



T.C.  
VAN YÜZÜNCÜ YIL ÜNİVERSİTESİ  
SAĞLIK BİLİMLERİ ENSTİTÜSÜ



**DOĞRUSAL OLMAYAN TEMEL BİLEŞENLER ANALİZİ İÇİN  
YAPAY SİNİR AĞLARI YAKLAŞIMI**

Canan DEMİR  
BİYOİSTATİSTİK ANABİLİM DALI  
(TIP PROGRAMI)  
DOKTORA TEZİ

DANIŞMAN  
Prof. Dr. Sıddık KESKİN

VAN-2019

T.C.  
VAN YÜZÜNCÜ YIL ÜNİVERSİTESİ  
SAĞLIK BİLİMLERİ ENSTİTÜSÜ

**DOĞRUSAL OLMAYAN TEMEL BİLEŞENLER ANALİZİ İÇİN  
YAPAY SİNİR AĞLARI YAKLAŞIMI**

Canan DEMİR  
BİYOİSTATİSTİK ANABİLİM DALI  
(TIP PROGRAMI)  
DOKTORA TEZİ

DANIŞMAN  
Prof. Dr. Sıddık KESKİN

VAN-2019

## KABUL VE ONAY

Van Yüzüncü Yıl Üniversitesi Sağlık Bilimleri Enstitüsü, Biyoistatistik (Tıp Programı) Anabilim Dalında Canan DEMİR tarafından hazırlanan “*Doğrusal Olmayan Temel Bileşenler Analizi İçin Yapay Sinir Ağları Yaklaşımı*” adlı tez çalışması aşağıdaki jüri tarafından DOKTORA TEZİ olarak OY BİRLİĞİ ile kabul edilmiştir.

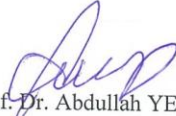
Tez Savunma Tarihi:10/04/2019



Prof. Dr. Sıddık KESKİN

Yüzüncü Yıl Üniversitesi

Jüri Başkanı

  
Prof. Dr. Abdullâh YEŞİLOVA  
Yüzüncü Yıl Üniversitesi

Jüri Üyesi

  
Doç. Dr. Mustafa Ağâh TEKİNDAL  
Selçuk Üniversitesi

Jüri Üyesi

  
Doç. Dr. Serdal Kenan KÖSE  
Ankara Üniversitesi

Jüri Üyesi

  
Dr. Öğr. Üyesi Gürol ZIRHLIOĞLU  
Yüzüncü Yıl Üniversitesi

Jüri Üyesi

Tez hakkında alınan jüri kararı, Van Yüzüncü Yıl Üniversitesi Sağlık Bilimleri Enstitüsü Yönetim Kurulu tarafından onaylanmıştır.



Prof. Dr. Semiha DEDE

Sağlık Bilimleri Enstitüsü Müdürü

## ETİK BEYAN

T.C.  
VAN YÜZÜNCÜ YIL ÜNİVERSİTESİ  
SAĞLIK BİLİMLERİ ENSTİTÜSÜ MÜDÜRLÜĞÜ'NE

Doktora tezi olarak hazırlayıp sunduğum “*Doğrusal Olmayan Temel Bileşenler Analizi İçin Yapay Sinir Ağları Yaklaşımı*” başlıklı tezim; bilimsel ahlak ve değerlere uygun olarak tarafımdan yazılmıştır. Tezimin fikir/hipotezi tümüyle tez danışmanım ve bana aittir. Tezde yer alan deneysel çalışma/araştırma tarafımdan yapılmış olup, tüm cümleler, yorumlar bana aittir. Bu tezdeki bütün bilgiler akademik kurallara ve etik ilkelere uygun olarak hazırlanıp, bu kural ve ilkeler gereği, çalışmada bana ait olmayan tüm veri, düşünce ve sonuçlara atıf yapılmış ve kaynak gösterilmiştir.

Yukarıda belirtilen hususların doğruluğunu beyan ederim.

Öğrencinin Adı Soyadı: Canan DEMİR

Tarih: 10.04.2019

İmza:

## TEŐEKKÜR

Bu tez alıőmasında bana verdiđi destekten dolayı ve yardımını esirgemeyen, danıőman hocam Sayın Prof. Dr. Sıddık KESKİN'e, deđerli katkılarından ve yardımlarından dolayı Prof. Dr. Hayrettin OKUT, Dr. Öğr. Üyesi Murat CANAYAZ ve Dr. Öğr. Üyesi Yıldırım DEMİR'e, bilgi ve birikimlerini esirgemeyen tez izleme komitesi üyelerim Prof. Dr. Abdullah YEŐİLOVA ve Dr. Öğr. Üyesi Gürol ZIRHLIOĐLU'na, ayrıca alıőmalarımda bana her zaman destek olan eőim Prof. Dr. Halit DEMİR, sabır ve anlayıőlarından dolayı ođlum Berken DEMİR ve kızım Eylül Zerin DEMİR'e en içten teőekkürlerimi sunarım.



## ÖZET

**Demir C, Doğrusal Olmayan Temel Bileşenler Analizi İçin Yapay Sinir Ağları Yaklaşımı, Van Yüzüncü Yıl Üniversitesi, Sağlık Bilimleri Enstitüsü, Tıp Fakültesi Biyoistatistik Anabilim Dalı, Doktora Tezi, Van, 2019.** Doğrusal Olmayan Temel Bileşenler Analizi (DOTBA), aralarında doğrusal veya doğrusal olmayan ilişki bulunan veri kümeleri için rakamsal ve görsel sonuçlar veren açıklayıcı bir boyut indirgeme yöntemidir. DOTBA’da, sürekli değişkenlerin yanı sıra, kategorik ve sıralı değişkenler de aynı anda analize dâhil edilebilir. Analizde gözlenen değişkenler arasındaki ilişkilerin doğrusal olduğu varsayımına gerek yoktur. Bu çalışmada DOTBA için yapay sinir ağları yaklaşımı açıklanarak uygulama yapılmıştır. Uygulamada veri seti olarak 422 hastaya ait 19 değişkenli hipotiroidi verisi kullanılmıştır. Yapay sinir ağlarında temel bileşenler analizi ile birlikte yapay sinir ağlarında doğrusal olmayan temel bileşenler analizi kullanılarak elde edilen sonuçlar, tablo ve grafikler halinde sunulmuş ve yorumlanmıştır. İlk iki temel bileşen, DOTBA’ da toplam varyansın %95.65’ini açıklarken, TBA’da %90.08’ini açıklamıştır. Sonuç olarak, DOTBA’nın TBA’ya göre yüksek bir varyans açıklama oranı ile başarılı sonuçlar verdiği ve böylece ileriye dönük yapılacak tahminlerde kullanılabilmesi vurgulanmıştır.

**Anahtar Kelimeler:** Doğrusal Olmayan Temel Bileşenler Analizi, Hipotiroidi, Temel Bileşenler Analizi

## ABSTRACT

**Demir C, Approach Artificial Neural Network for Nonlinear Principal Components Analysis, Van Yuzuncu Yil University, Institute of Health Sciences, Medical Faculty Department of Biostatistics, PhD Thesis, Van, 2019.** Nonlinear Principal Component Analysis (NLPCA) is one of the explanatory dimension reducing technique and presents numerical and graphical results for variable set included linear or nonlinear relationships. Nonlinear Principal Component Analysis, categorical and ordinal variables as well as numerical variables can be included to analysis. Linearity assumption for observed variables does not need for Nonlinear Principal Component Analysis. In this study, artificial neural network approach for NLPCA was explained and applied. The hypothyroid data with 19 variables from 422 patients were used in the application. The results obtained using Principle Component Analysis (PCA) together with NLPCA were interpreted by presenting in tables and graphics. The first two principle components explained 95.65% of the total variance in the NLPCA, while they explained 90.08% of the total variance in the PCA. As a result, it was emphasized that NLPCA gives satisfactory results with a high variance explanation rate compared to PCA and thus it can be used for future predictions.

**Key Words:** Hypothyroid, Nonlinear Principal Components Analysis, Principal Components Analysis

## İÇİNDEKİLER

KABUL VE ONAY.....	II
ETİK BEYAN.....	III
TEŞEKKÜR.....	IV
ÖZET.....	V
ABSTRACT.....	VI
İÇİNDEKİLER.....	VII
SİMGELER VE KISALTMALAR.....	IX
ŞEKİLLER LİSTESİ.....	X
TABLolar LİSTESİ.....	XI
1. GİRİŞ.....	1
2. GENEL BİLGİLER.....	3
2.1. Yapay Sinir Ağları.....	3
2.2. Yapay Sinir Ağlarının Tarihçesi.....	4
2.3. Biyolojik Sinir Hücresi.....	5
2.4. Yapay Sinir Hücresi.....	6
2.5. Yapay Sinir Ağının Yapısı.....	9
2.6. Yapay Sinir Ağlarında Öğrenme.....	10
2.6.1. Danışmanlı öğrenme (Supervised learning).....	10
2.6.2. Danışmansız öğrenme (Unsupervised learning).....	11
2.6.3. Takviyeli öğrenme (Reinforcement learning).....	11
2.7. Öğrenme Kuralları.....	11
2.7.1. Hebb kuralı.....	11
2.7.2. Hopfield öğrenme kuralı.....	12
2.7.3. Delta öğrenme kuralı.....	12
2.7.4. Kohonen kuralı.....	12
2.8. Yapay Sinir Ağlarında Mimari Yapı.....	12
2.9. Hipotiroidi.....	13
2.10. Literatür Özetleri.....	14
3. GEREÇ VE YÖNTEM.....	24
3.1. Gereç.....	24



3.2. Yöntem.....	24
3.2.1. Doğrusal olmayan temel bileşenler analizinin teorisi.....	24
3.2.2. Maksimum rank sayısı.....	29
3.2.3. Uyumluluk ve kayıp ölçüleri.....	30
3.2.4. Cronbach's alpha.....	30
3.2.5. Varyans açıklama oranları.....	31
3.2.6. Sentroid koordinatları.....	31
3.2.7. Vektör koordinatları.....	31
3.2.8. Korelasyonlar ve özdeğerler.....	32
3.2.9. Nesne skorları ve yükler.....	32
3.2.6. Ölçme.....	33
3.2.7. Artıklar.....	33
3.2.8. Planlanmış sentroidler.....	34
3.2.9. Ölçeklenmiş ikili, üçlü faktör ve yüklerin grafiği.....	34
3.3. Procrustes Yöntemi.....	34
3.4. Dalgalı En Küçük Kareler Yöntemi.....	34
3.5. Yapay Sinir Ağlarında Doğrusal Olmayan Temel Bileşenler Analizi.....	35
3.5.1. Çok katmanlı algılayıcı (Multi layer perceptron).....	37
3.5.2. Geriye yayılım algoritması (Backpropagation).....	39
3.5.3. Sıralı doğrusal olmayan temel bileşenler analizi.....	44
4. BULGULAR.....	48
5. TARTIŞMA VE SONUÇ.....	60
KAYNAKLAR.....	67
ÖZGEÇMİŞ.....	72
EKLER.....	73
EK 1. Etik Kurul Raporu.....	73
EK 2. Tez Orijinallik Raporu.....	74

## SİMGELER VE KISALTMALAR

<b>BP</b>	: Backpropagation (Geri Yayılım)
<b>BSA</b>	: Bayes Sınır Ağı
<b>CGD</b>	: Conjugate Gradient Descent
<b>DOKTBA</b>	: Doğrusal Olmayan Karmaşık Temel Bileşenler Analizi
<b>DOTBA</b>	: Doğrusal Olmayan Temel Bileşenler Analizi
<b>EEG</b>	: Elektroensefalografi
<b>EKG</b>	: Elektrokardiyogram
<b>GA</b>	: Genetik Algoritma
<b>KTBA</b>	: Karmaşık Temel Bileşenler Analizi
<b>LM</b>	: Levenberg-Marquardt
<b>MAPE</b>	: Mean Absolute Percentage Error (Ortalama Mutlak Yüzde Hata)
<b>MP</b>	: Morfolojik Profil
<b>MSE</b>	: Mean Squared Error (Hata Kareler Ortalaması)
<b>SA</b>	: Sınır Ağı
<b>SCG</b>	: Scaled Conjugate Gradient
<b>TBA</b>	: Temel Bileşenler Analizi
<b>YSA</b>	: Yapay Sınır Ağları

## ŞEKİLLER LİSTESİ

Şekil 1. Biyolojik nöron yapısı (Kuyucu, 2012).....	5
Şekil 2. Yapay sinir hücresi.....	6
Şekil 3. Lineer fonksiyon.....	7
Şekil 4. Adım fonksiyon.....	8
Şekil 5. Sigmoid fonksiyon.....	8
Şekil 6. Tanjant hiperbolik fonksiyon (Helhel, 2009).....	9
Şekil 7. Yapay sinir ağı.....	10
Şekil 8. İleri ve geri beslemeli ağlar.....	13
Şekil 9. Doğrusal olmayan temel bileşenler analizi için sinir ağı modeli.....	37
Şekil 10. Çok katmanlı algılayıcı .....	38
Şekil 11. İterasyon sayısı ile hatanın ilişkisi.....	43
Şekil 12. Sıralı DOTBA (Kramer,1991).....	45
Şekil 13. 18-6-2-6-18 DOTBA Modeli.....	48
Şekil 14. 18-6-2-6-18 DOTBA.....	50
Şekil 15. 12-6-2-6-12 DOTBA.....	51
Şekil 16. 10-6-2-6-10 DOTBA.....	52
Şekil 17. 8-6-2-6-8 DOTBA.....	53
Şekil 18. 6-4-1-4-6 DOTBA.....	54
Şekil 19. 4-6-2-6-4 DOTBA.....	55
Şekil 20. 6-4-1-4-6 DOTBA.....	56

## TABLULAR LİSTESİ

<b>Tablo 1.</b> Biyolojik sinir sistemi ile yapay sinir sistemi arasındaki benzerlikler.....	6
<b>Tablo 2.</b> Çalışmada ele alınan değişkenler ve özellikleri.....	24
<b>Tablo 3.</b> Uygulamalarda kullanılan değişkenler.....	47
<b>Tablo 4.</b> TBA ve DOTBA için açıklanan varyans oranları.....	50
<b>Tablo 5.</b> 12 kategorik değişkenin bulunduğu modelde TBA ve DOTBA için açıklanan varyans oranları.....	51
<b>Tablo 6.</b> 10 kategorik değişkenin bulunduğu modelde TBA ve DOTBA için açıklanan varyans oranları.....	52
<b>Tablo 7.</b> 8 kategorik değişkenin bulunduğu modelde TBA ve DOTBA için açıklanan varyans oranları.....	53
<b>Tablo 8.</b> 6 kategorik değişkenin bulunduğu modelde TBA ve DOTBA için açıklanan varyans oranları.....	54
<b>Tablo 9.</b> 4 kategorik değişkenin bulunduğu modelde TBA ve DOTBA için açıklanan varyans oranları.....	56
<b>Tablo 10.</b> 6 sürekli değişkenin bulunduğu modelde TBA ve DOTBA için açıklanan varyans oranları.....	57
<b>Tablo 11.</b> YSA sonuçları.....	58
<b>Tablo 12.</b> DOTBA ile elde edilen temel bileşenlerle YSA'da tahmin sonuçları.....	58

## 1. GİRİŞ

Değişkenler arasındaki doğrusal ilişkileri belirlemeye yönelik tek ve çok değişkenli yöntemler, veri kümesi ile ilgili, değişkenlerin sürekli olması ve değişkenler arasındaki ilişkilerin doğrusal olması gibi varsayımları gerektirmektedir. Diğer yandan, değişkenler arasındaki ilişkiler her zaman doğrusal yapıda olmayabilir. Değişkenler arasındaki doğrusal ilişki temeline dayalı çok değişkenli analiz yöntemlerinden birisi de Temel bileşenler analizidir (Kung ve Diamantaras, 1990). Değişkenlerin sürekli olması ve aralarındaki ilişkilerin de doğrusal olması durumunda, Temel Bileşenler Analizinin etkinliği yüksektir. Ancak, bilimsel çalışmalarda genellikle, sürekli değişkenlerin yanı sıra; kategorik veya kesikli değişkenler de söz konusu olabilir. Bu gibi durumlarda, temel bileşenler analizi kullanılamamaktadır. Sürekli olmayan ve aralarında doğrusal ilişki bulunmayan değişkenleri içeren veri kümeleri için geliştirilen alternatif çözüm yöntemlerinden birisi de Doğrusal olmayan temel bileşenler analizi (DOTBA)'dir (Kramer, 1991). Bu analiz yöntemi, aralarında doğrusal veya doğrusal olmayan ilişki bulunan; sürekli, kategorik veya kesikli değişkenleri içeren veri kümeleri için sayısal ve görsel sonuçlar veren açıklayıcı bir boyut indirgeme yöntemidir (Demir, 2010).

Uygulamada, veriler genellikle çok boyutludur. Örneğin,  $16 \times 16$ 'lık bir matris 256 boyutludur. Ancak, orijinal veri kümesi daha az boyutla temsil edilebilir. Bu durumda, veri kümesi fazla bilgi kaybı olmadan daha az boyuta indirgenmiş olur. Bu boyutlar bileşen olarak adlandırılır ve orijinal veri alanında bir eğri ile tanımlanır (Scholz, 2002).

Boyut indirgeme, regresyon veya sınıflandırma algoritmalarında ön işlem olarak performansın artmasına neden olabilir. Boyut indirgemedeki ortak bir varsayım, bilgi içeriğinin, verilerin varyansı ile doğrudan ilişkili olmasıdır. Büyük varyans, bilgilerin çoğuna eşitken, küçük varyans, ihmal edilebilir bilgilere karşılık gelir veya sadece verilerin gürültüsünü tanımlar. Özellik uzayında, maksimum varyans ile boyut indirgemenin en önemli yöntemlerinden birisi de Temel Bileşen Analizidir (TBA) (Diamantaras ve Kung, 1996).

DOTBA, Temel Bileşen Analizinin bilinen yöntemine benzer şekilde, çok değişkenli veri analizine özgü bir yöntemdir. TBA gibi DOTBA da; boyut indirgeme,

görselleştirme ve keşfedici veri analizine destek olarak, sorunlu değişkenler arasındaki bağıntıları saptama ve onları giderme için kullanılır. TBA, sadece değişkenler arasındaki doğrusal ilişkileri belirlerken, DOTBA hem doğrusal hem doğrusal olmayan ilişkileri birlikte inceler.

Birçok bilimsel çalışmada, TBA sıklıkla kullanılmaktadır. Ancak, TBA'nın doğrusal bir yöntem olduğu ve başta mühendislik bilimleri olmak üzere, birçok alanda değişkenler arası ilişkilerin doğrusal olmadığı göz önüne alındığında, TBA'nın yerine DOTBA'nın kullanılmasının daha uygun olacağı söylenebilir (Dong ve McAvoy, 1996). DOTBA, TBA'nın doğrusal olmayan bir genellemesi olarak düşünülebilir. Ancak DOTBA, az sayıda değişkenle, yüksek açıklama gücüne sahip olduğundan TBA'ya göre daha üstündür (Monahan, 2000). DOTBA, doğrusal olmayan karmaşık problemlere kolay çözüm sağlayabilir. Yapılan literatür incelemesinde, yapay sinir ağları yaklaşımı ile doğrusal olmayan temel bileşenler analizinin incelenmesi ve bu yaklaşımın performansının değerlendirilmesine ilişkin sınırlı sayıda çalışma olduğu görülmüştür. Böylece tez çalışmasında, yapay sinir ağları temelinde, doğrusal olmayan boyut indirgeme için DOTBA yöntemi incelenmiştir. Ayrıca, DOTBA'nın etkinliğinin gösterilmesine ve kullanılabilirliğinin yaygınlaştırılmasına yönelik sağlık bilimleri alanında farklı uygulamalar yapılarak elde edilen sonuçlar yorumlanmıştır.

## 2. GENEL BİLGİLER

### 2.1. Yapay Sinir Ağları

Yapay sinir ağları, insan beyninin özelliklerinden olan öğrenme yolu ile yeni bilgiler türetebilme, oluşturabilme ve keşfedebilme gibi yetenekleri, herhangi bir yardım almadan gerçekleştirebilmek amacı ile geliştirilen bilgisayar sistemleridir (Kaya, 2010).

Yapay Sinir Ağları (YSA), elle çözümü mümkün olmayan ve karmaşık yapıya sahip problemlerin çözümü için değişken yapısı konusunda herhangi bir varsayım gerektirmeden aralarındaki ilişkiyi belirleyen esnek bir yöntemdir. YSA, özellikle sınıflandırma ve boyut indirgeme amaçlı kullanılabilir. YSA, geriye yayılım algoritmasını kullanarak ve ağ hatasını minimize ederek birimlerin en az hata ile sınıflarına atanması için ağırlıklarını adım adım hesaplar (Kuyucu, 2012).

YSA; öğrenme, veriyi sınıflandırarak bilgiye çevirme ve eş zamanlı birden çok işlem yapabilmeye yeteneğine sahiptir. YSA beynin çalışma ilkelerinin bilgisayarlar üzerinde taklit edilmesi fikri ile ortaya çıkmış ve ilk çalışmalar beyni oluşturan biyolojik hücrelerin ya da nöronların matematiksel olarak modellenmesi üzerinde yoğunlaşmıştır. Ancak YSA, biyolojik sinir sisteminin mükemmelliğine, karmaşıklığına ve verimliliğine henüz ulaşmamıştır. Yapay sinir ağları, karar hızı açısından insan beyni ile yarışabilecek aşamaya henüz ulaşmamış olmasına rağmen gün geçtikçe hızları artmaktadır (Köktürk, 2012).

Yapay sinir ağı modelinin temel özellikleri:

- Bilgi işleme nöron (işlem elemanı) adı verilen birimlerde gerçekleşir.
- Sinyaller, bir nöronun diğerine bağlantılar aracılığıyla iletilir.
- Her bir bağlantının gönderilen sinyal ile çarpılan bir ağırlık değeri vardır.
- Her bir nöron, bir çıktı sinyali elde etmek için ağ girdisine (ağırlıklarla çarpılmış sinyallerin toplamı) bir aktivasyon fonksiyonu uygular. Bu, genellikle doğrusal olmayan bir fonksiyondur.

Herhangi bir yapay sinir ağı;

- Nöronlar arasındaki bağlantı,
- Bağlantılardaki ağırlıkların hesaplanması (bu hesaplama, eğitim kuralı ya da öğrenme algoritması olarak da adlandırılır) ve
- Aktivasyon fonksiyonu ile tanımlanabilir.

YSA, örnekleri kullanarak makine öğrenmesi gerçekleştirir, programları ve çalışma yöntemi bilinen programlama yöntemlerine benzememektedir. YSA'nın güvenle çalıştırılabilmesi için önce eğitilmesi ve performansının test edilmesi gerekmektedir. Yapay Sinir Ağları, tahmin, sınıflandırma, örüntü tanıma, veri tabanlı proses modelleme ve doğrusal olmayan proses denetimi gibi alanlarda kullanılan fonksiyonel araçlardır (Özer, 2010).

## 2.2. Yapay Sinir Ağlarının Tarihçesi

İnsan beyninin nasıl çalıştığı ve fonksiyonları uzun yıllar araştırılmıştır. 1940'dan önce Helmholtz, Pavlov ve Poincare gibi bazı bilim adamlarının YSA kavramı üzerinde çalıştıkları bilinmektedir. Ancak bu çalışmaların matematiksel bir tabanı yoktur. 1940'lı yıllarda McCulloch ve Pitts, Hebb, Rosenblatt gibi bilim adamlarının bu konudaki çalışmaları ve YSA çalışmalarının mühendislik alanına yönelmesi, günümüzdeki YSA'nın temelini oluşturmaya başlamıştır (Karabacak, 2012). Daha sonra 1949'da Hebb "Organization of Behavior" adlı kitabında bir yapay sinir ağının öğrenme yeteneğine temel oluşturan Hebb kuralını ortaya atmıştır (Hebb, 1949). YSA'lar üzerine ikinci büyük adım olarak Rosenblatt'ın 1958'deki çalışması sayılmaktadır (Rosenblatt, 1958). Tekli doğrusal algılayıcı (perceptron) olarak da bilinen bu model, tek katmanlı, öğrenebilen ve nöronlar arasındaki ağırlıkları rasgele değişen bir yapay sinir ağıdır (Karaoğlu, 2016).

