedir. Aşağıda kronolojik olarak alandaki önemli gelişmelere kısaca yer verilmiştir (Yegnanarayana, 1999):

- 1943 yılında McCulloch ve Pitts tarafından ortaya atılan ve girdilerin ağırlıklı toplamlarının mantıksal işlemlerini içeren yapay sinir ağları modeli önerilmiştir.
- 1949'da Donald Hebb yapay sinir ağları modelinin içine bir öğrenme kuralı yerleştirerek modeli bir ileri aşamaya taşır.
- 1954'de Marvin Minsky, bağlantıların kuvvetlerini (ağırlıklarını) otomatik olarak uyumlayabilen bir öğrenme makinesi geliştirir.
- 1958'de ise Rosenblatt algılayıcı bir model ortaya koyar. Amaç ayarlanabilir bir ağırlıklandırma ile sınıflandırma problemlerinde kullanılabilen bir öğrenme kuralı oluşturmaktır. Ancak tek katmanlı algılayıcı model, sadece doğrusal sınıflandırmalara uygundur.
- 1960'da Widrow tarafından girdileri oluşturan elemanları hesaplama modeli olarak ADALINE modeli geliştirilir. Öğrenme kuralı olarak en

küçük ortalama kareler (Least Mean Square) ya da delta kuralı önerilir. Ancak bu algoritma sadece uyumlu sinyal işleme durumları için başarılıdır.

- 1982 ve 1984 yıllarında Hopfield, girdi ve çıktıların kararlı denkliği yaklaşımı ile geri beslemeli sinir ağları analizini geliştirir.
- 1986'da Rumelhart, Hinton ve Williams, Hopfield'ın geliştirdiği algoritmaya alternatif olarak, çok katmanlı ileri beslemeli sinir ağı modelini geliştirir. Kullanılan öğrenme modeli ise genellenmiş delta kuralıdır.
- Daha sonraki kayda değer çalışmalar ise Boltzman makinesi, Yarışmacı Öğrenme Modeli, (Competitive Learning Model), Uyumlayıcı Rezonans Kuramı (Adaptive Resonance Theory) başlıkları altında yer alır. Son çalışmalar ise konuşma, görüntü işleme (image processing), anadil işleme (natural language processing) ve karar verme gibi problemlere açıklık getirebilecek düzeyde sinir ağları kapasitesini geliştirmede kullanılan bulanık mantık kavramlarıdır (fuzzy logic concepts).

2.3.3. 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 alanındaki teknolojik gelişmelerde önemli rol oynamaktadır. Savunma sanayiindeki radar ve sonar cihazları, mayın dedektörleri, haberleşme alanındaki gürültü filitreleme, 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. Geliştirilen ağ modelleri şu işlevleri yerine getirmede başarı göstermektedir (Öztemel, 2003 akt: 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

2.3.4. Yapay Sinir Ağlarının Topolojisi

Yapay sinir ağlarının topolojisi, nöronlar arasındaki bağlantının şeklini ifade eder. Yapay sinir ağları için iki genel topoloji bulunmaktadır (Gülseçen, 1993, akt: Baş, 2006): İleri beslemeli ağlar (feedforward networks) ve geri beslemeli ağlar (feedback networks) ya da yinelemeli (recurrent) ağlar.

İleri beslemeli Ağlar

Sinyallerin, girdiden çıktıya doğru, tek bir yönde ilerlemesini sağlayan ağ yapısına ileri beslemeli ağ denir. Bir katmandaki her nöron bir sonraki katmandaki tüm elemanlarla bağlantılıdır. Ancak, aynı katmandaki elemanlar arasında bir bağlantı bulunmamaktadır (Şekil 5). Bu nedenle ileri beslemeli yapay sinir ağlarında nöronlar arasındaki bağlantılar bir döngü oluşturmamakta ve bu ağlar girilen verilerden hızlı bir şekilde çıktı üretebilmektedir. Desen / örüntü tanıma, sinyal işleme ve sınıflandırma gibi problemlerde genellikle bu topoloji kullanılır (Baş, 2006).




Girdi katmanı *Çıktı katmanı*

Şekil 5. Tek Katmanlı İleri Beslemeli Yapay Sinir Ağı

Geri beslemeli Ağlar

Geri beslemeli yapay sinir ağlarında, en az bir nöron çıktısı kendisine ya da diğer nöronlara girdi olarak verilmekte ve genellikle geri besleme bir geciktirme elemanı (ara katman veya çıktı katmanındaki aktivasyon değerlerini bir sonraki iterasyona girdi olarak taşımakla görevli eleman) üzerinden yapılmaktadır (Şekil 6). Geri besleme bir katmandaki nöronlar arasında olduğu gibi katmanlar arasındaki nöronlar arasında da olabilmektedir. Bu yapısı sayesinde geri beslemeli yapay sinir ağları, doğrusal olmayan dinamik bir yapı gösterirler. Böylece, geri

beslemenin yapılış şekline göre farklı yapı ve davranışta geri beslemeli yapay sinir ağları elde edilebilir (Saraç, 2004. akt: Baş, 2006).



Girdi katmanı *çıkıktı katmanı*

Şekil 6. Tek Katmanlı Geri Beslemeli Yapay Sinir Ağı

2.3.5. Yapay Sinir Ağlarının Öğrenme Yöntemleri

Yapay sinir ağlarının öğrenme yöntemlerine göre üç sınıfta incelenir. Bunlar denetimli, denetimsiz ve pekiştirmeli öğrenme yöntemleridir.

Denetimli Öğrenme

Bu öğrenme yönteminde öğrenmeye dışarıdan müdahale eden bir öğretmen, danışman vardır. Öğrenme danışmanın kontrolündedir. Denetçi, eğitim kümesini ve hata değerini belirleyerek eğitimin ne kadar devam edeceğine karar verir. Bu yöntemin en önemli özelliği eğitim esnasında gerçek giriş ve çıkış değerlerinin kullanılmasıdır (Şen, 2004).

Denetimli öğrenmeyi bir örnekle açıklamak gerekirse; insanı tarif ederken su özellikler dikkate alınsın: boy, kilo, saç rengi, ayakkabı numarası. Bu ölçütlere göre bir öğrencinin futbol oynayabilir ya da oynayamaz şeklinde ayrımı yapılmak istensin. Bir denetçinin verdiği bilgiler ışığında her öğrenciye “oynayabilir”, “oynayamaz” bilgisi atansın. Eger yapay sinir ağı, 100 kişilik böyle bir grubu

öğrenseydi ve ardından 100 kişinin içinden herhangi biri yapay sinir ağına boyu, kilosunu, saç rengi, ayakkabı numarası verilerek sorulsaydı, yapay sinir ağı, öğrencinin oynayıp oynayamayacağını cevabını verecekti. Çünkü yapay sinir ağı her bir özellik için (boy, kilo vs.) ağırlık güncellemesini yapacak ve danışmanın gösterdiği her öğrenci ve ona iliştilirilen karar arasındaki korelasyonu “w” ağırlıkları üzerinde güncelleyerek öğrenecekti (Neural Network Fundamentals, t.y.). Bu tür ağlar, istatistiksel yöntemlerden regresyon ve lojistik regresyonla benzerlik gösterir (Francis, 2001).

Denetimsiz Öğrenme

Denetimsiz öğrenme yöntemi ise, yapay sinir ağlarında sürekli araştırılan ve gelişen bir öğrenme yöntemidir. Bu yöntem, gelecekte bilgisayarların insan yardımı olmadan öğrenebileceklerinin göstergesidir. Ancak günümüzde sınırlı kullanım alanları bulan ve hala yoğun araştırma konusu olan bir öğrenme yöntemidir (Anderson ve McNeill, 1992, akt: Baş, 2006). Denetimsiz öğrenme kullanan ağlar, veri indirgeme ve özellikleri ortaya çıkarmada TBA görevini yapan ve sınıflandırma görevi yapan ağlar için önemli bir öğrenme yöntemidir (Becker, 1991).

Denetimsiz öğrenmede sadece girdi katmanındaki değerler kullanılmaktadır; çıktı ya da beklenen değere ilişkin bir bilgi yoktur (Fritzke, 1995). Amaç, veri setindeki modelin ortaya çıkarılmasıdır. Sistemin çıktısı değerlendirecek, önceden belirlenmiş ya da bilinen bir ölçütü yoktur ancak girişlere göre kendi kendisini örnekler. Denetimsiz olarak eğitilebilen ağlar, istenen ya da hedef çıkış olmadan giriş bilgilerinin özelliklerine göre ağırlık değerlerini ayarlar. Burada ağ istenen dış verilerle değil, girilen bilgilerle çalışır. Bu tür öğrenmede saklı nöronlar dışarıdan yardım almaksızın kendilerini örgütlemek için bir yol bulmalıdır (Tolon ve Tozunoğlu, 2012).

Denetimsiz öğrenme, bir örnekle açıklanacak olursa; 100 kişilik bir sınıfın boy, kilo, saç rengi ve ayakkabı numarası yine girdi örüntülerinin değerlerini oluştursun. Yapay sinir ağı ilk gelen kişiyi bir sınıf olarak ilan edecek ve ardından sisteme beslenen tüm girdileri ilk örneğe benziyor ya da benzemiyor diye ayırt edecektir. Bu ayrımı yapabilmesi için 100 kişilik grubun değerleri 1000 kere sisteme tekrar tekrar beslendiği takdirde, yapay sinir ağı en sonunda öğrenmesini tamamlayacak ve 2 sınıflandırma öğrenmiş olacaktır. 1. girdiyi benzeyenler ve benzemeyenler. Adını koyamadığı bu sınıflar yardımıyla “hanımlar” ve “beyler” gibi bir sınıflandırma başarıyla öğrenilmiş olacaktır. Böyle bir ağ modeline yabancı bir kişinin değerleri verilirse, sinir ağı bu kişinin gerçekteki cinsiyetini söyleyecektir (Neural Network Fundamentals, t.y.). Bu tür ağlar, klasik istatistikte kümeleme analizine benzemektedir (Francis, 2001).

Pekiştirmeli Öğrenme

Gerçek bir yaşamda iş ya da görev, aralıklı pekiştireç kullanılarak öğrenilir (Stanley ve Miikkulainen 2002). Doyum ya da sıkıntı ne kadar büyük olursa, bağın kuvvetlenmesi ya da zayıflaması da o derecede olur (Thorndike, 1911 akt: Sutton ve Barto, 2000). Sutton ve Barto (2000), pekiştireçli durumlara dayalı uygun tepkiyi öğrenme fikrini, kökenini Thorndike'ın "Etki Yasası" gibi ilk psikolojik kuramlardan aldığını belirtir. Pekiştirmeli öğrenme algoritması, bu fikri yapay sinir ağlarına taşıyarak, ödül tabanlı bir eylem ya da çıktı yaratan değer fonksiyonu araştırmasına göre algoritma tasarlar. Pekiştirmeli öğrenme, sayısal bir ödül niteliğinde, sinyali büyütme için hangi durumda hangi tepkinin yapılacağını ağın öğrenmesidir (Sutton ve Barto, 2000).

Sutton ve Barto bu tarz öğrenme yöntemlerinde asıl meselenin, mevcut durumda ödül üreten davranışları belirleyebilecek bir değer fonksiyonu ile, en iyi ödüle götüren keşfedici davranışları belirleyen fonksiyon arasında en uygun seçimi yapabilmek olduğunu belirtir (Gallistel, 1999). Basit bir pekiştirmeli

öğrenme görevinin en büyük ödülle yerine getirilmesini sağlamak için durum-eylem çiftlerinden uygun olanını çeşitli fonksiyonların davranışlarını inceleyerek belirler. Değer fonksiyonları, farklı durumlar için daha önceden öğrendiği ödül getiren fonksiyonlardır. Bu fonksiyonlar, durum-eylem çiftlerinin belirli bir durum için ne derecede yararlı olabileceğini tahmin eden fonksiyonlardır (Yenikaya, 2006).

2.3.6. Yapay Sinir Ağlarının Mimari Yapısı

Yapay sinir ağlarının bir diğer açıdan sınıflaması ise mimari yapısıdır. Mimari yapısına göre ağlar tek katmanlı ve çok katmanlı olmak üzere iki grupta incelenir.

Tek Katmanlı Algılayıcılar

Tek giriş katmanı ve tek çıkış katmanı olan ağ yapıları, tek katmanlı algılayıcı olarak adlandırılır. Tek katmanlı yapılarda ağ topolojisi ileri beslemelidir (Chakraborty, 2010).

Tek nöronlu modelin yeterli olmadığı durumda, birden çok nöronun paralel olarak kullanıldığı farklı bir ağ mimarisi oluşturulur. Paralel nöronların bulunduğu kısma *katman* denilir.


R adet input ($p_{R \times 1}$) katmandaki her bir nörona farklı ağırlıklarla bağlantı kurabilir. Böylece S adet paralel nöron için ağırlık matrisi (W), $S \times R$ boyutlarında olur. Yine her bir nörona net girdi ile birlikte yanlılık değeri eklenir ($b_{S \times 1}$).

Tek katmanlı bir yapay sinir ağının çıktısı yine $S \times 1$ boyutunda bir vektör olacaktır. Tek bir katman olmasına rağmen, katmandaki her bir nöronun farklı transfer fonksiyonuna sahip olabilmesi mümkündür (Hagan ve diğ., 1996, s.2-9):

$$a=f(Wp+b) \text{ ya da } \begin{bmatrix} a_{11} \\ a_{21} \\ \vdots \\ a_{S1} \end{bmatrix} = f \left(\begin{bmatrix} w_{11} & \dots & w_{1R} \\ w_{21} & \dots & w_{2R} \\ \vdots & \ddots & \vdots \\ w_{S1} & \dots & w_{SR} \end{bmatrix} \begin{bmatrix} p_{11} \\ p_{21} \\ \vdots \\ p_{R1} \end{bmatrix} + \begin{bmatrix} b_{11} \\ b_{21} \\ \vdots \\ b_{S1} \end{bmatrix} \right) \quad (13)$$

Tek katmanlı algılayıcılar sınıflandırma problemlerinin çözümünde kullanılırlar. Bunun için kullanılan aktivasyon fonksiyonu adım fonksiyonudur (sinyal, eşik fonksiyonları). Eğer iki boyutlu girdi uzayında girdiler bir doğru ile iki sınıfa ayrılabilirse tek katmanlı algılayıcılar bu tür problemleri çözmek için yeterlidir (Takçı, 2010). Örneğin bir girdi vektörü sisteme sunulur. Net girdi ağırlıklandırılarak hesaplanır. Eğer net girdi eşik değerinden (q) büyükse nöron açıktır (1 değerini alır); değilse kapalıdır (0 değerini alarak farklı sınıf oluşturur). Elde edilen sonuç, girdi vektörünün gerçek sınıflandırmadaki yeri ile karşılaştırılır. Eğer girdi vektörü ağ tarafından doğru sınıflandırılmış ise ağırlıklıklarda herhangi bir değişiklik yapılmaz. Ancak gerçekte 0 sınıflamasına ait olan bir girdi için nöronun kapanıp 0 olarak çıktı vermesi gerekirken, açık ve 1 değeri verirse ağırlıklar ve eşik değerleri yeniden düzenlenir. Eşik değeri 1'e doğru yükseltilir (Pdp Handbook, t.v.).

Tek katmanlı algılayıcılar doğrusal sınıflandırmalarda başarılı iken doğrusal olmayan sınıflandırmalarda yetersiz kalmaktadır. Örneğin *VEYA (OR)* ve *VE (AND)* fonksiyonları doğrusal sınıflama yapabilirken *VE/VEYA (XOR)* fonksiyonu tek katmanlı algılayıcılar tarafından çözüme götürücü bir fonksiyon değildir. Bu durum Şekil 7'de, iki adet girdisi ve bir çıktısı olan basit bir ağıın iki boyutlu uzayda OR, AND ve XOR fonksiyonlarının geometrik gösteriminde de görülebilmektedir (Pdp Handbook, t.v.).



Şekil 7. İki Girdili Tek Katmanlı Algılayıcıların Geometrik Gösterimi

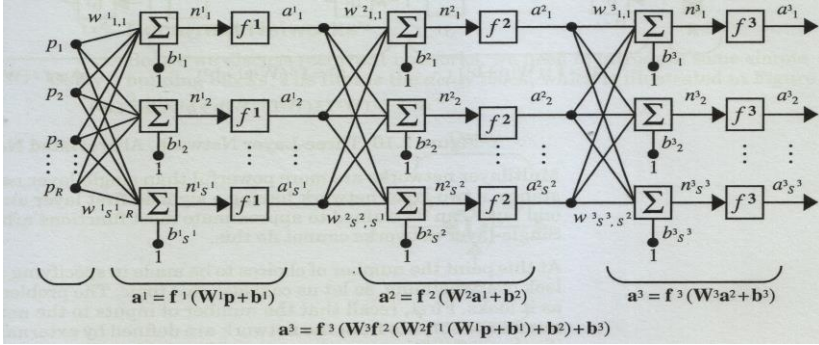
Çok Katmanlı Algılayıcılar

Tek katmanlı ağlardaki girdi ve çıktı katmanından başka, bir ya da daha fazla sayıda saklı katman içeren ağlara çok katmanlı algılayıcılar denir (Chakraborty, 2010). Şekil 8'de tipik üç katmanlı bir ağ yapısı görülmektedir.

Çok katmanlı nöronların her bir katmanının kendine ait ağırlık matrisi, yanlılık değeri, net girdi ve çıktı vektörleri vardır. Her bir katmanın çıktı vektörü bir sonraki katmanın girdi vektörüdür. Başlangıç girdi vektörü ile son çıktı vektörü arasında kalan katmanlara gizli katman denir. Gizli katmanların sayısı bir ya da daha fazla olabilir. Her bir katmandaki nöron sayısı farklı olabileceği gibi katmanlardaki transfer fonksiyonları da birbirinden farklı olabilir. Bu özelliğinden dolayı çok katmanlı yapay sinir ağları tek katmanlı ağa göre daha güçlüdür (Hagan ve diğ., 1996). Çok katmanlı algılayıcılarda kullanılan geri yayımlı öğrenme yöntemi, doğrusal olmayan sınıflamaları yapamayan tek katmanlı algılayıcıların çözemediği problemleri çözebilmektedir (Fritzke, 1995; Sengupta, 2006; Takçı, 2010).

Çok katmanlı algılayıcılar, ileri beslemeli bir ağdır. Sinyallerin, girdiden çıktıya doğru, tek bir yönde ilerlemesini sağlayan ağ yapısına ileri beslemeli ağ

denir (Baş, 2006). Çok katmanlı algılayıcılar, aynı zamanda denetimli ya da denetimsiz öğrenme yöntemi kullanır.



