

**T.C.
HACETTEPE ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ**

**KOHONEN ÖZ ÖRGÜTLEMELİ HARİTALAMA YÖNTEMİ İLE
PSİKOTİK HASTALIKLARIN KÜMELENMESİ**

Ash ÇİFTÇİ

**Biyoistatistik Programı
YÜKSEK LİSANS TEZİ**

ANKARA

2018

**T.C.
HACETTEPE ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ**

**KOHONEN ÖZ ÖRGÜTLEMELİ HARİTALAMA YÖNTEMİ İLE
PSİKOTİK HASTALIKLARIN KÜMELENMESİ**

Ash ÇİFTÇİ

**Biyoistatistik Programı
YÜKSEK LİSANS TEZİ**

**TEZ DANIŞMANI
Dr. Öğretim Üyesi Sevilay KARAHAN**

ANKARA

2018

KOHONEN ÖZ ÖRGÜTLEMELİ HARİTALAMA YÖNTEMİ İLE PSİKOTİK HASTALIKLARIN
KÜMELENMESİ

Öğrenci: Aslı Çiftçi

Danışman: Dr. Öğr. Üyesi Sevilay KARAHAN

Bu tez çalışması 25/06/2018 tarihinde jürimiz tarafından "Biyoistatistik Programı"nda yüksek lisans tezi olarak kabul edilmiştir.

Jüri Başkanı:

Prof. Dr. C. Reha ALPAR

(Hacettepe Üniversitesi)

Tez Danışmanı:

Dr. Öğr. Üyesi Sevilay KARAHAN

(Hacettepe Üniversitesi)

Üye:

Prof. Dr. M. Kazım YAZICI

(Hacettepe Üniversitesi)

Üye:

Prof. Dr. Erdem KARABULUT

(Hacettepe Üniversitesi)


Üye:

Doç. Dr. Beyza DOĞANAY ERDOĞAN

(Ankara Üniversitesi)

Bu tez Hacettepe Üniversitesi Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliğinin ilgili maddeleri uyarınca yukarıdaki jüri tarafından uygun bulunmuştur.

19 Temmuz 2018


Prof. Dr. Diclehan ORHAN

Enstitü Müdürü

YAYIMLAMA VE FİKRİ MÜLKİYET HAKLARI BEYANI

Enstitü tarafından onaylanan lisansüstü tezimin/raporumun tamamını veya herhangi bir kısmını, basılı (kağıt) ve elektronik formatta arşivleme ve aşağıda verilen koşullarla kullanıma açma iznini Hacettepe Üniversitesine verdiğimi bildiririm. Bu izinle Üniversiteye verilen kullanım hakları dışındaki tüm fikri mülkiyet haklarım bende kalacak, tezimin tamamının ya da bir bölümünün gelecekteki çalışmalarda (makale, kitap, lisans ve patent vb.) kullanım hakları bana ait olacaktır.

Tezin kendi orijinal çalışmam olduğunu, başkalarının haklarını ihlal etmediğimi ve tezimin tek yetkili sahibi olduğumu beyan ve taahhüt ederim. Tezimde yer alan telif hakkı bulunan ve sahiplerinden yazılı izin alınarak kullanılması zorunlu metinlerin yazılı izin alınarak kullandığımı ve istenildiğinde suretlerini Üniversiteye teslim etmeyi taahhüt ederim.

Yükseköğretim Kurulu tarafından yayınlanan **“Lisansüstü Tezlerin Elektronik Ortamda Toplanması, Düzenlenmesi ve Erişime Açılmasına İlişkin Yönerge”** kapsamında tezim aşağıda belirtilen koşullar haricince YÖK Ulusal Tez Merkezi / H.Ü. Kütüphaneleri Açık Erişim Sisteminde erişime açılır.