1970'lerin ilk başlarında Helsinki Teknik Üniversitesi'nden Teuvo Kohonen, öğrenme ve birleşik hafızalar üzerine çalışmalar yapmış ve bu çalışmalar danışmansız öğrenme yöntemlerinin gelişmesine ışık tutmuştur. Minsky ve Papert (1969) yapmış oldukları çalışmada, yapının XOR (eXclusive or) lojik problemlere çözüm




getiremediğini belirtmişlerdir. Bu nedenle YSA'ya olan ilgi azalmış ve bu YSA için 1982 yılına kadar süren karanlık bir dönemin başlangıcı olmuştur (Karabacak, 2012).

1982 ve 1984 yıllarında Hopfield tarafından yayınlanan çalışmalar ile yapay sinir ağlarının geliştirilebileceği ve özellikle geleneksel bilgisayar programlama ile çözülmesi zor olan problemlere çözüm üretilebileceği gösterilmiştir (Öztemel, 2016).

1986 yılında Rumelhart ve 1974'te Werbos tarafından bulunan çok katmanlı algılayıcı (multilayer perceptron) tipli geri yayımlı algoritma YSA alanında çığır açmıştır (Şen, 2004).

### 2.3. Biyolojik Sinir Hücresi

İnsan sinir sistemi, üç aşamalı bir sistem olarak düşünülebilir. Sistemin merkezi, sürekli olarak bilgiyi alan, algılayan ve onu uygun kararlar haline getiren sinir tarafından temsil edilen beyindir. İnsan vücudunda yaklaşık  $10^{10}$  (10 milyar) sinir hücresi olduğu tahmin edilmektedir (Haykin, 2009). Sinir hücrelerine tıp terminolojisinde nöron adı verilir. Nöron, sinir sisteminin temel birimi olup; gövde, gövdeye giren sinyal alıcılar (dentrit) ve gövdeden çıkan sinyal ileticiler (akson) olmak üzere başlıca üç kısımdan oluşmaktadır (Şekil 1). Dentritler üzerinden alınan girişler hücre gövdesi tarafından işlenir. Nörondaki sinyalleri taşıyan uzun bir sinirsel bağlantı halindeki akson, işlenen girişleri çıkışa aktarır. Sinaps, nöronlar arasındaki elektrokimyasal bağlantıyı sağlamaktadır (Köktürk, 2012).



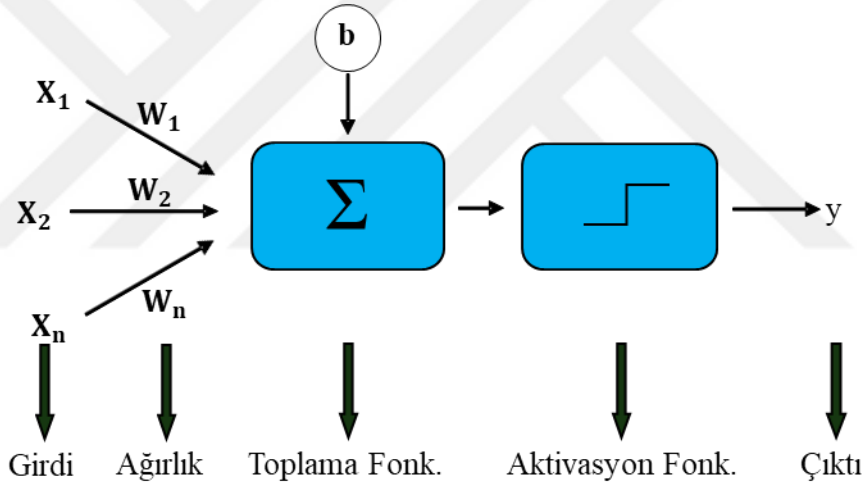
Şekil 1. Biyolojik nöron yapısı (Kuyucu, 2012).

**Tablo 1.** Biyolojik sinir sistemi ile yapay sinir ağı arasındaki benzerlikler

Biyolojik sinir sistemi	Yapay sinir ağı
Nöron	Algılayıcı
Dentrit	Toplama işlevi
Hücre gövdesi	Aktivasyon işlevi
Aksonlar	Algılayıcı çıkışı
Sinapslar	Ağırlıklar

## 2.4. Yapay Sinir Hücresi

Biyolojik sinir hücrelerini taklit eden yapay sinir hücreleri genel olarak girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktılardan oluşmaktadır (Şekil 2).



**Şekil 2.** Yapay sinir hücresi

1. Girdiler: Yapay sinir hücresine dış dünyadan gelen bilgilerdir. Bu girdiler dış dünyadan olduğu gibi başka hücrelerden veya kendisinden de olabilir.

2. Ağırlıklar: Bir yapay sinir hücresine gelen bilginin önem derecesini ve hücre üzerindeki etkisini belirleyen değerlerdir. Hesaplama başladığında ağırlıklar rasgele verilir ve yapılan işleme göre hata minimum olana kadar ağırlıklar değiştirilmeye devam eder. Yapay sinir ağlarında öğrenme, bu ağırlıkların değiştirilmesi ile meydana gelmektedir (Yetkin, 2014).


3. Toplama fonksiyonu: Toplama fonksiyonu gereğince, yapay sinir hücreesindeki her bir ağırlık ait olduğu giriş ile çarpılır. Bu girişler ile girişlere etki eden ağırlıklar çarpıldıktan sonra sonuçlar aritmetik olarak toplanır. Toplama işleminin sonucu eşik değeri ile toplanarak etkinlik işlevine gönderilir. Hesaplama “ $w_1, w_2, \dots, w_n$ ” ağırlıkları, “ $x_1, x_2, \dots, x_n$ ” ise giriş parametrelerinin değerlerini vermektedir (Yıldırım, 2014).

$$Net = w_1x_1 + w_2x_2 + \dots + w_nx_n = \sum_{i=1}^n w_ix_i \quad (1)$$

4. Aktivasyon fonksiyonu: Ağırlıklandırılmış girdi değeri aktivasyon fonksiyonu yardımıyla işlenerek bir çıktı değeri oluşturulur. Yapay sinir ağlarında birçok aktivasyon fonksiyonu kullanılmaktadır. En uygun aktivasyon fonksiyonu araştırmacının denemeleri sonucunda ortaya çıkar. Yapay sinir ağlarında yaygın kullanılan aktivasyon fonksiyonu sigmoid-fonksiyon olmakla birlikte, (Aktaş, 2010) diğer en sık kullanılan aktivasyon fonksiyonları aşağıda verilmiştir (Yetkin, 2014).

- Doğrusal Fonksiyon
- Adım Fonksiyon
- Sigmoid Fonksiyon
- Tanjant Hiperbolik Fonksiyon

Doğrusal fonksiyon: Sinir hücreesine gelen net girdileri doğrudan sinir hücre çıkışı olarak veren doğrusal fonksiyon, doğrusal problemlerin çözümünde kullanılmaktadır (Şekil 3). Doğrusal fonksiyon aşağıdaki gibi tanımlanabilir.




Şekil 3. Doğrusal fonksiyon

$$y = f(x) = x \quad (2)$$

Adım Fonksiyon: Sinir hücresine gelen net girdi, değeri belirlenen bir eşik değerinin altında ya da üstünde olmasına göre 1 veya 0 değerlerini almaktadır (Baş, 2006).


$$u_0(t) = \begin{cases} 0 & t < 0 \\ 1 & t > 0 \end{cases}$$



Şekil 4. Adım fonksiyon

Sigmoid fonksiyon: Sigmoid aktivasyon fonksiyonu türevi alınabilir bir fonksiyondur. Hem kendisinin hem de türevinin sürekli olması nedeniyle en çok kullanılan fonksiyonlardan birisidir (Şekil 5). Sigmoid aktivasyon fonksiyonu sadece pozitif değerler üretir ve eşitlik (3) ile ifade edilir:


$$y = \frac{1}{1+e^{-x}} \quad (3)$$



Şekil 5. Sigmoid fonksiyon

Tanjant hiperbolik fonksiyon: Tanjant hiperbolik aktivasyon fonksiyonu sigmoid aktivasyon fonksiyonuna benzer olmakla birlikte, çıkış uzayı biraz daha geniş olan bir fonksiyondur (Şekil 6). Sigmoid aktivasyon fonksiyonu [0,1] aralığında sonuç verirken, tanjant hiperbolik aktivasyon fonksiyonu [-1,1] aralığında sonuç verir. Tanjant hiperbolik fonksiyonu eşitlik (4)'te verilmiştir:

$$y = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (4)$$




**Şekil 6.** Tanjant hiperbolik fonksiyon (Helhel, 2009).

5. Çıktı: Aktivasyon fonksiyonu tarafından belirlenen çıktı değeridir. Bu değer başka bir sinir hücresinin girdisi olabilmektedir. Bir yapay sinir hücresi için çok sayıda girdi olmasına karşın yalnızca bir çıktı vardır.

## 2.5. Yapay Sinir Ağının Yapısı

Sinir hücreleri bir grup halinde işlev gördüklerinde ağ (network) olarak adlandırılır ve böyle bir grupta binlerce nöron bulunur. Yapay nöronların bağlantılar aracılığıyla bir araya gelmeleri yapay sinir ağını oluşturmaktadır. Yapay sinir ağıyla aslında biyolojik sinir ağının bir modeli oluşturulmak istenmektedir (Şeker, 2008). Nöronların bir araya gelmesi rasgele olmaz. Nöronlar 3 katman halinde bir araya gelerek ağı oluşturur ( Şekil 7).



**Şekil 7.** Yapay sinir ağı

Girdi katmanı (Input Layer): Nörona diğer nöronlardan veya dış ortamdan giren bilgilerdir. Bilgiler, ağırlıklardaki bağlantılar yoluyla hücreye girer (Alhasadi, 2016).

Ara (Gizli) katmanlar (Hidden Layers): Girdi katmanından gelen bilgiler ara katmanlarda işlenerek çıktı katmanına iletilir.

Çıktı katmanı (Output Layer): Ara katmandan gelen bilgiler işlenerek çıktıyı oluşturur. Çıktı aktivasyon fonksiyonu tarafından belirlenen değerdir (Gül, 2018).

## 2.6. Yapay Sinir Ağlarında Öğrenme

### 2.6.1. Danışmanlı öğrenme (Supervised learning)

Bu öğrenme yöntemi arzu edilen çıkışı elde etmek için öğrenmeyi gerçekleştirecek, problemin yapısını ve ortamın davranışlarını içeren, uygun bir eğitici giriş kullanır. Eğitici girişler eğitim setini oluşturur. İstenen çıkış değerleri ile ağın gerçek çıkışları arasındaki fark hata olarak YSA ağırlıklarına yansıtılır. Danışmanlı öğrenme algoritması arzu edilen çıkışları sağlamak için bir danışmana ihtiyaç duyar ve her bir giriş çıkış çifti için, ağ doğru sonuçları verebilecek bir öğrenme kuralı ile eğitilir. Widrow ve Hoff (1960); Rumelhart ve Mc Clelland (1986) tarafından geliştirilen delta

öğrenme kuralı veya geri yayılım algoritması danışmanlı öğrenmeye örnek olarak verilebilir (Güven, 2005).

### **2.6.2. Danışmansız öğrenme (Unsupervised learning)**

Danışmansız öğrenmede ağa sadece girdi verileri sunulur. Ağ yapısal tanıma ve sınıflandırma yapar. İstenen bir çıktı yoktur. Ağ, verilerin özelliklerini tanıyarak, benzer özellik gösteren verileri aynı gruplarda toplar (Aktaş, 2010).

### **2.6.3. Takviyeli öğrenme (Reinforcement learning)**

Bazı durumlarda ağa çıktının ne olduğunu vermek mümkün olmamasına rağmen ağın üretmiş olduğu çıktının doğru veya yanlış olduğu belirlenebilir. Bu öğrenme kuralında çıktının, verilen girişe uygun olup olmadığını değerlendiren bir kriter kullanılmaktadır. İstenen çıktıyı vermek için bir öğretici kullanılmaz. Yani, ağa giriş-çıkış değerleri vermek yerine çıktı değerlerinin doğru olup olmadığı kontrol edilir. Takviyeli öğrenme için Boltzmann kuralı ve Genetik Algoritma örnek gösterilebilir. Bu öğrenme kuralı, özellikle kontrol yöntemleri için idealdir (Çelik, 2010).

## **2.7. Öğrenme Kuralları**

Yapay sinir ağlarında farklı öğrenme kuralları bulunmaktadır. Bu kuralların birçoğu Hebb öğrenme kuralı olarak bilinen basit bir modele dayanmaktadır. Yaygın kullanılan öğrenme kurallarından bazıları aşağıda verilmiştir.

### **2.7.1. Hebb kuralı**

Hebb kuralı, geliştirilen ilk öğrenme kuralıdır. Diğer öğrenme kurallarının gelişmesine öncülük etmiştir. Donald Hebb tarafından geliştirilen bu öğrenme kuralının temeli, “iki proses elemanı arasında bilgi alışverişi varsa ve iki proses elemanı da aktifse aralarındaki bağ kuvvetlenmeli” esasına dayanmaktadır. Yani aktif olan proses elemanı bağlantılı olduğu proses elemanını da aktif hale getirmeye çalışacaktır (Şeker, 2008).

### **2.7.2. Hopfield öğrenme kuralı**

Hopfield öğrenme kuralı, Hebb kuralına benzer olup, bu kurala ek olarak, Hopfield öğrenme kuralında bağ kuvvetlerindeki değişimlerin ne kadar olacağı da belirtilmektedir. Bu kurala göre; bağ kuvveti öğrenme hızı kadar artırılır ya da azaltılır. Öğrenme hızı pozitif ya da negatif bir sayısal değerdir. Uygulamada öğrenme hızı 0 ile 1 arasında değişmektedir (Doğan, 2012).

### **2.7.3. Delta öğrenme kuralı**

Delta öğrenme kuralı, en çok kullanılan öğrenme kurallarından birisidir. Bu kural, nöronun gerçek çıkış değeri ile istenilen çıkış değeri arasındaki farkı azaltan, giriş bağlantılarını güçlendiren ve sürekli olarak değiştiren bir düşünceye dayanmaktadır. Bu kural, bağlantı ağırlık değerlerinin değiştirilmesiyle ortalama karesel hatayı düşürme prensibine dayanır. Hata, aynı anda bir katmandan önceki katmanlara geri yayılarak azaltılır ve sistemin ağı kontrol eden ağırlıkları ayarlamasını sağlar. Bu işlem, ağırlıklar sürekli ayarlandığı için tekrar tekrar devam eder. Bu kural, geri yayılım kuralı olarak da bilinir (Güler, 2007).

### **2.7.4. Kohonen kuralı**

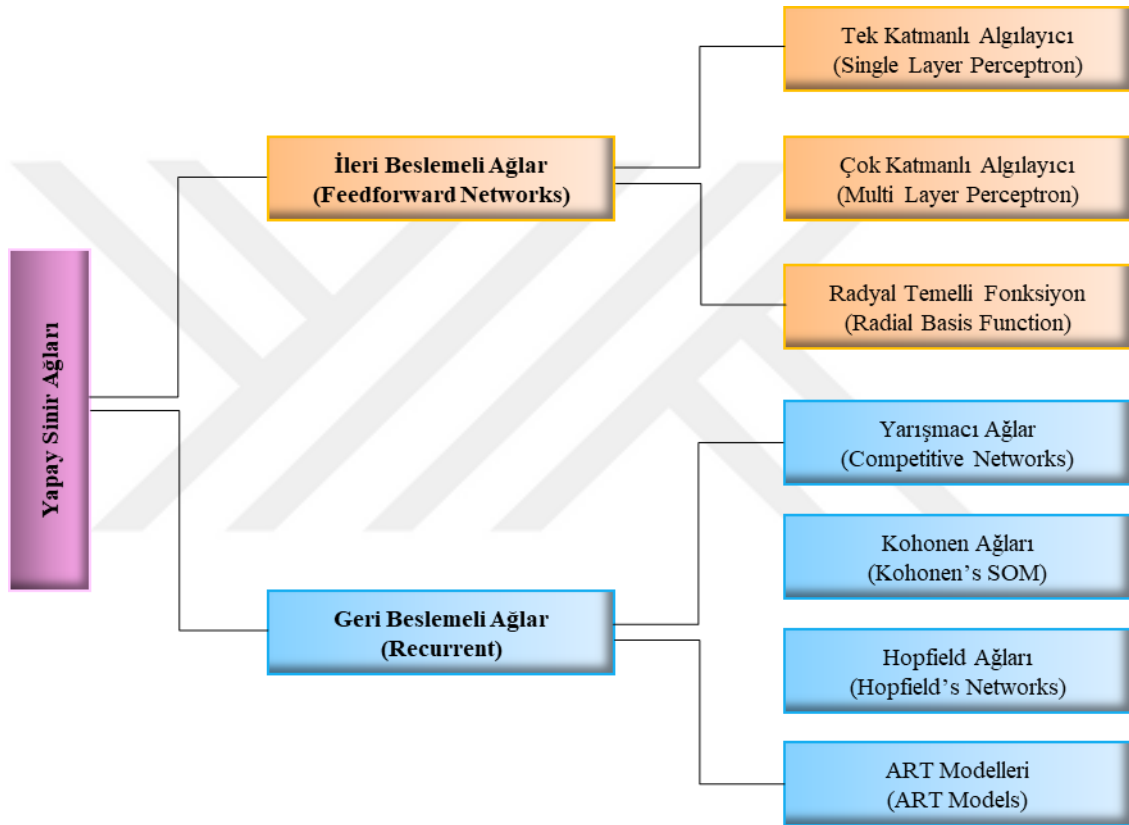
Bu kural 1982 yılında Teuvo Kohonen tarafından biyolojik sistemdeki öğrenmeden esinlenerek geliştirilmiştir. Bu yöntemde, elemanlar ağırlıkları ayarlamak için rekabet eder ve bu rekabet sonucunda yarışmayı kazanan proses elemanları “1” değerini alırken, diğerleri “0” değerini alır. Kazanan proses elemanı yakınındaki elemanlara göre daha kuvvetli hale gelmiş olup, onları uyarma ve yasaklama kapasitesine sahiptir (Helhel, 2009).

## **2.8. Yapay Sinir Ağlarında Mimari Yapı**

YSA, yapılarına göre ileri beslemeli (feedforward) ve geri beslemeli (feedback) ağlar olmak üzere iki sınıfa ayrılmıştır (Şekil 8). İleri beslemeli ağda işlemci elemanlar genellikle katmanlara ayrılmıştır. İşaretler, giriş katmanından çıkış katmanına doğru tek yönlü bağlantılarla iletilir. İşlemci elemanlar bir katmandan diğer bir katmana



bağlanırken, aynı katman içerisinde bağlantıları bulunmamaktadır. Geri beslemeli YSA’larda ise bazı nöronların çıkışları aynı nörona veya önceki katmanlardaki nöronlara geri beslenir. Böylece, girişler hem ileri yönde hem de geri yönde aktarılmış olur. Bu tip sinir ağları, dinamik yapıya sahip bir belleğe sahiptir, diğer bir ifade ile herhangi bir andaki çıkış, o andaki girişlerin bir fonksiyonu olduğu kadar önceki giriş ve çıkış değerlerini de yansıtmaktadır. Bu özelliği nedeniyle bu tip ağlar, özellikle önceden tahmin uygulamaları için uygun olmaktadır (Akpolat, 2007).



Şekil 8. İleri ve geri beslemeli ağlar

Çalışmanın uygulama aşamasında hipotiroidi tanısı almış 151 hasta ve hipotiroidi şüphesi ile hastaneye başvurmuş ancak hipotiroidi tanısı almamış 271 hastaya ait veri kullanılmıştır. Bu nedenle hipotiroidi kavramı kısaca açıklanmıştır.

## 2.9. Hipotiroidi

Tiroid bezi vücutta trakeanın hemen önünde bulunan H şeklinde bir bezdir. Bezin ağırlığı 15-20 gram arasında değişmektedir. Tiroid bezi tiroid hormonlarını (T3 ve T4) üretir, depolar ve salgılar. Bu hormonlar dolaşımında proteinlere bağlı halde

bulunur ve vücutta bazal metabolizma hızının kontrolü ile protein, karbonhidrat, lipit, vitamin ve serum kalsiyum düzeyinin kontrolünden sorumludur (Sağlam ve Çakır, 2012).

Tiroid hormonları tüm organ ve sistemler üzerinde etkilidir. Tiroid hormonlarının yetersizliği sonucu vücutta çeşitli semptomlar ve bulgular görülmektedir. Bu belirtiler arasında; yorgunluk, halsizlik, kilo alma, konsantrasyon bozukluğu, unutkanlık, saçlarda dökülme, cilt kuruluğu, üşüme, seste kabalaşma, kabızlık, düzensiz ve yoğun adet kanamaları, infertilite, kas ağrıları, kas sertliği, karpal tünel sendromu, demans ve depresyon yer almaktadır (Özçelik Yıldırım, 2016).

Tiroid bezinin yeterli düzeyde hormon üretememesi durumu "hipotiroidi" olarak adlandırılmaktadır. Hipotiroidi, tiroid bezi yetersizliğinden kaynaklanıyorsa primer hipotiroidi, Tiroid uyarıcı hormon (TSH, Tiroid stimulating hormone) salgısının yetersizliği sonucu gelişmiş ise sekonder hipotiroidi, Hipotalamusta sentezlenen ve salınan TRH (Tyrotropin relasing hormone) yetersizliği sonucu ortaya çıkmışsa tersiyer hipotiroidi olarak adlandırılır (Özata, 2005).

## **2.10. Literatür Bildirileri**

Kramer (1991), DOTBA yöntemini yapay sinir ağlarında tanıtmıştır. Tanıttığı bu ağ, toplam beş katmanlı bir ağdır ve bu ağda giriş veya çıkış katmanlarından daha az sayıda düğüm içeren "darboğaz" katmanı ile beraber üç gizli katman kullanılmıştır. Kramer çalışmasında çeşitli örnekler vererek TBA ve DOTBA yöntemlerini karşılaştırmıştır. Geri yayılım algoritması olarak Conjugate Gradient algoritmasını ve iki gizli katmanda doğrusal olmayan fonksiyonları kullanmıştır. İterasyon sayısı 1000 olarak belirlenen DOTBA yöntemini, zamana bağlı simüle edilmiş reaksiyon verileri kullanarak göstermiştir. DOTBA'nın başarılı bir şekilde boyut indirgemeyi yaptığını ve altta yatan sistem parametrelerinin gerçek dağılımını andıran bir özellik uzay haritası oluşturduğunu göstermiştir.

Dong ve McAvoy (1994) çalışmalarında, temel eğri algoritmasını ve sinir ağlarını bütünleştiren bir DOTBA yöntemi sunmuşlardır. Çalışmada, doğrusal olmayan temel bileşenleri modellemek için iki adet üç katmanlı sinir ağı (SA) kullanmışlardır.

Ayrıca doğrusal olmayan temel bileşenler ve doğrusal olmayan temel yük fonksiyonlarını da tanımlayarak DOTBA'nın potansiyel uygulamalarını ele almışlardır. Hem simülasyon hem de gerçek problemlere ait sonuçlar, yöntemin doğrusal olmayan temel bileşen problemlerini çözmede oldukça iyi olduğunu göstermiştir.