Şekil 8. Çok Katmanlı Nöronların Ağ Mimarisi

K katmanlı ileri beslemeli bir ağda, bir giriş katmanı, $K-1$ adet saklı katman ve bir çıktı katmanı bulunur. Bu katmanlar birbirlerine her biri belirli bir ağırlık derecesiyle bağlanır. Ancak aynı katman içindeki nöronlar arasında bir bağlantı bulunmadığı gibi katmanlar arası geri beslemeli ağlar da bulunmaz. Her bir nöron, eşik fonksiyonu ya da sigmoid fonksiyonu kullanır. Ağırlıkların belirlenmesinde geri yayımlı (back propagation) öğrenme algoritmasının gelişimi ile bu tip ağlar yaygın kullanılmaya başlanmıştır (Jain, Mao ve Mohiuddin, 1996).

Örneğin w_{ij}^k , $(K-1)$ katmanındaki i . nöronu ile K . katmandaki j . işlemci arasındaki bağlantının ağırlığı ve $[(x^1, d^1), (x^2, d^2), \dots, (x^p, d^p)]$ ise p adet eğitim örneği (girdi-çıkı çifti) olsun. Bu durumda $x^i \in R^l$ ise girdi vektörünü l boyutlu örnek uzayda $d \in [0,1]^n$ n boyutlu bir hiperküp olur. Yapılan sınıflandırma sonucu n adet küme oluşur. Hata maliyet fonksiyonu (E), bölüm 2.3.7'de formül 15'te de tanımlandığı gibi, formül 14 ile hesaplanır. Böylece geri yayımlı algoritma, eğitim düşümü (gradient descent) yöntemi kullanarak hatayı azaltacaktır (Fritzke, 1995; Jain ve diğerleri, 1996; Sengupta, 2006).

Her bir iterasyonla geçirdiği öğrenme sürecinde, çevresi hakkında daha çok bilgi sahibi olur. Ancak öğrenmenin tanımı bakış açılarına göre değiştiği için tek tip bir öğrenme tanımında uzlaşılammıştır. Öğrenme süreci şu basamaklardan oluşur (Haykin, 1999):

1. Yapay sinir ağları çevre tarafından uyarılır.
2. Çevresinden gelen bu uyarımlar nedeniyle, kendi serbest parametrelerindeki değişmelere maruz kalır.
3. İç yapısında oluşan değişimler yüzünden çevresine farklı bir yolla tepki verir.

Öğrenme probleminin çözümüne ilişkin tanımlanmış kurallara öğrenme algoritması denir (Haykin, 1999). Her bir öğrenme algoritması kendi avantajlarını içinde barındırır.

Burada dört temel öğrenme kuralından bahsedilecektir.

Hata Düzeltimi Öğrenme Kuralı (Error-Correction Learning)

Hata Düzeltimi Öğrenme Kuralı, ilk geliştirilen öğrenme kuralıdır. Bu öğrenme sürecinde amaç, gerçek çıktı (ağ çıktısı) ile beklenen çıktı arasındaki fark ile oluşan hatanın her bir iterasyonda (iterasyon sayısı= p) girdi ağırlıklarının yeniden düzenleyerek azaltmak ve gerçek çıktıyı beklenen (hedef) çıktıya doğru yaklaştırmaktır. Dolayısıyla amaç, maliyet fonksiyonu olarak adlandırılan E fonksiyonunu (15) azaltmaktır (Haykin,1999).

$$e_k = d_k - y_k$$

e_k : k nörondan çıkan hata miktarı

d_k : k nörondan çıkması beklenen değer

$$E(p) = 1/2 e_k^2(p) \quad (15)$$

Nöron k için ağırlık ayarlaması süreci, ağırlıklardaki azalma ve nihayetinde sabit kalması sonucunda iterasyon durdurularak tamamlanır. Bu yöntemin adı 1960'da Widrow ve Hoff tarafından ortaya atıldığı için Widrow – Hoff kuralı ya da delta kuralı denir (Haykin,1999). Delta öğrenme kuralında hata ölçümlerini azaltmak için kullanılan yöntem, an az ortalama kareler (LMS-Least Mean Square) yöntemidir. LMS yöntemi maliyet fonksiyonunu azaltan tüm ağırlık değerlerini, eğim düşümü (gradient descent) kullanarak hesaplar (McClland ve Rumelhard, 1987).

Eğer yalnızca k=0 nöronundan elde edilen hatayı tek bir gözlem için hesaplamak gerekirse düzeltme değeri için kullanılacak hata miktarı toplam hata E 'nin w_{0j} 'ye göre türevi alınarak bulunan eğim derecesi (gradient), formül 16 ile hesaplanır:

$$\frac{\partial E}{\partial w_{0j}} = \frac{\partial E}{\partial y_0} \frac{\partial y_0}{\partial w_{0j}}$$

$$\frac{\partial E}{\partial y_0} = -(d_0 - y_0)$$

$$\frac{\partial y_0}{\partial w_{0j}} = x_j$$

$$\frac{\partial E}{\partial w_{0j}} = -(d_0 - y_0)x_j \quad (16)$$

Düzeltilme formülü (17), eğim derecesi ile öğrenme hızı η ile çarpılarak elde edilir. Öğrenme hızı eğitimin ne kadar süratle yapılacağını belirleyen bir değerdir.

$$\Delta w_{0j} = \eta(d_0 - y_0)x_j \quad (17)$$

Düzeltilme değeri bir önceki ağırlığa eklenerek yeni ağırlık değerini (18) oluşturur.

$$w_{0j}(t) = w_{0j}(t - 1) + \Delta w_{0j} \quad (18)$$

Geniřletilmiş delta kuralı olarak bilinen geri yayılımlı öğrenme kuralı, hemen hemen her tür probleme uygulanabilir bir yapıyı oluşturur. Yapay sinir ağının yapısı ileri beslemeli olsa da hatanın aynı ağırlıklardan, ağırlıkları oranında, geriye doğru indirgenmesi söz konusudur. Dolayısıyla denetimli öğrenme söz konusudur. Delta kuralında olduđu gibi bu indirgeme aktivasyon fonksiyonunun türevi alınarak uygulanır. Bu yüzden türevi alınabilen bir fonksiyon kullanılması geri yayılımlı öğrenme kuralı için önemlidir. Çünkü türev, bir eğri üzerinde deđişim olarak tarif edilir. Hatanın azaltılması ile hatanın türevinin sıfır olması beklenir. Hatalar her bir iterasyon sonunda sıfıra yaklařır. Buna göre düzeltme deđeri formül 19 üzerinden belirlenir (Neural Network Fundamentals, t.y.).

$$\Delta w_{0j} = \eta(d_0 - y_0)f'(y_0)x_j \quad (19)$$

Hafıza Tabanlı Öğrenme Kuralı (Memory Based Learning)

Hafıza tabanlı öğrenme kuralında, geçmiş öğrenmelerle doğru sınıflandırılmış bir bilgi hafızasının bulunması gerekir. Çok fazla sayıda girdi-çıkı örneklerinden birisi x_i girdi vektörü diđeri ise d_i skaler olan beklenen çıktı deđeridir ve hafızada N adet girdi-çıkı örneđi bulunmaktadır: $\{\{x_i, d_i\}\}_{i=1}^N$ (Haykin, 1999).

Hafıza tabanlı öğrenmede en etkili öğrenme kuralı en yakın komřu kuralıdır (nearest neighbor rule). Bir eğitim örneđine (x'_N), test için verilen girdi vektörünün (x_{Test}) en yakın komřusu olduđunu söyleyebilmek için, örnek test vektörünün eğitim örnekleri ile uzaklıđı, öklid uzaklıđı hesaplanarak bulunur (20) ve en kısa mesafedeki örnek, test vektörünün en yakın komřusu olarak belirlenir (Haykin, 1999).

$$x'_N \in (x_1, x_2, \dots, x_N)$$

$$\min_i d(x_i, x_{Test}) = d(x'_N, x_{Test}) \quad (20)$$

En yakın komşu sınıflandırmasının bir diğer formu ise k adet en yakın komşu sınıflamasıdır (k-nearest neighbor). En yakın komşu sayısı olarak 3 ya da 4 yakın örneğin bulunması yeterlidir (Sengupta, 2009). Örneğin 0-1 kategorisinde yaşanan bir problemi çözmek için bu yöntem kullanılmaktadır. Cover ve Hart (1967, akt: Haykin, 1999, s.54), desen tanıma problemlerinde hafıza tabanlı öğrenmede en yakın komşu kuralını kullanmışlardır.

Hebb Öğrenme Kuralı (Hebbian Learning)

Hebb (1949), tarafından geliştirilen öğrenme kuralı en eski ve en çok kullanılan öğrenme kuralıdır ve öğrenmeyi şöyle tarif eder (akt: Haykin, 1999, s.55): Bir A akson hücresi B hücreyi ateşleyebiliyorsa ve bunu ısrarla tekrar ettiriyorsa, birinde ya da her ikisinde birden metabolik değişim gerçekleşir; öyle ki, A hücresinin B hücreyi ateşleyebilme etkililiği artar.

Elbette bu ifade nörobiyoloji bağlamında, bağlaşımcı öğrenme temeline dayalı bir önermedir (Haykin, 1999). Hebb öğrenme kuralı yapay sinir ağları açısından incelendiğinde görülür ki, iki nöron arasındaki bağın kuvvetlenmesi her ikisinin aktif duruma geçmeleri arasındaki zamanın kısalığına bağlıdır. Hatta aynı anda aktif olan hücrelerin bağı daha kuvvetli olur.

Bir x_j nöronundan y_k nöronuna olan bağlantı ağırlığı w_{kj} ile gösterilirse η öğrenme hızı olmak üzere n zaman diliminde, Hebb öğrenme kuralının matematiksel gösterimi formül 21 ile verilir.

$$\Delta w_{kj}(t) = \eta y_k(t) x_j(t) \quad (21)$$

Yarışmacı Öğrenme Kuralı (Competitive Learning)

Yarışmacı öğrenme kuralı, çıktı nöronlarının aktif hale geçebilmek için birbirleri ile yarışması olarak ifade edilebilir. Hebb öğrenme kuralında çeşitli çıktı nöronları aynı anda aktif hale gelebilir. Ancak yarışmacı öğrenme kuralında her

seferinde sadece tek bir çıktı nöronu aktif olabilir. Bu özelliğinden ötürü yarışmacı öğrenme kuralı, girdi veri setlerinin sınıflandırılmasında kullanılabilir (Haykin, 1999). Aktif olan nöron daha ileriki öğrenme süreçlerinde kuvvetlenir (Sengupta, 2009). Her bir girdi nöronu çıktı nöronları ile bağlantı halindedir. İleri beslemeli katmanlar arası bağlantılar, uyarıcı (excitatory) bağlantılardır. Çıktı katmanındaki nöronlar arasındaki geri beslemeli bağlantılar engelleyici (inhibitory) olarak görev yapar.

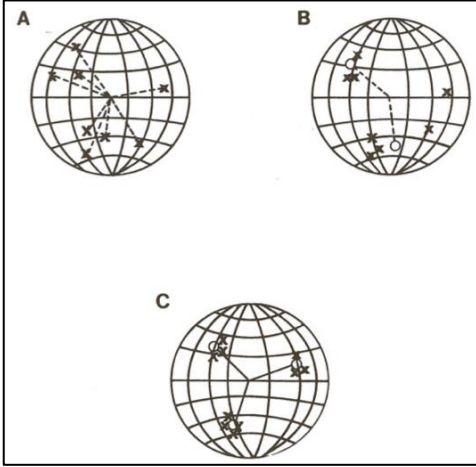
Çıktı nöronlarından sadece k nöronu aktif hale geldiyse toplam ağırlıklar 1 olmak üzere girdi nöronları arasında ağırlıklar paylaştırılarak dağıtılır. Böylece k nöronunda öğrenme olurken diğer nöronlarda öğrenme gerçekleşmez. Buna göre kazanan nörondaki ağırlık değişimi formül 22 ile verilir:

$$\sum_j w_{kj} = 1$$

$$\Delta w_{kj} = \begin{cases} \eta(x_j - w_{kj}) & k \text{ nöronu kazanırsa} \\ 0 & k \text{ nöronu kaybederse} \end{cases} \quad (22)$$

Şekil 10, yarışmacı öğrenme kuralına göre süreci anlatan kullanışlı bir geometrik analogi sunar (McClelland, 2015). Her bir uyarıcı girdi vektörü olarak düşünülür. Her bir vektör aynı sayıda aktif bağlantıya sahiptir. Böylece tüm girdi vektörleri N boyutlu bir hiper uzayda nokta olarak görüntülenebilir. N sayısı, girdi vektöründen birimlere ulaşan girdi bağlantı sayısı olarak düşünülebilir. Şekil 10'daki her 'x' sembolü girdi vektöründen gelen farklı uyarıcı durumlarını simgeler. Birbirine benzeyenler uzayda birbirlerine yakın durur. Farklı olanlar ile birbirlerine uzaktadırlar. İleri katmanda yer alan her bir nöron N adet girdi bağlantısına sahip, ağırlık vektörü de N boyutlu bir uzayda bir vektör olarak görüntülenebilir. Şekil 10'da görünen 'o' işareti, uyarıcı durumlar gibi iki nöronun ağırlıklarını temsil eder ve N boyutlu uzayda birlikte görüntülenebilirler. Bir uyarıcı durum geldiğinde kuvvetli tepki veren nöron bu uyarıcı durumun en

yakınında yer alan nöronun ağırlık vektörüdür. Bu uyarıcı durum için yarışmayı kazanan nöron, bulunduğu yerden bir miktar uyarıcı duruma (x) doğru lokasyonunu kaydırır (McClelland, 2015).



Şekil 10. Yarışmacı Öğrenme Kuralının Geometrik Yorumu

Şekil 10A'da 'x' sembolü ile gösterilen 8 uyarıcı durumdan, iki adet belirgin küme ve bu kümelerde 3'er uyarıcı durum görülmektedir. Diğer iki uyarıcı durum ise diğerlerinden ve birbirinden uzakta durmaktadır. Şekil 10B'de 'o' sembolü ile birbirinden farklı olan iki kümeye ait nöron ağırlıkları gösterilmektedir. Yarışmacı öğrenme kuralına göre, uyarıcı duruma en yakın olan nöronun ağırlık vektörü çalışır. Diğer bir deyişle o nöron yarışmayı kazanır. Şekil 10C'de ise, üç küme ve üç nöron görülmektedir. Doğal hali üç grupta toplanabilen uyarıcı durumlarına göre, üç nöronun ağırlık vektörleri daha kararlı duruma geçmek için kayma gösterecektir (McClelland, 2015).

Yarışmacı öğrenme kuralına ait bu mekanizmanın bazı özellikleri vardır (McClelland, 2015):

- Her bir küme, uyarıcıları M adet grupta sınıflar. Her biri kümedeki bir nörona gider ve böylece her bir nöronda eş sayıda uyarıcı durum bulunur. Bir kümenin M adet özellik değerinden birine sahip olduğu ve buna göre sınıflandırıldığı uyarıcı durumlardan oluştuğu ve böylece bir kümenin M adet özellik değerini barındırdığı düşünülebilir. İki nöron bulunduran bir küme ikili özellik dedektörü gibi hareket eder. Uyarıcı durumda belirgin bir özellik mevcutsa kümedeki bir nöron buna tepkide bulunur. Diğer durumda, kümedeki öteki nöron tepkide bulunur. Eğer uyarıcı durumda belirgin bir yapı mevcutsa nöronlar ilgili bağlantılarla bu nöronları doğru kümenin nöronuna yönlendirecektir.
- Eğer uyarıcılar yüksek düzeyde bir yapısal duruma sahipse, sınıflandırmalar da o düzeyde değişmez kalacaktır. Eğer yapısal durum çok belirgin değilse, sınıflandırmalar da daha değişken olacaktır. Bir uyarıcı ilkinde bir kümede görünürken, aynı uyarıcılar için yapılan diğer ağ analizinde, o uyarıcı başka bir kümede görülebilir.
- Bir kümede gruplanma, ağırlıkların başlangıç değerlerine ve uyarıcıların ağa giriş sırasına bağlıdır (genelde başlangıç ağırlık değerleri ve uyarıcıların sıralaması rasgele belirlenir). Fazla sayıda küme bulunması durumunda, kümeler aynı bağlantıdan gelen girdileri bir çok sayıda farklı gruplamaya tabi tutar. Bu da özelliklerine göre uyarıcı durumların dağılımına ait bir çeşit gösterim sunar.
- Birincil yaklaşım, sistem kümeleri kendi içindeki mesafeleri minimum, diğer kümelerle olan mesafeleri maksimum yapacak şekilde geliştirir. Böylece her bir küme tarafından yakalanan uyarıcı sayısı bir dengeye oturur.

2.3.8. Veri İndirgemedede Kullanılan Yapay Sinir Ağı Modelleri

Veri indirgeme amacıyla geliştirilen çeşitli yapay sinir ağı modelleri vardır. Bu araştırmanın kapsamında TBA yerine kullanılabilen GHA ve faktör analizi yerine kullanılabilen KDH tanıtılmıştır.

2.3.8.1. 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.

Diyelimki 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 (23).

$$y = \sum_{i=1}^n w_i x_i \quad (23)$$

Hebb kuralına göre, ağırlıkların zaman içinde değişkenlik göstermesi şunlara bağlıdır: 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 alınan ağırlık değerlerini bir stokastik süreç olarak ele alınacak olursa, oluşturulan yapay sinir ağı modelinin bir temel bileşen analizi işlevini göreceğini belirtir.

Oja öğrenme kuralında (24), 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. Kuvvetli çıktılar, ($y(t)$ tepkisi) unutmayı kuvvetlendirecektir.

$$w_i(t + 1) - w_i(t) = \eta y(t)[x_i(t) - y(t)w_i(t)] \quad (24)$$

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 orthogonalization" işlemini birleştirerek geliştirdiği algoritmaya Genelleştirilmiş Hebb Algoritması (GHA) denir. Bu çalışma ile Sagner (1989), GHA'nın özvektör çözümlemesinin yapay sinir ağlarına uygulanabilirliğini ve eğitilen ağın gücünü ispatlar. Bu şekilde eğitilmiş bir ağdan çıkan her bir çıktı, özdeğerleri 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. Diyelimki 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 (25).

$$w_{ij}(t + 1) - w_{ij}(t) = \eta [y_j(t)x_i(t) - y_j(t) \sum_{k=1}^j w_{ik} y_k] \quad (25)$$


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 özvektörü (e_1) elde edilir. Birinci özvektörün 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 özvektör (e_2) ise e_1 vektörü yüzünden yoğunluğu azalmış olan x verisinin

birinci temel bileşenidir. Çıktı katmanının üçüncü nöronundan çıkan özvektör (e_3) ise e_1 ve e_2 vektörleri yüzünden yoğunluğu tekrar azalmış olan x vektörünün birinci temel bileşenidir ve bu böyle devam eder (Diamantaras, 2002).

2.3.8.2. Kendini Düzenleyen Haritalama

Kohonen (1982), Kendini düzenleyen bir haritalama yapan ağın temel prensibinin, 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). Bunun için Kohonen'in (1990) verdiği örneklerden birisi semantik haritalamadır.