- Enstitü / Fakülte yönetim kurulu kararı ile tezimin erişime açılması mezuniyet tarihimden itibaren 2 yıl ertelenmiştir. ⁽¹⁾
- Enstitü / Fakülte yönetim kurulunun gerekçeli kararı ile tezimin erişime açılması mezuniyet tarihimden itibaren ... ay ertelenmiştir. ⁽²⁾
- Tezimle ilgili gizlilik kararı verilmiştir. ⁽³⁾

24/07/2018

(İmza)

Öğrencinin Adı SOYADI

Aslı Gıftçı

¹“Lisansüstü Tezlerin Elektronik Ortamda Toplanması, Düzenlenmesi ve Erişime Açılmasına İlişkin Yönerge”

- (1) Madde 6. 1. Lisansüstü teze ilgili patent başvurusu yapılması veya patent alma sürecinin devam etmesi durumunda, tez **danışmanının** önerisi ve **enstitü anabilim dalının** uygun görüşü üzerine **enstitü** veya **fakülte yönetim kurulu** iki yıl süre ile tezin erişime açılmasının ertelenmesine karar verebilir.
- (2) Madde 6. 2. Yeni teknik, materyal ve metotların kullanıldığı, henüz makaleye dönüşmemiş veya patent gibi yöntemlerle korunmamış ve internetten paylaşılması durumunda 3. şahıslara veya kurumlara haksız kazanç imkanı oluşturabilecek bilgi ve bulguları içeren tezler hakkında tez **danışmanının** önerisi ve **enstitü anabilim dalının** uygun görüşü üzerine **enstitü** veya **fakülte yönetim kurulunun** gerekçeli kararı ile altı ayı aşmamak üzere tezin erişime açılması engellenebilir.
- (3) Madde 7. 1. Ulusal çıkarları veya güvenliği ilgilendiren, emniyet, istihbarat, savunma ve güvenlik vb. konulara ilişkin lisansüstü tezlerle ilgili gizlilik kararı, **tezin yapıldığı kurum** tarafından verilir *. Kurum ve kuruluşlarla yapılan işbirliği protokolü çerçevesinde hazırlanan lisansüstü tezlere ilişkin gizlilik kararı ise, **ilgili kurum ve kuruluşun önerisi** ile **enstitü** veya **fakültenin** uygun görüşü üzerine **üniversite yönetim kurulu** tarafından verilir. Gizlilik kararı verilen tezler Yükseköğretim Kuruluna bildirilir.
- Madde 7.2. Gizlilik kararı verilen tezler gizlilik süresince enstitü veya fakülte tarafından gizlilik kuralları çerçevesinde muhafaza edilir, gizlilik kararının kaldırılması halinde Tez Otomasyon Sistemine yüklenir

* Tez **danışmanının** önerisi ve **enstitü anabilim dalının** uygun görüşü üzerine **enstitü** veya **fakülte yönetim kurulu** tarafından karar verilir.

ETİK BEYAN

Bu çalışmadaki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi, görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu, kullandığım verilerde herhangi bir tahrifat yapmadığımı, yararlandığım kaynaklara bilimsel normlara uygun olarak atıfta bulunduğumu, tezimin kaynak gösterilen durumlar dışında özgün olduğunu, Dr. Öğretim Üyesi Sevilay KARAHAN danışmanlığında tarafımdan üretildiğini ve Hacettepe Üniversitesi Sağlık Bilimleri Enstitüsü Tez Yazım Yönergesine göre yazıldığını beyan ederim.



Aslı ÇİFTÇİ

TEŞEKKÜR

Tezin her aşamasında bana destek olan ve yol gösteren olan değerli hocam Dr.Öğr. Üyesi Sevilay KARAHAN'a teşekkür ederim.

Analiz aşamasında, R yazılımının kullanılmasında kısıtlı zamanını ayıran ve yardımcı olan Araş.Gör. Osman Dağ'a teşekkür ederim.

Ankara Üniversitesi Tıp Fakültesi Klinik Araştırmalar Etik Kurul Başkanı Sayın Prof.Dr. Mehmet MELLİ'ye ders aşamasında ve tez aşamasında bana destek ve yardımcı olduğu için teşekkür ederim.

Tez çalışması boyunca yanımda olan eşim, ailem ve arkadaşlarıma teşekkür ederim.