Devulapalli (1996), fiziksel olarak engelli bir kişi tarafından alfabe olarak farklı zihinsel görevleri kullanmanın fizibilitesini araştırmak için çeşitli zihinsel aktivitelere ait EEG sinyallerini sınıflandırabilmeyi amaçlamıştır. İki farklı mental görevin sınıflandırılmasını sağlayan ve boyut azaltmaya yönelik bir yöntem kullanmıştır. Altı zihin kanalından kaydedilen EEG sinyallerini, iki zihinsel görevin gerçekleşmesi sırasında incelemiştir. Göz kırpmasız serbest EEG verilerinin boyutlarını azaltmak için bir DOTBA ağı ve boyutu azaltılmış verileri sınıflandırmak için standart bir geriye yayılım ağı kullanmıştır. Sonuç olarak; DOTBA yönteminin %86.22 oranında doğru sınıflandırma yapabildiğini göstermiştir.

Dong ve McAvoy (1996) tarafından yapılan çalışmada, temel eğri algoritması ve sinir ağlarını bütünleştiren bir DOTBA yöntemi sunulmuştur. Yöntemde; temel eğri algoritması, doğrusal olmayan başlangıç puanları ve düzeltilmiş veriler oluşturmak için kullanılmış olup; bu verileri modellemek için de iki adet üç katmanlı sinir ağı kullanılmıştır. Oto-ilişkili sinir ağlarını ve doğrusal olmayan süreç izlemeyi göstermek amacıyla DOTBA'nın iki uygulaması verilmiştir. Gerek simülasyon, gerekse gerçek problem sonuçları, DOTBA'nın her iki uygulama için de iyi bir yaklaşım olduğunu ve önemli süreç problemlerini çözmede kullanılabileceğini göstermiştir.

Mantere ve ark. (1997), zıt renk sinyalleri ve akromatik bir sinyalin beyaz ışık adaptasyon karakteristiklerini simüle etmek için doğrusal olmayan nöral temel bileşen analizine dayanan bir algoritma kullanmışlardır. Kullanılan algoritmayı, Sanger'in genelleştirilmiş Hebbian algoritmasından kısa dalga boyu koni çıkışlarında doğrusal olmayanları kullanarak elde etmişlerdir. Temel bileşenleri tek akromatik ve iki zıt renk sinyali olarak yorumlamışlardır. Simülasyon örnekleri ile algoritmanın zıt renk sinyallerine ve literatürde bildirilenlere benzeyen kırmızı-yeşil sinyal için adaptasyon özelliklerine yaklaştığını göstermişlerdir. Doğrusal olmayan haritalamanın oldukça zengin bir davranışa sahip olması nedeniyle (matematiksel olarak analiz edilmesi zor olsa da) karmaşık araştırmalarda kullanılabileceğini ifade etmişlerdir.

Stamkopoulos ve ark. (1998), DOTBA'ya dayanan bir algoritma geliřtirmişlerdir. Bir hastanın elektrokardiyogram (EKG) sinyalinde iskemik kalp atımlarının saptanmasının, ST segmenti olarak adlandırılan vuruşun belirli bir kısmının özelliklerine dayandığını ve vuruşların doğru sınıflandırmasının, ST segment özelliklerinin etkin ve doğru şekilde çıkarılmasına dayandığını belirtmişlerdir. Kalp atımlarındaki her bir segmenti, normal ve anormal (ST +, ST- veya artefakt) olmak üzere iki sınıftan birine sınıflandırmak üzere DOTBA yöntemini kullanmışlardır. Algoritmanın eğitimi aşamasında, sadece normal kalıplar ve sınıflandırmada ise her ST segmenti için iki doğrusal olmayan özellik kullanmışlardır. Bu özelliklerin dağılımını, bir radyal temel fonksiyon ağı kullanarak modellemişlerdir. Testin, sadece iki doğrusal olmayan bileşen ve her dosyadan 1000 normal örnek içeren bir eğitim setinin normal atımlar için yaklaşık %80 ve iskemik atımlar için %90'dan daha yüksek bir doğrulukla sınıflandırma yaptığını göstermişlerdir.

Frate ve Schiavon (1999), atmosferik profilleri almak ve radyometrik verilerin inversiyonu için sinir ağı tabanlı bir algoritma sunmuşlardır. Sinir ağlarının sadece inversiyon için değil, aynı zamanda veri özelliği çıkarma ve boyut küçültme için de kullanılabileceğini belirtmişlerdir. Algoritmada üç aşamadan oluşan bir sinir ağı mimarisi kullanmışlardır. Giriş aşamasında; giriş vektörünün boyutu azaltılmış, orta aşamada; indirgenmiş giriş vektöründen azalan çıktı vektörüne eşleştirme gerçekleştirilmiş ve son aşamada ise orta kademenin çıktısı istenen gerçek boyuta getirilmiştir. Algoritmanın performansı, daha geleneksel doğrusal yöntemlerle karşılaştırılarak değerlendirilmiştir. Değişkenler arasında doğrusal olmayan bir korelasyon olduğunda, DOTBA'nın verileri daha doğru ve TBA'dan daha az bileşenle açıklayacağı belirtilmiştir. Sonuç olarak, yedi parlaklık sıcaklığından 33 seviyeli profillerin ve bir gizli katmanı olan çok katmanlı bir algılayıcı ile zemin ölçümlerinin doğrudan tahmin edildiği ve sonuçların, DOTBA kullanılarak elde edilen sonuçlara oldukça yakın olduğu vurgulanmıştır.

Monahan (2000) çalışmasında, DOTBA ile TBA arasında bir karşılaştırma yapmak üzere; beş tabakalı, kendiliğinden birleşmeli ileri beslemeli bir sinir ağı kullanmıştır. Yöntem, Lorenz çekim noktasından örneklenmiş bir veri setinde test edilmiştir. Sonuç olarak, bir ve iki boyutlu DOTBA'nın, sırasıyla varyansın %76 ve

%99.5'ini açıklayarak; yine sırasıyla varyansın %60 ve %95'ini açıklayan TBA tahminlerinden daha üstün olduğu ifade edilmiştir. Lorenz verisine gürültü eklendiğinde, hem tek hem de iki boyutlu DOTBA'nın, karşılık gelen TBA yaklaşımlarından daha üstün olduğu gösterilmiştir. Bununla birlikte, gürültü yeterli bir güce sahip olduğunda, veri kümesinin altında yatan doğrusal olmayan yapının artık ortaya çıkmadığı durumlarda, sonuçların sağlam olmadığı ve DOTBA'nın, verilerin küçük boyutlu yapısını tanımlamak için yararlı bir yöntem olmadığı vurgulanmıştır.

Hsieh (2001) çalışmasında, klasik temel bileşen analizi yöntemini doğrusal olmayan şekilde genelleştiren bir sinir ağı modeli sunmuştur. DOTBA'nın stabilitesini artırmak için hata fonksiyonuna ağırlık ceza şartlarını ekleyerek düzenli hale getirmiştir. Doğrusal yaklaşımla, TBA ve döndürülen TBA yöntemleri arasında bir ikilik olduğunu ve bunun genellikle aynı anda bir çözüme sahip olma imkansızlığından kaynaklandığını ifade etmiştir. Hem verilerin maksimum küresel varyansını açıklamak hem de yerel veri kümelerine yaklaşmak için DOTBA kullanmış ve böylece her iki amaca birlikte ulaşmıştır. DOTBA yaklaşımını göstermek için Lorenz (1963) 3 bileşenli kaotik sistem ve aylık tropikal Pacific deniz suyu sıcaklık verilerini (1950-1999) kullanmıştır. Giriş değişkenlerine önce TBA uygulamış ve elde edilen üç temel bileşen varyansın sırasıyla %51.4, %10.1 ve %7.2'sini açıklamıştır. Daha sonra bu üç temel bileşen DOTBA için girdi verisi olmuştur. DOTBA ile ilk temel bileşen varyansın %56.6'sını açıklamıştır.

Erguo ve Jinshou (2002) çalışmalarında, proses hata tespiti için giriş-eğitim sinir ağına dayanan doğrusal olmayan bir temel bileşen analizi yöntemi sunmuşlardır. Doğrusal olmayan temel bileşen puanlarının tahmininde giriş-eğitim (Input-training) ve geri yayılım (Backpropagation) sinir ağı kullanmışlardır. Giriş-eğitim sinir ağının öğrenme algoritmasını değiştirmiş ve geliştirmişlerdir. Giriş-eğitim ve BP sinir ağı, doğrusal olmayan temel bileşenleri tahmin etmek için işbirliği içinde olduğundan önerilen yöntemin, süreç performansını izlemek için kullanılabileceğini belirtmişlerdir. DOTBA, hem doğrusal hem de doğrusal olmayan korelasyonları çıkarabildiğinden, sürecin tam olarak tanımlanmasıyla sonuçlandığını ifade etmişlerdir. Nominal veri setine önce doğrusal temel bileşenler analizi daha sonra doğrusal olmayan temel bileşenler analizi uygulamışlardır. DOTBA ile sadece süreç değişkenleri arasındaki doğrusal olmayan ilişkiyi yakalamak değil, aynı zamanda TBA'dan daha düşük

boyutlarda daha etkili bir model oluşturmayı amaçlamışlardır. Böylece, DOTBA modelinin oluşturulma aşamasında, nominal veri kümesindeki toplam değişkenliğin %90' nını iki doğrusal olmayan temel bileşen ile açıklamışlardır.

Lu ve Hsieh (2003) çalışmalarında, 3-gizli-katmanlı DOTBA'da aşırı uyumun (overfitting), basitleştirilmiş 2-gizli-katmanlı bir DOTBA'da hafifletilebileceğini göstermişlerdir. 3-gizli-katman DOTBA'da, giriş sinyallerini ilk olarak 'kodlama' nöronlarına aktarmışlardır. Hiperbolik tanjant fonksiyonunu burada transfer fonksiyonu olarak kullanmış ve sinyal ikinci gizli katmandaki 'darboğaz' nöronundan üçüncü gizli katmandaki 'kod çözme' nöronlarına doğru hareket ettiğinde tekrar bu fonksiyonu kullanmışlardır. Doğrusal transfer fonksiyonlarını ise kodlama katmanından darboğaz katmanına ve kod çözme işleminden çıkış katmanına eşlemek için kullanmışlardır. Veri sıkıştırma, tek darboğaz nöronu ile darboğaz tarafından sağlanmıştır. 2-gizli-tabakalı bir DOTBA'da kodlama katmanını ortadan kaldırmış, darboğaz tabakasındaki doğrusal fonksiyonu doğrusal olmayan bir fonksiyonla değiştirmişlerdir. Hiperbolik tanjant fonksiyonunu her iki gizli katmanda kullanırken, doğrusal transfer fonksiyonunu çıkış tabakasında kullanmışlardır. Bu yöntemi, tropikal Pasifik deniz yüzeyi sıcaklık dalgalanmaları, Lorenz kaotik sistemi ve stratosferik yarı bienal rüzgar salınımları ile test etmişlerdir.

Shirakura ve Kurata (2004), doğrusal olmayan temel bileşenleri çıkarabilen, ileri beslemeli ve kendi kendini düzenleyen bir harita (self-organizing maps) modeli önermişlerdir. Bu model, birbirlerini karşılıklı olarak engelleyen bir takım öğrenme sınır alanlarından oluşur ve daha önce yazarlar tarafından önerilen kendi kendini düzenleyen harita modelinin bir uzantısıdır. İleri beslemeli (Feedforward) modelin, doğrusal olmayan temel bileşen analizi için yeterli olduğunu, ancak sinir hücreleri arasındaki simetrik engelleyici bağlantılara sahip recurrent (geri beslemeli) modelin, ilginç ek özelliklere sahip olduğunu belirtmişlerdir. Modellerinin doğrusal olmayan temel bileşenleri birinci ile üçüncü bileşenden çıkardıklarını teyit etmişlerdir. Kullanılan algoritmanın yakınsama için oldukça fazla zaman gerektirdiği ve bu nedenle pratik olmadığını ifade etmişlerdir.

An ve ark., (2005), Tropikal Pasifik'teki termoklin anomalilerine DOTBA uygulayarak, kayda değer doğrusal olmayan bir ENSO döngüsü belirlemişlerdir. TBA

ve döndürülen TBA'yı, bir veri kümesinden en uygun doğrusal yapıyı çıkarmak için kullanmışlardır. Veri kümesinin, doğrusal olmayan bir alt yapıya sahip olması durumunda, DOTBA yönteminin, veri kümesini tanımlamak için daha iyi bir yol olduğunu göstermişlerdir. Her ne kadar DOTBA'nın deniz yüzeyi sıcaklığı anomalilerine önceki uygulamaları, verileri U şeklinde bir açık eğri bulmuş olsa da, bu çalışmada, termoklin anomalilerinin DOTBA modunun kapalı bir eğri verdiğini belirtmişlerdir.

Liu ve ark. (2005), görüntü verisindeki küçük nesnelere algılanması, sinyal-gürültü oranı karakteristiklerini ve görünüm özelliklerini birleştiren ve küçük nesnelere arka planının, boyutunun, yoğunluğunun ve yöneliminin varyansını tolere edebilen etkili bir yöntem önermişlerdir. Böyle bir tespit şemasında, küçük nesnelere görünüşünü modellemek ve bir önemlilik ölçüsü fonksiyonu oluşturmak için DOTBA sinir ağını kullanmışlardır. TBA kullanılarak, her bir piksel pozisyonundan çıkarılan özellik vektörüne dayanan bu fonksiyona, giriş görüntüsünün küçük bir nesne çıktı haritası oluşturulmakta ve ara nesne konumu haritasının elde edilmesi için çıktı haritası eşiklenmektedir. Bu yöntem, sadece küçük nesne görüntüsünün eğitimini gerektirmektedir. Başka bir görünüme dayalı tespit algoritmasında yer alan eğitim seti oluşturma problemini ortadan kaldırmaktadır. Aynı zamanda, böyle bir çıktı haritasının, giriş görüntüsünün mekansal olarak filtrelenmiş bir sonucu olarak ele alınabileceğini ve birçok filtre tabanlı tespit yöntemiyle karşılaştırıldığında, önerilen algoritmanın bu yöntemleri geride bıraktığını göstermişlerdir.

Rattan ve Hsieh (2005) çalışmalarında, karmaşık veri kümelerinde doğrusal olmayan özellik çıkarma ve boyut azaltma sağlayan doğrusal olmayan karmaşık bir temel bileşenler analiz (DOKTBA) yöntemini tanıtmışlardır. Bunun için iki bölüme oluşan bir mimari kullanmışlardır. Girişten darboğaza kadar olan ilk bölümü, girişi  $z$  tek doğrusal olmayan karmaşık temel bileşen  $f(z)$  ile, tıkanıklıktan  $z'$  çıkışına kadar olan ikinci kısım, ters haritalama  $g(f(z))$  ile göstermişlerdir. Kodlama ve kod çözme katmanlarındaki nöronların sayısının artırılması, ağına doğrusal olmayan modelleme yeteneğini artırdığını belirtmişlerdir. DOKTBA'nın test veri kümeleri üzerinde uygulanması, DOKTBA'nın KTBA yöntemine göre daha iyi becerilere sahip olduğunu, daha fazla varyansı açıkladığını ve DOKTBA ile elde edilen özellikler de altta yatan

sinyale daha yakın olduğunu (korelasyon ve kök ortalama kare hatası açısından) ifade etmişlerdir. DOKTBA yönteminin, 2 boyutta varyansın %62'sini, 3 boyutta ise %80'ini açıkladığını ifade etmişlerdir.

Rattan ve ark. (2006), Karmaşık Temel Bileşen Analizinin (KTBA), genellikle 2 boyutlu vektör alanlarına uygulanan doğrusal çok değişkenli bir yöntem olduğunu ifade etmişlerdir. Karmaşık değerli çok katmanlı algılayıcı sinir ağları aracılığıyla yeni bir doğrusal olmayan KTBA (DOKTBA) yöntem geliştirmişlerdir. Hilbert dönüşümü ile verileri karmaşık hale getirdikten sonra KTBA ve DOKTBA yöntemlerini uygulamışlardır. İlk iki temel bileşenin, KTBA ile varyansın %66.4'ünü, DOKTBA ile %81.4'ünü açıkladığını belirtmişlerdir.

Hsieh (2006), gürültülü verilerle, aşırı uyumun (overfitting) model tanımlamada önemli bir problem olduğunu ifade etmiştir. Doğrusal olmayan regresyon için, bol miktarda veriye sahip olmanın aşırı uyumu ortadan kaldırabileceğini, ancak DOTBA için, aşırı uyumun bol miktarda veriyle bile devam edebileceğini belirtmiştir. Böylece, ortalama karesel hatayı tamamen minimize etmek, DOTBA'nın gürültülü verilerde iyi çözümler bulması için yeterli bir ölçüt olmadığını belirtmiştir.

Ji ve ark. (2006) çalışmalarında, genetik algoritma (GA) ve doğrusal olmayan temel bileşenler analizi ile kombine edilmiş bir sinir ağı (DOTBA SA) aracılığıyla hidro-jeneratör ünitelerindeki arızaların tespit edilmesine yönelik bir yaklaşım sunmuşlardır. İlk olarak, DOTBA SA'nın hem yapısı hem de bağlantısı GA ile optimize edilmiştir. Yüksek boyutlu örneklerden temel özellikleri çıkarmak için GA DOTBA SA, kullanmışlardır. Arızaların tespit edilme performansını test etmek için Bayes sinir ağını (BSA) da eklemişlerdir. Önerilen şemayı, hidro-jeneratör ünitesinin hata örneklerini tespit etmek için uygulamış ve simülasyon sonuçları ile bu yöntemin etkinliğini belirlemişlerdir. Genetik algoritmaya dayanan DOTBA sinir ağının yakınsama oranının, BP algoritmasına dayanan DOTBA sinir ağından daha hızlı olduğunu ifade etmişlerdir.

Herman (2007), Alman Kuzey Denizi sığ kıyılarındaki gelgit su seviyesini ölçmek amacıyla mevcut alanlara yapay sinir ağı temelli bir DOTBA modeli uygulamıştır. Kıyı bölgesindeki su seviyelerinin ve akımların mekansal ve zamansal değişkenliğini analiz etmiştir. Su seviyelerine ve akımlarına ait ilk doğrusal olmayan



temel bileşenler sırasıyla varyansın toplam %97.4'ünü ve %89.5'ini açıklamıştır. DOTBA'nın klimatoloji ve atmosferik bilimlerde yararlı bir veri analiz aracı olduğunu ve aynı zamanda verideki fiziksel kalıpları tanımlamaya yardımcı olan doğrusal TBA için tamamlayıcı bir araç olduğunu göstermiştir.

Qiaoling ve ark. (2007) tarafından, Genetik Algoritma (GA) ve doğrusal olmayan temel bileşenler analizi ile kombine edilmiş sinir ağları aracılığıyla, hidro-jeneratör ünitelerindeki arızaların tespit edilmesine yönelik bir yaklaşım sunulmuştur. İlk olarak, yapay sinir ağlarında doğrusal olmayan temel bileşenler analizinin yapısı ve bağlantısı genetik algoritma tarafından optimize edilmiştir. Yüksek boyutlu örneklerden temel özellikler çıkarmak için sistem çalıştırılmıştır. DOTBA'nın darboğaz tabakasının çıktıları, daha iyi tespit için ayrıca bir Bayesian sinir ağına gönderilmiştir. Genetik algoritmaya dayalı DOTBA sinir ağının, BP algoritmasına dayalı DOTBA sinir ağından daha hızlı olduğu belirtilmiştir.

Scholz ve ark. (2008) çalışmalarında, DOTBA için oto-ilişkili nöral ağ yaklaşımının kapsamlı bir tanımını sunmayı amaçlamışlardır. DOTBA'nın standart TBA'nın doğrusal olmayan bir genellemesi olarak, temel bileşenleri düz çizgilerden eğrilere doğru genelleştirdiğini belirtmişlerdir. Hiyerarşik, dairesel ve ters modeli içeren DOTBA'yı, moleküler biyoloji verilerine uygulamışlardır. Bu yöntemle, Arabidopsis thaliana bitkisi ve enfekte olmuş kırmızı kan hücreleri içindeki sıtma paraziti Plasmodium falciparum'un üreme döngüsünü modellemeyi amaçlamışlardır. Yöntemlerinde standart DOTBA'nın, istenen alt alanı yalnızca bir bütün olarak karakterize ederken, hiyerarşik DOTBA'nın, bu alt alanı, doğrusal TBA'ya benzer bir hiyerarşik sıraya göre düzenlenmiş bileşenler tarafından açıklamak için zorladığını belirtmişlerdir. Bu nedenle, hiyerarşik DOTBA'nın standart TBA'nın doğrusal olmayan bir uzantısı olarak görülebileceğini ifade etmişlerdir.

Lu ve Pandolfo (2011), DOTBA'yı yürütmek için, darboğaz ve çıktı nöronlarının matematiksel tanımlarında hiçbir kodlama katmanı ve eşik değer teriminin bulunmadığı basitleştirilmiş iki-gizli-tabakalı ileri beslemeli ağ önermişlerdir. Bu yoğun DOTBA modelinin, DOTBA için daha karmaşık sinir ağı mimarisini kullanırken, karşılaşılan problemleri hafiflettiğini belirtmişlerdir. Yöntemlerinde, sayısal deneyler için, Lorenz kaotik çekiciden üretilen bir veri seti kullanmışlardır. Aynı sayıda darboğaz

nöronu veya azaltılmış boyutlar göz önüne alındığında, yoğun DOTBA modelinin, üç gizli katman kullanılan DOTBA modeline göre daha az sayıda parametreyle Lorenz çekiciyi daha iyi karakterize ve temsil ettiğini belirtmişlerdir.

Licciardi ve ark. (2012) tarafından, morfolojik profillerin (MP), uzaktan algılanan verilerin sınıflandırılması ve daha iyi sonuçlar elde edilmesi için yardımcı araçlar olarak kullanıldığı belirtilmiştir. Morfolojik profiller, TBA'dan türetilen bileşenler gibi verinin bilgi içeriğinin çoğunu içeren özellikler kullanılarak oluşturulmuştur. DOTBA'nın özelliklerinden oluşturulan genişletilmiş MP'ler kullanılarak elde edilen sınıflandırma doğrulukları araştırılmıştır. İki yaklaşımın karşılaştırılması, farklı mekânsal ve spektral karar/oranlara sahip iki farklı veri kümesinde iki farklı sınıflandırma algoritması kullanılarak doğrulanmıştır. DOTBA'nın doğrusal TBA'dan daha iyi sınıflandırma doğruluğu elde etmesine izin verdiği belirtilmiştir. Yöntemin etkinliğini değerlendirmek için sınıflandırma iki farklı algoritma, sinir ağları ve destek vektör makineleri tarafından gerçekleştirilmiştir.

Suşac ve ark. (2013), TBA ve YSA gibi parametrik olmayan iki yöntem kullanarak öğrencilerin girişimcilik yeteneklerini modellemeyi amaçlamışlardır. Modellemenin ilk aşamasında öznitelik çıkarımı yapmak için TBA ve ikinci aşamada öğrencileri girişimcilik amaçlarına göre sınıflandırma yapmak için YSA kullanmışlardır. Temel bileşen faktörlerinden çıkarılan değişkenlerle, girişimcilik amacına sahip öğrencilerin tanınmasında, veri toplama ve model eğitimi için gereken zamanın belirlenmesinde doğruluk ölçütleri açısından en etkili yöntem olduğunu ifade etmişlerdir. İleride, sonuçları genelleştirmek ve üniversitelerde öğrencilerin girişimci yanlarına daha fazla dikkat çekmek için uygulanabilecek bir model üretmek amacıyla daha fazla veri kümesi üzerinde yöntembilimi test etmeyi amaçlamışlardır.

Bouzenad ve Ramdani (2017), doğrusal olmayan süreçleri izlemek ve anormal davranışları tespit etmek için bir kontrol çizelgesi geliştirmişlerdir. Genellikle üretilen yanlış alarmları azaltabilen ve geleneksel üst kontrol sınırlarına dayanan bir strateji önermişlerdir. Bu stratejinin, üretilen yanlış alarmları azaltabilen bir adaptif üst kontrol sınırı kullanarak çok değişkenli istatistik süreç kontrolünü geliştirmek için Gaussian karışım modelini, gelişmiş darboğaz nöral ağlarla birleştirdiğini belirtmişlerdir. Önerilen gelişmiş darboğaz nöral ağların sadece giriş vektörünün tahmin değerini değil,

aynı zamanda farklı çalışma modlarına ait olasılık oranlarını da sağladığını ifade etmişlerdir. Ayrıca, sensör geçerlilik endeksi ve hata tahmin karesine uygulanan filtrenin, yanlış alarm sayısını minimize ederek sisteme önemli bir özellik eklediğini göstermişlerdir.