Beynin üst düzey soyut kavram, sembol ve dili nasıl işlediği ve insan beyinde dilsel birimler olarak nasıl yerleştiği gibi psikolojik araştırmaların yapay sinir ağları modelleri ile nasıl işlendiği, KDH üzerinden örneklendirilir. Semantik haritalama işleminde, 10x15 adet nöron üzerinden iki boyutlu bir görüntü tasarlanır. 2000 adet üç kelimelik İngilizce cümleler üzerinden kelime-bağlam çiftleri örnek veri seti olarak kullanılır. KDH ağı, gramer ve semantik ilişkileri çözümlenerek, isim, fiil ve zarf olmak üzere kelimeleri kümeler. Bu kümeler 10x15'lik nöronlar üzerinde gözlenir. Nöronlar arası mesafeye göre kümelerin belirlenmesinin yanı sıra, kümeler içindeki kelimelerde anlamca yakınlıklarına göre komşuluk ilişkisi gösterir (Şekil 11).



Şekil 11. KDH ile Yapılan 10x15 Nöronlu Semantik Harita

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 kullanır. Buna göre algoritmada eğitim girdi vektörlerinin (x_i), c kümelerine sınıflandırılması için ağırlık güncellemesini koşullu olarak formüllendirilir (26).

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

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

$$w_i(t+1) = w_i(t) \quad \text{Eğer } i \neq c \quad (26)$$

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

2.3.4. İlgili Araştırmalar

TBA ve yapay sinir ağları arasındaki bağlantının incelenmesine ilişkin birçok çalışma yer almaktadır. Cottrell, Munro ve Zipser (1987; akt. Oja, 1992)

denetimli öğrenmede geri yayımlı algoritma kullanan çok katmanlı algılayıcı ağ modelini veri sıkıştırma kullanmayı önermişlerdir. Ayrıca bu ağların TBA ile yakından ilişkili olduğu Baldi ve Hornik (1989 akt. Oja, 1992) ve Bourlard ve Kamp (1988 akt. Oja, 1992) tarafından gösterilmiştir. Ayrıca Oja 1982’de farklı bir model önermektedir. Bu öneride, tek katmanlı ileri beslemeli denetimsiz öğrenmede Hebb öğrenme kuralını temel alarak oluşturulan ağın, TBA yapabildiği belirtilir. Tek nöronlu Oja kuralı ile veri setinin tek bir özelliği saptanır, bu özellik birinci temel bileşen olarak adlandırılır.

Sagner(1989), Oja öğrenme kuralını nöron sayısını artırarak birden çok temel bileşeni ortaya çıkarabilecek GHA öğrenme kuralını ortaya koyar ve bu kuralın TBA’nin işlevini, bu çalışmada da kullanılacak olan yapay sinir ağı modeli ile yapılabileceğini teorik olarak ispatlar.

TBA yerine kullanılan farklı bir ağ yapısını Kramer (1991) çalışmasında açıklar. Doğrusal olmayan TBA (Nonlinear principle component analysis) yapan bu ağ, temel bileşenler analizi gibi boyut indirgeme ve açıklayıcı veri analizi amacıyla kullanılır ve değişkenler arası korelasyondan hareket eder. TBA değişkenler arası doğrusal ilişkileri ortaya koyarken, doğrusal olmayan TBA hem doğrusal hem de doğrusal olmayan ilişkileri ortaya çıkarabilir. İleri beslemeli bir ağ olan doğrusal olmayan TBA, girdileri çıktı katmanında tekrar üretir. Ağın eğitimi, geri yayımlı ya da otoilişkili (Autoassociative) yöneme göre yapılır. Girdi, çıktı ve aralarında üç gizli katmanın bulunduğu bu ağ ile elde edilen sonuçlar, ağın veri indirgeme ve özellik tespitinde başarılı olduğunu gösterir (Kramer, 1991).

Xu ve Yuille (1992), uç değerlerin varlığında TBA için mevcut kendini düzenleyen kuralların zayıf kaldığı eleştirisinde bulunarak çalışmalarında, Gibbs dağılımını içeren istatistiksel fizik teknikleri kullanarak, ikili karar verme ve etkili enerji kullanma bağlamında, yapay sinir ağları için kendini düzenleyen TBA

kuralları önermişlerdir. Xu ve Yuille (1992) tarafından yapılan bu çalışmada, uç değerler mevcutken, TBA algoritmalarının performansını artırıcı kuralların, karşılaştırmalı deneysel çalışmaların sonuçları ile desteklendiği gösterilmiştir.

Warner ve Misra (1996) yaptıkları incelemede, tahmin ve sınıflandırma problemlerinde, yapay sinir ağı kullanımına odaklanmışlardır. Çalışma, çok katmanlı ileri beslemeli yapay sinir ağı modelleri ile sınırlandırılmıştır. Bu çalışmada, regresyon modellerinde kullanılan terminoloji ile paralel olarak yapay sinir ağı modellerinin açıklaması yapılmış ve böylelikle yapay sinir ağının anlaşılabilirliğini artırmaya yönelik bir katkı sağlanmıştır. Örneğin, ‘katsayı’ (coefficient) terimi yerine yapay sinir ağına ‘ağırlık’ (weight) kavramı kullanılır; ‘gözlemler’ (observations) yerine de ‘durumlar’ (patterns) kavramı kullanılır. Warner ve Misra (1996), yapay sinir ağı modellerini parametrik olmayan regresyon modeli olarak tanımlar ve istatistikçilerin yapay sinir ağı modellerinin kapasitesini ve potansiyel kullanımını anlamalarının önemli olduğunu vurgular.


Fancourt ve Principe (1998) tarafından gerçekleştirilen çalışmada, zaman serileri üzerine yarışmacı TBA’ni gerçekleştiren denetimsiz yapay sinir ağı için bir algoritma önerilmiştir. Ağın çalışması sonucu girdinin, dolayısıyla zamanın bir fonksiyonu olarak, girdiden daha az boyutlu uzayda optimum düzeyde bir projeksiyon elde edilmiştir. Yan ürün olarak zaman serilerini, hem ayırmış hem de kararlı bölgelere göre tanımlamıştır.

Bryliuk ve Starovoitov (2001) tarafından yüz görüntüsü tanımda, büyük veri setinden temel bileşenleri hesaplayan devri daim yapay sinir ağı (recirculation neural network) çalışması yapılmıştır. Devri daim yapay sinir ağının yapısında, tek gizli katmanlı olan çok katmanlı bir mimari vardır. Görüntüdeki eleman (pixel) sayısı (n) kadar girdi ve çıktı nöronları bulunur. Ancak gizli katmandaki nöron sayısı (m) daha az olmalıdır ($m < n$). Bu sayı (m), aynı zamanda temel bileşen sayısıdır. Doğrusal olmayan aktivasyon fonksiyonlarının kullanımı ile - Bryliuk ve


Starovoitov (2001) tarafından hazırlanan bu ağda hiperbolik tanjant aktivasyon fonksiyonu kullanılmıştır- TBA ile benzer sonuçlar elde edilmiştir. Devri daim yapay sinir ağı matris denklemlerini çözmede daha avantajlıdır. Özellikle amaç az sayıda temel bileşen belirlemekse, bu sayede tüm özvektörleri çözümlenmeye gerek kalmaz (Bryliuk ve Starovoitov, 2001).

Kiang ve Kumar (2001) tarafından yapılan çalışmada faktör ve küme yapısı daha önceden belirlenen simulasyon verileri üzerinden KDH ağ yapısı, faktör analizi ve K-ortalama kümeleme analizleri açısından incelenmiştir. Yapılan karşılaştırmalar sonucu, KDH ağının, özellikle çarpık dağılımlı verilerde, döndürme öncesi faktör analizi sonuçlarından daha üstün olduğu ve örtük küme yapısını daha doğru ortaya koyduğu gözlenmiştir.

Francis (2001), yaptığı çalışmada doğrusal regresyon ve faktör analizi gibi doğrusal modellemeler yapan istatistiksel yöntemler yerine yapay sinir ağı modellerini incelemiştir. Bu araştırmanın bir parçası olan faktör analizi ve yapay sinir ağı modelinin karşılaştırmasında öncelikle, faktör analizi ve yapay sinir ağı modeli şekilsel olarak incelenmiştir. Şekil 12’de girdi değişkenleri, faktör ve bağımlı değişken bağlantısı görülmektedir. Şekildeki ilişkilere göre girdi değişkenler tek bir faktör üretmişler ve bu faktör bir bağımlı değişken tahmininde kullanılmıştır. Şekil 13’te ise, aynı veri yapay sinir ağı modelinde kullanılmış ve yapay sinir ağında faktör yerine tek nöronlu bir gizli katman bulunmaktadır. Faktör analizindeki faktör, girdi değişkenlerin ağırlıklı doğrusal kombinasyon olmakta; ancak yapay sinir ağı modelinde gizli katmanda girdilerin doğrusal olmayan bir ağırlıklı fonksiyonuna göre tepki üretmektedir. Bu durumda boyut azaltmada, doğrusal olmayan ilişkiler mevcutsa yapay sinir ağı modelleri düşünülebileceği bu çalışmada belirtilmiştir. Francis (2001), bu durumun TBA ile yapılan karşılaştırmalar için de geçerli olduğunu belirtmiştir.



Şekil 12. Faktör Analizi Sonucunun Şematik Gösterimi



Şekil 13. Bir Gizli Katmanda Tek Nöronlu Yapay Sinir Ağı Modelinin Şematik Gösterimi

Bu çalışmada sonuç olarak, yapay sinir ağı modeli, doğrusal modele yaklaşık olarak uyumlu görünmekle birlikte, faktör analizinin daha fazla uyum gösterdiği saptanmıştır. Bağımlı ve bağımsız değişkenler arasında doğrusal bir ilişki olduğu düşünülen durumlarda klasik doğrusal model analizleri, karmaşık yapıya sahip olan yapay sinir ağı modellerine göre tercih edilebilir sonucu çalışmada vurgulanmıştır.

Lee, Rey, Mentele ve Garver (2004) tarafından yapılan araştırmanın temel sorusu, karlılık ve/veya sadakat ile ilgili teorik tanım ve ilişkiler çerçevesinde doğrusal ve simetrik ilişki göstermeyen, normallik ya da dağınık verilerin varyans homojenliği sayılıları olmadan, neden-sonuca dayalı bir ilişkiyi modellemenin mümkün olup olmadığıdır. Bu durumda doğrusal olmayan yapısal eşitlik modeli ya da kısmi en küçük kareler gibi yöntemler kullanılabilir ancak sayılılar ve büyük ve dağınık veriler nedeniyle bu yöntemler çözüm yaratmada sıkıntılıdır (Lee ve diğ., 2004). Bu nedenle çalışmada, yapılandırılmış yapay sinir ağı modeli önerilmiştir ve uygulaması bir kimya şirketinin verileri üzerinden yapılmıştır.

Geliştirilen modelde her bir düğüm noktası örtük bir değişkeni temsil eder ve gizli katman sayısı yapının teorik çerçevesine göre belirlenir. Tüketici sadakati değişkeni açıcı faktör analizi sayesinde, iki boyuttan oluştuğu belirlenmiştir. Boyutlarda oluşan faktörlerden birisi satın alma niyeti, diğeri ise satın alma davranışıdır. Her bir faktör için ağdaki düğüm noktasını, düğüm noktalarındaki nöron sayısı ise, girdi değişkenlerinden (gözlenen değişkenler) oluşan temel bileşen sayısına eşittir. Girdi ve gizli katman arasında kullanılan aktivasyon fonksiyonu hiperbolik tanjant fonksiyonudur. Gizli katman ile çıktı arasında ise lojistik aktivasyon fonksiyonu kullanılmıştır. Araştırmada dört model karşılaştırması yapılmıştır. Model karşılaştırmaları ortalama hata karekök yaklaşımı (root mean squared error) üzerinden yapılmıştır. Modeller, doğrusal regresyon modeli, örtük değişkenin tek temel bileşeni üzerinden düşünülerek hazırlanan tek nöronlu yapılandırılmış sinir ağı, çok nöronlu yapılandırılmış sinir ağı ve klasik yapay sinir ağı modelidir.

Yapay sinir ağları ve TBA'nın birlikte kullanımına ilişkin diğeri bir çalışma Mohamad-Sales ve Hoyle (2008) tarafından yapılmıştır. Araştırmacılar, bu çalışmada veri setindeki ilişkili bilgileri dışta tutma yöntemi olarak TBA

kullanmayı önermişlerdir. Bu öneriyi elektriksel kapasite tomografisi verilerinde kullanmışlardır. Gaz-petrol akışından elde edilen gaz damıtımı tahmini için kullanılan tomografik veriler, TBA'nden sonra ilişkisiz veri seti haline dönüştürülmüş ve daha sonra çok katmanlı ağılayıcı sinir ağının eğitiminde kullanılmıştır. Eğitim ve testlerden sonra elde edilen bulgular TBA sayesinde ağı eğitiminin daha kısa sürede tamamlandığını ve yapay sinir ağlarının tahmin gücünün arttığını göstermiştir (Mohamad-Sales ve Hoyle, 2008).

Sun, Deng, Gong, Wang, Yang ve Zhao (2009), Kohonen sinir ağları ve faktör analizini jeokimyasal örüntü/desen tanımada birlikte kullanmışlardır. Araştırmacılar bu yaklaşımın, yalnızca faktörlerin jeolojik önemini yorumlamadaki etkililiği artırmada değil, madencilikte keşif alanlarının daraltılması açısından da önemli olduğunu vurgulamaktadırlar.

Araştırmada ilk olarak veriler, Kohonen sinir ağları tekniği ile sınıflandırılmıştır (Bu teknik araştırmamızda Kendini Düzenleyen Haritalama-KDH olarak verilmiştir). Denetimsiz öğrenme yöntemli Kohonen sinir ağları tekniği, yüksek boyutlu veri setini daha az boyutta haritalamaktadır. Bu teknik denetimsiz olması ve çok fazla karmaşık olmaması nedeniyle kullanım kolaylığı sağlamaktadır (Kohonen ve diğ. 1996; akt. Sun ve diğ. 2009).

Girdi değerleri iki kategorili ya da sürekli olabilir. Öğrenme süresi üç ana adımdan oluşur: Örnek girdi setinin sunulması, çıktının hesaplanması ve ağırlıkların belirli öğrenme kuralına göre düzenlenmesidir. Bu işlem ağı eğitilinceye kadar tekrar ettirilir. Araştırma şu şekilde tasarlanmıştır (Sun ve diğ., 2009):

1. Kohonen sinir ağları ile örneklemelerin sınıflandırılması
2. Tüm örneklerin ve seçilen örneklemelerin faktör analizlerinin yapılması
3. Sonuçların yorumlanması

Araştırmada 9 ayrı örneklem olmak üzere 2860 veri bulunmaktadır. Bu örneklemeler 10 adet maden için betimsel istatistikleri hesaplanmıştır (Au, Ag, As, Sn, Bi, Co, Cu, Pb, Zn, ve Mo). Bu örneklemeler, ilk olarak Kohonen sinir ağı ile sınıflandırılmıştır. Buna göre 3. ve 9. örneklemelerin konsantre katsayılarının yüksekliği nedeniyle temsil güçlerinin yüksek olduğu sonucuna varılmıştır. Toplamda 679 örnekten oluşan 3. (179 örnek) ve 9. (500 örnek) örneklemeler üzerinde faktör analizi yapılmıştır. Faktör analizi ve varimax döndürme işlemi sonucunda elde edilen faktörler sırasıyla aşağıdaki gibidir:

F1: Pb-Zn-Mo

F2: As-Co

F3: Bi-Cu

F4: Au-Ag

Faktör analizi sonucunda elde edilen 4 faktörlü yapı ile açıklanan toplam varyans %67,54'tür. 2860 adet tüm veriden faktör analizi sonucu elde edilen faktör sayısı ise 3'tür ve açıklanan toplam varyans %57,04'tür:

F1: Ag-Pb-Zn

F2: As-Co-Bi-(-Sn)

F3: Au

Görüldüğü üzere tüm veri setinden elde edilen faktörlerde Mo bulunmamaktadır. jeolojik araştırmalarından bilindiği üzere Pb, Zn ve Mo minareleşmesi birbirleri ile bağlantılıdır. Bu yüzden Kohonen yapay sinir ağı modeli ile faktör analizinden önce örneklemelerin sınıflandırılması, faktörlerin mantıksal açıklamasının yapılabilmesi için önemlidir (Sun ve diğ., 2009).

Kumar, Kumar ve Ali (2012) tarafından yapılan çalışmada, faktör analizi görevini yapan iki aşamalı yapay sinir ağı mimarisi önerilmiştir. Önerilen modelde iki yapay sinir ağı bulunmaktadır. Bunlardan birincisi girdi değişkenlerini indirgeyerek faktörlere ayıran ağı; ikincisi ise, faktörlerden orjinal değişkenlere ait

veriyi tekrar oluşturan ağdır. Amaç, özellikle veri sıkıştırma yöntemi ile bilgisayarlarda daha az alan kaplayan veri depolamayı sağlamaktır.

İlk olarak birinci ağı eğitim safhasında, rasgele girdi değişkenlerinden faktörler elde edilir. Birinci ağdan elde edilen faktörler (çıktılar), girdi olarak ikinci ağa verilir ve ikinci ağın çıktıları birinci ağın girdileri ile karşılaştırılır. Bunun için ileri beslemeli sinir ağında öğrenme algoritması olarak geri yayımlı öğrenme kullanılır. Faktörizasyon değerlendirme ölçütü olarak G katsayısı kullanılır. Simülasyon sonucu pozitif G değeri (0,70) ile bilgi kazanımının %70 olduğu yorumu yapılır. Orjinal veriyi saklamak için 100 MB gerekirken, faktörlerle elde edilen veri için 30 MB yeterli olmuştur. Buna göre iki aşamalı modelin oldukça etkili olduğu görülmüştür (Kumar ve diğ., 2012).

Yapılan incelemelerde, yapay sinir ağları ve TBA'nın farklı bir uygulamasından söz edildiği görülmektedir. Bu uygulama şu şekilde özetlenebilir: Girdiler (değişkenler) öncelikle TBA sayesinde, bilgi kaybı olmadan, azaltılır. Değişken azaltımından sonra problem, yapay sinir ağları ile daha az girdi üzerinden çözümlenebilir. Bu kapsamda Zekić-Sušac, Šarlija ve Pfeifer (2013) tarafından yapılan çalışmada yapay sinir ağlar ve TBA'yı birleştirerek, öğrencilerin girişimcilik niyetlerini modelleyen bir yöntem önermişlerdir. Modellemenin amacı, yalnızca girişimcilik niyetinin yordayıcılarını ortaya koymak değil, aynı zamanda veri toplama maliyetini ve yapay sinir ağları eğitiminin maliyetini azaltmaktır.