Ash ÇİFTÇİ

ÖZET

Çiftçi A. Kohonen Öz Örgütlemeli Haritalama Yöntemi ile Psikotik Hastalıkların Kümelenmesi. Hacettepe Üniversitesi Sağlık Bilimleri Enstitüsü Biyoistatistik Programı Yüksek Lisans Tezi, Ankara, 2018. Veri madenciliği; büyük miktarda veri içerisinde, gizli kalmış, değerli, kullanılabilir bilgileri açığa çıkaran ve stratejik karar destek sağlamak amacıyla kullanılan bir yöntemdir. Veri madenciliği çeşitli alanlarda kullanılmasına rağmen, özellikle sağlık alanında çeşitli zorluklarla karşılaşmaktadır. Sağlık alanında bilginin sürekli değişmesi, fazla miktarda yapısal olmayan veriye sahip olması ve bu verilerin farklı ortamlarda bulunması verileri analiz etmeyi zorlaştıran faktörlerdir. Sınıflama ya da kümeleme sorununun yaşandığı durumlarda 'Kohonen öz örgütlemeli haritalama yöntemi' ile sınıflama ya da kümeleme yapılması sınıflama ve kümeleme problemini çözeceği düşünülmektedir. Tezin amacı; veri madenciliğinde, sınıflama ve kümeleme amacı ile kullanılan “Kohonen öz örgütlemeli haritalama yöntemi”ni kuramsal olarak tanıtmak, bu yöntemin özelliklerini incelenmek, psikotik hastalıkların alt türlerini ilgili yöntem ile sınıflamak/kümelemek, sağlık alanında sınıflama ya da kümeleme gereksinimi olduğu durumlarda bu yöntemin kullanılabilirliğini göstermektir. Tezin hipotezi, bu yöntem sonucunda elde edilen sınıflama/kümeleme performansının (doğruluk oranının vb.) diğer klasik yöntemlere göre daha yüksek olacaktır. Bu tez çalışmasında; 'Şizofreni ve diğer psikotik bozukluklarda faktör yapısı' başlıklı uzmanlık tezi için toplanmış ait 268 psikotik bireyin verisi kullanılmıştır. Kümeleme ve sınıflama yöntemleri R programı kullanılarak analiz edilmiştir. Kohonen öz örgütlemeli haritalama yöntemi ile sınıflamanın performansı değerlendirildiğinde, sınıflama performansının yüksek olduğu görülmüştür. Kohonen haritalama yönteminin, sağlık verisi üzerinde kümeleme performansı araştırılmış ve Kohonen öz örgütlemeli haritalama yönteminin sonucu klasik kümeleme yöntemleri (k-ortalamlar yöntemi ve hiyerarşik kümeleme yöntemi) ile karşılaştırılmıştır. Kümeleme performansları; kümeleme indeksleri kullanılarak değerlendirilmiştir. 4 farklı tanı grubu açısından Kohonen öz örgütlemeli haritalama yöntemi ile diğer kümeleme yöntemlerinin sonuçları karşılaştırılmıştır. Tanı gruplarına ve indekslere göre, yöntemlerin başarı oranının değiştiği ve sadece bir indekste Kohonen öz örgütlemeli haritalama yönteminin diğer yöntemlerden daha iyi performansa sahip olduğu görülmüştür.

Anahtar Kelimeler: Veri Madenciliği, Kümeleme Analizi, Kohonen Öz Örgütlemeli Haritalama Yöntemi, Psikotik Bozukluk

Destekleyen Kurumlar: H.Ü. Bilimsel Araştırma Projeleri Koordinasyon Birimi, (TYL-2018-17163)

ABSTRACT

Çiftci A. Kohonen Cluster of Psychotic Diseases by Self Organizing Mapping Method. Hacettepe University Institute of Health Science Department of Biostatistics Master's Thesis, Ankara, 2018. Data mining is a method that is used to extract hidden, valuable, usable information among large amounts of data, and to support strategic decisions. Despite the fact that data mining is used in a variety of fields, it faces various challenges, especially in the field of health. The constant change of information in the health field, the excessive amount of non-structural data, and the presence of these data in different environments make it difficult to analyze data. It is thought that classification or clustering by 'Kohonen self-organization mapping method' in cases where classification or clustering problem is experienced will solve classification and clustering problem. The aim of this thesis is to theoretically introduce the 'Kohonen self-organization mapping method' used in data mining for classification and clustering purposes, to examine its properties, to classify/cluster the subtypes of psychotic diseases with related methods, to show its applicability of this method in case of necessity of classifying or clustering in health field. The thesis hypothesis is that the classification / clustering performance (accuracy rate, etc.) obtained as a result of this method will be higher than the other classical methods. In this thesis study, data of 268 psychotic individuals collected for the dissertation thesis named 'Factor structure in schizophrenia and other psychotic disorders' were used. Clustering and classification methods were analyzed using the R program. When the performance of the classification made by the Kohonen self-organization mapping method was evaluated, it was found that the classification performance was high. The clustering performance of the Kohonen self-organization mapping method on health data was investigated and the result of the Kohonen self-organization mapping method was compared with classical clustering methods (k-means method and hierarchical clustering method). Clustering performances were evaluated using clustering indexes. In terms of 4 different diagnostic groups, the results of Kohonen self-organization mapping method and other clustering methods were compared. It was seen that the success rate changes according to the diagnostic groups and indexes, and only in one index Kohonen self-organisation mapping map has better performance than the other methods.