Villas-Boas ve ark., (2017) çalışmalarında, Piabanha Nehri havzasındaki su kalitesi ağı parametrelerinin fazlalığını ve konumlarını değerlendirmek için bir otomatik sinir ağına dayalı DOTBA sunmuşlardır. Çalışmada su kalitesi ve izleme konumu verilerine hem TBA hem DOTBA uygulamışlardır. Su kalitesine ait değişkenleri TBA için 4 boyuta indirgeyerek varyansı %76, DOTBA için 2 boyuta indirgeyerek varyansı %80 bulmuşlardır. İzleme konumu için ise TBA'nın varyansın %75'ini, DOTBA'nın ise %96'sını açıkladığını ve DOTBA'nın, Piabanha su havzasının su kalitesi ve izleme konum verilerinin yeniden yapılandırılmasında TBA'dan daha iyi performans gösterdiğini belirtmişlerdir.

### 3. GEREÇ VE YÖNTEM

#### 3.1. Gereç

Çalışmada, uygulama materyali olarak serbest erişimli veri sitesinden (<http://mlr.cs.umass.edu/ml/machine-learning-databases/thyroiddisease/hypothyroid.data>) Erişim tarihi: 10.09.2018) sağlanan 422 hastaya ait 19 değişkenli hipotiroidi verisi kullanılmış olup, ele alınan değişkenler ve özellikleri Tablo 2’de verilmiştir.

**Tablo 2.** Çalışmada ele alınan değişkenler ve özellikleri

Değişken adı	Kategoriler	Tür
Tiroksin tedavisi alan	(1) Var, (0) Yok	Nominal
Antitiroid tedavi alan	(1) Var, (0) Yok	Nominal
Hipotiroidi öyküsü olan	(1) Var, (0) Yok	Nominal
Gebelik	(1) Var, (0) Yok	Nominal
Tümör	(1) Var, (0) Yok	Nominal
Guatr	(1) Var, (0) Yok	Nominal
Tiroksin öyküsü olan	(1) Var, (0) Yok	Nominal
Tiroid ameliyatı olan	(1) Var, (0) Yok	Nominal
Hipertiroidi öyküsü olan	(1) Var, (0) Yok	Nominal
Eşlik eden hastalık	(1) Var, (0) Yok	Nominal
Lityum	(1) Var, (0) Yok	Nominal
Hipotiroidi	(1) Var, (0) Yok	Nominal
Cinsiyet	(1) Erkek,..(2) Kadın	Nominal
Yaş	Sürekli	Sürekli
TSH	Sürekli	Sürekli
TT4	Sürekli	Sürekli
FTI	Sürekli	Sürekli
T3	Sürekli	Sürekli
T4U	Sürekli	Sürekli

#### 3.2. Yöntem

##### 3.2.1.Doğrusal olmayan temel bileşenler analizinin teorisi

Doğrusal olmayan temel bileşenler analizi eşitliklerinde aşağıdaki notasyonlar kullanılmıştır.

n: Gözlem, deney ünitesi veya nesne sayısı

$n_w$ :  $(\sum_{j=1}^n w_j)$  Analize tabi tutulan ağırlıklandırılmış gözlem sayısı

$n_{tot}$ : Toplam gözlem sayısı (analiz edilen ve bütünleyici veya tamamlayan gözlem sayısı)

$w_j$ : j. gözlemin veya nesnenin ağırlığı

( $w_j = 1$  'dir; i. gözlem ağırlıklandırılmamışsa)

( $w_j = 0$  'dır; i. gözlem tamamlayıcı veya bütünleyici (supplementary) gözlemse)

W: " $n_{tot} \times n_{tot}$ " boyutlu, diyagonal elemanları  $w_j$  olan diyagonal matris

m: Analiz edilen değişken sayısı

$m_w$ : ( $m_w = \sum_{j=1}^m v_j$ ) Ağırlıklandırılmış analiz edilen değişken sayısı

$m_{tot}$ : Toplam değişken sayısı (analiz edilen + tamamlayıcı veya bütünleyici değişken)

$m_1$ : Çoklu nominal ölçekleme seviyeli analiz edilen değişken sayısı

$m_2$ : Çoklu olmayan ölçekleme seviyeli analiz edilen değişken sayısı

$m_{w1}$ : Çoklu nominal ölçekleme seviyeli ağırlıklandırılmış analiz edilen değişken sayısı

$m_{w2}$ : Çoklu olmayan ölçekleme seviyeli ağırlıklandırılmış analiz edilen değişken sayısı

J: Çoklu nominal ölçekleme seviyesine sahip indeks değeri

H: " $n_{tot} \times m_{tot}$ " boyutlu veri matrisi (kategori göstergeleri)

P: Boyut sayısı, j. değişken için  $j = 1, \dots, m_{tot}$

$v_j$ : Değişken ağırlığı; (j. değişken için ağırlık belirlenmemişse veya j. değişken bütünüleyici ise  $v_j = 1$ 'dir.)

$k_j$ : j. değişkenin kategori sayısı ( $h_j$ 'deki uzaklık değerlerinin sayısı)

$G_j$ : " $n_{tot} \times k_j$ " boyutlu j. değişken için gösterge matrisi,  $G_j$ 'nin elemanları  $i = 1, \dots, n_{tot}$ ;  $r = 1, \dots, k_j$ 'dir.

$$g_{(j)ir} = \begin{cases} 1 \text{ dir; } i. \text{ nesne } j. \text{ değişkenin } r. \text{ kategorisinde ise} \\ 0 \text{ dir; } i. \text{ nesne } j. \text{ değişkenin } r. \text{ kategorisinde değilse} \end{cases}$$

$D_j$ :  $k_j \times k_j$  boyutlu diyagonal matris (ağırlıklandırılmış tek değişkenli marjinal değerleri içerir. Yani  $G_j$ 'nin ağırlıklandırılmış sütun toplamları ( $D_j = G_j' W G_j$ ))

$M_j$ : " $n_{tot} \times n_{tot}$ " boyutlu diyagonal matris. Bu matrisin diyagonal elemanları aşağıdaki gibi tanımlıdır.

$$m_{(j)ii} = \begin{cases} 0 \text{ dir; } j. \text{ pasif değişkendeki } i. \text{ gözlem kayıp gözlem ise} \\ 0 \text{ dir; } i. \text{ gözlem } j. \text{ değişkenin } r. \text{ kategorisinde ise} \\ v_j \text{ dir; Diğer durumlar için} \end{cases}$$

$$M^* = \sum_j M_j \quad (5)$$

$S_j$ :  $k_j \times (s_j + t_j)$  boyutta j. değişken için spline tabanı

$b_j$ : Eğrilik katsayıları vektörü  $s_j + t_j$  mertebeden

$d_j$ : Eğrilik kesim değeri

$s_j$ : Polinomial derecesi

$t_j$ : İç düğümlerin sayısı

$X$ :  $n_{tot} \times p$  boyutlu nesne skorları matrisi

$X_w$ : Ağırlıklandırılmış nesne skorları ( $X_w = W X$ )

$X^n$ : Gerekli normalizasyon seçeneklerine normalize yapılmış nesne skorları

$Y_j$ :  $k_j \times p$  boyutlu sentroit koordinatları, değişkenler optimal ölçekli ise çoklu nominaldır ve bu kategoriler rakamsaldır yani nümeriktir.

$y_j$ :  $k_j$ . seviyedeki çoklu ölçekleme seviyesi ile kategorik değişkenler için nümerik değerler

$a_j$ :  $p$ . boyutta çoklu ölçekleme seviyesinde olmayan değişkenler için bileşen yükleri

$a_{nj}$ :  $a_j$ 'nin gerekli normalizasyon seçeneğine uygun normalize edilmiş bileşen yükleri

$Y$ : Çoklu nominal ölçekleme seviyesindeki değişkenler için ( $Y_j$ ) kategorilerin nümerik değerleri toplamı ve çoklu ölçekleme seviyeleri olmayan vektör koordinatları ( $y_j, a_j$ )

Kategorik temel bileşenler analizi, bazı normalizasyon sınırlamaları altında çeşitli yollarla  $x$  nesne skorlarının ve  $Y_j$  ortalama değerlerinin bulunmasını amaçlar. Böylece aşağıdaki fonksiyon minimize edilir.

$$\sigma(X; Y) = n_w^{-1} \sum_j c^{-1} \text{tr} \left( (X - G_j Y_j)' M_j W (X - G_j Y_j) \right) \quad (6)$$

Normalizasyon sınırlaması altında  $X' M^* W X = n_w m_w I$ 'dir. ( $I$   $p \times p$  boyutlu birim matristir).  $M_{j\sigma}(X; Y)$  buraya dâhil edilince pasif konumdaki kayıp gözlemlerin etkisi giderilmiş olur.  $M^*$  her bir nesne için aktif veri değerlerinin sayısını içerir. Nesne skorları aynı zamanda merkezileştirir ve  $u' M^* W X = 0$  eşitliği sağlanır.

Doğrusal olmayan temel bileşenler analizi algoritmasında amaç fonksiyonunun optimizasyonu için aşağıdaki iterasyon süreci takip edilir.

- a) Başlatma
- b) Kategori ölçeklerinin güncellenmesi
- c) Nesne skorlarının güncellenmesi
- d) Ortonormalizasyon
- e) Yakınsama testi (2-4 tekrarlanarak)
- f) Döndürme ve yansıtma

a) Başlatma

Başlangıç konfigürasyonu belirlenmemişse  $X$  nesne skorları için rasgele rakamlarla başlangıç değeri verilir. Sonra  $X$  ortonormalize edilir. Böylece  $u'M*WX=0$  ve  $X'M*WX=n_w m_w I$  olur ve  $X_w^+$  elde edilmiş olur.

Başlangıç bileşen yükleri  $X_w^+$  matrisinin karşılıklı (çapraz) çarpımı ile hesaplanır. Ayrıca orijinal değişkenler  $(I-M_j u u' W / (u' M_j W u)) h_j$  merkezileştirilir ve birim uzunluğa yeniden ölçeklendirilir (IBM SPSS, 2010).

b) Kategori ölçeklerinin güncellenmesi

$X_w^+$ 'nin sabit değeri ile  $Y_j$  ortalama güncellenir ve  $\tilde{Y}_j = D_j^{-1} G_j' X_w^+$  olur. Çoklu nominaller için  $Y_j^+ = \tilde{Y}_j$ 'dir. Çoklu ölçekleme seviyesi olmayanlar için güncelleme işlemi benzer şekilde  $\tilde{Y}_j = D_j^{-1} G_j' X_w^+$  olarak hesaplanır.

$\tilde{Y}_j$ 'nin rank ayrışımının hesaplanabilmesi için dalgali en küçük kareler algoritması kullanılır.  $\tilde{y}_j = \tilde{Y}_j a_j$  olur. Nominal değişkenler içinde  $y_j^* = \tilde{y}_j$ 'dir. Sonraki dört optimal ölçekleme seviyeleri için  $j$ . değişken ekstra kategori olarak alınmışsa;  $y_j^*$ ,  $k_j$  kategorisine başlangıç aşamasında dahil edilir ve final aşamasında çıkarılır.

Spline-nominal, spline-ordinal değişkenler için  $y_j^* = d_j + S_j b_j$ 'dir. Spline transformasyonu  $\tilde{y}_j$  ağırlıklandırılmış regresyon olarak hesaplanır ve  $D_j$ 'nin diyagonal elemanları ile ağırlıklandırılır. Spline-ordinal ölçekleme seviyesi için  $b_j$ 'nin elemanları negatif olmayacak şekilde kısıtlanır ki bu da  $y_j^*$ 'i monoton artan yapar. Ordinal değişkenler için  $y_j^* \leftarrow \text{WMON}(\tilde{y}_j)$ 'dir. Buradaki  $\text{WMON}(\tilde{y}_j)$  fonksiyonu ağırlıklandırılmış monoton regresyon sürecini göstermek için kullanılır ve bu  $y_j^*$ 'i monoton artan yapar. Kullanılan ağırlıklar  $D_j$ 'nin diyagonal elemanlarıdır.

Nümerik değişkenler için  $y_j^* \leftarrow \text{WLIN}(\tilde{y}_j)$ 'dir.  $\text{WLIN}(\tilde{y}_j)$  ağırlıklandırılmış doğrusal regresyon sürecini göstermek için kullanılır. Ağırlıklar  $D_j$ 'nin diyagonal elemanlarıdır. Sonra  $y_j^*$  normalize edilir ( $j$ . değişken ekstra kategori olarak girmişse  $y_j^*$ 'e dahil edilir). Normalizasyon sonrası  $y_j^+ = n_w^{1/2} y_j^* (y_j^{*'} D_j y_j^*)^{-1/2}$  olur. Buradan



bileşen yükleri  $a_j^+ = n_w^{-1} \tilde{Y}' D_j y_j^+$  olarak elde edilir ve son olarak da  $Y_j^+ = y_j^+ a_j^+$  olur (IBM SPSS, 2010).

c) Nesne skorlarının güncellenmesi

İlk olarak yardımcı skorlar matrisi olan  $ZZ \leftarrow \sum_j M_j G_j Y_j^+$  olarak hesaplanır ve  $W$  ve  $M^*$  göre merkezileştirilir. Buradan  $X^* = (I - M^* u u' W / (u' M^* W u)) Z$  olur (IBM SPSS, 2010).

d) Ortonormalizasyon

$M^*$  i ve ortonormal  $X^+$  bulmak için en küçük kareler yaklaşımı ile procrustes rotasyonu kullanılır. Tekil değer ayrışımı ile  $m_w^{1/2} M_*^{-1/2} W^{1/2} X^* = K \Lambda^{1/2} L'$  eşitliğinden  $n_w^{1/2} m_w^{1/2} M_*^{-1/2} W^{1/2} K L'$  elde edilir. Buradan ortonormal ağırlıklandırılmış nesne skorları  $X_w^+ \leftarrow n_w^{1/2} m_w M_*^{-1} W X^* \Lambda^{1/2} L'$  olarak hesaplanır ve  $X^+ = W^{-1} X_w^+$  olur (IBM SPSS, 2010).

e) Yakınsama testi (2-4 tekrarlanarak)

Yakınsama testi  $TFIT = (pn_w)^{-1} \sum_{j \in J} V_j \text{tr}(Y_j' D_j V_j) + \sum_{j \notin J} V_j a_j' a_j$  eşitliği ile yapılır. Yakınsamadan sonra  $TFIT$  değeri  $\text{tr}(\Lambda^{1/2})$  olur.  $\wedge$  son iterasyon sürecinde ortonormalizasyon adımı hesaplanır (IBM SPSS, 2010).

f) Döndürme (rotasyon)

Dönüşüm sonucunda temel eksenleri elde edebilmek için  $X^+$  matrisi  $L$  matrisine döndürülür. Buna ek olarak  $X^+$  matrisinin  $s$ . sütunu  $s$  boyutlu yüklere ait kareler ortalamasını yansıtmaktadır. Negatif işaretler olması karesel yüklerin ortalamasının daha yüksek olduğunu gösterir (IBM SPSS, 2010).

### 3.2.2. Maksimum rank sayısı

Maksimum rank " $\rho_{\text{mak}}$ " herhangi bir veri seti için hesaplanabilen maksimum boyut sayısını belirtmektedir ve genellikle;

$$\rho_{\max} = \begin{cases} \min\{(n-1), r_1, r_2\} & K = 2 \text{ ise} \\ \min\{(n-1), \max r_k\} & K > 2 \text{ ise} \end{cases}$$

olarak hesaplanır. Buradaki  $r_k$  değeri, eşitlik (7)'deki gibi tanımlanır.

$$r_k = \sum_{j \in JM(k)} k_j + m_{k1} - m_{k2} \quad (7)$$

Eşitlik (7)'de  $m_{k1}$ ,  $k$  değişken setindeki kayıp gözlem içermeyen çoklu değişken sayısı,  $m_{k2}$ ,  $k$  değişken setindeki tekli değişken sayısı ve  $JM(k)$  ise indeks seti olup çoklu setlerdeki değişkenlerin sayısıdır. Aşağıdaki üç koşuldan herhangi birisi yerine gelmezse OVERALS durdurulur.

1. Koşul:  $r_k < n_k - 1$ , 2. Koşul:  $n_k > 2$ , 3. Koşul:  $\sum_k r_k \leq \sum_k (n_k - 1) - (n_{\max} - 1)$ 'dir. Buradaki  $n_k$ ,  $k$ . setteki kayıp gözlem içermeyen nesne sayısını ve  $n_{\max}$  ise bütün  $n_k$ 'lardaki nesne sayısını gösterir (IBM SPSS, 2010).

### 3.2.3. Uyumluluk ve kayıp ölçüleri

Toplam uyum (total fit) bir önceki aşamadaki yakınsama testindeki TFIT değeridir. Toplam kayıp fonksiyonu ise çoklu ve tekli kayıp fonksiyonu olmak üzere sırasıyla aşağıdaki gibi yazılır.

$$TMLOSS = (m_{w1} + pm_{w2}) - \left( (n_w p)^{-1} \sum_{j \in J} v_j \text{tr}(Y_j' D_j Y_j) + n_w^{-1} \sum_{j \notin J} v_j \text{tr}(Y_j' D_j Y_j) \right) \quad (8)$$

$$LOSS = n_w^{-1} \sum_{j \in J} v_j \text{tr}(Y_j' D_j Y_j) - \sum_{j \notin J} v_j a_j' a_j \quad (9)$$

### 3.2.4. Cronbach's alpha

Her bir boyut için Cronbach's Alpha  $a_s = m_w (\lambda_s^{1/2} - 1) / (\lambda_s^{1/2} (m_w - 1))$  eşitliği ile toplam Cronbach's Alpha ise  $a = m_w (\sum_j \lambda_s^{1/2} - 1) / \sum_j \lambda_s^{1/2} (m_w - 1)$  eşitliği ile hesaplanır. Burada  $\lambda_s$ ,  $\Lambda$ 'nın  $s$ . diagonal elemanıdır ve en son iterasyon sürecinde ortonormalizasyon adımı hesaplanır (IBM SPSS, 2010).

### 3.2.5. Varyans açıklama oranları

s=1,...,p'ye kadar her bir boyut için varyans açıklama oranları; çoklu nominal değişkenler için:

$$VAF1S = n_w^{-1} \sum_{j \in J} V_j \text{tr}(y'_{(j)s} D_j y_{(j)s}), (\% \text{ varyans } VAF1_s \times 100 / m_{w1})$$

ile çoklu nominal olmayan değişkenler için:

$$VAF2S = \sum_{j \in J} V_j a_{js}^2, (\% \text{ varyans } VAF2_s \times 100 / m_{w2}) \text{ ile hesaplanır.}$$

Her bir boyut için özdeğer  $\lambda_s^{1/2} = \sqrt{VAF1S + VAF2S}$ 'dir.  $\lambda_s$ ,  $\Lambda$ 'nın s. diagonal elemanıdır ve en son iterasyon sürecinde ortonormalizasyon adımında hesaplanır.

Boyutların ortalamaları üzerinden çoklu nominal ve çoklu olmayan nominal değişkenler için toplam açıklanabilen varyans;  $\text{tr}(\Lambda^{1/2}) = P^{-1} \sum_s VAF1_s + \sum_s VAF2_s$  eşitliği ile hesaplanır. Bu eşitlik toplam özdeğerler olarak bilinir. Eğer pasif kayıp gözlem yoksa  $\Lambda^{1/2}$  değişken ağırlıkları ile ağırlıklandırılmış korelasyon matrisinin özdeğerleridir ve aşağıdaki gibi hesaplanır (IBM SPSS, 2010).

$$r_{ij}^w = v_j r_{jj}, \text{ver}_{j1}^w = v_j^{1/2} \cdot r_{j1} \quad (10)$$

pasif kayıp gözlem varsa bu özdeğerler,

$$mw Q_c' M_*^{-1} Q, \text{ ile } Q_c = n_w^{-1/2} (I - M_* u u' W) / (u' M_* W u) Q \text{ 'dir.}$$

### 3.2.6. Sentroid koordinatları

Sentroid koordinatları  $VAF_j s = v_j \text{tr}(Y'_{js} D_j Y_{js})$  eşitliği ile hesaplanır (IBM SPSS, 2010).

### 3.2.7. Vektör koordinatları

Vektör koordinatları  $VAF_j s = v_j a_{js}^2$ 'dir. (her  $j \in J$  için)

### 3.2.8. Korelasyonlar ve özdeğerler

#### 3.2.8.1. Transformasyon öncesi

$R = n_w^{-1} H_c' W H_c$ , eşitliği  $H_c$  ile ağırlıklandırılmış merkezi ve normalize edilmiş  $H$  matrisidir.  $j$  değişkeni tamamlayıcı değişken ise  $R$  matrisinin özdeğer ayrışımı için birinci satır ve birinci sütun atılır. Sonra  $r_{ij}, (v_i v_j)^{1/2}$  ile çarpılır.

#### 3.2.8.2. Transformasyon sonrası

Analiz çoklu olmayan değişkenler için yapılmışsa ve kayıp gözlem yoksa veya pasif olarak belirlenmişse korelasyon matrisi  $q_j = G_j y_j$  ile  $R = n_w^{-1} Q' W Q$  olur.  $R$ 'nin ilk  $p$  özdeğeri  $\lambda^{1/2}$ 'e eşittir. Analizde çoklu nominal değişkenler varsa  $p$  korelasyon matrisleri  $s = 1, \dots, p$ 'ye kadar olmak üzere  $R(s) = n_w^{-1} Q'_{(s)} W Q_{(s)}$  eşitliği ile hesaplanır. Çoklu olmayan değişkenler için  $q_{(s)j} = G_j y_j$ , çoklu nominal değişkenler için ise  $q_{(s)j} = n_w^{1/2} G_j Y_{(j)s} (Y'_{(j)s} D_j Y_{(j)s})^{-1/2}$ 'dir. Genellikle  $R_{(s)}$ 'nin birinci özdeğeri daha yüksektir ve  $\lambda_s^{1/2}$ 'e eşittir.  $\lambda^{1/2}$ 'nin daha düşük değerleri çoğunlukla  $R_{(s)}$  matrisinin ikinci ya da daha sonraki özdeğerleridir. Kayıp gözlem pasif olarak belirlenmişse, nümerik değişkenler korelasyonlar hesaplanmadan modele girer. Bu durumda korelasyon matrisinin özdeğerleri  $\lambda^{1/2}$ 'e eşit olmaz. Çoklu nominal değişkenlerin ilave kategorileri için ölçekleme  $Y_{(j)(k_j+1)s} = (\sum_{i \in I} W_i)^{-1} \sum_{i \in I} W_i X_{is}$  ile hesaplanır. Çoklu olmayan değişkenler için ilave kategorilerin ölçeği ilk aşamada eşitlik (11) ile hesaplanır.

$$Y_{(k_j+1)j} = n_w^{1/2} \left( \sum_s a_{js}^2 \right)^{-1} \sum_s a_{js} Y_{(j)(k_j+1)s} \quad (11)$$

$R$ 'nin özdeğerlerinin hesaplanması (özdeğer ayrışımı) için  $R$  matrisinden ilk  $j$ . sütun ve  $j$ . satır atılır.  $j$  bütünlüycü değişken ise  $r_{ij}$  ile  $(v_i v_j)^{1/2}$  olur (IBM SPSS, 2010).

#### 3.2.9. Nesne skorları ve yükler

$X$ , çoklu ölçekleme seviyesinde değilse  $n_w^{-1/2} W^{1/2} Q V^{1/2}$ 'nin ilk  $p$ . tekil değerlerinin normalizasyon ayrışımı,  $X$ 'in nesne skorları üzerinden  $m_w$  ve  $A$ 'ya

bölümüyle ve daha sonrada Q ve V'nin diyagonal elemanları olan v<sub>j</sub> ile çarpılması sonucu elde edilir. Buna göre  $n_w^{-1/2}W^{1/2}QV^{1/2}$  'nin tekil değer ayrışımı,  $SVD(n_w^{-1/2}W^{1/2}QV^{1/2}) = K\Phi^{1/2}L'$  olur. X = K<sub>p</sub> (p indisi K'nın ilk p. sütunlarını göstermektedir).