Öncelikle 94 maddelik anket 443 iş yönetimi bölümünü okuyan üniversite öğrencilerinden elde edilen veriler, açıklayıcı TBA'ne tabi tutulmuş ve elde edilen yordayıcılar ile yapay sinir ağı eğitim seti oluşturulmuştur. Yapay sinir ağlarından çıkan sınıflandırma iki kategorilidir (1=girişim niyeti olanlar; 0=girişim niyeti olmayanlar).

Ağ modeli ileri beslemeli çokkatmanlı algıyıcıdır. Bu modelde en çok kullanılan sigmoid fonksiyonlarından biri olan lojistik aktivasyon fonksiyonu ($f(x) = 1/(1 + e^{-x})$) ve öğrenme kuralı olarak Delta kuralı uygulanmıştır. Hatayı azaltmak için üç farklı hata indirgeme algoritmasını karşılaştırmışlardır: Eğim düşümü, conjugate eğim düşümü ve BFGS (Broyden–Fletcher–Goldfarb–Shanno) algoritması. Sonuçta oldukça hızlı olması nedeniyle BFGS algoritması seçilmiştir. Eğitimler sonucu ağ, farklı test örnekleri ile test edilmiş ve en düşük hata veren test örneği kaydedilmiştir. Araştırmanın sonucuna, doğru sınıflandırma oranı üzerinden karşılaştırma yapılarak ulaşılmıştır. Dört model doğru sınıflandırma oranı üzerinden karşılaştırıldığında, araştırmacılar en yüksek doğru sınıflandırma oranının 1. ve 4. modele ait olduğunu; her iki modele göre doğru sınıflandırma oranları arasında manidar bir fark bulunmadığını belirtmişlerdir.

İlgili araştırmalardan çıkarılması gereken yorum ve önemle vurgulanması gereken nokta, eğitim alanında yapılan araştırmalarda, gerekli olan veri analizleri için, yapay sinir ağı modellerinin istatistiksel analiz yöntemlerine göre üstün yanları olup olmadığını inceleyen araştırmaların sayısında artış olması gerekliliğidir.

BÖLÜM III

YÖNTEM

3.1. Araştırmanın Türü

Bu tez kapsamında yapılan araştırmanın türü temel araştırmadır. Temel araştırmalar, varolan 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.

3.2. Araştırma Grubu

Çalışma 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 öğretmeni 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 tanımlı 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 karşılaştırılabilmesi amacıyla yapılan DFA’da kullanılmıştır.

Araştırma problemlerinin cevaplanabilmesinde kullanılan ilk gruptan, verisi bulunan 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, verisi bulunan 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, 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

3.3. 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 2). 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.

3.4. Verilerin Analizi

1. Alt Problem İçin Veri Analizi

Birinci araştırma sorusu için denemelik ÖYTÖ ile çalışma grubu üzerinden toplanan veriler üzerinden SPSS 21.0 paket programı kullanılarak TBA yapılmıştır.

TBA'ne başlamadan önce gerekli olan temel koşullardan birisi gözlenen değişkenlerin normal dağılım göstermesidir. Tablo 4'te maddelere ait bazı istatistikler görülmektedir. 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. 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 karşılama da, veriler kullanılabilir (Tabachnick ve Fidell, 2001). 400 adet verinin, bu çalışmanın amacı olan analiz tekniklerinin karşılaştırmasına yönelik olarak, kullanılabilir olduğu kabul edilmiştir.

Tablo 4. TBA, GHA ve KDH İin Kullanılan Veri Seti Üzerinden Denemelik ÖYTÖ Maddeleri İin Bazı İstatistikler

	Ortalama	S. Sapma	arpıklık	arpıklık İin S. Hata	Basıklık	Basıklık İin S. Hata
madde1	4,31	0,77	-1,34	0,12	2,57	0,24
madde2	4,48	0,64	-1,24	0,12	2,49	0,24
madde3	3,63	1,14	-0,56	0,12	-0,52	0,24
madde4	3,56	0,82	-0,25	0,12	-0,20	0,24
madde5	2,86	1,04	0,18	0,12	-0,42	0,24
madde6	3,86	0,98	-0,81	0,12	0,38	0,24
madde7	3,72	1,00	-0,66	0,12	-0,07	0,24
madde8	3,71	0,89	-0,82	0,12	0,73	0,24
madde9	3,80	0,85	-0,71	0,12	0,78	0,24
madde10	4,06	0,83	-1,05	0,12	1,57	0,24
madde11	3,48	0,82	-0,32	0,12	0,40	0,24
madde12	3,44	0,84	-0,25	0,12	0,18	0,24
madde13	3,71	0,93	-0,56	0,12	0,12	0,24
madde14	3,22	0,93	-0,16	0,12	-0,27	0,24
madde15	4,10	0,85	-1,28	0,12	2,29	0,24
madde16	3,75	0,90	-0,76	0,12	0,61	0,24
madde17	3,68	1,01	-0,68	0,12	0,11	0,24
madde18	3,39	0,95	-0,47	0,12	-0,22	0,24
madde19	3,40	0,94	-0,42	0,12	-0,19	0,24
madde20	3,61	0,92	-0,54	0,12	0,09	0,24
madde21	3,56	1,02	-0,63	0,12	-0,22	0,24
madde22	3,69	0,91	-0,66	0,12	0,07	0,24
madde23	3,88	0,97	-0,87	0,12	0,57	0,24
madde24	3,29	1,06	-0,25	0,12	-0,70	0,24
madde25	3,53	0,96	-0,71	0,12	0,38	0,24
madde26	3,97	0,74	-0,81	0,12	1,65	0,24
madde27	3,69	0,83	-0,61	0,12	0,26	0,24
madde28	3,48	0,93	-0,22	0,12	-0,31	0,24
madde29	3,68	0,95	-0,80	0,12	0,39	0,24
madde30	3,56	1,05	-0,57	0,12	-0,12	0,24

TBA öncesi, denemelik ÖYTÖ'nin 30 maddesi üzerinden hesaplanan ve içtutarlık 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 30 madde üzerinden madde-madde korelasyon matrisi incelendiğinde (Ek 4-Tablo 20), 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, bileşenlerin analizine geçmeden önce, analiz için gerekli olan koşullar incelenmiştir. Buna göre, 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 ($|R|>,00001$).

Bir dizi değişkenleri kendi aralarındaki ilişkiyi matematiksel olarak analiz etme ya da bir dizi değişkeni gruplayarak ya da kümeleyerek tanımlama tekniği olarak tanımlanabilen TBA'da ilk olarak, madde-madde korelasyonları matrisi (C) incelenir. Madde-madde korelasyonlarında, bir maddenin diğer maddelerle istatistiksel olarak anlamlı bir ilişkinin olmadığı görülmesi durumunda, o maddenin analizden çıkarılması gerekir. Çünkü maddelerin birbiri ile ilişkili olması, maddelerin hep birlikte, ölçülmek istenen özelliği ölçüyor olduklarına işaret eder. Bir maddenin diğer maddelerle ilişkisiz olması, o maddenin ölçme aracının ölçmek istediği özelliği ölçemediği anlamı taşıyabilir.

Ölçek maddeleri arasındaki ilişkiyi -korelasyon katsayılarına bakarak- belirledikten sonra yüksek ilişkiye sahip olanların bir araya getirilmesini sağlayan bileşenler ortaya çıkarılır. Ancak maddeler arası çok yüksek ilişki de (multicollinearity) istenmeyen bir durumdur. Çünkü iki madde arasındaki yüksek ilişkililik ($r > .8$), aynı şeyi ölçen iki madde olarak düşünülür ve tekrara neden vermemek için maddenin birisi analizden çıkarılır (Field, 2009). Bunun için SPSS, multicollinearity testi yapar. Korelasyon matrisinin önem düzeylerini veren matrisin determinantının 0,00001'den yüksek olması beklenir.

Bunun yanı sıra örneklem büyüklüğünün yeterliğinin ve değişkenler arası korelasyonun düşük olup olmadığının testi sonuçları da analizin kendi içindeki koşullarıdır. SPSS, KMO ve Barlet testi yapar. KMO, güvenilir faktörler için örnek büyüklüğünü test eder ve değer, 0,5'den büyük olmalıdır. Barlet testi ise, değişkenler arası korelasyonun çok düşük olup olmadığını test eder (önem düzeyi 0,05'ten küçük olmalıdır) .

Sonuçta ortaya çıkan ve kümelenmiş maddeler ölçmek istediğimiz özelliğin bir yüzünü gösterir. Her bir küme, özelliği ölçen bir boyut olarak anlamlandırılır ve bu boyutlar kullanılan analize göre 'bileşen' ya da 'faktör' adını alır. Bu çalışmada TBA kullanıldığı için boyutlar, bileşen olarak adlandırılmıştır.

Ortaya çıkan bileşenler özvektörler olarak formüle edilir (V). Formül 27'de görüldüğü gibi özvektör matrisinin devriği (V^t), korelasyon matrisi (C) ve özvektör matrisinin (V) çarpımlarından özdeğerler matrisi elde edilir. Böylece elde edilen bileşenlerin özdeğerleri, bileşenlerce açıklanan varyansın miktarını ortaya çıkarmaktadır. Bileşen miktarını belirlemek için, SPSS Kaiser ölçütünü kullanır (Özdeğerlerin 1'den büyük olması).

$$L = V^t C V \quad (27)$$

Bu aşamadan sonra faktör yüklerinin belirlenmesi gereklidir. Faktör yükü maddelerin koordinat değerleri olarak düşünülebilir. Her bir maddenin hangi bileşen ya da bileşenlerle yüksek ilişkide olduğunun belirlendiği bir işlemdir. Bir faktör yükü o değişkenin faktöre yaptığı görece katkıdır. Faktör yüklerinin (A) hesaplanması için özvektör matrisi, özdeğerler matrisinin karekökü ile çarpılmıştır (28). Her madde için elde edilen faktör yükleri, korelasyon katsayıları ya da regresyon katsayıları olarak yorumlanabilir.

$$A = V\sqrt{L} \quad (28)$$

Döndürme işlemi TBA'nın en önemli aşamalarından birisidir. Döndürme ile analizi daha sağlamlaştırmak mümkündür. Faktörler arasında bağımsızlık sayılıtsı kabul edilirse, dik döndürme kullanılır. İstatistiksel anlamı ise, faktör yükü, korelasyon katsayısı ve aynı zamanda regresyon katsayısına karşılık gelir. Genellikle SPSS'de varimax kullanılır. Varimax, faktörlerin kendi içinde faktör yüklerini en yüksek değere getirir. Böylece faktör üzerinde yüksek gücü olan değişkenleri seçerek değişken sayısını azaltır (Field, 2009).

Faktörlerin birbirleriyle ilişkili olduğu sayılıtsı kabul edilirse, eğik döndürme kullanılır. İstatistiksel anlamı ise, faktör yükü yalnızca korelasyon katsayısına karşılık gelir. Genellikle Direct oblimum kullanılır. Delta sabiti ile faktörlerin korelasyonu sınırlandırılır. SPSS, '0' delta derecesini önerir. Faktörler arasında yüksek korelasyon olduğu kabulü ile, 0'dan yüksek delta değeri belirlenebilir ya da düşük korelasyon olduğu sayılıtsı ile negatif değer belirlenebilir (Field, 2009).

SPSS faktör yüklerinin manidarlık testini yapmaz. Faktör yüklerinin manidarlığı örnek büyüklüğü ile ilişkilidir. Stevens'in (2002, akt: Field, 2009, s. 644) belirlediği ölçüte göre örneklem büyüklüğüne karşılık gelen yük değerinden büyük olan değişkenlerin bileşenlere ataması yapılır:

- Örnek büyüklüğü 50 ise 0,722 yük değeri
- Örnek büyüklüğü 100 ise 0,512'den büyük yük değeri
- Örnek büyüklüğü 200 ise 0,364'den büyük yük değeri
- Örnek büyüklüğü 300 ise 0,298'den büyük yük değeri
- Örnek büyüklüğü 600 ise 0,210'dan büyük yük değeri
- Örnek büyüklüğü 1000 ise 0,162'dan büyük yük değeri

Bir diğer ölçüt ise Comrey ve Lee (1992; akt: Tabachnick ve Fidell, 2001) tarafından verilmiştir. 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. Bu araştırmada 0,45 faktör yükü ölçüt olarak seçilmiştir.

2. Alt Problem İçin Veri Analizi

Yine aynı veri seti üzerinden 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 için kullanılan komut dosyasında, elde edilen sonuçları TBA sonucuyla karşılaştırabilmek için TBA analizi yapan komutlar da vardır. Ancak bu araştırmada yalnızca GHA üzerinden temel bileşen tahmini yapan komutlar kullanılmıştır.

GHA üzerinden temel bileşen tahmini yapan komut dosyası incelendiğinde bir ana komut dosyası ve içerisinde iki fonksiyon dosyası vardır. Fonksiyon komut dosyalarından birisi GHA için ağın eğitimini sağlayan ve ağın öğrenme algoritmasının bulunduğu dosyadır (ghafun.m). Diğeri ise girdilerin rasgele olarak ağa atanmasını sağlayan fonksiyon komut dosyasıdır (randomize.m).

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. Bu değer 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 (Ek 3).

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

3. Alt Problem İçin Veri Analizi

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 ağdır. Bu kural, girdileri iki boyutlu topoloji üzerinden sınıflandırarak kümelemektedir. Küme sayısı ağ için önceden belirlenen nöron sayısına göre değişiklik gösterebilir. Küme sayıları, oluşan faktörler olarak değerlendirilmektedir. Bu araştırmada 5x5 ve 4x4 nörondan oluşan iki boyutlu topoloji üzerinden çıktılar ele edilmiştir. Bulgular iki farklı nöron sayısı üzerinden elde edilerek değerlendirilmiştir.

4. Alt Problem İin Veri Analizi

TBA, GHA ve KDH iin kullanılan veri setinin dıřında, DFA sonularının incelenmesi iin aynı gruptan elde edilen diđer 400'lük veri seti ile ÖYTÖ maddeleri normallik sayılıtı aısından incelenmiřtir. Bu veri seti üzerinden elde edilen maddelerin dađılımları 1, 2 ve 3 numaralı arařtırma problemlerinde kullanılan veri seti üzerinden elde edilen madde istatistikleri ile benzer sonular gstermektedir (Tablo 5). İlk veri setinde arpıklık aısından sıkıntı yaratabilecek maddeler 1., 2., 10. ve 15. maddeler iken ikinci veri setinde 1., 2. ve 15. maddelerin sola arpıklığı -1'in altındadır. Basıklık deđerleri aısından ilk veri setindeki 5 maddenin yanısıra 2 adet maddenin daha +1'in üzerinde sivrilik gsterdiđi grlmektedir (1., 2., 10., 15., 16., 26. ve 27. maddeler). Analiz sonularına gre elde edilen lek yapılarının DFA üzerinden karřılařtırılması amalandığından dolayı, madde dađılımlarının analiz iin uygun olduđu sylenebilir. nk herhangi bir genelleme yapılmayacađı gibi maddelerin arpıklık ve basıklık deđerleri ± 3 deđerleri arasında olduđundan dolayı, DFA iin uygun olduđu kabul edilmiřtir.

Tablo 5. DFA İçin kullanılan Veri Seti Üzerinden Denemelik ÖYTÖ Maddeleri İçin Bazı İstatistikler

	Ortalama	S. Sapma	Çarpıklık	Çarpıklık İçin S. Hata	Basıklık	Basıklık İçin S. Hata
Madde1	4,21	0,79	-1,32	0,12	2,69	0,24
Madde2	4,48	0,61	-1,19	0,12	2,97	0,24
Madde3	3,60	1,19	-0,55	0,12	-0,61	0,24
Madde4	3,62	0,83	-0,36	0,12	0,01	0,24
Madde5	2,95	0,97	0,03	0,12	-0,30	0,24
Madde6	3,81	0,94	-0,66	0,12	0,11	0,24
Madde7	3,81	0,91	-0,66	0,12	0,28	0,24
Madde8	3,66	0,81	-0,87	0,12	0,97	0,24
Madde9	3,76	0,79	-0,32	0,12	-0,21	0,24
Madde10	3,94	0,83	-0,93	0,12	1,11	0,24
Madde11	3,49	0,79	-0,22	0,12	0,31	0,24
Madde12	3,47	0,81	-0,48	0,12	0,40	0,24
Madde13	3,72	0,81	-0,29	0,12	-0,03	0,24
Madde14	3,28	0,90	-0,20	0,12	-0,37	0,24
Madde15	4,08	0,72	-1,16	0,12	2,92	0,24
Madde16	3,67	0,83	-0,96	0,12	1,06	0,24
Madde17	3,65	0,91	-0,49	0,12	0,02	0,24
Madde18	3,35	0,95	-0,43	0,12	-0,28	0,24
Madde19	3,31	0,95	-0,46	0,12	-0,23	0,24
Madde20	3,63	0,89	-0,61	0,12	0,21	0,24
Madde21	3,60	0,88	-0,60	0,12	0,03	0,24
Madde22	3,61	0,93	-0,71	0,12	0,26	0,24
Madde23	3,95	0,83	-0,92	0,12	1,22	0,24
Madde24	3,43	1,00	-0,34	0,12	-0,46	0,24
Madde25	3,50	0,97	-0,50	0,12	-0,13	0,24
Madde26	3,91	0,71	-0,84	0,12	1,50	0,24
Madde27	3,67	0,81	-0,72	0,12	1,15	0,24
Madde28	3,49	0,92	-0,46	0,12	0,06	0,24
Madde29	3,71	0,87	-0,78	0,12	0,70	0,24
Madde30	3,66	0,94	-0,58	0,12	0,14	0,24

Her üç alt probleme ait bulgular çerçevesinde oluşan ölçek boyutları, LISREL9.2 paket programı aracılığıyla yapılan DFA ile incelenerek karşılaştırılmıştır. Ortaya çıkan yol analizi sonuçlarındaki hata ve uyum indeksleri karşılaştırılarak yorumlanmıştır. Kullanılan DFA yöntemini ve sayıtlarını daha

iyi anlamak ve sonuçlarını değerlendirebilmek amacıyla ynteme dair kısa bir giriř tanıtımı yapılabilir.