Key Words: Data Mining, Clustering Analysis, Kohonen Self-Organising Mapping Method, Psychotic Disorder

Supported by H.U. Scientific Research Projects Coordination Unit (TYL-2018-17163)

İÇİNDEKİLER

ONAY SAYFASI	iii
YAYIMLAMA VE FİKRİ MÜLKİYET BEYANI	iv
ETİK BEYAN SAYFASI	v
TEŞEKKÜR	vi
ÖZET	vii
ABSTRACT	viii
İÇİNDEKİLER	ix
SİMGELER VE KISALTMALAR	xi
ŞEKİLLER	xii
TABLolar	xiii
1. GİRİŞ	1
2. GENEL BİLGİLER	5
2.1. Veri Madenciliği	5
2.1.1. Veri Madenciliği Süreci	6
2.1.2. Veri Madenciliği Modelleri (Teknikleri)	7
2.1.3. Tıbbi Veri	9
2.1.4. Tıbbi Veri Madenciliği	9
2.2. Kümeleme Analizi	10
2.2.1. Kümeleme Analizinin Aşamaları	11
2.2.2. Kümeleme Yöntemleri	12
2.3. Yapay Sinir Ağları	15
2.4. Kohonen Öz Örgütlemeli Haritalama Yöntemi	17
2.4.1. Kohonen Öz Örgütlemeli Haritalama Yönteminin Tanımı	19
2.4.2. Kohonen Öz Örgütlemeli Haritalama Yönteminin Yapısı	21
2.4.3. Kohonen Öz Örgütlemeli Haritalama Yönteminin Bileşenleri	24
2.4.4. Kohonen Öz Örgütlemeli Haritalama Yönteminin Adımları	24
2.4.5. Kohonen Öz Örgütlemeli Haritalama Yönteminin Algoritması	28

2.5. Ruh Sağlığı ve Bozukluğunun Tanımlanması	30
2.5.1. Ruh Sağlığı ve Bozukluklarının Sınıflandırılması	30
3. GEREÇ VE YÖNTEM	33
3.1. Kümeleme Analizi Sonuçlarını Değerlendirmek için Kullanılan İndeksler	35
4. BULGULAR	38
4.1. Kümeleme İndeks Sonuçları	44
4.2. Sınıflama Sonuçları	61
5. TARTIŞMA	70
6. SONUÇ ve ÖNERİLER	81
6.1. Sonuçlar	81
6.2. Öneriler	82
7. KAYNAKÇA	84
8. EKLER	97
EK-1: Global Değerlendirme Ölçeği (GAS/GAF)	
EK-2: Veri Toplama Formu	
EK-3 Pozitif ve Negatif Semptom Ölçeği (PANNS)	
EK-4 Pozitif Belirtileri Değerlendirme Ölçeği (SAPS)	
Ek-5 Negatif Belirtileri Değerlendirme Ölçeği (SANS)	
Ek-6 Etik Kurul Karar Örneği	
9. ÖZGEÇMİŞ	107

SİMGELER VE KISALTMALAR

BMU	En İyi Eşleşen Düğüm
DSM	Mental Bozuklukların Tanısal ve Sayımsal El Kitabı veya Ruhsal Bozuklukların Tanısal ve İstatistiksel El Kitabı
GAF	Global Değerlendirme Ölçeği
ICD	The International Classification of Diseases (Uluslararası Hastalık Sınıflandırması)
MRI	Manyetik Rezonans
OECD	Ekonomik Kalkınma ve İşbirliği Örgütü
PANSS	Pozitif ve Negatif Sendrom Ölçeği
SANS	Negatif Belirtileri Değerlendirme Ölçeği
SAPS	Pozitif Belirtileri Değerlendirme Ölçeği
SOFM	Kendini Organize Eden Özellik Haritası
SOM	Kendini Organize Eden Harita