$A = (L\Phi^{1/2})_{p'}$   $XA'n_w^{-1/2}W^{1/2}QV^{1/2}$  'nin en iyi p boyutlu yaklaşımını verir.  $\Phi_p^{1/2}$  'nin ilk p. tekil değerleri  $\Lambda^{1/4}$  'e eşittir. İlk p. tekil değerlerinin ayrışımı için  $(K\Phi^{1/2}L')_p = K_p\Phi_p^{a/2}\Phi_p^{b/2}L'_p = K_p\Lambda^{a/4}\Lambda^{b/4}L'_{p'(a+b-1)}$  eşitliği yazılır. Optimizasyon aşamasında temel değişken normalizasyonu kullanılır ve yakınsamadan sonra  $X = n_w^{1/2}W^{-1/2}K_p$  ve  $A = V^{-1/2}L_p\Lambda^{1/4}$  olur. Çoklu nominal değişkenler analiz ediliyorsa  $n_w^{-1/2}W^{1/2}Q_{(s)}V^{1/2}$ ,  $\Lambda_s^{1/4}$ , e eşit olur. Değişkenler çoklu nominal ölçekleme seviyesinde ise normalize edilmiş faktörler sentroidler içinde gösterilir ve  $Y_j^n = Y_j\Lambda^{1/4(b-1)}$  olur.

### 3.2.10. Ölçme

Çoklu ölçekleme seviyesinde ölçümler  $y_j$  olarak gösterilir. Vektör koordinatları  $y_j(a_j^n)$  ile sentroid koordinatları  $y_j$  temel normalizasyon ya da diğer normalizasyon seçeneklerinden birisi olan  $D_j^{-1}G_j'WX^n$  ile gösterilir Çoklu nominal değişkenler için ölçümler sentroid koordinatlarıyla  $Y_j^n$  dir. Herhangi bir kategori tamamlayıcı nesnelere olarak kullanılmışsa (pasif kayıp gözlem) bu kategori için yalnızca sentroid koordinatları gösterilir ve  $y_{(j)r} = n_w^{1/2}n_{jr}^{-1}\sum_{j\in J}x_j^n$  olarak hesaplanır. Çoklu ölçekleme seviyesinde olmayan değişkenler için  $y_{(j)r} = n_w^{1/2}n_{jr}^{-1}\sum_{j\in J}x_j\Lambda^{1/4(b-1)}$  olarak hesaplanır. Burada  $y_{(i)r}$   $Y_j$ 'nin r. satırıdır,  $n_{jr}$  kategorideki nesne sayısıdır ve I, r. kategorideki nesnelere için kayıt indeks değeridir (IBM SPSS, 2010).

### 3.2.11. Artıklar

Çoklu olmayan değişkenler için artıklar yaklaşık  $Xa_j$  'nin  $j(G_ja_j)$  değişkeni ile saçılım grafiği olarak verilir. Çoklu nominal değişkenlerde her boyut için saçılım grafiği  $x_s^n$  'e karşı  $G_jy_{(j)s}^n$  'nin çizilmesiyle elde edilir (IBM SPSS, 2010).

### 3.2.12. Planlanmış sentroidler

Birinci deęişkenin  $j$ . deęişken üzerine planlanmış sentroidi,  $j \notin J$  olmak üzere  $Y_j a_j (a_j' a_j)^{-1/2}$ 'dir.

### 3.2.13. Ölçeklenmiş ikili, üçlü faktör ve yüklerin grafięi

Nesne skorları ile ya da sentroidlerle yüklerin her ikisinin de saçılım grafiklerinde nesne skorları ve sentroidler ařağıdaki ölçekleme faktörleri kullanılarak yeniden ölçeklenir (Demir, 2010).

$$\text{Ölçekleme Faktörü} = \frac{2 \sum_{s=1}^p \max(a_{1s}^n, \dots, a_{ms}^n)}{\sum_{s=1}^p \left( \min(x_{1s}^n, \dots, x_{ns}^n) I + (\max(x_{1s}^n, \dots, x_{ns}^n)) \right)} \quad (12)$$

### 3.3. Procrustes Yöntemi

Procrustes yöntemi, ilk olarak Mosier (1939) tarafından sunulmuş ve Hurley ve Cattell (1962) tarafından faktör analizinde kullanılmak üzere geliştirilmiştir. Daha sonra, Schonemann ve Carroll (1970) ile Gower (1971) tarafından yapılan çalışmalarda, çok boyutlu ölçeklendirmede önemli bir yöntem olarak görülmüştür (Sibson, 1978).

Procrustes yöntemi, karesel uzaklıkların toplamını minimum yapan bir yaklaşım olarak bilinmektedir. Bu yöntem; en küçük kareler yöntemini kullanarak, Öklid uzaklığına göre benzerlik dönüşümleri (öteleme, ölçekleme, döndürme) altında, noktaları olabildiğince yakın olarak eşleştirmeyi amaçlamaktadır (Ocakoglu, 2011).

### 3.4. Dalgalı En Küçük Kareler Yöntemi

Bu yöntem, Leeuw, Young ve Takane (1976) tarafından dalgalı en küçük kareler (Alternating least square = ALS) olarak adlandırılan ve zorunlu olarak yakınsak olması istenen özellięe sahip olan bir işlem sürecidir. Dalgalı en küçük kareler yöntemi, parametrelerin birkaç alt gruba bölünmesini ve alt gruplardan her biri için ayrı ayrı en küçük kareler tahminlerinin elde edilmesini içeren parametre tahminine genel bir yaklaşımdır. Tahmin, dönüşümlü olarak, tüm alt kümeler tahmin edilinceye kadar

tekrarlanır. Bu işlemin tamamı daha sonra yakınsama elde edilene kadar yinelenir (Takane ve ark., 1977)

Rastgele süreçlerin en önemlilerinden biri beyaz gürültü sürecidir. Birçok pratik durumdaki sinyaller beyaz gürültü işlemiyle yaklaştırılmaktadır. Beyaz gürültü sinyallerin modellenmesinde önemli bir rol oynar. Ayrık zamanda, beyaz gürültü, numuneleri sıfır ortalama ve sonlu varyans ile seri olarak ilişkili olmayan rastgele değişkenler dizisi olarak kabul edilen ayrık bir sinyaldir (Nussbaum, 1996).

### 3.5. Yapay Sinir Ağlarında Doğrusal Olmayan Temel Bileşenler Analizi

Doğrusal Temel Bileşenler Analizi yaygın olarak kullanılan bir yöntemdir, Ancak bu yöntem, değişkenlerin sürekli değişken olmasını ve aralarındaki ilişkilerin doğrusal olması ön şartını gerektirir. Değişkenler arası ilişki doğrusal değilse doğrusal olmayan ilişkilerin saptanması için doğrusal TBA genelleştirilmiş ve DOTBA geliştirilmiştir. DOTBA, TBA'nın doğrusal olmayan bir uzantısıdır.

Uygulamalarda, veriler  $x(t) = [x_1, \dots, x_l]$  şeklinde ifade edilebilir. Burada her değişken  $x_i$ , ( $i = 1, \dots, l$ ) n gözlem içerir. TBA,  $u$ 'yu,  $x_i$ 'nin doğrusal bir birleşimi ve  $a$  ile ilişkili bir vektörü olarak bulmaya çalışır. Bu ilişki aşağıdaki gibi yazılabilir.

$$u(t) = a \cdot x(t) \quad (13)$$

Böylece;

$$\langle \|x(t) - a \cdot u(t)\|^2 \rangle \text{ minimize edilir.} \quad (14)$$

Eşitlik (14)'te  $u$  ilk temel bileşen olarak adlandırılır. Kovaryans matrisinin ilk özvektörü (Ampirik ortogonal fonksiyon (EOF) olarak da adlandırılır)  $a$ , genellikle bir uzaysal modeli tanımlar. Hata,  $x - au$ 'dan ikinci temel bileşenle de edilir ve bu bileşen sayısı kadar devam eder. Uygulamada, temel bileşenler eş zamanlı olarak elde edilir (Jolliffe, 1986). DOTBA ve TBA arasındaki temel farklılık; DOTBA,  $x$ 'den  $u$ 'ya doğrusal olmayan bir haritalama yapılmasına izin verirken, TBA yalnızca doğrusal bir haritalamaya izin verir. DOTBA'yı gerçekleştirmek için Şekil 9'daki sinir ağı değişkenlerinin giriş ve çıkış katları arasında (veya "nöron") değişkenlerin 3 gizli

katmanını içerir. Transfer fonksiyonu olarak tanımlanan  $f_1$ ,  $l$  uzunluğundaki giriş sütun vektörü olan  $x$ 'den, birinci gizli tabaka olan ve  $h^{(x)}$  ile gösterilen  $m$  uzunluğundaki sütun vektörüne haritalama yapar. Buna göre  $h_k^{(x)}$ ;

$$h_k^{(x)} = f_1[(W^{(x)}x + b^{(x)})_k] \quad (15)$$

olarak yazılır. (15) no'lu eşitlikte  $w^{(x)}$ , "m x l" boyutlu ağırlık matrisi,  $b^{(x)}$  ise yanlılık parametrelerini içeren  $m$  boyutlu sütun vektörüdür ( $k = 1, \dots, m$ ). Benzer şekilde, ikinci bir transfer fonksiyonu olan  $f_2$ , kodlayıcı katmandan doğrusal olmayan temel bileşeni gösteren darboğaz katmana haritalama yapar ve bu doğrusal olmayan temel bileşen olan  $u$  için;

$$u = f_2(w^{(x)} \cdot h^{(x)} + \bar{b}^{(x)}) \quad (16)$$

olarak yazılır.

$f_2$ , genellikle doğrusal bir fonksiyon olarak alınırken, dönüşüm fonksiyonu  $f_1$  doğrusal değildir (Fonksiyonu kesin olmamakla birlikte genellikle hiperbolik tanjant veya sigmoid fonksiyon olabilir). Daha sonra, bir dönüşüm fonksiyonu  $f_3$ ,  $u$ 'dan son gizli tabaka olan  $h^{(u)}$ 'ya haritalama yapar. Böylece  $h_k^{(u)}$ ;

$$h_k^{(u)} = f_3[(w^{(u)}u + b^{(u)})_k] \quad (17)$$

olarak yazılır ( $k = 1, \dots, m$ ). Bu fonksiyonu eşitlik (18) izler.


$$x'_i = f_4[(W^{(u)}h^{(u)} + \bar{b}^{(u)})_i] \quad (18)$$

Burada hata fonksiyonu olan  $j = \langle \|x - x'\|^2 \rangle$   $W^{(x)}$ ,  $b^{(x)}$ ,  $w^{(x)}$ ,  $\bar{b}^{(x)}$ ,  $w^{(u)}$ ,  $b^{(u)}$ ,  $W^{(u)}$  ve  $\bar{b}^{(u)}$  optimal değerlerinin bulunması ile minimize edilir (Hsieh, 2001). Orijinal veri  $x$  ile sinir ağı çıktısı  $x'$  arasındaki hata kareler ortalaması böylece minimize edilir.

DOTBA tarafından kullanılan toplam serbest (ağırlık ve eşik değer) parametrelerin sayısı  $(m+f+1)(M_1+M_2)+m+f$ 'dir. Hem kodlama hem de kod çözme katmanlarındaki gizli nöronların sayısı ve  $M$ 'nin seçimi genel bir kuralı izler. Daha büyük bir  $M$ , ağın doğrusal olmayan modelleme yeteneğini artırır, ancak aynı zamanda aşırı uyum probleminde de yol açabilir. Daha düşük bir  $M$  için, ağın temsil kapasitesi



sınırlı olduğu için doğruluk oranı düşük olabilir.  $M$ 'nin sayısı, ağ tarafından üretilebilecek doğrusal olmayan işlevlerin karmaşıklığı ile ilgilidir.  $f_4$  doğrusal bir fonksiyon ve  $M = 1$  ise tüm  $x_i'$ 'nin tek bir gizli nöronla doğrusal olarak ilişkili olduğunu eşitlik (18) gösterir, dolayısıyla  $x_i'$  değişkenleri arasında sadece doğrusal bir ilişki olabilir. Doğrusal olmayan çözümler için,  $M \geq 2$  olması gerekir (Kramer, 1991).



Şekil 9. Doğrusal olmayan temel bileşenler analizi için sinir ağı modeli

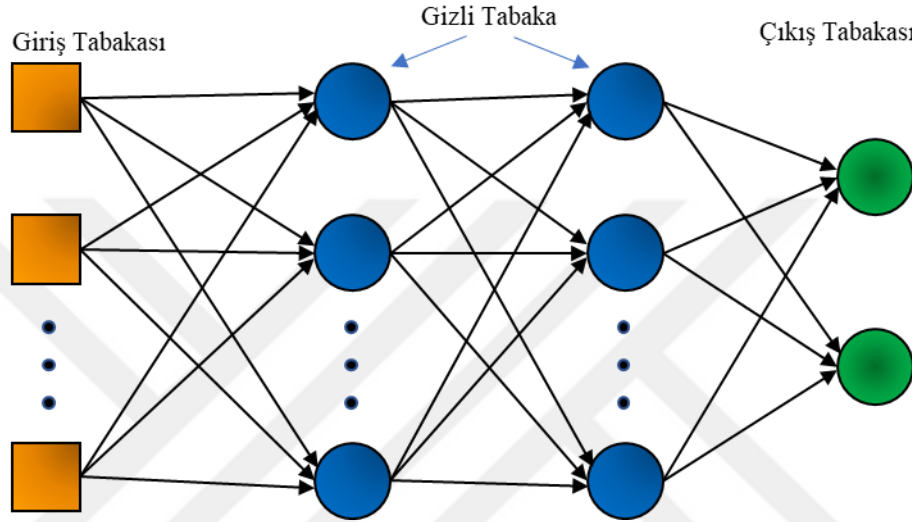
Şekil 9'da sol taraftaki girdi katmanı  $x$  ve sağ taraftaki çıktı katmanı  $x'$  arasında 3 gizli katman (daire ile gösterilen) vardır. Giriş katmanının yanında, kodlama katmanı vardır ve bunu sırasıyla “darboğaz” (tek bir nöron  $u$  ile) ve çözümlenme katmanları izler.

Doğrusal olmayan fonksiyon, yüksek boyutlu giriş uzayından düşük boyutlu darboğaz uzayına haritalama yapar ve bunu darboğaz uzayından çıktı olarak gösterilen orijinal uzaya geri haritalamanın yapılması izler. Burada çıktılar,  $J = \langle \|x - x'\|^2 \rangle$  olan hata fonksiyonunun mümkün olduğu kadar girdi değişkenlerine yakın olacak şekilde minimize edilmesini sağlar. Verilerin sıkıştırılması veya boyut indirgeme, darboğazdaki nöron olan  $u$  ile sağlanır ve bu doğrusal olmayan temel bileşen olarak adlandırılır (Hsieh, 2001).

### 3.5.1. Çok katmanlı algılayıcı (Multilayer perceptron)

Yapay sinir ağlarının ilk modellerinden olan tek katmanlı algılayıcı (Perceptron), ilk defa Frank Rosenblatt (1957) tarafından geliştirilmiştir. Tek katmanlı algılayıcı modellerinin en temel özelliği, bu modellerin doğrusal problemleri çözebilme yeteneğidir. Bu tip ağlarla doğrusal olmayan problemler öğrenilememektedir. Bu sorunu çözmek için çok katmanlı ağlar geliştirilmiştir. Rumelhart ve ark. tarafından geliştirilen

bu modele hata yayma modeli veya geriye yayılım modeli denmektedir. Bu model Delta öğrenme kuralı denilen bir öğrenme yöntemini kullanmaktadır. Çok katmanlı ağların yapısı Şekil 10’da verilmiştir. Çok katmanlı ağlar, ileri beslemeli olup; giriş katmanı, gizli katman ve çıkış katmanı olmak üzere üç katmana sahiptir. Giriş ve çıkış katmanları, sinyaller için aynı sayıda sinirlere sahiptir. Gizli katman sayısı için genel bir ölçüt yoktur ve bu sayı genellikle deneme yanılma yoluyla bulunur (Güler, 2007).



Şekil 10. Çok katmanlı algılayıcı

Girdi katmanında herhangi bir bilgi işleme olmaz. Bu katman dış ortamdan gelen bilgileri alarak ara katmana gönderir. Girdi katmanındaki her işlem elemanı, bir sonraki gizli katmanda bulunan işlem elemanı ile bağlantılıdır. Gizli katman, girdi katmanından gelen bilgileri işleyerek çıkış katmanına gönderir. Yine, gizli katmandaki her işlem elemanı, çıkış katmanındaki bütün işlem elemanlarıyla bağlantılıdır. Birden fazla gizli katman olabilir. Gizli katman sayısı ile gizli katmanlardaki işlemci eleman sayısı, deneme-yanılma yoluyla bulunur. Çıkış katmanı, gizli katmandan gelen bilgileri işleyerek çıktıları dış dünyaya iletir (Gülbağ, 2006).

Tek katmanlı ağların önemli kısıtlamaları vardır. Minsky ve Papert (1969) çok katmanlı algılayıcı ağının birçok kısıtlamanın üstesinden gelebileceğini göstermişlerdir. Gizli (ara) katman birimlerinin hatası, çıktı katman birimlerinin hatalarının geri yayılması ile belirlenir. Bu nedenle, bu yöntem genellikle geri yayılma öğrenme kuralı (Backpropagation) olarak adlandırılır. Geri yayılma, doğrusal olmayan aktivasyon

fonksiyonlarının çok katmanlı ağırları için delta kuralının genelleştirilmesi olarak da düşünülebilir (Okut, 2016).

### 3.5.2. Geriye yayılım algoritması (Backpropagation)

Standart geri yayılım ağının; bir giriş katmanı, bir çıkış katmanı ve en az bir gizli katmanı vardır. Gizli katmanların sayısı için teorik bir sınır yoktur, ancak genellikle bir veya iki gizli katman kullanılır. Her katman, sonraki katmanlara tamamen bağlıdır (fullconnected) (Anderson ve McNeill, 1992).

Çok katmanlı ağlar danışmanlı öğrenme ilkesine göre çalışır. Bu ağlara eğitim sırasında hem girdiler hem de o girdilere karşılık üretilmesi gereken çıktılar gösterilir. Ağın görevi her girdi için o girdiye karşılık gelen çıktıyı üretmektir. Çok katmanlı ağın öğrenme kuralı en küçük kareler yöntemine dayalı Delta öğrenme kuralının genelleştirilmiş halidir. Bu nedenle öğrenme kuralına “Genelleştirilmiş Delta Kuralı” da denir. Bu kural iki aşamadan oluşur. Birincisi, ağ çıktısının hesaplandığı ileri doğru hesaplama aşaması, ikincisi ise ağırlıkların değiştirildiği geriye doğru hesaplama aşamasıdır (Güler, 2007; Gülbağ, 2006).

İleri doğru (Forward) hesaplama: Bu aşama, ağ çıktısının hesaplama aşamasıdır. Bu aşamada bilgi işleme, eğitim kümesindeki bir verinin girdi katmanından ağa gösterilmesi ile başlar. Daha önce de değinildiği gibi girdi katmanında herhangi bir bilgi işleme gerçekleşmemektedir. Gelen girdiler hiç bir değişiklik yapılmadan ara katmana gönderilir. Bu durum  $y_i = x_i$  eşitliği ile gösterilir.

Ara katmandaki her işlemci eleman, girdi katmanındaki bütün işlemci elemanlardan gelen bilgileri bağlantı ağırlıklarıyla ağırlıklandırarak alır. Ara katmandaki işlemci elemanlara gelen net girdi;

$$n^1 = \left( \sum_{i=1}^j w_{ir} x_i + b_i \right) \quad (19)$$

olarak hesaplanır.

Eşitlik (19)'da

$w_{ir}$ : i. girdi katmanı elemanını,

r: ara katman elemanına bağlayan bağlantının ağırlık değerini,

$x_i$ : Girdi katmanındaki i. işlemci elemanın çıktısını,

$n^1$ : Ara katman elemanının çıktı değerini göstermektedir.

Çıktı katmanındaki işlemci elemanlara gelen net girdi;

$$n^2 = \sum_{k=1}^s w_k^2 a_k^1 + b^2 \quad (20)$$

olarak yazılır.

Ağın çıktısı;

$$\hat{y} = g \left\{ \sum_{k=1}^s w_k f \left( \sum_{i=1}^j w_i x_i + b^1 \right) + b^2 \right\} \quad (21)$$

olarak ve toplam hata ise;

$$E_D = \frac{1}{2} \sum_{i=1}^j (y - \hat{y})^2 \quad (22)$$

eşitliği ile hesaplanmaktadır.

Transfer fonksiyonu olarak genellikle sigmoid veya hiperbolik tanjant fonksiyonu kullanılmakta, ancak bu bir zorunluluk değildir. Geriye doğru hesaplamada fonksiyonun türevinin alınması gerektiğinden, seçilen fonksiyonun, türevi alınabilir bir fonksiyon olmasına dikkat edilmelidir (Kargı, 2013).

Geriye doğru (Backward) hesaplama: Geri yayılım adımı, tüm ağın geriye doğru çalışmasını içerir. Son tabakanın çıktısı ile istenen çıktı arasındaki fark genellikle transfer fonksiyonunun türevi ile modifiye edilir ve bir önceki tabakaya (katmanlara) geri yayılır. Böylece bir sonraki iterasyonda hatanın azaltılması sağlanır. Bu işlem, giriş katmanına ulaşılan kadar önceki katman (lar) için ilerler.

Aşamaları aşağıdaki gibi sıralanabilir:

- Eğitim seti olarak kullanılacak girdiler ve ona karşılık gelen çıktılar normalize edilir (Eşitlik 23)

$$x_{yeni} = \frac{x_i - x_{min}}{x_{max} - x_{min}} \quad (23)$$

- Ağın başlangıç parametreleri, ağırlıklar ve eşik değeri belirlenir.
- Ara katmandaki her işlemci eleman, girdi katmanındaki bütün işlemci elemanlardan gelen bilgileri bağlantı ağırlıklarıyla ağırlıklandırarak alır. Ara katmandaki işlemci elemanlara gelen net girdi;

$$n_k^1 = \left( \sum_{i=1}^j w_{ir} x_i + b_1 \right) \quad (24)$$

eşitliği ile hesaplanır.

- Ara katmandaki işlemci elemanlara gelen net girdi için bir aktivasyon fonksiyonu kullanılarak ara katmanın çıktısı belirlenir;

$$a_k^1 = f \left( \sum_{i=1}^j w_i x_i + b_1 \right) \quad (25)$$

- Çıktı katmandaki her işlemci eleman, ara katmanındaki bütün işlemci elemanlardan gelen bilgileri bağlantı ağırlıklarıyla ağırlıklandırarak alır. Çıktı katmandaki işlemci elemanlara gelen net girdi;

$$n^2 = \sum_k^s w_k^2 a_k^1 + b_2 \quad (26)$$

eşitliği ile hesaplanır.

- Çıktı katmanı için doğrusal bir aktivasyon fonksiyonu kullanılarak çıktı katmanının çıktısı belirlenir;

$$g\left(\sum_k^s w_k^2 a_k^1 + b^2\right) = \sum_k^s w_k^2 a_k^1 + b^2 \quad (27)$$

· Gerçek değer ile ağıın ürettiği çıktılar arasındaki fark olan hata terimi, hata kareler toplamı olarak;

$$E_D = SSE = \frac{1}{2} \sum_{i=1}^j (y - \hat{y})^2 \quad (28)$$

eşitliği ile hesaplanır.