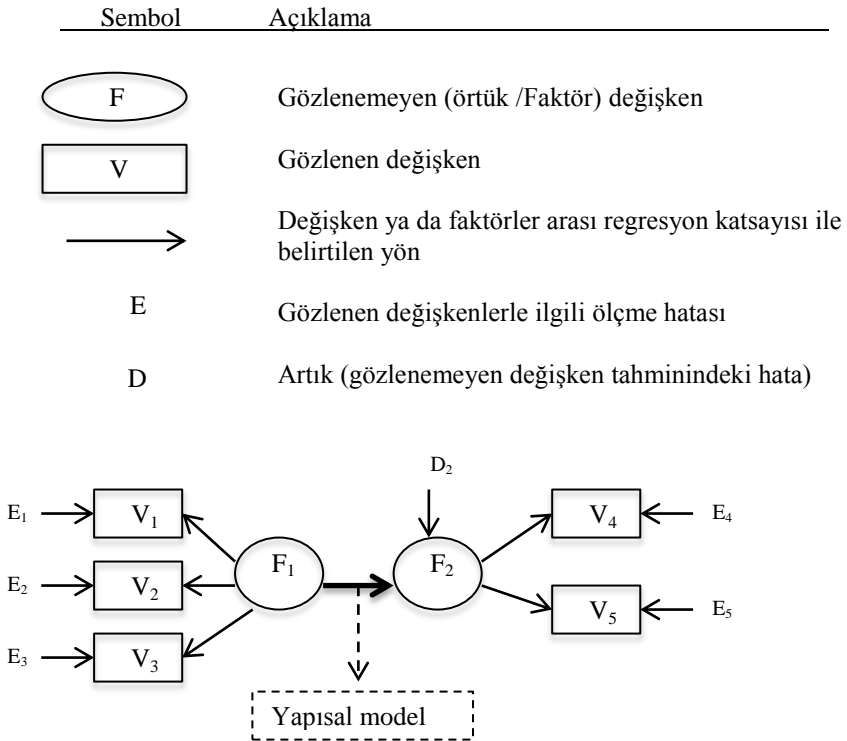
DFA ve yapısal eřitlik modeli birbirine yakın yntemlerdir. Ancak yapısal eřitlik modelinde, lme modeli ve yapı modeli bir arada iken, DFA’da yalnızca lme modeli test edilir. Yapısal eřitlik modeli, istatistiksel tekniklerin bir araya gelerek bir ya da daha fazla bağımsız deęiřken ile bir ya da daha fazla bağımlı deęiřken arasındaki iliřkileri belirlemek zere kullanılan bir modeldir. Bu modeldeki analizlerin amacı, bir modeli test etmek ya da birbiri ile iliřkili modeller dizisini test etmektir. Yapısal eřitlik modeli tahminleri ok deęiřkenli normallik sayılıtı altında yapılır. Ayrıca, deęiřkenler arasında doęrusal iliřkiler incelenir (Ullman, 2001). Yapısal eřitlik modelinin uygulanmasındaki en kritik konu, oluřturulan modelin olduka saęlam bir teorik alt yapıya sahip olmasıdır (Dursun ve Kocagz, 2010).

Yapısal eřitlik modelinde, veri setinden elde edilen kovaryans matrisi ile, modelin rettięi tahmini evren kovaryans matrisi karřılařtırılarak; model tarafından retilen tahmini evren kovaryans matrisinin gzlenen kovaryans matrisi ile tutarlı olup olmadıęı sorusu cevaplanır (Ullman, 2001).

Tahmini kovaryans matrisini oluřturmak iin yn katsayıları ve bağımsız deęiřkenlerin varyans-kovaryanslarından oluřan parametreler tahmin edilir. Elde edilen kovaryans matrisi, veri setinden elde edilen matrise yakınsa, model kabul edilir. Matrislerin birbiri ile karřılařtırılması ki-kare testi ile deęerlendirilir.

Sadece gzlenen deęiřkenlerden oluřan veri setinden modelin parametreleri oluřturulmalıdır. Bu grev matematiksel bir modelle yerine getirilir. EQS programında bu model, Bentler ve Weeks (1979, 1980; akt Byrne, 1994) tarafından yapılan alıřmalardan tretilmiřtir. EQS bilgisayar programındaki sembollerle yapısal eřitlik modeli incelenecek olursa, Őekil 14’te grldęu gibi,

modelin şematik gösteriminde yön diyagramları (path diagrams) terimi kullanılır (Byrne, 1994).




Şekil 14. EQS Yapısal Eşitlik Modeli

Yukarıda verilen şekil 14'te $V_1, V_2, V_3, V_4, V_5, F_2$ bağımlı değişkenler ve $E_1, E_2, E_3, E_4, E_5, F_1, D_2$ bağımsız değişkenlerdir. Gözlenen değişkenler ve faktörler arası bağlantılar, yine faktörler arası tek yönlü bağlantılar, regresyon katsayılarını temsil eder. Örneğin V_1 'in yordayıcısı F_1 'dir ve basit regresyon eşitliğinde (29) gösterilir. Burada b_{11} bilinmeyen ve tahmin edilmesi gereken β ağırlığıdır.

$$V_1 = b_{11}F_1 + E_1 \quad (29)$$

Bu işlem diğer bağımlı değişkenler için de yapılarak ağırlıklar hesaplanır. Böylece yön katsayılarını veren ağırlıkların ve bağımsız değişkenler arasındaki varyans-kovaryans matrisinin tahmin edilmesi ile model uyum iyiliği testine tabi tutulur. Eğer model geçerlenemezse bunun nedeni, gözlenen değişkenlerdeki ölçme hatalarının büyüklüğü ya da model ile ispatlanmaya çalışılan teorinin geçersizliği olabilir.

DFA'nde yapısal bir model bulunmamaktadır. Yalnızca ölçme modeli mevcuttur. Şekil 15'te her biri üç sürekli değişken / faktör göstergesi tarafından ölçülen ve birbirleriyle ilişkisi bulunan iki faktörlü bir model görünmektedir.



Şekil 15. DFA'da Bir Model Örneği

Özellikle ölçme araçlarının faktör yapısının, psikolojik kuramlar ya da uygulamalı araştırmalarla ortaya çıkarılabilmesi, DFA'nin kullanılmasını önemli kılmaktadır. Yapısal eşitlik modeli daha çok örtük yapılar arasında nedensel ilişkiyi araştıran modeller ile ilgili iken; DFA, denence olarak ortaya konan yapının veri seti ile iyi bir uyum gösterip göstermediğini belirler (Holtzman ve Vezzu,

2011). DFA yapılırken bazı adımlar izlenir. Birinci adım, geçerliği belirlenecek modelin belirlenmesidir. Daha sonra test etmek üzere veri toplanır. Eğer model açılımlayıcı faktör analizi ile belirlenmiş ise DFA için farklı bir veri seti kullanılır ya da veri seti tesadüfi olarak ikiye ayrılarak ve biri açılımlayıcı faktör analizi için diğeri DFA için kullanılır.

Her bir faktörün, yeterli madde sayısı ile temsil edilmesi (overdetermination) için madde ve faktör oranına bakmak gereklidir (Preacher & MacCallum, 2002; akt: Holtzman ve Vezzu, 2011). Her bir faktörde en az üç madde bulunması önemlidir yoksa zayıf ve kararsız olur (Anderson & Rubin, 1956; akt: Holtzman ve Vezzu, 2011). Bunun yanısıra, modelde sadece bir adet böyle bir faktörün bulunması kabul edilebilir bir durumdur (Costello & Osborne, 2005; akt: Holtzman ve Vezzu, 2011). DFA için örnek büyüklüğünün yeterli olup olmadığı da incelenmesi gereken bir durumdur. Bununla ilgili çeşitli ölçütler bulunmakla birlikte, ortak bir kural olarak, madde başına 10 birey önerilir (Everitt, 1975; akt: Holtzman ve Vezzu, 2011). Bu demektir ki 30 madde için 300 birey üzerinden veri toplanmalıdır. Model ve örnek büyüklüğü sayıltıları karşılandığında kayıp veri için tüm veri setinin incelenmesi gerekir. Ayrıca, uç değerler, çok değişkenli normallik ve yüksek ilişkililik (collinearity) gibi sayıltıların da kontrol edilmesi gerekmektedir (Holtzman ve Vezzu, 2011).

Elde edilen DFA sonuçlarında, uyumun olup olmadığı, Ki kare uyum istatistiği ve farklı açıdan geliştirilen birçok uyum ve hata indeksleri üzerinden incelenir. Marsh, Balla ve Hau (1996), araştırmacılara hangi uyum indekslerinin değerlendirileceğine karar vermede bazı kriterler önerir. Bunlar örneklem büyüklüğüne yönelik hassasiyet, karmaşık modelleri cezalandırma, basit modeli ödüllendirme ve güvenilirlik tahminidir. Karşılaştırma için seçilen uyum indeksleri Ki kare uyum indeksi (X_M^2), yaklaşımın ortalama karekök hata tahmini (RMSEA), uyum iyiliği indeksi (GFI), uyumlaştırılmış uyum iyiliği indeksi (AGFI),

normlaştırılmış uyum indeksi (NFI), normlaştırılmamış uyum indeksi (NNFI) ve karşılaştırmalı uyum indeksidir (CFI).

X_M^2 uyum istatistiği örneklem büyüklüğü ve yüksek korelasyonlara karşı duyarlı bir testtir (Kline, 2005). Ayrıca X_M^2 uyum istatistiği, serbestlik derecesi ile birlikte değerlendirilir. Serbestlik derecesi, örnek modelden gelen varyans ve kovaryans sayısı ile tahmin edilen evren parametrelerinin sayısı arasındaki farktır. X_M^2 istatistiği kullanmak için gerekli olan sayıtların ihlali durumunda karar için Ullman (2001), sayısal uyum ölçümlerini önerir. X_M^2 uyum istatistiğini değerlendirmek için, elde edilen değer serbestlik derecesine oranının kullanılması önerilir. Çıkan sonuç 2, 3 ya da 5'e kadar kabul edilebilir bir uyumu simgeler. Ancak Ullman (2001), bu oranın model uyumu için kaba bir gösterge olduğunu belirtir.

RMSEA aslında bir hata indeksi olup, uyumun kötülüğünün bir göstergesidir. Örneklemin büyüklüğünü dikkate alarak basit modeli ödüllendiren bir indekstir. Hata yaklaşım miktarını verdiği için bu değer ne kadar düşük çıkarsa, uyum iyiliğine o kadar ulaşıldığı anlamını verir. Hesaplanan değer 0,05'den küçük olması beklenir; ancak 0,05-0,08 arasındaki değerleri de kabul edilebilir bir uyumu sergiler (Kline, 2001).

GFI, çoklu regresyon modelindeki R^2 ile benzerlik gösterir ve modelin basitliğinden etkilenir (Kline, 2001; Ullman, 2001). Diğer bir deyişle modelde tahmin edilen parametre sayısı azalırsa uyum derecesi artar. GFI değerinin 0,9'dan büyük olması iyi bir uyumun göstergesidir (Kline, 2001). AGFI ise, modelin basitliğinden kaynaklı etkiyi düzeltir.

NFI ve NNFI iki artmalı (incremental) uyum indeksidir. İkisi arasındaki temel fark NFI, 0 ve 1 arasında değer alırken NNFI bu değerlerin dışına çıkabilir. Her ikisi için de iyi bir uyumun ölçütü 0,90'dan yüksek olmalarıdır. NFI örneklem büyüklüğünden ve model karmaşıklığından etkilenir. NNFI ise karmaşık

modellerden ya da modelin basitliđinden ve örneklem büyüklüğünden etkilenmez. Ayrıca, model belirsizliklerindeki farklılıđı da yansıtabilir. Bu açılardan NNFI, başarılı bir artmalı indeks olarak görülebilir (Marsh ve Diđ., 1996).

CFI, oldukça sık kullanılan bir indekstir. Diđer artmalı indeksler gibi CFI'nin yokluk hipotezi, deđişkenler arasındaki evren kovaryanslarının 0 olması şeklindedir. 0,90'nın üzerinde bir CFI deđeri iyi bir uyum iyiliđi ölçütü olarak kabul edilebilir (Kline, 2001).

BÖLÜM IV

BULGULAR

Bu bölümde araştırma problemlerine yanıt vermek amacıyla yöntem başlığı altında verilen analizlerin uygulanması ile elde edilen bulgulara yer verilmiştir. Bulgular alt problemlere göre başlıklandırılarak yorumlanmıştır.

4.1. Birinci Alt Probleme İlişkin Bulgular

1. Denemelik ÖYTÖ'nin yapısı, TBA sonuçlarına göre nasıldır?

TBA analizi 1 maddenin diğer maddelerle ilişkisizlik göstermebi nedeni ile 29 madde üzerinden yapılmıştır. Tablo 6'ya göre denemelik ölçekteki 29 madde üzerinden 5 bileşenli bir yapı ortaya çıktığı görülmektedir. Kaiser ölçütüne göre özdeğerleri 1'in üzerinde olan 5 bileşenin açıkladığı varyans %55,11'dir.

Tablo 6. TBA Sonucunda Bileşenlerce Açıklanan Toplam Varyans

Bileşen	Başlangıç Özdeğerleri			İndirgeme Sonrası Özdeğerler		
	Toplam	Varyans Yüzdesi	Yığmal Varyans Yüzdesi	Toplam	Varyans Yüzdesi	Yığmal 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 7’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 7. 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, 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 8'e 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 8. 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		

4.2. İkinci Alt Probleme İlişkin Bulgular

2. Denemelik ÖYTÖ'nin yapısı, GHA kullanan yapay sinir ağı modeli sonuçlarına göre nasıldır?

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 (Ek 3). 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 ulaşılamadığı görülmüştür.

Yapılan deneme çalışmasında madde sayısının eta değerinin 0,005 iken maksimum 17 adet madde için sonuç bulunduğu 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 ($0 \times \infty$, $0/0$, ∞/∞ 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, özvektörler matris çıktısı vermektedir. Özvektörler 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 ile yapılan TBA karşılaştırmaların döndürme öncesi bulgular üzerinden olması gerekir.

Bu araştırma probleminde dikkat edilmesi gereken nokta, bu yazılım için kullanılması gereken verilerin standartlaştırılmış olması gerekliliğidir. Normalde

Likert tipi bir ölçekten elde edilen ham veriler için TBA yapılırken SPSS korelasyon matrisi kullanır ve bu matrisden özvektör ve özdeğerler 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 ağdan çıkan özvektör matrisi (V) (Ek 4-Tablo 18) ve devrik hali (V'), standartlaştırılmamış ham veri seti kullanılarak SPSS üzerinden elde edilen korelasyon matrisi (C) (Ek 4-Tablo 20) ile çarpılarak özdeğerler matrisi (L) elde edilmiştir ($L= V'CV$) (Ek 4-Tablo 19). Daha sonra faktör yüklerinin (A) hesaplanması için özvektör matrisi, özdeğerler matrisinin karekökü ile çarpılmıştır ($A=V\sqrt{L}$) (Ek 4-Tablo 21). TBA sonuçları ile karşılaştırmak 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. Bu analizler için kullanılan matrisler Ek 4'te verilmiştir.

Tablo 9'da 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.

Tablo 9. GHA Sonucunda Bileşenlerce Açıklanan Toplam Varyans

Bileşen	Başlangıç Özdeğerler			İndirgeme Sonrası Özdeğerler		
	Toplam	Varyansın Yüzdesi	Yığılmış Varyansın Yüzdesi	Toplam	Varyansın Yüzdesi	Yığılmış 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			

Maddelere bileşenlere verilen faktör yüklerine bakıldığında, 1. maddenin hiç bir bileşene yük vermediği görülmektedir (Tablo 10). 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 10. 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 10'da görüldüğü gibi 8. madde ile 1. bileşenin ilişkisini veren faktör yükü 1'den büyük çıkmıştır (1,019). Ağdan çıkan özvektör matrisi ile SPSS'den çıkan korelasyon matrisi kullanılarak hesaplanan özdeğerler matrisinin

diagonal olmayan birimleri 0'dan büyük çıkabilmektedir (Ek 4). 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 özvektör matrisi olmakla birlikte; Sagner (1989), GHA'dan çıkan özvektörlerin tam değil, yaklaşık değerler olduğunu belirtir.

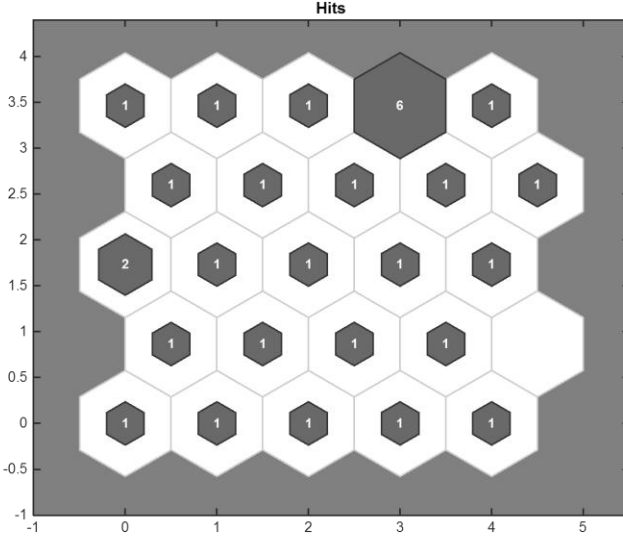
4.3. Üçüncü Alt Probleme İlişkin Bulgular

3. Denemelik ÖYTÖ'nin yapısı, KDH yapan yapay sinir ağı modeli sonuçlarına göre nasıldır?

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 16'da 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 kümelenmiştir.




Şekil 16. 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. 25 adet nöron üzerinde yalnızca iki nöron üzerinde madde kümelenmesi görülmektedir; 11 nolu nöronda 1. ve 2. maddeler, 24 nolu nöronda ise 9., 22., 25., 26., 27. ve 30. maddeler bulunmaktadır (Tablo 11). Buna göre 5x5 KDH üzerinden yapılan yapay sinir ağı ÖYTÖ yapısını, TBA terminolojisi üzerinden, 8 maddeli iki bileşenli bir yapı olarak ortaya koymuştur.

Tablo 11. 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 kümelenme ve madde sayısı Şekil 17’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 17. 4x4 Nöron Üzerinden KDH Çıktısında Sınıflandırılan Madde Sayıları

Tablo 12'ye 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 KDH 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 2), tutum ifadelerinin öğretmenlere değil ancak öğretmenlik mesleğine yönelik tutum ifadeleri olduğu görülmektedir.

Tablo 12. 4x4 Nöron Üzerinden KDH Çıktısında Maddelerin Norönlara 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 13). KDH kendi içinde değerlendirildiğinde, 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 13. 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

4.4. Dördüncü Alt Probleme İlişkin Bulgular

4. Denemelik ÖYTÖ için farklı yöntemlerle elde edilen yapıların, doğrulayıcı faktör analizinden elde edilen uyum ve hata indeksleri açısından sonuçları nasıldır?

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.

4.a. TBA’nde döndürme öncesi ortaya çıkan denemelik ÖYTÖ’nin yapısı ile GHA kullanan yapay sinir ağı modeli sonucu ortaya çıkan yapısının uyum ve hata indeksleri nasıldır?