· Çıktı ünitesinde Sigmoid fonksiyonunun kullanılması durumunda hata ( $\delta$ ) aşağıdaki gibi hesaplanır;

$$\delta_i(t) = \frac{\partial E_D(t)}{\partial n_k^1(t)} = \sum_k \frac{\partial E_D(t)}{\partial n^2(t)} \cdot \frac{\partial n^2(t)}{\partial n_k^1(t)}$$

$$\delta_i(t) = f'(n_k^1(t)) \sum_k w_k^{(2,1)} \Delta_i$$

$$\Delta_i(t) = -\frac{\partial E_D(t)}{\partial n^2(t)} = g'(n^2(t)) e_i$$

$$\delta = (y - \hat{y}) \hat{y} (1 - \hat{y}) \quad (29)$$

· Değişim miktarı hesaplandıktan sonra ağırlıkların t. iterasyondaki yeni değerleri; girdi katmanı ile gizli katman arasında güncellenen ağırlıklar:

$$\frac{\partial E_D(t)}{\partial w_k^{(2,1)}} = \frac{\partial E_D(t)}{\partial n^2(t)} \cdot \frac{\partial n^2(t)}{\partial w_k^{(2,1)}}$$

$$\Delta w_i = e_i x_i$$

$$\Delta w_i(t) = \alpha (y - \hat{y}) x_i$$

$$w_i(t + 1) = w_i(t) + \Delta w_i(t)$$

$$w_{ki}^{1(t+1)} = w_{ki}^{1(t)} + \eta \Delta w^1 \quad (30)$$

olarak hesaplanır ve gizli katman ile çıktı katmanı arasında güncellenen ağırlıklar aşağıdaki gibi hesaplanır.

$$\frac{\partial n^2(t)}{\partial w_k^{(2,1)}(t)} = a_k^1(t)$$

$$\frac{\partial n_k^1(t)}{\partial w_{kj}^{(1,1)}(t)} = x_j$$

$$w_k^{2(t+1)} = w_k^{2(t)} + \eta \Delta w^2 \quad (31)$$

Eşik değerinin t. iterasyonda güncellenen değeri ise


$$\frac{\partial E_D(t)}{\partial b^2(t)} = \frac{\partial E_D(t)}{\partial n^2(t)} \cdot \frac{\partial n^2(t)}{\partial b^2(t)}$$

$$b_i(t+1) = b_i(t) + \Delta b_i(t)$$

$$\Delta b_i(t) = \alpha(y - \hat{y}) \quad (32)$$

olarak hesaplanır.

Yapılan bu işlemler sonunda ağırlıkların hepsi değiştirilmiş olacaktır. Bir iterasyon, hem ileri hem de geriye hesaplamalar yapılarak tamamlanır. Daha sonra yeni bir örnek verilerek ikinci iterasyona başlanır. Burada her bir iterasyonda ağ hatasının azalması beklenir ve bu durum Şekil 11'de gösterilmektedir. İterasyon sayısının artması ile ağ hatası azalma eğilimi gösterir.



Şekil 11. İterasyon sayısı ile hatanın ilişkisi

Belirli bir iterasyon sayısından sonra hata sayısı daha fazla azalmaz. Bu durum, ağın öğrenmesinin durduğu ve daha iyi bir sonuca ulaşamayacağı anlamına gelir. Söz konusu işlemler gerçek çıktı ile beklenen çıktı arasındaki fark en aza indirilene kadar sürdürülür. Öğrenmenin sonlanması bir durdurma ölçütü ile gerçekleştirilir. Bu ölçüt genelde yöntemin kabul edebildiği bir hata düzeyine inmesiyle gerçekleşir (Kargı, 2013).

### 3.5.3. Sıralı doğrusal olmayan temel bileşenler analizi


DOTBA'nın yürütülmesi için iki farklı yaklaşım kullanılmıştır. İlk yaklaşım, Şekil 9'da gösterildiği gibi problemi çözmektedir. Yani, ağı darboğaz tabakası, istenen doğrusal olmayan bileşenlerin toplam sayısı kadar çok sayıda sinir hücresi ile donatılmıştır ve ağ, hedef işlevi kullanarak kimlik haritalamasını üretmek üzere eğitilmiştir. Ağ hatası;

$$E_D = \frac{1}{2} \sum_{i=1}^J (y - \hat{y})^2 \quad (33)$$

olarak hesaplanır.

Bileşen sayısı 1' den büyükse alternatif bir yaklaşım sıralı DOTBA'dır. Bu yaklaşımda giriş matrisinin sadece birincil doğrusal olmayan faktör çıkarılır. Önceki ağdan kalan artık, sonraki ağ için girdi (ve hedef çıktı) olur ve eğitim seri olarak devam eder (Şekil 10).





Şekil 12. Sıralı DOTBA (Kramer,1991)

DOTBA'nın sıralı versiyonu, eş zamanlı faktör belirleme yöntemine göre çeşitli potansiyel avantajlara sahiptir. İlk olarak, sıralı eğitim süreci, yakınsamaya neden olabilen basamaklar arasındaki bireysel matrisin yeniden ölçeklenmesini sağlar. Artıklar giderek daha küçük hale geldiğinden, yeniden ölçeklendirme yapılmadan ağın daha yüksek faktörleri modellemesi zor olabilir. İkincisi, seri eğitim, her bir darboğaz düğümünü, verilerde ayrı bir faktörü modellemeye zorlar. İki ya da daha fazla darboğaz düğümünün eşzamanlı eğitimi ile tüm ağırlık değişimlerinin en büyük çıktı hatalarına yanıt vermesi durumunda, darboğaz düğümlerinin iki ya da daha fazlasının eğitimin başındaki ana faktörle hizalanmasına yönelik bir eğilim gözlemlenir. Darboğaz tabakasındaki ağırlıklar hizaya geldiğinde, darboğaz düğümlerinin sayısında etkili bir azalma olur (Kramer, 1991).

Sıralı DOTBA esas olarak, ilişkisiz bileşenlere yol açar. Doğrusal olmayan bir şekilde, bu bile sıralı DOTBA'nın bileşenler arasındaki karmaşık doğrusal olmayan

korelasyonları kaldırabildiği anlamına gelir. Bir bileşenli alt ağın  $E_1$  hatası ve iki bileşenli toplam ağ hatası her bir yinelemede tahmin edilir. Ağ ağırlıkları daha sonra toplam sıralı hata  $E = E_1 + E_{1,2}$ 'ye göre bir kerede uyarlanır. Bu bağlamda sıralı DOTBA, ölçeklenebilirlik ve istikrar gibi iki önemli özellik ile açıklanabilir: Ölçeklenebilirlik, ilk bileşenlerin,  $n$  boyutlu bir alt uzay tarafından kapsanabilecek maksimum varyansı açıkladığı anlamına gelir. İstikrar, bir  $n$  bileşen çözümünün  $i$ . bileşeninin, bir  $m$  bileşen çözümünün  $i$ . bileşeni ile aynı olduğu anlamına gelir.

Sıralama, ya bileşen uzayındaki varyansa bir kısıtlama ile ya da yeniden yapılandırma hatasına bir kısıtlama ile elde edilebilir: Doğrusal TBA bu kısıtlamayı  $i$ . bileşenin  $i$ . en yüksek varyansını işleme dahil ederek yapar. Ancak, DOTBA'da, varyansa getirilen kısıtlama içsel veya özgün değildir. Bunun yerine hata kontrol edilebilir ve bu nedenle hatanın hiyerarşik bir kısıtlaması çok daha etkilidir (Scholz ve Vigario, 2002).

Verilerin analizi için Matthias Scholz'un <http://www.nlpca.org/> açık erişimli internet adresindeki Nonlinear PCA toolbox'ı için Matlab R2012 paket programı kullanılmıştır. Yapay sinir ağlarında DOTBA ve TBA'nın farklı uygulamaları yapılarak, yöntemler karşılaştırılmış ve elde edilen temel bileşenler ile hastaların hipotiroidi olma olasılıkları tahmin edilmiştir.

Çalışmada yapılan 9 uygulama için uygulamaya dâhil edilen değişkenler Tablo 3'te verilmiştir.


**Tablo 3.** Uygulamalarda kullanılan değişkenler

	Uygulamalar								
	1	2	3	4	5	6	7	8	9
Değişkenler	Tiroksin tedavisi alan	Tiroksin tedavisi alan	Tiroksin tedavisi alan	Tiroksin tedavisi alan	Tiroksin tedavisi alan	Tiroksin tedavisi alan	Yaş	Tiroksin tedavisi alan	DOTBA yöntemi ile 1. uygulamadaki değişkenlerden elde edilen 2 temel bileşen ve Hipotiroidi değişkeni kullanılmıştır.
	Antitiroid tedavi alan	Antitiroid tedavi alan	Antitiroid tedavi alan	Antitiroid tedavi alan	Antitiroid tedavi alan	Antitiroid tedavi alan	TSH	Antitiroid tedavi alan	
	Hipotiroidi öyküsü olan	Hipotiroidi öyküsü olan	Hipotiroidi öyküsü olan	Hipotiroidi öyküsü olan	Hipotiroidi öyküsü olan	Hipotiroidi öyküsü olan	TT4	Hipotiroidi öyküsü olan	
	Gebelik	Gebelik	Gebelik	Gebelik	Gebelik	Gebelik	FTI	Gebelik	
	Tümör	Tümör	Tümör	Tümör	Tümör		T3	Tümör	
	Guatr	Guatr	Guatr	Guatr	Guatr		T4U	Guatr	
	Tiroksin öyküsü olan	Tiroksin öyküsü olan	Tiroksin öyküsü olan	Tiroksin öyküsü olan				Tiroksin öyküsü olan	
	Tiroid ameliyatı olan	Tiroid ameliyatı olan	Tiroid ameliyatı olan	Tiroid ameliyatı olan				Tiroid ameliyatı olan	
	Hipertiroidi öyküsü olan	Hipertiroidi öyküsü olan	Hipertiroidi öyküsü olan					Hipertiroidi öyküsü olan	
	Eşlik eden hastalık	Eşlik eden hastalık	Eşlik eden hastalık					Eşlik eden hastalık	
	Lityum	Lityum						Lityum	
	Cinsiyet	Cinsiyet						Hipotiroidi	
	Yaş							Cinsiyet	
	TSH							Yaş	
	TT4							TSH	
	FTI							TT4	
	T3							FTI	
	T4U							T3	
							T4U		

## 4. BULGULAR

### Birinci Uygulama:

Doğrusal Olmayan Temel Bileşenler Analizi, ağ girişlerinin çıktı katmanında yeniden üretildiği kimlik haritalamasını gerçekleştirmek için ileriye dönük bir sinir ağını eğiterek çalışır. DOTBA'nın uygulaması için kullanılan sinir ağının mimarisi Şekil 13'de gösterilmiştir.



Şekil 13. 18-6-2-6-18 DOTBA modeli

Bu mimari, 3'ü gizli olmak üzere beş katmanlı bir sinir ağıdır. Bu beş katmanlı sinir ağı, bir oto-ilişkili (autoassociative) sinir ağı oluşturur. Oto-ilişkili sinir ağı modelinde, temel bileşenler darboğaz tabakasında elde edilir. Darboğaz nöronunun

sayısı bir ise (Şekil 9’da gösterildiği gibi), tek boyutlu doğrusal olmayan temel bileşen elde edilir. Yani, bu veri sonuçlarına en iyi uyan tek boyutlu doğrusal olmayan bir eğridir. Darboğaz nöronunun sayısı iki ise veriye en iyi uyan iki boyutlu doğrusal olmayan bir eğri elde edilir.


Kullanılan ağ mimarisinde; giriş katmanı, kodlama katmanı, darboğaz katmanı, kod çözme katmanı ve çıkış katmanı olmak üzere toplam 5 katman kullanılmıştır. Kodlama ve kod çözme katmanında doğrusal olmayan hiperbolik tanjant fonksiyonu, diğer katmanlarda ise doğrusal fonksiyon kullanılmıştır. Diğer algoritmalara göre öğrenme hızı yüksek olduğu ve öğrenme oranı sabitlerinin, eğitimden önce belirtilmesi gerekmeyecek şekilde otomatik ve uyarlanabilir olarak hesaplandığı için eğitim algoritması olarak CGD (Conjugate Gradient Descent) algoritması tercih edilmiştir.

Orijinal veri seti, 12 kategorik ve 6 sürekli değişkenin bulunduğu 18x422 boyutlu bir matristen oluşmaktadır. DOTBA’yı gerçekleştirmek için kullanılan ağda hem kodlama hem de kod çözme katmanlarındaki gizli nöronların sayısı  $M_1=M_2=6$  olarak belirlenmiştir. DOTBA tarafından kullanılan toplam serbest (ağırlık ve eşik değer) parametrelerin sayısı  $(m+f+1)(M_1+M_2)+m+f$  ile hesaplanmıştır ( $M_1$  ve  $M_2$  sırasıyla kodlama ve kod çözme katmanlarındaki nöron sayısı,  $m$  değişken sayısı,  $f$  darboğaz katmanındaki nöron sayısıdır). Bu durumda 2 temel bileşen için toplam hesaplanan parametre sayısı 271’dir.

DOTBA’nın TBA’dan farkını görebilmek amacıyla kategorik ve sürekli değişkenlerin bulunduğu veri setine hem TBA hem de DOTBA uygulanmıştır.  $n=422$  için 2 boyutlu TBA yaklaşımı, toplam varyansın %90.08’ini açıklarken, 2 boyutlu DOTBA yaklaşımı ise toplam varyansın %95.65’ini açıklamaktadır.  $n=300$  için 2 boyutlu TBA yaklaşımı, toplam varyansın %67.12’sini açıklarken, 2 boyutlu DOTBA yaklaşımı ise toplam varyansın %95.15’ini açıklamaktadır.  $n=200$  için 2 boyutlu TBA yaklaşımı, toplam varyansın %66.50’sini açıklarken, 2 boyutlu DOTBA yaklaşımı ise toplam varyansın %95.79’ünü açıklamaktadır.  $n=100$  için 2 boyutlu TBA yaklaşımı, toplam varyansın %65.51’ini açıklarken, 2 boyutlu DOTBA yaklaşımı ise toplam varyansın %94.69’ünü açıklamaktadır. (Tablo 4). Sonuçlar, DOTBA’nın gözlem sayısından bağımsız olarak boyutsallığı başarılı bir şekilde düşürdüğünü göstermektedir (Şekil 14).

**Tablo 4.** TBA ve DOTBA için açıklanan varyans oranları

	TBA için Varyans			DOTBA için Varyans		
	Boyut 1	Boyut 2	Toplam	Boyut 1	Boyut 2	Toplam
$n=422$	%70.16	%19.92	%90.08	%92.20	%3.45	%95.65
$n=300$	%67.10	%0.02	%67.12	%91.66	%3.49	%95.15
$n=200$	%66.48	%0.02	%66.50	%93.22	%2.57	%95.79
$n=100$	%65.49	%0.02	%65.51	%94.68	%0.01	%94.69



**Şekil 14.** 18-6-2-6-18 DOTBA

### İkinci Uygulama:

Kategorik değişkenler 12x422 boyutlu bir matristen oluşmaktadır. Kullanılan ağ mimarisi 12-6-2-6-12 şeklinde bir mimaridir. DOTBA'yı gerçekleştirmek için kullanılan ağda hem kodlama hem de kod çözme katmanlarındaki gizli nöronların sayısı  $M=6$  olarak belirlenmiştir. Kategorik değişken sayısı 12'dir. DOTBA mimarisinde giriş ve çıkış katmanlarındaki nöron sayısı değişken sayısına eşit olup 12 olarak, doğrusal olmayan temel bileşen sayısı ise 2 olarak belirlenmiştir. Eğitim algoritması olarak CGD algoritması kullanılırken, kodlama ve kod çözme katmanında doğrusal olmayan hiperbolik tanjant fonksiyonu ve diğer katmanlarda ise doğrusal fonksiyon kullanılmıştır. İterasyon sayısına ön deneme yapılarak karar verilmiş olup, maksimum iterasyon sayısı 3000 olarak belirlenmiş ve sadece kategorik değişkenler kullanılarak uygulanan DOTBA'da 2 temel bileşen toplam varyansın %81.2'sini açıklamıştır (Şekil 15).



**Şekil 15.** 12-6-2-6-12 DOTBA

Her ne kadar TBA sadece nümerik olarak ölçülmüş değişkenlere uygulanan bir yöntem olsa da, DOTBA ile farkını görebilmek amacıyla 12 kategorik değişkene TBA uygulanmış ve TBA uygulanarak elde edilen 2 bileşen toplam varyansın %53.7'sini açıklamıştır (Tablo 5).

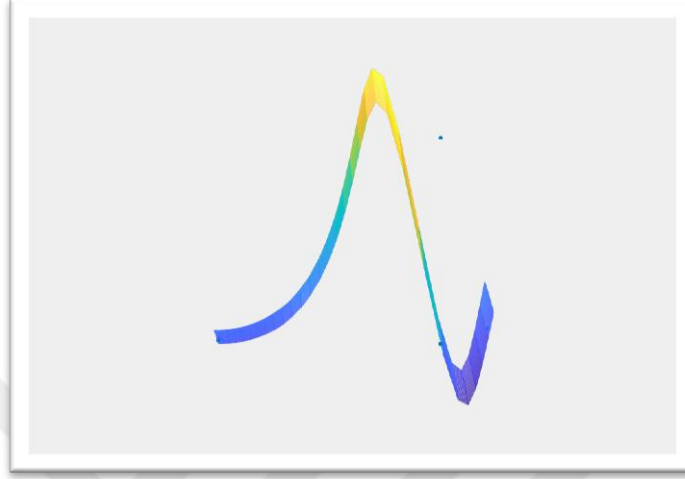
**Tablo 5.** 12 kategorik değişkenin bulunduğu modelde TBA ve DOTBA için açıklanan varyans oranları

	TBA için Varyans			DOTBA için Varyans		
	Boyut 1	Boyut 2	Toplam	Boyut 1	Boyut 2	Toplam
$n=422$	%34.4	%19.3	%53.7	%61.3	%19.9	%81.2
$n=300$	%34.88	%19.06	%53.94	%50.12	%23.35	%73.47
$n=200$	%36.97	%0.01	%36.98	%59.01	%28.00	%87.01
$n=100$	%38.35	%18.20	%56.55	%63.44	%15.04	%78.48

### Üçüncü Uygulama:

Kategorik değişkenler  $10 \times 422$  boyutlu bir matristen oluşmuştur. Kullanılan ağ mimarisi 10-6-2-6-10 şeklinde bir mimariye sahiptir. DOTBA'yı gerçekleştirmek için kullanılan ağda hem kodlama hem de kod çözme katmanlarındaki gizli nöronların sayısı  $M=6$  olarak alınmıştır. 12 kategorik değişkenden katkısı en az olan iki değişken çıkarılmıştır. Böylece, DOTBA mimarisinde giriş ve çıkış katmanlarındaki nöron sayısı değişken sayısına eşit olup 10 olarak, doğrusal olmayan temel bileşen sayısı ise 2 olarak belirlenmiştir. Eğitim algoritması olarak CGD algoritması, kodlama ve kod çözme katmanında doğrusal olmayan hiperbolik tanjant fonksiyonu, diğer katmanlarda

doğrusal fonksiyon kullanılmıştır. Maksimum iterasyon sayısı 3000 olarak belirlenmiş ve 10 kategorik değişken kullanılarak uygulanan DOTBA yönteminde 2 temel bileşen toplam varyansın %80.7'sini açıklamıştır (Şekil 16).



**Şekil 16.** 10-6-2-6-10 DOTBA

DOTBA ile farkını görebilmek için 10 kategorik değişkene TBA uygulanmıştır. TBA uygulanarak elde edilen 2 temel bileşen varyansın toplam %58.1'ini açıklamıştır (Tablo 6).

**Tablo 6.** 10 kategorik değişkenin bulunduğu modelde TBA ve DOTBA için açıklanan varyans oranları


	TBA için Varyans			DOTBA için Varyans		
	Boyut 1	Boyut 2	Toplam	Boyut 1	Boyut 2	Toplam
$n=422$	%37.2	%20.9	%58.1	%59.6	%21.1	%80.7
$n=300$	%37.79	%20.68	%58.47	%73.56	%10.55	%84.11
$n=200$	%40.54	%20.33	%60.87	%66.27	%21.02	%87.29
$n=100$	%41.47	%20.21	%61.68	%61.39	%25.66	%87.05

#### **Dördüncü Uygulama:**

Kategorik değişkenler  $8 \times 422$  boyutlu bir matristen oluşmaktadır. Kullanılan ağ mimarisi 8-6-2-6-8 şeklinde bir mimaridir. DOTBA'yı gerçekleştirmek için kullanılan ağda hem kodlama hem de kod çözme katmanlarındaki gizli nöronların sayısı  $M=6$  olarak belirlenmiştir. Kategorik değişkenlerden katkısı en az olan 4 değişken çıkarılmıştır. DOTBA mimarisinde giriş ve çıkış katmanlarındaki nöron sayısı değişken



sayısına eşit olup 8 olarak, doğrusal olmayan temel bileşen sayısı ise 2 olarak belirlenmiştir. Eğitim algoritması olarak CGD algoritması kullanılırken, kodlama ve kod çözme katmanında doğrusal olmayan hiperbolik tanjant fonksiyonu, diğer katmanlarda ise doğrusal fonksiyon kullanılmıştır. Maksimum iterasyon sayısı 3000 olarak belirlenmiştir. Böylece, 8 kategorik değişken kullanılarak uygulanan DOTBA’da 2 temel bileşen toplam varyansın %89.2’sini açıklamıştır (Şekil 17).



**Şekil 17.** 8-6-2-6-8 DOTBA

DOTBA ile farkını görebilmek için 8 kategorik değişkene TBA uygulanmış ve TBA uygulanarak elde edilen 2 temel bileşen toplam varyansın % 58.8’ini açıklamıştır (Tablo 7).

**Tablo 7.** 8 kategorik değişkenin bulunduğu modelde TBA ve DOTBA için açıklanan varyans oranları

	TBA için Varyans			DOTBA için Varyans		
	Boyut 1	Boyut 2	Toplam	Boyut 1	Boyut 2	Toplam
$n=422$	%37.7	%21.1	%58.8	%70.1	%19.1	%89.2
$n=300$	%38.02	%20.80	%58.82	%61.82	%25.95	%87.77
$n=200$	%40.95	%20.52	%61.47	%67.43	%19.58	%87.01
$n=100$	%42.26	%19.98	%62.24	%71.46	%14.27	%85.73

### **Beşinci Uygulama:**

Kategorik değişkenler 6x422 boyutlu bir matristen oluşmaktadır. Kullanılan ağ mimarisi 6-6-2-6-6 şeklinde bir mimariye sahiptir. DOTBA’yı gerçekleştirmek için

kullanılan ağda hem kodlama hem de kod çözme katmanlarındaki gizli nöronların sayısı  $M=6$  olarak belirlenmiştir. Verilen 12 kategorik değişkenden katkısı en az olan 6 değişken çıkarılmıştır. DOTBA mimarisinde giriş ve çıkış katmanlarındaki nöron sayısı değişken sayısına eşit olup 6 olarak, doğrusal olmayan temel bileşen sayısı ise 2 olarak belirlenmiştir. Eğitim algoritması olarak CGD algoritması kullanılırken, kodlama ve kod çözme katmanında doğrusal olmayan hiperbolik tanjant fonksiyonu, diğer katmanlarda ise doğrusal fonksiyon kullanılmıştır. Maksimum iterasyon sayısı 3000 olarak belirlenirken, 6 kategorik değişken kullanılarak uygulanan DOTBA'da 2 temel bileşen toplam varyansın %89.0'unu açıklamıştır (Şekil 18).



**Şekil 18.** 6-6-2-6 DOTBA

DOTBA ile farkını görebilmek için 6 kategorik değişkene TBA uygulanmış ve TBA uygulanarak elde edilen 2 temel bileşen toplam varyansın %73.2'sini açıklamıştır (Tablo 8).

**Tablo 8.** 6 kategorik değişkenin bulunduğu modelde TBA ve DOTBA için açıklanan varyans oranları

	TBA için Varyans			DOTBA için Varyans		
	Boyut 1	Boyut 2	Toplam	Boyut 1	Boyut 2	Toplam
$n=422$	%47.2	%26.0	%73.2	%75.6	%13.4	%89.0
$n=300$	%49.44	%25.69	%65.13	%85.17	%7.44	%92.61
$n=200$	%52.81	%21.73	%74.54	%89.49	%5.27	%94.76
$n=100$	%55.93	%0.02	%55.92	%87.50	%0.11	%87.61

### Altıncı Uygulama:

Kategorik deęişkenler 4x422 boyutlu bir matristen oluşmaktadır. Kullanılan aę mimarisi 4-6-2-6-4 şeklinde bir mimaridir. DOTBA'yı gerçekleştirmek için kullanılan aęda hem kodlama hem de kod çözme katmanlarındaki gizli nöronların sayısı  $M=6$  olarak belirlenmiştir. Kategorik deęişkenlerden katkısı en az olan 8 deęişken çıkarılmıştır. DOTBA mimarisinde giriş ve çıkış katmanlarındaki nöron sayısı deęişken sayısına eşit ve 4 olarak, doğrusal olmayan temel bileşen sayısı ise 2 olarak belirlenmiştir. Eğitim algoritması olarak CGD algoritması, kodlama ve kod çözme katmanında doğrusal olmayan hiperbolik tanjant fonksiyonu, dięer katmanlarda doğrusal fonksiyon kullanılmıştır. Maksimum iterasyon sayısı 3000 olarak belirlenmiş ve 4 kategorik deęişken kullanılarak uygulanan DOTBA'da 2 temel bileşen toplam varyansın %97.35'ini açıklamıştır (Şekil 19).



Şekil 19. 4-6-2-6-4 DOTBA


DOTBA ile farkını görebilmek amacıyla 6 kategorik deęişkene TBA uygulanmış ve TBA uygulanarak elde edilen 2 temel bileşen toplam varyansın %81.0'ini açıklamıştır (Tablo 9).

**Tablo 9.** 4 kategorik deęişkenin bulunduęu modelde TBA ve DOTBA için açıklanan varyans oranları

	TBA için Varyans			DOTBA için Varyans		
	Boyut 1	Boyut 2	Toplam	Boyut 1	Boyut 2	Toplam
$n=422$	%52.2	%28.8	%81.0	%82.7	%14.6	%97.35
$n=300$	%55.01	%28.62	%83.63	%90.62	%1.18	%91.80
$n=200$	%57.91	%23.78	%81.69	%73.69	%23.25	%96.94
$n=100$	%59.27	%0.02	%59.29	%74.29	%22.22	%96.49

### Yedinci Uygulama:

Sürekli deęişkenler 6x422 boyutlu bir matristen oluşmaktadır. Kullanılan aę mimarisi 6-4-1-4-6 şeklinde bir mimaridir. DOTBA'yı gerçekleştirmek için kullanılan aęda hem kodlama hem de kod çözme katmanlarındaki gizli nöronların sayısı  $M=4$  olarak belirlenmiş ve sürekli deęişken sayısı 6'dır. DOTBA mimarisinde giriş ve çıkış katmanlarındaki nöron sayısı deęişken sayısına eşit ve 6 olarak alınmış, doğrusal olmayan temel bileşen sayısı ise 1 olarak belirlenmiştir. Eğitim algoritması olarak CGD algoritması kullanılırken, kodlama ve kod çözme katmanında doğrusal olmayan hiperbolik tanjant fonksiyonu, dięer katmanlarda ise doğrusal fonksiyon kullanılmıştır. Maksimum iterasyon sayısı 3000 olarak belirlenmiştir. Sadece sürekli deęişkenler kullanılarak uygulanan DOTBA'da 1 temel bileşen toplam varyansın %91.2'sini açıklamıştır (Şekil 20).



**Şekil 20.** 6-4-1-4-6 DOTBA

DOTBA ile farkını görebilmek amacıyla 6 sürekli değişkene TBA uygulanmış ve TBA uygulanarak elde edilen 1 temel bileşen toplam varyansın %69.6'ünü açıklamıştır (Tablo 9).

**Tablo 10.** 6 sürekli değişkenin bulunduğu modelde TBA ve DOTBA için açıklanan varyans oranları

	TBA için Varyans			DOTBA için Varyans		
	Boyut 1	Boyut 2	Toplam	Boyut 1	Boyut 2	Toplam
<i>n</i> =422	%69.6	%0.00	%69.6	%91.2	%0.00	%91.2
<i>n</i> =300	%68.09	%21.76	%89.85	%91.34	%0.00	%91.34
<i>n</i> =200	%67.36	%23.05	%90.41	%89.51	%1.92	%91.43
<i>n</i> =100	%66.16	%25.88	%92.04	%91.94	%0.63	%92.57

### **Sekizinci Uygulama:**

YSA uygulamasında çok katmanlı ileri beslemeli yapay sinir ağı modeli kullanılmıştır. Yaş, TSH, TT4, FTI, T3, T4U, Tiroksin tedavisi alan, Antitiroid tedavi alan, Hipotiroidi öyküsü olan, Hamile, Tümör, Guatr, Tiroksin öyküsü olan, Tiroid ameliyatı olan, Hipertiroidi öyküsü olan, Lityum, Eşlik eden hastalık ve cinsiyet değişkenleri girdi değişkenleri olarak, hipotiroidi ise çıktı değişkeni olarak toplam 19 değişken analize dahil edilmiş ve yapay sinir ağlarında hastaların hipotiroidi olma olasılığı tahmin edilmiştir.

Analiz sırasında verilerin 296'sı eğitim verisi, 63'ü doğrulama verisi ve diğer 63'ü de test verisi olarak ayrılmıştır. Yapay sinir ağının mimarisinde gizli katman sayısı 1 olarak belirlenmiştir. Girdi katmanında 18 birim, çıktı katmanında ise 1 birim bulunmaktadır. Gizli katmanda 6, 10 ve 25 birimle üç farklı uygulama yapılmış olup, eğitim algoritması olarak, YSA'ların eğitiminde sağlamış oldukları hız ve kararlılık nedeniyle LM ve SCG algoritmaları kullanılmıştır. Gizli katmandaki nöron sayısı, kullanılan algoritma, hata kareler ortalaması (MSE), ortalama mutlak yüzde hata (MAPE) ve  $R^2$  değerleri Tablo 11'de verilmiştir.

**Tablo 11.** YSA sonuçları

Algoritma	Gizli katmandaki nöron sayısı	Hata Kareler Ortalaması (MSE)	Ortalama Mutlak Yüzde Hata (MAPE)	R <sup>2</sup>
Levenberg-Marquardt	6	0.0656	6.077	%87.26
	10	0.0680	6.270	%84.51
	25	0.0710	6.330	%83.06
Scaled Conjugate Gradient	6	0.0598	9.071	%86.61
	10	0.0753	8.071	%84.24
	25	0.0824	8.610	%79.47

Tablo 11 incelendiğinde; LM algoritmasına göre R<sup>2</sup>'nin en yüksek değerini %87.26 ile gizli katmanda 6 nöron kullanılan uygulama verirken, SCG algoritmasına göre ise R<sup>2</sup>'nin en yüksek değerini %86.61 ile gizli katmanda yine 6 nöron kullanılan uygulama vermektedir. Çok katmanlı algılayıcı kullanılarak yapılan tahminlerde R<sup>2</sup>'nin %79.47 ile %87.26 arasında değiştiği söylenebilir.

### Dokuzuncu Uygulama:

YSA uygulamasında çok katmanlı ileri beslemeli yapay sinir ağı modelinde giriş vektörleri olarak DOTBA yönteminden elde edilen 2 temel bileşen, çıktı vektörü olarak hipotiroidi değişkeni kullanılarak hastaların hipotiroidi olma olasılığı tahmin edilmiştir. Analiz sırasında verilerin 296'sı eğitim verisi, 63'ü doğrulama verisi ve diğer 63'ü de test verisi olarak ayrılmıştır. Girdi katmanında 2 birim, çıktı katmanında ise 1 birim bulunmaktadır. Gizli katmanda 6, 10 ve 25 birimle üç farklı uygulama yapılmış ve eğitim algoritması olarak ise LM ve SCG algoritmaları kullanılmıştır. Gizli katmandaki nöron sayısı, kullanılan algoritma, hata kareler ortalaması (MSE), ortalama mutlak yüzde hata (MAPE) ve R<sup>2</sup> değerleri Tablo 12.'de verilmiştir.

**Tablo 12.** DOTBA ile elde edilen temel bileşenlerle YSA'da tahmin sonuçları

Algoritma	Gizli katmandaki nöron sayısı	Hata Kareler Ortalaması (MSE)	Ortalama Mutlak Yüzde Hata (MAPE)	R <sup>2</sup>
Levenberg-Marquardt	6	0.018143	4.3487	%93.53
	10	0.046523	5.5977	%90.40
	25	0.028903	4.5076	%91.84
Scaled Conjugate Gradient	6	0.023360	4.3029	%92.14
	10	0.041317	5.0282	%91.16
	25	0.054942	7.0153	%89.42

Tablo 12 incelendiğinde; her iki algoritmayla da  $R^2$ 'nin en yüksek değeri gizli katmanda 6 nöron kullanılan uygulamadan elde edilmiştir. Bu değerler LM algoritmasıyla %93.53 iken, SCG algoritmasıyla %92.14 olarak bulunmuştur. Çok katmanlı algılayıcı kullanılarak yapılan tahminlerin %89.42 ile %93.53 arasında değiştiği görülmüştür.



## 5. TARTIŞMA ve SONUÇ

Çalışmada, DOTBA'nın daha iyi açıklanması ve etkinliğinin görülmesi için DOTBA'nın yanı sıra, TBA için de YSA yaklaşımı incelenerek hem TBA hem de DOTBA için farklı uygulama yapılmıştır.

İlk 7 uygulamada, DOTBA ve TBA'yı karşılaştırmak için giriş katmanı, kodlama katmanı, darboğaz katmanı, kod çözme katmanı ve çıkış katmanı olmak üzere toplam 5 katman içeren bir ağ mimarisi kullanılmıştır. İlk 6 uygulamada, DOTBA ve TBA'yı gerçekleştirmek için kullanılan ağda hem kodlama hem de kod çözme katmanlarındaki gizli nöronların sayısı 6 olarak belirlenmiştir. Giriş ve çıkış katmanlarındaki nöron sayısı değişken sayısına eşit olarak alınmıştır. Eğitim algoritması olarak CGD algoritması, kodlama ve kod çözme katmanında doğrusal olmayan hiperbolik tanjant fonksiyonu ve diğer katmanlarda ise doğrusal fonksiyon kullanılmıştır. Maksimum iterasyon sayısı 3000 olarak belirlenmiş ve açıklama oranı yüksek olan 2 temel bileşen dikkate alınmıştır. Yedinci uygulamada, ilk 6 uygulamadan farklı olarak hem kodlama hem de kod çözme katmanlarındaki gizli nöron sayısı 4 olarak belirlenmiş ve uygulamada sadece sürekli değişkenler kullanılarak ilk iki bileşen dikkate alınmıştır. Sekiz ve dokuzuncu uygulamalarda ise yapay sinir ağı mimarisinde gizli katman sayısı 1 olarak belirlenmiştir. Gizli katmanda 6, 10 ve 25 birimle üç farklı uygulama yapılarak ve eğitim algoritması olarak LM ve SCG algoritmaları kullanılarak hastalığın olup olmadığı tahmin edilmiştir. Sekizinci uygulamada YSA uygulaması 18 giriş değişkenini kullanılarak yapılmış, dokuzuncu uygulamada ise YSA uygulaması sadece DOTBA ile elde edilen iki temel bileşeni kullanarak yapılmıştır.

Birinci uygulamada, hipotiroidi hastalığı hariç 18 değişkenin (12 kategorik, 6 nümerik) tümü analize dahil edilerek 18-6-2-6-18 YSA mimarisi kullanılmıştır. DOTBA'yı gerçekleştirmek için kullanılan ağda hem kodlama hem de kod çözme katmanlarındaki gizli nöronların sayısı  $M_1=M_2=6$  olarak belirlenmiştir.  $M$ 'nin daha küçük değerleri için açıklanan varyans oranı azalırken, daha büyük değerleri içinse açıklanan varyans oranı bir miktar artmaktadır. Ancak,  $M$ 'nin büyük değerleri için hesaplanan daha uzun sürdüğü ve bilgisayarın daha yüksek belleğe gereksinim duyduğu görülmüştür. Gözlem sayısı  $n=422$  için; DOTBA ile elde edilen 2 temel



bileşen toplam varyansın %95.65'ini açıklarken, TBA ise toplam varyansın %90.08'ini açıklamıştır. Gözlem sayısı azaltılarak yapılan analizlerde gözlem sayısından bağımsız olarak DOTBA'nın TBA'ya göre yüksek bir açıklama oranına sahip olduğu görülmüştür. Bu durum, DOTBA'nın doğrusal olmayan ilişkileri belirleyebilme özelliği ile ilişkilendirilebilir. Buna göre DOTBA'nın hem nümerik hem de kategorik değişkenlerle yapılan analizlerde etkin sonuçlar verdiği söylenebilir.

İkinci uygulamada, sadece 12 kategorik değişken analize dahil edilmiş ve analiz için 12-6-2-6-12 YSA mimarisi kullanılmıştır. Gözlem sayısı n=422 için; DOTBA ile elde edilen 2 temel bileşen toplam varyansın %81.2'sini açıklarken, TBA ise (toplam varyansın) %53.7'sini açıklamıştır. Bu değerlere göre sadece kategorik değişkenler ile yapılan analizlerde de DOTBA'nın TBA'dan daha iyi sonuçlar verdiği söylenebilir. Ayrıca, birinci uygulamaya göre hem DOTBA'nın hem de TBA'nın varyans açıklama oranında bir düşüş gözlenmektedir. Bu durum, ilk uygulamada kategorik ve sürekli değişkenlerin aynı anda analize tabi tutulması ile ve değişken sayısının azalması ile ilişkilendirilebilir.

Üç, dört, beş ve altıncı uygulamalarda da kategorik değişkenler kullanılmıştır. Ancak, her uygulamada kullanılan değişken sayısı bir önceki uygulamadan varyansı en az etkileyen iki değişken çıkarılarak belirlenmiştir. Böylece sırayla 10, 8, 6 ve 4 kategorik değişkenli 4 farklı uygulama yapılmıştır. Üçüncü uygulamada gözlem sayısı n=422 için; DOTBA ile elde edilen 2 temel bileşen toplam varyansın %80.7'sini açıklarken, TBA (toplam varyansın) %58.1'ini açıklamaktadır. Dördüncü uygulamada gözlem sayısı n=422 için; DOTBA ile elde edilen 2 temel bileşen toplam varyansın %89.2'sini açıklarken, TBA (toplam varyansın) %58.8'ini açıklamaktadır. Beşinci uygulamada gözlem sayısı n=422 için; DOTBA ile elde edilen 2 temel bileşen toplam varyansın %89'unu açıklarken, TBA (toplam varyansın) %73.2'sini açıklamaktadır. Altıncı uygulamada gözlem sayısı n=422 için; DOTBA ile elde edilen 2 temel bileşen toplam varyansın %97.3'ünü açıklarken, TBA toplam varyansın %81'ini açıklamaktadır. Kategorik değişkenler ile gerçekleştirilen bu 4 uygulamada da DOTBA'nın TBA'dan daha üstün olduğu ve aralarında önemli farkların olduğu görülmektedir. Ancak değişken sayısı azaldıkça DOTBA ve TBA arasındaki fark da doğrusal olmamakla birlikte azalmaktadır. Zira, değişken sayısı azaldıkça TBA'nın

varyans açıklama oranlarında düzenli bir artış görülürken, DOTBA'da bu artışlar düzenli değildir. Sonuç olarak, ilk 2 temel bileşenin varyansı en yüksek açıklama oranı DOTBA'da %97.3, TBA'da ise %81 ile 4 kategorik değişkenli altıncı uygulamadan elde edilmiştir. Zira bu durum, değişken sayısı azaldıkça varyans açıklama oranının arttığı anlamına gelmemektedir. Buradaki azalmaya bağlı periyodik artışın, toplam varyansa katkısı en az olan 2 kategorik değişkenin bir önceki değişken kümesinden çıkarılması ile ilişkili olduğu söylenebilir.

Yedinci uygulamada, sadece 6 nümerik değişken analize dahil edilmiş ve 6-4-2-4-6 YSA mimarisi kullanılarak iki temel bileşen elde edilmiştir. Gözlem sayısı  $n=422$  için; DOTBA ile elde edilen iki temel bileşen toplam varyansın %91.2'sini açıklarken, TBA ile elde edilen iki temel bileşen toplam varyansın %69.6'sını açıklamıştır. Analiz sonuçları göz önüne alındığında, sadece kategorik verilerin analizinde değil, nümerik verilerin analizinde de DOTBA'nın, TBA'ya göre daha iyi sonuçlar verdiği söylenebilir. TBA sürekli değişkenler arasındaki ilişkinin doğrusal olan kısmını göz önüne alırken, DOTBA değişkenler arasındaki ilişkinin hem doğrusal hem de doğrusal olmayan kısmını göz önüne almaktadır. Sürekli değişkenlerin saçılım grafiklerinde aralarındaki ilişkinin doğrusal olmadığı görülmüştür. Bu nedenle DOTBA'nın yüksek açıklama gücüne sahip olması, bu yöntemin, doğrusal olmayan ilişkileri de belirleyebilmesi ile ilişkilendirilebilir.

Sekizinci uygulamada, veri setinin yapay sinir ağlarındaki tahmin başarısını görmek için çok katmanlı ileri beslemeli yapay sinir ağı modeli ile hastaların hipotiroidi olma olasılığı tahmin edilmiştir. Veri setinde verilen 19 değişkenden 18'i giriş değişkeni olarak, hipotiroidi değişkeni ise hedef değişken olarak alınmış ve veri setindeki gözlemler eğitim, doğrulama ve test verisi olmak üzere üç gruba ayrılmıştır. İki farklı algoritma kullanılmış ve her algoritma ile gizli katmanda farklı sayıda nöron bulduran 3 uygulama yapılarak hastaların hipotiroidi olma olasılığı tahmin edilmiştir.  $R^2$ 'nin en iyi tahmini, %87.26 gibi bir değer ile LM algoritması kullanılan ve gizli katmanda 6 nöron bulduran uygulamadan elde edilmişken, en düşük (%79.47) değeri ise SCG algoritması kullanılan ve gizli katmanda 25 nöron bulunan uygulamadan elde edilmiştir. Ayrıca, SCG algoritması kullanılarak yapılan uygulamalarda  $R^2$ 'nin en iyi değeri (%86.61) gizli katmanında 6 nöron bulunan uygulamadan elde edilmiştir.

Dokuzuncu uygulama, sekizinci uygulama ile benzerlik göstermektedir. Bu uygulama ile boyut indirgeme yapıldıktan sonra yapılacak tahminlerin başarısı görülmek istenmiştir. Bu iki uygulama arasındaki en önemli fark, giriş değişkeninin durumudur. Sekizinci uygulamada 18 giriş değişkeni hiçbir ek işlemle geçirilmeden, yani veri setinde verilen 19 değişkenin (18 giriş ve hipotiroidi hedef) tümü ile doğrudan bir tahmin yapılmıştır. Ancak dokuzuncu uygulamada, 18 giriş değişkeni yerine bunların DOTBA ile elde edilen 2 temel bileşeni yapay sinir ağları ile analiz edilerek hipotiroidi hastalığının olup olmadığı hakkında bir tahmin yapılmıştır. LM algoritması kullanılan ve gizli katmanında 6 nöron bulunduran uygulamanın %93.35  $R^2$  değeri ile en iyi tahmini yaptığı gözlenmiştir. Ayrıca gizli katmanında 6 nöron bulunduran ve SCG algoritması kullanan uygulamanın da iyi bir tahmin (%92.14) yaptığı söylenebilir.

18 giriş değişkeni kullanılarak yapay sinir ağları ile hipotiroidi hastalığı tahmin edilmiş ve en iyi tahmin %87.26  $R^2$  değeri ile yapılmıştır. Bu değer YSA ile yapılan tahminde her 100 hipotiroidi hastasından sadece 87'sine doğru teşhis konulduğunu göstermektedir. Ancak bu 18 değişkenin DOTBA ile elde edilen 2 temel bileşeni kullanılarak yapay sinir ağlarıyla yapılan tahminde %93.53 gibi bir sonuç elde edilmiştir. Bu tahmin sonucu, hipotiroidi hastalarına daha yüksek doğruluk oranı ile teşhis konulabileceğini göstermektedir.

Araştırmacılar genellikle çok sayıda değişkenle çalışmakta ve mümkün oldukça çok az bilgi kaybıyla bu değişkenleri minimize etmek istemektedir. Geleneksel olarak TBA bu tür değişkenlerin minimize edilmesi için uygun bir yöntem olarak düşünülmektedir. Yaygın olarak kullanılan bu yöntem çok sayıda değişkeni gözlenen veriyi mümkün olduğunca iyi temsil eden, temel bileşenler olarak adlandırılan, bu değişkenleri çok daha az sayıda ilişkisiz doğrusal kombinasyona indirgemektedir. Bununla birlikte, TBA iki önemli sınırlamaya sahiptir. Birincisi değişkenler arasındaki ilişkilerin doğrusal olduğunu ve ikincisi tüm değişkenler sayısal düzeyde (aralığın veya oranın ölçüm seviyesinde) ölçeklendirilirse yorumlanabilir olduğunu varsaymaktadır. Ancak bilimsel çalışmalarda, çoğunlukla değişkenler arasındaki ilişki doğrusal değildir ve bu ilişki, doğrusal ilişkileri belirlemeye yönelik geliştirilmiş olan yöntemlerle belirlenemeyebilir. Bu durumda, temel bileşenler analizi yönteminin kullanımı güçleşmekte hatta çoğu kez bu yöntem kullanılamamaktadır. Bu nedenle, TBA'nın

doğrusal olmayan bir uzantısı olan ve doğrusal olmayan temel bileşenler analizi olarak adlandırılan alternatif bir yöntem geliştirilmiştir. Bu yöntemin ilk olarak Guttman (1941) tarafından tanımlanmış ve konuyla ilgili literatüre, Kruskal (1965), Shepard (1966), Kruskal ve Shepard (1974), Young ve ark. (1978) ve Winsberg ve Ramsay (1983) gibi araştırmacıların önemli katkıları olmuştur (Linting ve ark., 2007).