GHA kullanan yapay sinir ağı modelinden çıkan ÖYTÖ’nin yapısı, TBA işlemi sonucu döndürme öncesinde ortaya çıkan ÖYTÖ yapısı karşılaştırıldığında, her iki yapının birbiri ile oldukça benzer olduğu söylenebilir (Tablo 14). 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 analiz 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 bunun ikisinin (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 14. Döndürme Öncesi TBA ve GHA Sonuçlarında Maddelerin Bileşenlere Dağılımı

Bileşen	TBA Döndürme Öncesi (28 Madde)	GHA (29 Madde)
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, 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
3. Bileşen	4	4
4. Bileşen	6	6
5. Bileşen	21	21

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 çıkmıştır. Bunun bir çok nedeni olabilir. Heywood vakaları olarak geçen bazı durumlar, gözlenen verilerden oluşan örnek kovaryans matrisi ile parametre tahminlerinin oluşturduğu modele ait evren kovaryans matrisinin 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 değişkenin bulunması, kötü başlangıç değerleri, aşırı düşük ya da yüksek evren korelasyon değerleri gibi durumlar sayılabilir (Kline, 2005).

İki sonucun verdiği yapı, DFA uyum istatistikleri üzerinden karşılaştırıldığında da birbirine yakın değerler verdiği görülmektedir (Tablo 15). 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 15). 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 15. Döndürme Öncesi TBA ve GHA'dan Ortaya Çıkan ÖYTÖ Yapısının DFA Uyum ve Hata İndeksleri

<i>Uyum İndeksleri</i>	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

4.b. TBA’nde döndürme sonrası ortaya çıkan denemelik ÖYTÖ’nin yapısı ile KDH yapan yapay sinir ağı modeli sonucu ortaya çıkan yapısının uyum ve hata indeksleri nasıldır?

Döndürmeli TBA’dan çıkan ölçek yapısı 5 bileşenli bir yapıdır (Tablo 16). 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.

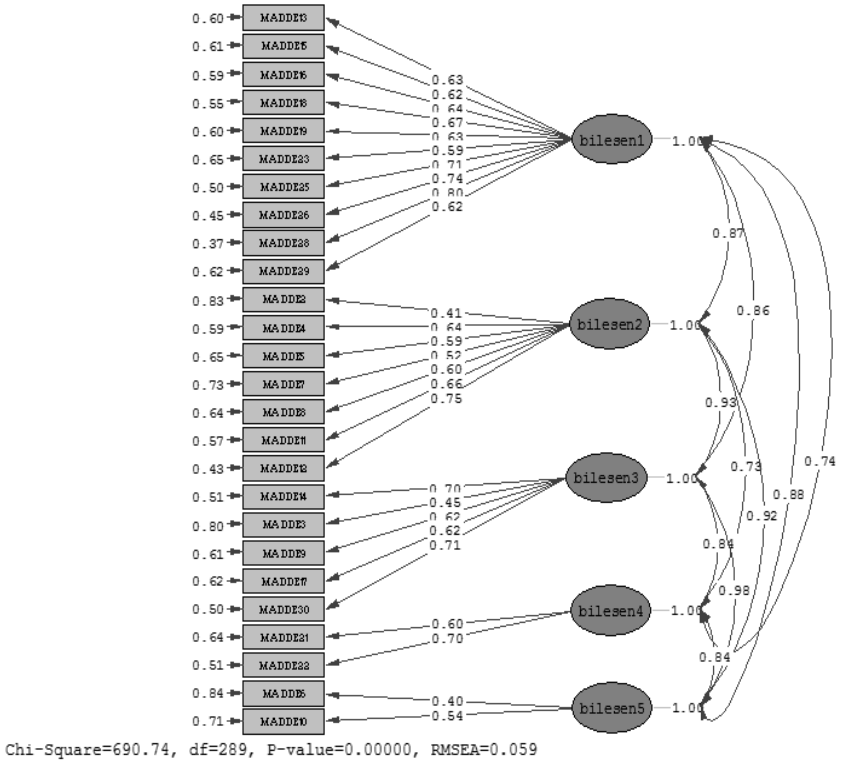
Tablo 16. Döndürme Sonrası TBA ve KDH Sonuçlarına Göre Maddelerin Bileşenlere Dağılımı

Bileşen	Döndürme TBA (26 Madde)	Sonrası	5x5 Nöronlu KDH (8 Madde)	4x4 Nöronlu KDH (16 Madde)
1. Bileşen	13, 15, 16, 18, 19, 23, 25, 26, 28, 29		9, 22, 25, 26, 27, 30	9, 10, 11, 12, 13, 16, 17, 19, 20, 22, 23, 25, 27, 30
2. Bileşen	2, 4, 5, 7, 8, 11, 12, 14		1, 2	1, 2
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). 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 madde maddeden oluşmuştur.

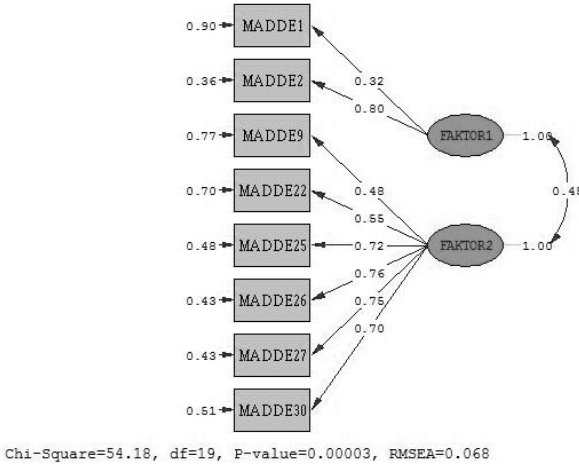
Analizlerin yön diyagramları incelenecek olursa, Döndürme sonrası TBA sonucu çıkan yapıda bileşenlerde ortak maddeler bulunmamaktadır. Ancak Şekil 18’de görüldüğü üzere faktörler arası korelasyon oldukça yüksek bu da iraksaklık açısından yapı geçerliğinin düşük olduğu anlamına gelebilir. Değişkenlerin çoğunun faktör yüklerinin 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. faktör ise faktör yükleri ölçütün üzerinde olmakla birlikte, iki maddeli bir faktör olduğu için zayıf bir yapıdır.



Şekil 18. Döndürme Sonrası TBA Sonucunda Ortaya Çıkan ÖYTÖ Yapısının Yön Diyagramı

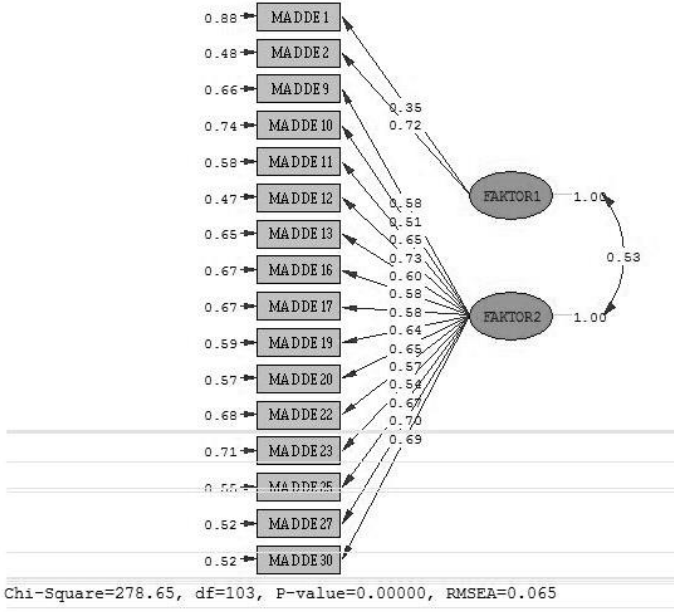
İki bileşenli 8 maddeden oluşan 5x5 nöronlu KDH modeli sonucunda çıkan ölçek yapısı için yön diyagramı incelendiğinde, iraksaklık açısından yapı geçerliğinin faktörler arası korelasyonun 0,45 olması nedeni ile kabul edilebilir olduğu söylenebilir (Şekil 19). Yakınsaklık açısından 2. faktörde 6 maddeden 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 19. KDH Modelinde 5x5 Nöron Üzerinden Ortaya Çıkan ÖYTÖ Yapısının Yön Diyagramı

4x4 nöronlu KDH modeli sonucunda çıkan ölçek yapısı için yön diyagramı incelendiğinde (Şekil 20), iraksaklık 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 çıkamamıştır; bunun da yakınsaklığı düşüren bir sonuç olduğu söylenebilir.



Şekil 20. KDH Modelinde 4x4 Nöron Üzerinden Ortaya Çıkan ÖYTÖ Yapısının Yön Diyagramı

Tablo 17 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 uyum indekslerine göre ise döndürmeli TBA modeli KDH modellerinden daha iyi uyum göstermektedir ($X_M^2 / sd=2,25$, RMSEA=0,057, NNFI=0,98). Ancak RMSEA dışındaki tüm indeksler

5x5 nöronlu KDH modelinin, ölçütlerin oldukça üstünde, daha kabul edilebilir bir yapı ortaya çıkardığı söylenebilir.

Tablo 17. Döndürme Sonrası TBA ve KDH'dan Ortaya Çıkan ÖYTÖ Yapısının DFA Uyum ve Hata İndeksleri

<i>Uyum İndeksleri</i>	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)
χ^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

BÖLÜM V

TARTIŞMA VE YORUM

Bu bölümde araştırmanın alt problemlerine göre ortaya çıkan bulgular yorumlanarak, elde edilen sonuçlar vurgulanmıştır. Ayrıca bütüncül bir değerlendirme yapılarak bu araştırma kapsamında ele alınacak ileriki araştırmalara öneriler sunulmuştur.

Yapay sinir ağlarının veri analizleri amacıyla kullanarak kuvvetli sonuçlar elde edildiğini göstermeye yönelik bir çok çalışma bulunmaktadır. Regresyon, yapısal eşitlik modeli, varyans analizi, faktör analizi, kümeleme analizi gibi bir çok istatistiksel yöntemlerden elde edilen bulguların, yapay sinir ağı modelleri üzerinden de elde edilebileceğine ve bir takım avantajlar getirdiğine yönelik çalışmalar, dikkat çekici çalışmaları arasındadır.

Bu araştırmanın temel amacı, tutum ölçeği geliştirme çalışmalarında kullanılan istatistiksel analiz yöntemlerinden biri olan TBA ile aynı amaç 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 verilmektedir.

İlk olarak bir tutum ölçeği geliştirme çalışması yapılmış ve bu amaçla hazırlanan 30 maddelik ÖYTÖ, 400 kişilik çalışma grubuna uygulanmıştır. Elde

edilen veriler üzerinden ölçek yapısı, TBA ile incelenmiştir. Bu incelemede özellikle döndürme öncesi yapı ve döndürme sonrası yapıya ait bulgular verilmiştir. Çünkü araştırmamanın ilgilendiği yapay sinir ağı modellerinden birisi olan GHA kullanan yapay sinir ağı modeli, döndürme öncesi bileşenleri ortaya koyabilmektedir. Dolayısıyla iki yapay sinir ağı modelinden birisi olan ve TBA yerine kullanılabilen GHA yapay sinir ağı modeli sonuçları, döndürme öncesi TBA sonuçları ile karşılaştırılmıştır. Faktör analizi yerine kullanılan, kendini düzenleyen haritalama yapabilen yapay sinir ağı modeli olan KDH'dan çıkan sonuçlar ise, döndürme sonrası TBA sonuçları ile karşılaştırılmıştır.

Buna göre döndürme öncesi elde edilen 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 aynıdır. Yine ortak olarak, 1. madde her iki analizden çıkan yapıda da yoktur.

Farklı analizlerden elde edilen ölçek yapılarının karşılaştırılabilmesi uyum indeksleri üzerinden yapılmaktadır. Bunun için DFA uygulanmıştır. Bu analiz için aynı çalışma grubundan yine aynı sayıda (400) elde edilen ikinci bir veri seti kullanılmıştır. 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, ağın ortaya çıkardığı sonuç bir özvektör matrisidir. Dolayısıyla GHA, pratik olarak, özdeğerleri ve bileşen-madde ilişkisini (faktör yükleri) vermediğinden ötürü özdeğerlerin, açıklanan varyansın ve bileşen-madde ilişkilerinin hesaplanması ve TBA sonuçları ile karşılaştırılabilir hale getirilmesi gerekmektedir. Diamantaras (2002) veriler sonlu ve az boyutlu ise ayrıca kovaryans matrisi elde edilebiliyor ise klasik özdeğer çözümlemesinin, 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.

Bu işlemlerin sonuç verebilmesi için ölçekten elde edilen ham verilerin standartlaştırılmış olması gerekmektedir. Çünkü bu çalışmada özvektörleri elde etmek için korelasyon matrisi kullanılmıştır. Ham verilerin bileşen analizi için standartlaştırılmış kovaryans matrisi olan korelasyon matrisinden çıkan özvektör sonuçları, ancak standartlaştırılmış verileri işleyen GHA ağı çıktısı özvektörü ile aynı sonucu vermektedir. Sagner (1989, s. 463) optimum düzeyi anlatırken, x için, korelasyon matrisi bulunan 0 ortalamalı veri olarak tanımlar.

GHA sonuçlarında ortaya çıkan bir sorun vardır. GHA'ndan ortaya çıkan özvektör matrisi (V) ile elde edilen özdeğerler matrisindeki ($L=V'CV$) diagonal 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 özvektörlere yaklaşık sonuçlar

verebileceğini ve ilk birkaç özvektörün bulunmasındaki hata, geri kalan özvektörleri 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 birkaç özvektöre 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 tanımda GHA'nın TBA'ya göre daha iyi, görüntü sıkıştırımda ise TBA'nın GHA'ya göre daha iyi sonuç verdiğini belirtir.

Araştırmanın diğer bir parçası ise yapay sinir ağı yerine kullanılan KDH modeli 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 indirgemede sonuca götüren bir öğrenme algoritmasına sahiptir.

KDH analizi yapabilmek için, sonucun kaç nöronluk bir katmanda haritalamak istenildiğine karar verilmesi gerekmektedir. Çünkü bu bilginin analizin başlangıcında girilmesi gerekir. 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 çıktılarından 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 önemli 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 araştırmada KDH'nın, döndürme sonrası TBA sonuçlarına göre daha kullanışlı olduğu ortaya çıkmıştır.

Bunun yanısıra 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), hücresele üretim araştırmalarında, TBA'da açıklanan varyansın yüksek olduğu ancak daha büyük boyutlu hücresele oluşumlarda KDH'nın daha iyi sonuç verdiğini ve görsel sınıflandırma sonuçları verebilmesi nedeni ile gelecek çalışmalar açısından önemli bir katkı sağladığını belirtir. Görselle ilgili vurgu, Peeters ve Dassargues (2006) tarafından da ifade edilir ve KDH'nın görselliği nedeni ile

sonuları yorumlama gcnden bahsedilir. TBA'nın avantajının ise matematiksel olarak bileşenlerin tespiti ve ilişkilerin görlebilmesi olduėu belirtilir.

Bu araştırma sonularına dayanarak oluşturulan çeşitli öneriler aşıėıda maddeler halinde verilmiştir. Buna göre 1. madde aė algoritması geliştirme alıřması ile ilgili olmakla birlikte, diėerleri gerek veri ya da simülasyon zerinden uygulamalı olarak incelenebilecek alıřmalardır:

1. GHA ncelikle kullanılabilirlik aısından zellikle bileşen belirlemede dndrme iřlevini saėlayabilecek bir ikinci aė yapısı ile desteklenebilir.
2. TBA ve GHA kullanım sayıltıları aısından incelenebilir. TBA iin deėişkenlerin lek tr, deėişkenlerin normal daėılım gstermesi, deėişkenler arası ilişkilerin doėrusallıėı ve rneklem byklė gibi konularda n kořulları vardır. GHA'nın bu kořullara karřı dayanıklılıėı incelenebilir.
3. KDH, kendi iinde inceleneceėi gibi, diėer faktr analizi teknikleri ile kařılařtırmalı olarak incelenebilir.
4. KDH ayrıca kmeleme analizi ile karřılařtırmalı olarak incelenebilir.
5. KDH ile ilgili olarak, zellikle gzlenen deėişkenler zerinden rtk yapının belirlenmesi alıřmaları iin, gerekli olan nron sayısı ve deėişken sayısı ilişkisinin ortaya ıkarılmasına ynelik temel ve uygulamalı alıřmalar yapılabilir.
6. lek tr, normallik, doėrusal ve doėrusal olmayan iliřki biimleri, minimum rneklem sayısı gibi sayıltılar aısından KDH'nın kullanım dayanıklılıėının belirlenmesine ynelik alıřmalar yapılabilir.
7. KDH'nın genelleme alıřmalarında kullanılabilirliėi simülasyon zerinden alıřılabilir.
8. Faktr sınırlandırması yapılarak, TBA, GHA ve KDH sonuları karřılařtırmalı olarak incelenebilir.

9. Boyutları ve madde sayısı belirlenmiş nihai bir ölçek üzerinden yapay sinir ağı modellerinin karşılaştırması çalışılabilir.

KAYNAKLAR

- Anastasi, A. (1988). *Psychological Testing*. New York: Macmillan Publishing Company.
- Ataseven, B. (Ocak 2013). Yapay Sinir Ağları ile Öngörü Modellemesi. *Öneri Dergisi*, 10(39); 101-115. [Online]: http://e-dergi.marmara.edu.tr/index.php/oneri/article/download/.../pdf_137 adresinden 15 Nisan 2013 tarihinde alınmıştır.
- 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*. Yayınlanmamış Yüksek Lisans Tezi. Mimar Sinan Güzel Sanatlar Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Bayındır, R. ve Sesveren, Ö. (2008). YSA Tabanlı Sistemler İçin Görsel Bir Arayüz Tasarımı. *Pamukkale Üniversitesi Mühendislik Fakültesi Mühendislik Bilimleri Dergisi*, 14(1), 101-109.
- Bayır, F. (2006). *Yapay Sinir Ağları ve Tahmin Modellemesi Üzerine Bir Uygulama*. Yayınlanmamış Yüksek Lisans Tezi. İstanbul Üniversitesi, Sosyal Bilimler Enstitüsü, İstanbul.
- Becker, S. (1991). Unsupervised Learning Procedures for Neural Networks. *The International Journal of Neural Systems*, 1(2), 17-33.
- Bogdan, R. C. ve Biklen, S. K. (1998). *Qualitative Research for Education*. Boston: Allyn and Bacon.
- Bryliuk, D. ve Starovoitov, V. (2001). Application of Recirculation Neural Network and Principal Component Analysis for Face Recognition. The 2nd

International Conference on Neural Networks and Artificial Intelligence, 2, 136-142, [Online]: [http:// www. research gate.net/publication/228398705_ Applicakion_of_recirculation_neural_network_and_principal_component_analysis_for_face_recognition](http://www.researchgate.net/publication/228398705_Applicakion_of_recirculation_neural_network_and_principal_component_analysis_for_face_recognition) adresinden 13 Aralık 2013 tarihinde indirilmiştir.

Byrne, B. M. (1994). *Structural Equation Modeling with EQS and EQS/Window*. California: SAGE Publication, Inc.