Fiziksel olarak engelli kişilerin alfabe olarak farklı zihinsel görevleri kullanmanın fizibilitesini araştırmak için çeşitli zihinsel aktivitelere ait EEG sinyalleri sınıflandırılmıştır. Sonuçlar, DOTBA'nın ayırt edici özellikleri %86.22'lik bir değer ile doğru sınıflandırabildiğini göstermektedir (Devulapalli, 1996). Temel eğri algoritmasını ve sinir ağlarını bütünleştiren bir DOTBA yöntemi kullanılmıştır. Hem simülasyon hem de gerçek problemler, DOTBA'nın her iki uygulama için de iyi bir yaklaşım olduğunu ve önemli süreç problemlerini çözmede kullanılabileceğini göstermiştir (Dong ve McAvoy, 1996). DOTBA'ya dayanan bir algoritma geliştirilerek hastaların EKG sinyalinden iskemik kalp atımlarının saptanması ve vuruşların doğru sınıflandırması hedeflenmiştir. DOTBA ile yapılan sınıflandırmada sadece iki doğrusal olmayan bileşen ve her dosyadan 1000 normal örnek içeren bir eğitim setinin normal atımlar için %80 ve iskemik atımları için %90 gibi yüksek bir oran ile doğru sınıflandırma yapıldığı görülmektedir (Stamkopoulos ve ark., 1998). Atmosferik profilleri almak ve radyometrik verilerin inversiyonu için sinir ağı tabanlı bir algoritma kullanılmıştır. Yedi parlaklık sıcaklığından 33 seviyeli profili ve bir gizli katmanı olan çok katmanlı bir algılayıcı ile zemin ölçümleri doğrudan tahmin edilmiştir. Tahmin doğruluğu, DOTBA kullanılarak elde edilen sonuçlara çok yakın bulunmuştur (Frate ve Schiavon, 1999). DOTBA ile TBA arasında bir karşılaştırma yapmak amacıyla beş tabakalı kendiliğinden birleşmeli ileri beslemeli bir sinir ağı kullanılmış ve yöntem Lorenz çekicinden örneklenmiş bir veri seti ile test edilmiştir. Bir boyutlu ve iki boyutlu DOTBA sırasıyla varyansın %76 ve %99.5'ini açıklarken, TBA sırasıyla varyansın %60 ve %95'ini açıklamıştır. Böylece, DOTBA'nın TBA'dan daha üstün olduğu gösterilmiştir (Monahan, 2000). Proses hata tespiti için giriş-eğitim sinir ağına dayanan bir DOTBA yöntemi kullanılmıştır. Nominal veri seti önce TBA ile ve daha sonra DOTBA ile analiz edilmiştir. DOTBA yönteminin, nominal veri setindeki toplam değişkenliğin %90'nını iki doğrusal olmayan temel bileşenle açıklamıştır (Erguo ve Jinshou, 2002). Bir oto-ilişkili sinir ağına dayanan DOTBA yöntemi kullanılmış ve

DOTBA'nın, Piabanha su havzasının su kalitesi verilerini yeniden yapılandırmada TBA'dan daha iyi performans gösterdiği, ayrıca veri varyansının çoğunu açıkladığı belirtilmektedir (Villas-Boas ve ark., 2017).

DOTBA, doğrusal olmayan bir şekilde klasik TBA modelini genelleştiren nöral ağlar yöntemi ile uygulanabilir. Doğrusal yaklaşım ile TBA ve dönüştürülmüş TBA modelleri arasında bir karşıtlık vardır. Zira, eşzamanlı olarak hem verilerin maksimum küresel değişkenlerini açıklayan, hem de lokal veri kümelerine yaklaşan çözüm bulmak genellikle imkansızdır. DOTBA ile her iki amaca birlikte ulaşılabilir, bu nedenle DOTBA'daki doğrusal olmayan yapı, TBA ve dönüştürülmüş TBA yaklaşımlarını birleştirir. Ağ darboğazındaki (bottleneck) dairesel bir devre ile DOTBA periyodik ya da dalga modları çıkarabilir (Hsieh, 2001).

DOTBA, genellikle çok katmanlı bir sinir ağı tarafından uygulanan doğrusal olmayan özellik çıkarma için önerilen bir yöntemdir. TBA ile karşılaştırıldığında, daha iyi performansa sahiptir ve değişkenler arasındaki ilişkilerin karmaşık problemleri doğrusal değildir (Stamkopoulos ve ark., 1998).

DOTBA, doğrusal TBA ile aynı problemlere uygulanabilir ve doğrusal olmayan bir işlem için doğrusal olmayan ilişkileri yakalayabildiğinden daha iyi sonuçlar vermesi beklenir (Kramer, 1991). TBA birçok uygulamaya sahip olmasına rağmen sadece doğrusal süreçler için uygundur. DOTBA sonuçları TBA sonuçları ile karşılaştırıldığında, kullanılan veri seti için üç önemli avantajı bulunmaktadır. Birincisi nominal değişkenlerle başa çıkabilme kabiliyeti, ikincisi DOTBA'nın değişkenler arasındaki doğrusal olmayan ilişkileri keşfetmesi ve ele alması, üçüncü ise nominal veya ordinal analiz seviyeleri kullanılırsa, verilerdeki varyansı daha iyi açıklayabilmesidir. Nümerik olmayan verilerin analizi için, yöntem daha az kısıtlayıcı ve bu nedenle daha yüksek bir varyans açıklama oranına sahiptir.

Çalışmada, yapay sinir ağlarında doğrusal olmayan temel bileşenleri bulup modelleyen bir DOTBA yöntemi sunulmuş ve DOTBA yönteminin doğrusal olmayan problemleri çözmede daha iyi bir yaklaşım olduğu görülmüştür.

Sonuç olarak; Yapay sinir ağılarıyla yapılan tahminlerde DOTBA'nın TBA'dan daha başarılı sonuçlar verdiği ve ileriye dönük tahmin yapmada kullanılabileceği söylenebilir.



## KAYNAKLAR

- Akpolat V. Kemik Mineral Yoğunluğunun Yapay Sinir Ağları ile Saptanması [Doktora tezi]. Diyarbakır: Dicle Üniversitesi; 2007.
- Alhasadi AFH. Predicting Breast Cancer by Using Artificial Neural Network [Master thesis]. İstanbul: Atılım University; 2016.
- Aktaş E. Ph'ya Bağımlı Çözünürlüğe Sahip Etkin Madde İçin Ph'dan Bağımsız Kontrollü Salım Sisteminin Geliştirilmesi Ve Yapay Sinir Ağları ile Optimizasyonu [Yüksek lisans tezi]. Ankara: Hacettepe Üniversitesi; 2010.
- An SI, Hsieh WW, Jin FF. A Nonlinear Analysis of the ENSO Cycle and Its Interdecadal Changes. *Int J Climatol*. 2005; 18(16): 3229-39.
- Anderson D, McNeill G. Artificial Neural Networks Technology, New York: Rome Laboratory RL/C3C Griffiss AFB.1992; 83. A011.
- Baş N. Yapay Sinir Ağları Yaklaşımı Ve Bir Uygulama [Yüksek Lisans Tezi]. İstanbul: Mimar Sinan Güzel Sanatlar Üniversitesi; 2006.
- Bouzenad K, Ramdani M. Multivariate Statistical Process Control Using Enhanced Bottleneck Neural Network. *Algorithms*. 2017; 10(2): 49-72.
- Çelik MM. Radyasyon Onkolojisinde Yapay Sinir Ağı Uygulaması [Yüksek lisans tezi]. Ankara: Gazi Üniversitesi; 2010.
- Demir C. Doğrusal Olmayan Temel Bileşenler Analizi ve Sağlık Alanında Uygulaması [Yüksek lisans tezi]. Van: Yüzüncü Yıl Üniversitesi; 2010.
- Diamantaras KI, Kung SY. Principal Component Neural Networks Theory and Applications. New York: John Wiley & Sons; 1996.
- Doğan O. Talep Tahmininde Sinirsel Ağ Tabanlı Bulanık Mantık Yöntemi (Anfis) Kullanımı Ve Yalın Yapay Sinir Ağı Metodu İle Karşılaştırmalı Bir Uygulama [Doktora tezi]. İzmir: Dokuz Eylül Üniversitesi; 2012.
- Dong D, McAvoy TJ. Nonlinear Principal Component Analysis Based on Principal Curves and Neural Networks [Bildiri]. American Cont. Conf.'94; 29 June-1 July 1994; Baltimore, Maryland, USA.
- Dong D, McAvoy TJ. Nonlinear Principal Component Analysis-Based On Principal Curves and Neural Networks. *Computers chem. Engng*.1996; 20(1): 65-78.
- Erguo L, Jinshou Y. An Input-Training Neural Network-Based Nonlinear Principal Component Analysis Approach for Fault Diagnosis [Bildiri]. World Cong. Intel. Cont. Auto; 10-14 June 2002; Shanghai, China.
- Frate FD, Schiavon G. Nonlinear Principal Component Analysis for the Radiometric Inversion of Atmospheric Profiles by Using Neural Networks. *IEEE-Transactions Geosci. Remote Sens*. 1999; 37(5): 2335-42.
- Gül E. EEG Sinyallerinin Wavelet Yöntemiyle Dönüştürülerek Yapay Sinir Ağları ile Sınıflandırılması [Yüksek lisans tezi]. Eskişehir: Eskişehir Osmangazi Üniversitesi; 2018.

- Gülbağ A. Yapay Sinir Ağı ve Bulanık Mantık Tabanlı Algoritmalar ile Uçucu Organik Bileşiklerin Miktersal Tayini [Doktora tezi]. Sakarya: Sakarya Üniversitesi; 2006.
- Güler H. Çinko-Alüminyum Alaşımının Korozyon Davranışına Alaşım Elementlerinin Etkisinin Yapay Sinir Ağıyla Tahmini [Yüksek lisans tezi]. Sakarya: Sakarya Üniversitesi; 2007.
- Güven A. Göze Ait Elektrofizyolojik Sinyaller Kullanılarak Yapay Sinir Ağları Destekli Bazı Göz Hastalıklarının Teşhisi [Doktora Tezi]. Kayseri: Erciyes Üniversitesi; 2005.
- Haykin S. Neural Networks and Learning Machines. Third Edition. Canada: Prentice Hall; 2009.
- Hebb D. The Organization of Behavior A Neuro psychological Theory. New York: John Wiley& Sons; 1949.
- Helhel Y. Makroekonomik Değişkenler ve Döviz Kuru İlişkisi: Yapay Sinir Ağı ve Var Yaklaşımları İle Öngörü Modellemesi [Doktora tezi]. Isparta: Süleyman Demirel Üniversitesi; 2009.
- Herman A. Nonlinear principal component analysis of the tidal dynamics in a shallow sea. Geophysical Research Letters. 2007; 34(2): 2608-11.
- Hsieh WW. Nonlinear principal component analysis by neural networks. Tellus. 2001; 53(5): 599-615.
- Hsieh WW. Nonlinear principal component analysis of noisy data. 2006 Int. Joint Conf. Neural Networks; 16-21 July 2006; Vancouver, Canada.
- IBM SPSS. Spss for Windows version 16.0. Chicago: IBM; 2010.
- Ji Q, Qi W, Cai W, Cheng Y. Study Of Fault Diagnosis Of Hydro-Generator Unit Via Ga Nonlinear Principal Component Analysis Neural Network And Bayesian Neural Networks. The 5th Int. Conf. Mach. Lrng. Cybernetics; 13-16 August 2006; Dalian, China.
- Jolliffe IT. Principal Component Analysis. New York: Springer-Verlag; 1986.
- Karaoğlu E. Gecikmeli bir yapay sinir ağı modeli ile gecikmeli bir Av-Avcı modelinin kararlılık ve hopf çatallanma Analizleri [Doktora tezi]. Ankara: TOBB Ekonomi ve Teknoloji Üniversitesi; 2016.
- Karabacak M. Çok Katmanlı Perseptron Yapay Sinir Ağlarıyla Sigara İçme ve Bırakmaya Etki Eden Faktörlerin İncelenmesi [Yüksek lisans tezi]. Edirne: Trakya Üniversitesi; 2012.
- Kargı VSA. Yapay Sinir Ağ Modelleri ve Bir Tekstil Firmasında Uygulama [Doktora tezi]. Bursa: Uludağ Üniversitesi; 2013.
- Kaya MO. Prostat Spesifik Antijeni (Psa)'nın Değişik Yapay Sinir Ağı Modelleri İle Tahmini [Yüksek lisans tezi]. Elazığ: Fırat Üniversitesi; 2010.
- Kuyucu YE. Lojistik Regresyon Analizi (Lra), Yapay Sinir Ağları (Ysa) ve Sınıflandırma Ve Regresyon Ağaçları (C&Rt) Yöntemlerinin Karşılaştırılması ve Tıp Alanında Bir Uygulama [Yüksek lisans tezi]. Tokat: Gaziosmanpaşa Üniversitesi; 2012.



- Kung SY, Diamantaras KI. A Neural Network Learning Algorithm for Adaptive Principal Component Extraction (APEX). Int. Conf. Acoustics, Speech, and sign. Procs-Albq. 90; 3-6 April 1990; NM, USA.
- Köktürk FK. En Yakın Komşuluk, Yapay Sinir Ağları ve Karar Ağaçları Yöntemlerinden Sınıflandırma Başarılarının Karşılaştırılması [Doktora tezi]. Zonguldak: Bülent Ecevit Üniversitesi; 2012.
- Kramer MA. Nonlinear principal component analysis using auto-associative neural networks. AIChE Journal. 1991; 37(2): 233-43.
- Licciardi G, Marpu PR, Chanussot J, Benediktsson JA. Linear Versus Nonlinear PCA for the Classification of Hyperspectral Data Based on the Extended Morphological Profiles. IEEE Geosci. Remote Sens. Let. 2012; 9(3): 447-51.
- Linting M, Meulman JJ, Groenen PJF, Kooij AJVD. Nonlinear Principal Components Analysis: Introduction and Application. Psychological Methods. 2007; 12(3); 336-58.
- Liu Z, Chen C, Shen X, Zou X. Detection of small objects in image data based on the nonlinear principal component analysis neural network. Optical Engineering. 2005; 44(9): 1-9.
- Lu B, Hsieh WW. Simplified nonlinear principal component analysis. Int. Joint Conf. Neural Networks; 20-24 July 2003; USA; 759-63.
- Lu BW, Pandolfo L. Quasi-objective nonlinear principal component analysis. Neural Networks. 2011; 24(2): 159-70.
- Mantere K, Parkkinen J, Jaaskelainen T. Simulation of white-light adaptation characteristics with use of nonlinear neural principal component analysis. J. Opt. Soc. Am. A. 1997; 14(9): 2049-56.
- MathWorks. Matlab version R2013b. Natick: 2013.
- Monahan AH. Nonlinear Principal Component Analysis by Neural Networks: Theory and Application to the Lorenz System. J Climate 2000; 13: 821-35.
- Nussbaum M. Asymptotic Equivalence of Density Estimation and Gaussian White Noise. The Annals of Statistics. 1996; 24(6): 2399-430.
- Ocañoğlu G. İstatistiksel Şekil Analizinde İki Örneklem Testlerinin Karşılaştırılması [Doktora Tezi]. Bursa: Uludağ Üniversitesi; 2011.
- Okut H. Bayesian Regularized Neural Networks for Small n Big p Data. Rosa JLG. Artificial Neural Networks-Models and Applications. London: InTechOpen; 2016.
- Özata M. Tiroid Hastalıklarına Güncel Yaklaşım, 1. Baskı. İstanbul: Epsilon Yayınları; 2005.
- Özçelik (Yıldırım) DS. Hipotiroidizmlili Obez Kadınlarda Yüksek Proteinli Diyetlerin Ağırlık Kontrolü Üzerine Etkisi [Yüksek Lisans Tezi]. İstanbul: Haliç Üniversitesi; 2016.
- Özdemir İ. Fen ve Teknoloji Öğretmenlerinin Mesleki Tükenmişliğini Etkileyen Değişkenlerin Yapay Sinir Ağı İle Öngörüsü (Zonguldak İl Örneği) [Doktora tezi]. Kırşehir: Ahi Evran Üniversitesi; 2015.

- Özer Ü. Constrained Neural Networks [Master thesis]. İstanbul: Boğaziçi University; 2012.
- Öztemel E. Yapay Sinir Ağları. İstanbul: Papatya Yayıncılık; 2016.
- Rattan SSP, Hsieh WW. Complex-valued neural networks for nonlinear complex principal component analysis. *Neural Networks*. 2005; 18: 61-9.
- Rosenblatt F. The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological Review*. 1958; 65(6): 386-408.
- Qiaoling J, Weimin Q, Weiyou C. Fault Diagnosis of Hydro-Generator Unit via GA-Nonlinear Principal Component Analysis Neural Network. *Chinese Cont. Conf.* 2007; 26-31 July 2007; Hunan, China.
- Sağlam F, Çakır B. Birinci Basamakta Tiroid Hastalıklarına Klinik Yaklaşım. *Ankara Medical Journal*. 2012; 12(3):136-139.
- Sibson R. Studies in the Robustness of Multidimensional Scaling: Procrustes Statistics. *RSS Series B*. 1978; 40(2): 234-238.
- Scholz M. Nichtlineare Hauptkomponentenanalyse auf Basis neuronaler Netze [Diplomarbeit]. Berlin: Humboldt-Universität zu Berlin; 2002.
- Scholz M, Fraunholz M, Selbig J. Nonlinear Principal Component Analysis: Neural Network Models and Applications. Gorban AN, Kégl B, Wunsch DC, Zinovyev A. *Principal Manifolds for Data Visualization and Dimension Reduction*. New York: Springer; 2008.
- Scholz M, Vigario R. Nonlinear PCA: a new hierarchical approach. *European Symp. Artificial Neural Networks*, 2002; 24-26 April 2002; Bruşes, Belgium.
- Shirakura J, Kurata K. Nonlinear Principal Component Analysis by Learning Nerve Fields United by Inhibitory Connections. *Syst Comput Jpn*. 2004; 35(3): 68-78.
- Stamkopoulos T, Diamantaras K, Maglaveras N, Strintzis M. ECG Analysis Using Nonlinear PCA Neural Networks for Ischemia Detection. *IEEE-Trans. Sign. Procs*. 1998; 46(11): 3058-69.
- Sušac MZ, Sarlija N, Pfeifer S. Combining TBA Analysis and Artificial Neural Networks in Modelling Entrepreneurial Intentions of Students. *Croatian Operational Res Rev*. 2013; 4(1): 306-17.
- Şeker S. Düzlemsel Çerçevesel Yapı Sistemlerinde Deprem Performanslarının Yapay Sinir Ağı Metodu İle Belirlenmesi [Yüksek lisans tezi]. Manisa: Celal Bayar Üniversitesi; 2008.
- Şen Z. Yapay sinir ağları ilkeleri. İstanbul: Su Vakfı Yayınları; 2004.
- Takane Y, Young WF. Nonmetric Individual Differences Multidimensional Scaling: An Alternating Least Squares Method With Optimal Scaling Features. *Psychometrika*. 1977; 42(1): 7-67.
- Villas-Boas MD, Olivera F, de-Azevedo JPS. Assessment of the water quality monitoring network of the Piabonha River experimental watersheds in Rio de Janeiro, Brazil, using auto-associative neural networks. *Environ Monit Assess*. 2017; 189(9): 439-54.

Yetkin M. Tanker Şamandıra Bağlama Sistemlerinin Yapay Sinir Ağları Tekniğıyle Optimizasyonu [Yüksek lisans tezi]. İstanbul: İstanbul Teknik Üniversitesi; 2014.

Yıldırım U. Ankara'da Şehir İçinde Meydana Gelen Trafik Kazalarının Analizi, Kritik Noktaların Belirlenmesi ve Bir Yapay Sinir Ağı ile Modellenmesi [Doktora tezi]. Ankara: Gazi Üniversitesi; 2014.



## ÖZGEÇMİŞ

Diyarbakır'da 1978 yılında doğdu. İlk, orta ve lise öğrenimini Diyarbakır'da tamamladı. 1998 yılında Yüzüncü Yıl Üniversitesi, Eğitim Fakültesi, İlköğretim Matematik Öğretmenliği Bölümü'nde lisans eğitimine başladı ve 2002 yılında aynı bölümden mezun oldu. Aynı yıl MEB Van Merkez Mimar Sinan İlköğretim Okulunda Matematik öğretmeni olarak göreve başladı. 2006-2011 yılları arasında MEB Van Merkez Fevzi Çakmak İlköğretim Okulunda Matematik öğretmeni olarak görev yaptı. Daha sonra Van Yüzüncü Yıl Üniversitesi, Sağlık Bilimleri Enstitüsü, Biyoistatistik Anabilim Dalında Yüksek Lisans eğitimine başladı. 2010 yılında mezun oldu. 2012 yılında MEB'den naklen Hakkâri Üniversitesi, Sağlık Hizmetleri Meslek Yüksekokulunda Öğretim Görevlisi olarak göreve başladı. 2015 yılında Van Yüzüncü Yıl Üniversitesi, Sağlık Hizmetleri Meslek Yüksekokulu'na Öğretim Görevlisi olarak geçti. 2015 yılında Van Yüzüncü Yıl Üniversitesi, Sağlık Bilimleri Enstitüsü, Biyoistatistik Anabilim Dalında Doktora eğitimine başladı. Halen Van Yüzüncü Yıl Üniversitesi, Sağlık Hizmetleri Meslek Yüksekokulunda Öğretim Görevlisi olarak devam etmektedir. Evli ve iki çocuk annesidir.

## EKLER

### EK 1.Etik Kurul Raporu



T.C.  
YÜZÜNCÜ YIL ÜNİVERSİTESİ  
Girişimsel Olmayan Klinik Araştırmalar  
Etik Kurul Başkanlığı

Sayı : B.30.2.YYU.0.01.00.00/23

Tarih: 21.02.2018

Konu :Etik Kurul Başvurunuz

Sn. Prof.Dr. Sıddık KESKİN

**İlgi:** 08.02.2018 tarih ve bila sayılı yazınız.

İlgi yazı ile Etik Kurulumuza sunulan “Yapay Sinir Ağları İle Doğrusal Olmayan Temel Bileşenleri Analizi” isimli proje özetiniz 16.02.2018 tarihinde yapılan Etik Kurul toplantımızda görüşüldü. Yapılan görüşmede çalışmanın proje özetinin içeriği tamamiyle istatistiksel analiz değerlendirmesi olduğundan adı geçen çalışmanın etik kurulla doğrudan ilişkisi saptanmamıştır.


Bilgilerinize rica ederim.


Prof. Dr. Oğuz TUNCER  
Girişimsel Olmayan  
Klinik Araştırmalar  
Etik Kurul Başkanı

Adres: 65080 Zeve Kampüsü - VAN Tel : (0432) 2150470 E-Posta: etikkurull@gmail.com  
Fax : (0432) 2168352 Web: http://www.yyu.edu.tr

## EK 2.Tez Orijinallik Raporu

	<p style="text-align: center;"><b>T.C.</b> <b>VAN YÜZÜNCÜ YIL ÜNİVERSİTESİ</b> <b>Sağlık Bilimleri Enstitüsü</b></p>	
<b>DOKTORA TEZİ ORJİNALLİK RAPORU</b>		

Tez Başlığı / Konusu:	Tarih: 18/03/2019
Doğrusal Olmayan Temel Bileşenler Analizi İçin Yapay Sinir Ağları Yaklaşımı /Biyostatistik	
<p>Yukarıda başlığı/konusu belirlenen tez çalışmamın Kapak sayfası, Giriş, Ana bölümler ve Sonuç bölümlerinden oluşan toplam 43 sayfalık kısmına ilişkin, 18/03/2019 tarihinde şahsım/tez danışmanım tarafından Turnitin intihal tespit programından aşağıda belirtilen filtreleme uygulanarak alınmış olan orijinallik raporuna göre, tezin benzerlik oranı % 10 (on)'dur.</p>	
<u>Uygulanan filtreler aşağıda verilmiştir:</u>	
<ul style="list-style-type: none"><li>- Kabul ve onay sayfası hariç,</li><li>- Teşekkür hariç,</li><li>- İçindekiler hariç,</li><li>- Simge ve kısaltmalar hariç,</li><li>- Gereç ve yöntemler hariç,</li><li>- Kaynakça hariç,</li><li>- Alıntılar hariç,</li><li>-Tezden çıkan yayınlar hariç,</li><li>- 7 kelimededen daha az örtüşme içeren metin kısımları hariç (Limit match size to 7 words)</li></ul>	
<p>Van Yüzüncü Yıl Üniversitesi Lisansüstü Tez Orijinallik Raporu Alınması ve Kullanılmasına İlişkin Yönergeyi inceledim ve bu yönergede belirtilen azami benzerlik oranlarına göre tez çalışmamın herhangi bir intihal içermediğini; aksinin tespit edileceği muhtemel durumda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve yukarıda vermiş olduğum bilgilerin doğru olduğunu beyan ederim.</p>	
Gereğini bilgilerinize arz ederim.	 Canan DEMİR İmza

Öğrencinin Adı Soyadı	Canan DEMİR
Anabilim Dalı	: Biyoistatistik (Tıp Programı)
Öğrenci No	149302049
Programı	: <input type="checkbox"/> Yüksek Lisans <input checked="" type="checkbox"/> Doktora
<b>DANIŞMAN ONAYI</b> UYGUNDUR Prof. Dr. Sıddık KESKİN 	<b>ENSTİTÜ ONAYI</b> UYGUNDUR Dr. Öğr. Üyesi Hacer SAHİN AYDINYURT 