Chakraborty, R.C. (2010). Fundamentals of Neural Networks. [Online]: http://www.myreaders.info/08_Neural_Networks.pdf adresinden 15 Nisan 2013 tarihinde indirilmiştir.

Chattopadhyay, M., Dan, P. K. ve Majumdar, S. (2011). Principal Component Analysis and Self Organizing Map for Visual Clustering of Machine-Part Cell Formationin Cellular Manufacturing System [Abstract]. [Online]: <http://arxiv.org/pdf/1201.5524.pdf> adresinden 19 Mart 2015 tarihinde indirilmiştir.

Cohen, R.J., Montague, P., Nathanson L.S. ve Swerdlik, M.E. (1988). *Psychological Testing*. Mountain View: Mayfield Publishing Company.

Cronbach, L.J. (1984). *Essentials of Psychological Testing*. New York: Harper & Row Publishers Inc.

DeVellis, R.F. (2003). *Scale Developmert Theory and Applications*. Thousand Oaks: SAGE Publications.

Diamantaras, K.I. (2002). Neural Networks and Principal Component Analysis. In Y.-H. Hu, J.-N. Hwang (Eds), *Handbook of Neural Networks for Signal Processing* (p. 8. 1-37). Boca Raton: CRC Press.

- Downing, S.M. (2003). Validity: on the Meaningful Interpretation of Assessment Data. *Medical Education*, 37, 830-837.
- Dursun Y., Kocagöz, E. (2010). Yapısal Eşitlik Modellemesi ve Regresyon: Karşılaştırmalı Bir Analiz. *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 35, 1-17.
- Elmes, D. G., Kantowitz, B. H. ve Roediger III, H. L. (1992). *Research Methods in Psychology*. St. Paul: West Publishing Company.
- Fancourt, C.L. ve Principe, J.C. (1998). Competitive Principal Component Analysis for Locally Stationary Time Series. *IEEE Transactions on Signal Processing*, 46(11), 3068-3081.
- Field, A. (2009). *Discovering Statistics Using SPSS*. London: SAGE Publications Inc.
- Francis, L. (2001). Neural Network Demystified. 2001 Winter Forum Ratemaking Discussion Papers and Data Management/Data Quality/ Data Technology Call Papers. [Online]: www.cacact.org./pubs/forum/01wforum/01wf253.pdf adresinden 25 Ağustos 2015 tarihinde indirilmiştir.
- Fritzke, B. (1995). A Growing Neural Gas Network Learns Topologies. In Tesauro, G., Touretzky, D.S., and Leen, T.K. (eds.), *Advances in Neural Information Processing System 7*. [Online]: <http://web.cs.swarthmore.edu/~meeden/DevelopmentalRobotics/fritzke95.pdf> adresinden 15 Nisan 2013 tarihinde indirilmiştir.
- Gallistel, C. R. (1999). Reinforcement Learning. *Massachusetts Institute of Technology Journal of Cognitive Neuroscience*, 11(1), 126-134. [Online]: https://www.academia.edu/1139850/Reinforcement_learning adresinden 18 Nisan 2015 tarihinde indirilmiştir.
- Guilford, J.P. (1954). *Psychometric Methods*. New York: McGraw-Hill Company.

- Haykin, S. (1999). *Neural Network-A Comprehensive Foundation*. New Jersey: Prentice Hall, Inc.
- Holtzman, S. ve Vezzu, S. (2011). Confirmatory Factor Analysis and Structural Equation Modeling of Noncognitive Assessments Using PROC CALIS. [Online]: <http://www.lexjansen.com/nesug/nesug11/sa/sa07.pdf> adresinden 15 Haziran 2015 tarihinde indirilmiştir.
- Hu, Y.H. (2001). ghademo.m - Generalized Hebbian Learning Demonstration. [Online]:https://svn.ssec.wisc.edu/repos/willem.marais.msthesis/examples/Hebbian%20Learning/m_scripts/ghademo.m adresinden 15 Kasım 2014 tarihinde indirilmiştir.
- Jain, A.K., Mao, J. ve Mohuiddin, K.M. (1996). Artificial Neural Network: A Tutorial. [Online [http:// web.cs.swarthmore.edu/~meeden/](http://web.cs.swarthmore.edu/~meeden/)]: [https:// artificial-intelligence-programming.googlecode.com](https://artificial-intelligence-programming.googlecode.com) adresinden 18 Nisan 2013 tarihinde indirilmiştir.
- Jamal M. Nazzal, J.M., El-Emary, I.M. ve Najim, S.A. (2008). Multilayer Perceptron Neural Network (MLPs) For Analyzing the Properties of Jordan Oil ShaleWorld. *Applied Sciences Journal* 5(5), 546-552.
- Kalaycı, Ş. (2014). *SPSS Uygulamalı Çok Değişkenli İstatistik Teknikleri*. Ankara: Asil Yayın Dağıtım Ltd. Şti.
- Kane, M.T. (2006). Validation. In R. L. Brennan (Eds), *Educational Measurement* (p. 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.
- Kramer, M.A. (1991). Nonlinear Principle Component Analysis Using Autoassociative Neural Networks. *AIChE Journal*, 37(2), 233-243.
- Krenker, A., Bestř, J. ve Kos, A. (2011). Introduction to the Artificial Neural Networks. In K. Suzuki (Eds.), *Artificial Neural Networks- Methodological Advances and Biomedical Applications* (p. 3-18). [Online]: http://cdn.intechopen.com/pdfs/14881/InTech-introduction_to_the_artificial_neural_networks.pdf adresinden 18 Nisan 2013 tarihinde indirilmiştir.
- Kulkarni, A.D. (1994). *Artificial Neural Networks for Image Understanding*. New York: Van Nostrand Reinhold.
- Kumar, S., Kumawat, T., Marwal, N.K. ve Singh, B.K. (2013) Artificial Neural Network and its Applications. *International Journal of Computer Science and Management Research*, 2(2), 1621-1626.
- Lee C., Rey T., Mentele J., Garver M. (2004). Structured neural network techniques for modeling loyalty and profitability. *SUGI 30 Proceedings*, [Online]: <http://www2.sas.com/proceedings/sugi30/082-30.pdf> adresinden 15 Ekim 2013 tarihinde indirilmiştir.
- Marsh, H.W., Balla, J.R. ve Hau, K. (1996). An Evaluation of Incremental Fit Indices: A Clarification of Mathematical and Empirical Properties. In G.A. Marcoulides ve R.E. Schumacker (Eds.), *Advanced Structural Equation*

Modeling Issues and Tecnniques (p. 315-353). New Jersey: Lawrence Erlbaum Associates

McClelland, J.L. (2015). Explorations in Parallel Distributed Processing: A Handbook of Models, Programs, and Exercises. [Online]: <https://web.stanford.edu/group/pdplab/pdphandbook/handbookch7.html> adresinden 20 Ağustos 2015 tarihinde indirilmiştir.

Messick, S. (1994). Validity of Psychological Assessment: Validation of Inferences From Persons' Responses and Performances as Scientific Inquiry Into Score Meaning. *Research Report*. Princeton: Educational Testing Service.

Miller, M.D., Linn, R.L., Gronlund, N.E. (2009). *Measurement and Assessment in Teaching*. New Jersey: Pearson Education

Mohamad-Saleh, J. ve Hoyle, B.S. (2008). Improved Neural Network Performance Using Principle Component Analysis on Matlab. *International Journal of the Computer, the Internet, and Management*, 16(2), 1-8.

Murphy, K.R. ve Davidshofer, C.O. (2001). *Psychological Testing Principles and Applications*. New Jersey: Prentice Hall Inc.

Narain, S. ve Jain, A. (2005) Evaluation of The Sensitivity of Learning Rate on The Training of Neural Network Hydrologic Models [Abstract]. *American Geophysical Union, Fall Meeting*. [Online]: <http://adsabs.harvard.edu/abs/2005AGUFM.H53F0538N> adresinden 19 Nisan 2013 tarihinde indirilmiştir.

Neural Network Fundamentals, (t.y.). [Online]: <http://ube.eg.edu.tr/~cinsdiki/UBI521/Chapter-1> adresinden 10 Nisan 2013 tarihinde indirilmiştir.

- Pdp Handbook. (t.v.). Training Hidden Units: The Generalized Delta Rule. [Online]: http://www.stanford.edu/group/pdplab/original_pdphandbook/chapter%205.pdf adresinden 15 Nisan 2013 tarihinde indirilmiştir.
- 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. [Online]: <http://ulg.ac.be/handle/2268/3388> adresinden 19 Mart 2015 tarihinde indirilmiştir.
- 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* (p. 214-219). Cairo: IEEE.
- Sengupta, S. (2009) Artificial Neural Networks. *Ders notları*, Indian Institute of Technology [Online]: www.youtube.com/playlist=PLi-bxY2I4hXxf7vZKF2EcanZzWr-I7Pm adresinden 5 Nisan 2013 tarihinde indirilmiştir.
- Stanley, K.O. ve Miikkulainen, R. (2002). *Efficient Reinforcement Learning through Evolving Neural Network Topologies*. Paper presented at the Genetic and Evolutionary Computation Conference, San Francisco, CA.
- Sun, X., Deng, J., Gong, Q., Wang, Q., Yang, L., Zhao, Z. (2009). Kohonen Neural Network and Factor Analysis Based Approach to Geochemical Data Pattern Recognition. *Journal of Geochemical Exploration*, 103(2009), 6-16.
- Sutton, R.S. ve Barto, A. G. (2000). Learning to Maximize Rewards: A Review of Reinforcement Learning: An Introduction. *Neural Networks*, 13(1), 135-137.
- Şen, Z. (2004). *Yapay Sinir Ağları İlkeleri*. İstanbul: Su Vakfı Yayınları.

- Takçı, H. (2010). *Yapay Sinir Ağları ve Uygulamaları*. Ders notları. [Online]: http://htakci.sucati.org/YSA/index_dosyalar/ adresinden 16 Nisan 2013 tarihinde indirilmiştir.
- Tabachnick, B.G. ve Fidell, L.S. (2001). *Using Multivariate Statistics*. Boston: Allyn and Bacon.
- Tepehan, T. (2011). *Türk Öğrencilerinin PISA Başarılarının Yordanmasında Yapay Sinir Ağı ve Lojistik Regresyon Modeli Performanslarının Karşılaştırılması*, Yayımlanmamış Doktora Tezi. Hacettepe Üniversitesi, Sosyal Bilimler Enstitüsü, Ankara.
- Tezbaşaran, A. A. (1997a). *Likert Tipi Ölçek Geliştirme Klavuzu*. Ankara: Türk Psikologlar Derneği Yayınları.
- Tezbaşaran, A. A. (1997b). Validity Issues of Likert Type Scales (ACase Study). *Hacettepe Üniversitesi Eğitim Fakültesi Dergisi*, 13, 41-45.
- Thompson, B. (2005). *Exploratory and Confirmatory Factor Analysis*. Washington: American Psychological Association.
- Tolon, M. ve Tosunoğlu, N.G., (2012). Tüketici Tatmini Verilerinin Analizi: Yapay Sinir Ağları Ve Regresyon Analizi Karşılaştırması. [Online]: <http://www.metehantolon.com/wp-content/uploads/2012/04/tuketici-tatmini-verilerinin-analizi-yapay-sinir-aglari-regresyon-analizi-karsilastirmasi.pdf> adresinden 18 Nisan 2013 tarihinde indirilmiştir.
- Ullman, J. B. (2001). Structural Equation Modeling. In B.G. Tabachnick and L.S. Fidell (Eds.), *Using Multivariate Statistics* (p. 653-771). Boston: Allyn & Bacon.
- Warner, B. ve Misra, M. (1996). Understanding Neural Networks as Statistical Tools. *The American Statistician*, 50(4), 284-293.

- Xu, L. ve Yuille, A. (1992). Self Organizing Rules for Robust Principal Component Analysis. [Online] :<http://papers.nips.cc/paper/686-self-organizing-rules-for-robust-principle-component-analysis> adresinden 20 Nisan 2015 tarihinde indirilmiştir.
- Yegnanarayana, B. (1999). *Artificial Neural Networks*. London: Prentice Hall, Inc.
- Yenikaya, G. (2006). *Sürücü Davranışlarının Modellenmesine Bilişsel Mimari Yaklaşımı*, Yayınlanmamış Doktora Tezi. Uludağ Üniversitesi, Fen Bilimleri Enstitüsü, Bursa.
- Yurtoğlu, H. (2005). *Yapay Sinir Ağları Metodolojisi İle Öngörü Modellemesi: Bazi Makroekonomik Değişkenler İçin Türkiye Örneği*, Yayınlanmış Uzmanlık Tezi. Devlet Planlama Teşkilatı, Ankara.
- Zekić-Sušac, M., Šarlija, N., Pfeifer S. (2013). Combining PCA Analysis on Artificial Neural Networks in Modelling Entrepreneurial Intentions of Students. *Coration Operational Research Review*, 4, 306-317.
- Zeller, R.A. (1988). Validity. In J. P. Keeves (Eds.), *Educational Research, Methodology, and Measurement*, (p. 322-330). New York: Pergamon Press.

EKLER

Ek 1. Aktivasyon Fonksiyonları ve Grafik Gösterimi


Sinyal (Signal)

Fonksiyonu:

$$\text{Sgn}(V_k) = y_k$$

Eğer $V_k \geq 0$ ise $y_k = +1$

Eğer $V_k < 0$ ise $y_k = -1$




Eşik (Threshold)

Fonksiyonu:

$$j(V_k) = y_k$$

Eğer $V_k \geq 0$ ise $y_k = +1$

Eğer $V_k < 0$ ise $y_k = 0$




Sigmoid Fonksiyonu:

Doğrusal olmayan ve monotonik artan sigmoid fonksiyonu

$$j(v_k) = \frac{1}{1 + \exp(-av)}$$


a : Eğrinin eğimi ($a \rightarrow \infty$ ise fonksiyon eşik fonksiyonuna yaklaşır.)



Tanjant Hiperbolik

Fonksiyonu:

$$j(v_k) = \tanh(v) = \frac{\exp(v) + \exp(-v)}{\exp(v) - \exp(-v)}$$



Ek 2. Denemelik Öğretmenlere Yönelik Tutum Ölçeği

AÇIKLAMA:	Hiç katılmıyorum	Katılmıyorum	Kararsızım	Katılıyorum	Tamamen katılıyorum
Aşağıda, ilkokul, ortaokul ve lise öğretmenleri düşünülerek hazırlanmış 30 madde bulunmaktadır. Bu maddelere ilişkin görüşünüzü belirtmek için herbir ifadenin karşısındaki uygun bulduğunuz seçeneğe X işareti koyunuz.					
1. Öğretmenler ülkenin geleceğini belirler.					
2. Öğretmenler saygıyı hakeder.					
3. Öğretmenler eğitimin kalitesini olumsuz etkiler.					
4. Öğretmenler mesleklerinde fedakardırlar.					
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 modeldir.					
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.					

Ek 3. GHA için Kullanılan MATLAB Komut Dosyası

```
% ghademo.m - generalized Hebbian learning demonstration
% call ghafun.m, randomize.m
% (C) 2001 by Yu Hen Hu
% created: 2/25/2001

clear all

% generate data samples
% K=15; M=3; N = 2;
% K=input('dimension of feature space = ');
% M=input(['# of training vectors (size of cov matrix <' int2str(K) ') = ']);
x=xlsread('OYTO1 GHA Z.xlsx');
[K, M]=size(x);
N=input(['# of principal component vectors, (<' int2str(M) ') = ']);
disp('the randomly generated covariance matrix is:');
C = (x'*x)/(K-1);
[V,D]=eig(C);
% load x
% eigenvalue /eigenvector of covariance matrix
[Dsort,eidx]=sort(diag(-D)); % sort eigenvalue from largest to smallest
V=V(:,eidx); % sort eigenvector accordingly
yexact=x*V(:,1:N); % desired output if exact principal components are there

% beginning of the algorithm
winit=randn(N,M)*0.05; eta=0.001; (Bu arařtırmada 0.005 olan deęer 0.001
olarak dzenlenmiřtir.)

itermax=500;
w=ghafun(x,winit,itermax,eta,5);

% to compare with the principal components computed using eigenvalue
% decomposition, we first normalize each row of w:
disp(['first ' int2str(N) ' columns: true principal componenet vectors']);
disp(['last ' int2str(N) ' columns: estimated principal component vectors']);
Trueest=[V(:,1:N) w'];

function w=ghafun(x,winit,itermax,eta,dp)
% Usage: w=ghafun(x,winit,itermax)
% generalized Hebbian Learning Algorithm for PCA
```

```

% Sanger, T. D., "Optimal unsupervised learning
% in a single layer linear feed-forward neural
% network", Neural Networks, vol. 12, pp. 459-473, 1989.
% (C) 2001 copyright by Yu Hen Hu
% created: 2/25/2001
% x: K by M data matrix. Each row is a data sample
% w, winit: N by M weight matrix.
% eta: learning rate. default = 0.005
% itermax: maximum number of iterations. default = 500. Each iteration
% entire set of data x will be used once.
% dp = 0 (default, do not display intermediate result)
% >0 will display new w matrix after each dp iteration

if nargin<5,
    dp=0; %default do not display intermediate result
end

if nargin<4,
    eta=0.001; % default value (Bu arařtırmada 0.005 olan deęer 0.001 olarak
düzenlenmiřtir.)
end
if nargin<3,
    itermax=500;
end
[K,M]=size(x);
[N,M]=size(winit);
w=winit;

iter=0; done=0;

while done==0,
    iter=iter+1;
    x=randomize(x); % randomize order of presenting x
    for i=1:K,
        y=w*x(i,:); % y is N by 1
        u=[];
        for j=1:N,
            u=[u; y(j)*(x(i,:)-y(1:j)'*w(1:j,:))];
        end
        wold=w;
        w=wold+eta*u; % updated weight matrix
    end
end

```

```

% display intermediate result if desire
if dp>0,
    if mod(iter,dp)==0, % for every dp iteration
        disp(['iteration count = ' int2str(iter) ', and W is: ']);
        disp(w)
        pause(0.1)
    end
end
end
if iter==itermax,
    done=1;
end
end
end

```

```

function [B,I]=randomize(A,rowcol)
% Usage: [B,I]=randomize(A,rowcol)
% randomize row orders or column orders of A matrix
% rowcol: if =0 or omitted, row order (default)
%     if = 1, column order
% copyright (C) 1996-2001 by Yu Hen Hu
% Last modified: 8/30/2001

```

```

rand('state',sum(100*clock))
if nargin == 1,
    rowcol=0;
end
if rowcol==0,
    [m,n]=size(A);
    p=rand(m,1);
    [p1,I]=sort(p);
    B=A(I,:);
elseif rowcol==1,
    Ap=A';
    [m,n]=size(Ap);
    p=rand(m,1);
    [p1,I]=sort(p);
    B=Ap(I,:);
end
end

```

Ek 4. GHA Sonuçları için Kullanılan Veri Matrisleri

Tablo 18. GHA Sonucu Elde Edilen Özvektörler matrisi (30x30)

0,09	-0,41	0,21	0,30	-0,29	0,23	-0,04	0,04	0,02	0,23	0,23	-0,07	0,32	0,03	-0,28	-0,13	-0,30	0,13	-0,18	-0,08	0,05	-0,03	-0,08	-0,16	-0,17	0,07	-0,20	-0,03	-0,02	0,01
0,14	-0,21	0,36	0,15	-0,02	0,10	0,12	0,34	0,04	0,26	-0,39	0,20	-0,15	-0,41	0,19	0,00	0,24	0,13	0,20	0,11	-0,06	-0,01	-0,04	-0,04	0,16	0,02	-0,05	-0,05	-0,02	0,02
0,11	0,34	0,19	0,03	-0,51	-0,11	-0,19	-0,18	-0,12	0,21	0,10	0,20	-0,15	0,15	0,24	-0,17	-0,17	0,03	0,16	0,27	0,02	0,31	-0,08	-0,05	0,01	0,00	0,05	0,16	0,09	-0,04
0,18	-0,04	0,40	-0,21	-0,03	0,14	0,02	-0,07	0,12	-0,15	-0,09	0,00	0,31	0,39	0,35	0,02	0,16	0,05	-0,19	0,00	0,37	-0,14	0,24	0,07	0,19	0,06	0,00	-0,07	0,10	0,02
0,17	0,04	0,21	-0,52	-0,04	0,11	-0,11	0,22	0,07	-0,07	0,43	0,29	-0,19	-0,15	-0,14	0,41	-0,04	-0,26	-0,07	0,04	0,13	-0,21	-0,26	0,01	0,03	-0,09	-0,02	0,06	-0,08	-0,09
0,13	-0,04	0,09	0,59	0,05	0,03	-0,12	0,09	-0,38	-0,29	-0,01	0,02	0,02	0,22	-0,10	0,42	0,17	-0,14	0,07	0,05	0,04	0,23	0,06	0,01	0,00	0,01	0,15	-0,06	-0,02	0,00
0,18	0,19	0,28	0,15	0,11	0,01	0,16	-0,14	-0,11	-0,14	0,08	-0,19	-0,27	-0,03	-0,18	-0,28	0,16	-0,11	0,00	0,02	-0,07	-0,41	0,06	-0,26	-0,09	0,25	0,03	0,32	0,23	0,05
0,23	-0,05	0,11	-0,02	0,05	0,30	0,33	-0,26	0,40	-0,28	-0,09	-0,05	0,05	0,00	-0,01	0,17	-0,27	-0,09	0,31	0,06	-0,26	0,27	0,07	-0,09	-0,04	-0,09	-0,03	0,18	-0,07	-0,18
0,19	0,24	0,25	0,12	0,04	-0,13	0,09	-0,01	-0,07	-0,11	-0,09	-0,09	-0,22	0,00	-0,07	-0,27	-0,26	-0,04	-0,12	-0,21	0,03	-0,07	-0,02	0,06	0,10	-0,33	-0,03	-0,48	-0,31	-0,27
0,16	0,10	-0,09	0,23	0,31	-0,44	0,11	0,04	0,20	0,18	0,06	-0,09	0,09	-0,07	0,00	0,15	-0,31	0,05	0,05	0,28	0,40	-0,01	0,06	-0,01	0,20	0,17	-0,19	0,16	-0,12	0,03
0,20	-0,03	0,21	-0,19	0,25	-0,23	-0,02	0,21	-0,04	-0,04	0,00	0,03	0,10	0,26	-0,22	-0,12	-0,03	0,27	0,07	-0,17	-0,17	0,22	-0,23	-0,02	0,11	-0,32	0,12	0,26	0,06	0,38
0,21	-0,05	0,13	-0,18	0,29	-0,11	-0,12	0,08	0,02	0,19	0,08	-0,03	0,11	0,06	0,00	-0,10	0,03	-0,15	0,00	-0,08	-0,20	0,30	-0,12	0,08	-0,12	0,58	0,23	-0,21	0,04	-0,33
0,17	-0,28	-0,05	-0,04	0,03	0,00	-0,11	0,03	-0,18	-0,02	0,19	-0,39	-0,24	0,01	0,46	-0,01	0,07	0,10	0,01	-0,17	0,03	0,05	-0,03	0,10	-0,16	-0,05	-0,16	0,55	-0,36	-0,12
0,21	-0,13	0,05	-0,07	0,28	0,13	-0,21	-0,21	-0,13	0,12	-0,01	-0,01	-0,08	-0,04	0,13	-0,04	-0,19	-0,28	0,01	0,33	-0,18	-0,05	0,14	0,21	-0,20	-0,13	-0,20	-0,26	0,11	0,46
0,19	-0,25	-0,01	0,05	-0,09	-0,29	-0,07	-0,16	0,22	-0,02	0,24	-0,07	0,07	-0,26	-0,04	-0,08	0,22	0,04	0,23	0,04	0,19	-0,05	0,17	0,11	-0,21	-0,32	0,43	-0,10	0,23	-0,12
0,20	-0,21	-0,12	-0,03	-0,17	-0,03	-0,03	-0,21	0,15	-0,13	0,09	-0,03	-0,31	-0,15	-0,20	-0,08	0,18	-0,03	-0,39	-0,01	-0,01	0,38	0,12	-0,02	0,47	0,13	-0,08	-0,04	0,01	0,18
0,17	0,31	0,08	0,07	-0,18	-0,19	-0,17	-0,13	0,12	0,08	-0,06	-0,14	0,33	-0,18	-0,08	0,19	0,28	-0,08	0,04	-0,28	-0,25	-0,06	-0,04	0,30	0,01	-0,03	-0,44	0,06	0,06	-0,01
0,23	-0,06	-0,15	-0,09	-0,05	0,07	-0,29	-0,24	0,10	-0,20	-0,32	0,03	-0,05	0,10	-0,23	-0,07	0,17	0,16	0,27	0,12	0,29	-0,11	-0,42	-0,08	-0,15	0,17	-0,08	-0,13	-0,25	0,07
0,20	0,05	-0,11	-0,16	-0,11	-0,07	-0,36	0,32	0,05	-0,14	-0,11	0,13	-0,09	0,01	-0,12	0,04	-0,17	0,16	0,14	-0,14	-0,09	-0,06	0,64	-0,23	-0,14	0,12	-0,09	0,00	-0,06	-0,01
0,22	0,08	-0,14	0,06	0,05	0,10	-0,33	-0,06	0,05	0,14	-0,36	-0,07	0,21	-0,18	0,11	0,04	-0,12	-0,25	-0,38	-0,02	-0,03	-0,07	-0,10	-0,30	0,08	-0,19	0,35	0,26	-0,04	-0,08
0,12	0,23	-0,20	0,19	0,32	0,42	-0,22	0,01	0,06	0,00	0,37	0,15	0,12	-0,04	0,08	-0,21	0,16	0,36	0,06	0,14	-0,11	-0,03	0,01	-0,01	0,24	-0,11	-0,07	-0,04	0,02	-0,18
0,18	0,22	-0,20	0,17	-0,02	0,33	0,09	0,27	0,28	0,17	-0,05	-0,06	-0,24	0,10	0,01	-0,07	-0,04	-0,14	0,03	-0,35	0,34	0,15	-0,04	0,26	-0,19	0,02	0,07	0,02	0,24	0,20
0,20	-0,16	-0,22	0,20	-0,22	-0,15	0,06	0,19	0,19	-0,22	-0,05	0,16	-0,03	0,22	0,13	-0,09	-0,16	0,03	-0,11	0,16	-0,36	-0,36	-0,14	0,41	0,10	0,14	0,16	0,07	0,00	-0,01
0,17	0,16	-0,11	-0,21	-0,24	0,16	0,20	0,33	-0,09	0,14	0,03	-0,30	0,16	0,07	-0,21	-0,01	0,17	-0,09	0,07	0,43	-0,05	0,01	0,08	0,01	0,08	-0,07	0,11	-0,09	-0,21	0,04
0,19	0,04	-0,12	-0,11	0,04	-0,03	0,25	0,10	-0,23	-0,21	-0,17	0,25	0,11	-0,15	-0,09	-0,13	0,07	0,10	-0,36	0,24	0,14	0,21	0,00	0,14	-0,39	-0,10	-0,24	0,15	0,17	-0,25
0,19	-0,05	-0,26	0,05	-0,06	-0,16	0,25	0,10	-0,02	-0,05	0,17	0,28	0,22	0,09	0,25	-0,23	0,19	-0,42	0,15	-0,15	-0,01	0,02	-0,07	-0,42	0,01	-0,04	-0,17	-0,13	-0,12	0,15
0,20	0,07	-0,06	-0,10	-0,07	0,15	0,22	-0,23	-0,40	0,03	0,03	0,21	0,22	-0,28	-0,07	-0,01	-0,16	0,08	0,14	-0,24	0,11	-0,07	0,13	0,27	0,12	0,21	0,29	0,11	-0,26	0,21
0,22	-0,16	-0,23	-0,16	-0,06	0,02	0,02	0,01	-0,33	-0,02	-0,09	-0,20	-0,03	0,00	0,04	0,12	-0,24	0,04	0,23	-0,11	0,05	-0,10	-0,16	-0,09	0,33	-0,04	-0,15	-0,12	0,57	-0,22
0,15	-0,13	-0,14	-0,02	0,07	0,00	0,17	-0,25	-0,03	0,55	-0,09	0,23	-0,20	0,42	-0,21	0,18	0,20	0,02	-0,03	-0,04	-0,08	-0,15	0,16	0,00	-0,01	-0,15	-0,03	0,07	-0,09	-0,22
0,19	0,19	-0,06	0,00	-0,07	-0,06	0,23	-0,10	0,05	0,03	0,09	-0,08	-0,07	-0,07	0,24	0,39	0,00	0,45	-0,24	-0,04	-0,16	-0,04	-0,13	-0,29	-0,26	0,09	0,13	-0,31	0,05	0,23

Tablo 20. Madde-Madde Korelasyon Matrisi (30x30)

1,00	0,33	0,07	0,23	0,15	0,25	0,14	0,22	0,13	0,07	0,18	0,19	0,30	0,24	0,35	0,30	0,07	0,17	0,13	0,17	0,04	0,10	0,29	0,11	0,11	0,17	0,18	0,23	0,22	0,09	
0,33	1,00	0,11	0,33	0,27	0,26	0,30	0,28	0,31	0,20	0,34	0,34	0,31	0,32	0,32	0,27	0,18	0,22	0,25	0,26	0,08	0,22	0,28	0,18	0,29	0,22	0,24	0,25	0,26	0,23	
0,07	0,11	1,00	0,24	0,25	0,14	0,30	0,12	0,39	0,15	0,17	0,18	0,10	0,17	0,16	0,18	0,42	0,22	0,27	0,24	0,14	0,23	0,18	0,26	0,20	0,18	0,29	0,15	0,16	0,34	
0,23	0,33	0,24	1,00	0,40	0,19	0,39	0,43	0,40	0,20	0,45	0,44	0,35	0,40	0,33	0,31	0,32	0,35	0,32	0,33	0,16	0,22	0,26	0,28	0,35	0,27	0,33	0,30	0,27	0,35	
0,15	0,27	0,25	0,40	1,00	0,15	0,35	0,33	0,36	0,22	0,43	0,45	0,31	0,40	0,33	0,36	0,31	0,32	0,43	0,30	0,23	0,29	0,27	0,33	0,37	0,30	0,36	0,34	0,26	0,37	
0,25	0,26	0,14	0,19	0,15	1,00	0,35	0,20	0,34	0,28	0,24	0,22	0,28	0,29	0,25	0,24	0,26	0,25	0,23	0,29	0,25	0,24	0,32	0,13	0,28	0,26	0,24	0,26	0,20	0,25	
0,14	0,30	0,30	0,39	0,35	0,35	1,00	0,40	0,62	0,37	0,43	0,44	0,32	0,42	0,34	0,36	0,42	0,35	0,31	0,35	0,32	0,35	0,27	0,34	0,41	0,32	0,41	0,31	0,30	0,45	
0,22	0,28	0,12	0,43	0,33	0,20	0,40	1,00	0,39	0,28	0,35	0,38	0,30	0,42	0,37	0,42	0,29	0,40	0,28	0,34	0,24	0,36	0,35	0,28	0,37	0,33	0,39	0,35	0,31	0,42	
0,13	0,31	0,39	0,40	0,36	0,34	0,62	0,39	1,00	0,43	0,51	0,46	0,32	0,43	0,34	0,37	0,48	0,36	0,41	0,43	0,28	0,42	0,35	0,34	0,46	0,35	0,44	0,37	0,29	0,49	
0,07	0,20	0,15	0,20	0,22	0,28	0,37	0,28	0,43	1,00	0,41	0,44	0,28	0,37	0,41	0,30	0,37	0,29	0,32	0,39	0,29	0,34	0,36	0,24	0,37	0,38	0,29	0,32	0,34	0,44	
0,18	0,34	0,17	0,45	0,43	0,24	0,43	0,35	0,51	0,41	1,00	0,62	0,41	0,44	0,41	0,36	0,35	0,40	0,46	0,36	0,24	0,26	0,34	0,32	0,48	0,36	0,37	0,43	0,37	0,40	
0,19	0,34	0,18	0,44	0,45	0,22	0,44	0,38	0,46	0,44	0,62	1,00	0,47	0,58	0,45	0,43	0,39	0,43	0,45	0,47	0,30	0,34	0,34	0,35	0,46	0,42	0,42	0,45	0,42	0,42	
0,30	0,31	0,10	0,35	0,31	0,28	0,32	0,30	0,32	0,28	0,41	0,47	1,00	0,52	0,50	0,50	0,22	0,40	0,38	0,38	0,22	0,28	0,41	0,30	0,37	0,40	0,36	0,57	0,36	0,39	
0,24	0,32	0,17	0,40	0,40	0,29	0,42	0,42	0,43	0,37	0,44	0,58	0,52	1,00	0,45	0,45	0,30	0,47	0,40	0,52	0,35	0,29	0,35	0,27	0,45	0,37	0,44	0,51	0,46	0,36	
0,35	0,32	0,16	0,33	0,33	0,25	0,34	0,37	0,34	0,41	0,41	0,45	0,50	0,45	1,00	0,56	0,35	0,46	0,39	0,37	0,17	0,22	0,47	0,25	0,38	0,46	0,36	0,43	0,38	0,38	
0,30	0,27	0,18	0,31	0,36	0,24	0,36	0,42	0,37	0,30	0,36	0,43	0,50	0,45	0,56	1,00	0,31	0,50	0,42	0,42	0,22	0,32	0,48	0,31	0,46	0,43	0,40	0,49	0,43	0,42	
0,07	0,18	0,42	0,32	0,31	0,26	0,42	0,29	0,48	0,37	0,35	0,39	0,22	0,30	0,35	0,31	1,00	0,37	0,39	0,46	0,28	0,36	0,29	0,37	0,34	0,32	0,39	0,28	0,26	0,48	
0,17	0,22	0,22	0,35	0,32	0,25	0,35	0,40	0,36	0,29	0,40	0,43	0,40	0,47	0,46	0,50	0,37	1,00	0,48	0,50	0,30	0,35	0,43	0,31	0,45	0,37	0,40	0,51	0,40	0,39	
0,13	0,25	0,27	0,32	0,43	0,23	0,31	0,28	0,41	0,32	0,46	0,45	0,38	0,40	0,39	0,42	0,39	0,48	1,00	0,47	0,29	0,39	0,44	0,38	0,45	0,39	0,37	0,47	0,30	0,41	
0,17	0,26	0,24	0,33	0,30	0,29	0,35	0,34	0,43	0,39	0,36	0,47	0,38	0,52	0,37	0,42	0,46	0,50	0,47	1,00	0,37	0,44	0,39	0,35	0,44	0,39	0,42	0,46	0,37	0,44	
0,04	0,08	0,14	0,16	0,23	0,25	0,32	0,24	0,28	0,29	0,24	0,30	0,22	0,35	0,17	0,22	0,28	0,30	0,29	0,37	1,00	0,43	0,21	0,23	0,30	0,28	0,32	0,22	0,22	0,34	
0,10	0,22	0,23	0,22	0,29	0,24	0,35	0,36	0,42	0,34	0,26	0,34	0,28	0,29	0,22	0,32	0,36	0,35	0,39	0,44	0,43	1,00	0,37	0,42	0,37	0,38	0,33	0,33	0,34	0,43	
0,29	0,28	0,18	0,26	0,27	0,32	0,27	0,35	0,35	0,36	0,34	0,34	0,41	0,35	0,47	0,48	0,29	0,43	0,44	0,39	0,21	0,37	1,00	0,30	0,44	0,51	0,31	0,45	0,35	0,40	
0,11	0,18	0,26	0,28	0,33	0,13	0,34	0,28	0,34	0,24	0,32	0,35	0,30	0,27	0,25	0,31	0,37	0,31	0,37	0,31	0,38	0,35	0,23	0,42	0,30	0,42	0,34	0,37	0,43	0,27	0,41
0,11	0,29	0,20	0,35	0,37	0,28	0,41	0,37	0,46	0,37	0,48	0,46	0,37	0,45	0,38	0,46	0,34	0,45	0,45	0,44	0,30	0,37	0,44	0,42	1,00	0,50	0,55	0,50	0,38	0,49	
0,17	0,22	0,18	0,27	0,30	0,26	0,32	0,33	0,35	0,38	0,36	0,42	0,40	0,37	0,46	0,43	0,32	0,37	0,39	0,39	0,28	0,38	0,51	0,34	0,50	1,00	0,44	0,48	0,40	0,42	
0,18	0,24	0,29	0,33	0,36	0,24	0,41	0,39	0,44	0,29	0,37	0,42	0,36	0,44	0,36	0,40	0,39	0,40	0,37	0,42	0,32	0,33	0,31	0,37	0,55	0,44	1,00	0,53	0,41	0,48	
0,23	0,25	0,15	0,30	0,34	0,26	0,31	0,35	0,37	0,32	0,43	0,45	0,57	0,51	0,43	0,49	0,28	0,51	0,47	0,46	0,22	0,33	0,45	0,43	0,50	0,48	0,53	1,00	0,44	0,44	
0,22	0,26	0,16	0,27	0,26	0,20	0,30	0,31	0,29	0,34	0,37	0,42	0,36	0,46	0,38	0,43	0,26	0,40	0,30	0,37	0,22	0,34	0,35	0,27	0,38	0,40	0,41	0,44	1,00	0,40	
0,09	0,23	0,34	0,35	0,37	0,25	0,45	0,42	0,49	0,44	0,40	0,42	0,39	0,36	0,38	0,42	0,48	0,39	0,41	0,44	0,34	0,43	0,40	0,41	0,49	0,42	0,48	0,44	0,40	1,00	