ŞEKİLLER

Şekil	Sayfa
2. 1. Kohonen öz örgütlemeli haritalama yönteminin yapısı	22
4.1. Kümeleme 1'e göre değişkenlerin alt kümelerdeki dağılımı	39
4.2. Kümeleme 1'e göre değişkenlerin alt kümelerdeki dağılımı	41
4.3. Kümeleme 1'e göre düğüm frekansları	42
4.4. Kümeleme 2'ye göre değişkenlerin alt kümelerdeki dağılımı	45
4.5. Kümeleme 2'ye göre düğüm frekansları	46
4.6. Kümeleme 3'e göre değişkenlerin alt kümelerdeki dağılımı	49
4.7. Kümeleme 3'e göre düğüm frekansları	50
4.8. Kümeleme 4'e göre değişkenlerin alt kümelerdeki dağılımı	53
4.9. Kümeleme 4'e göre düğüm frekansları	54
4.10. Kümeleme 5'e göre değişkenlerin alt kümelerdeki dağılımı	57
4.11. Kümeleme 5'e göre düğüm frekansları	58
4.12. Sınıflama 1'e göre kohonen öz örgütlemeli haritalama yöntemi özellik haritası	57
4.13. Sınıflama 2'ye göre kohonen öz örgütlemeli haritalama yöntemi özellik haritası	59
4.14. Sınıflama 3'e göre kohonen öz örgütlemeli haritalama yöntemi özellik haritası	61
4.15. Sınıflama 4'e göre kohonen öz örgütlemeli haritalama yöntemi özellik haritası	63
4.16. Sınıflama 5'e göre kohonen öz örgütlemeli haritalama yöntemi özellik haritası	69

TABLOLAR

Tablo	Sayfa
3.1. Çalışmaya alınan kişilerin sosyodemografik özellikleri	34
4. 1. Kümeleme bir bölümünde yer alan tanı grupları	37
4.2. Kohonen öz örgütlemeli haritalama yöntemi, k-ortalamlar ve hiyerarşik kümeleme yöntemlerine ait indeks sonuçları	43
4.3. Kümeleme iki bölümünde yer alan tanı grupları	44
4.4. Kohonen öz örgütlemeli haritalama yöntemi, k-ortalamlar ve hiyerarşik kümeleme yöntemlerine ait indeks sonuçları	47
4.5. Kümeleme üç bölümünde yer alan tanı grupları	48
4.6. Kohonen öz örgütlemeli haritalama yöntemi, k-ortalamlar ve hiyerarşik kümeleme yöntemlerine ait indeks sonuçları	51
4.7. Kümeleme dört bölümünde yer alan tanı grupları	52
4.8. Kohonen öz örgütlemeli haritalama yöntemi, k-ortalamlar ve hiyerarşik kümeleme yöntemlerine ait indeks sonuçları	55
4.9. Kümeleme beş bölümünde yer alan tanı grupları	56
4.10. Kohonen öz örgütlemeli haritalama yöntemi, k-ortalamlar ve hiyerarşik kümeleme yöntemlerine ait indeks sonuçları	59
4. 11. Sınıflama 1'e göre kohonen öz örgütlemeli haritalama yöntemi ile elde edilen sınıflama sonucu	60
4.12. Sınıflama 2'ye göre kohonen öz örgütlemeli haritalama yöntemi ile elde edilen sınıflama sonucu	62
4. 13. Sınıflama 3'e göre kohonen öz örgütlemeli haritalama yöntemi ile elde edilen sınıflama sonucu	64
4.14. Sınıflama 4'e göre kohonen öz örgütlemeli haritalama yöntemi ile elde edilen sınıflama sonucu	66
4. 15. Sınıflama 5'e göre kohonen öz örgütlemeli haritalama yöntemi ile elde edilen sınıflama sonucu	68

1. GİRİŞ

Bir düşünceyi, bir olguyu anlamlandırma ve sistematikleştirme becerisi bilimlerin tarihinin eski zamanlarından bu yana temel hedefi olagelmıştır. Dünya'ya bakışında bir bilgi yığını ile karşılaşan insan; bilgisi artıkça, bu bilgileri düzenleme başka bir ifade ile sınıflama ihtiyacı hissetmiştir. Bilgilerin işlevsel bir hale gelmesi ve sistematikleştirilmesi, artan bilgi karşısında bir zorunluluk olmuştur. Bu sistematikleştirme çabası farklı bilim dallarının oluşmasına da neden olmuştur. Bilimsel bilginin işlevselliğinin gündeme gelmesi, bu bilginin kaynaklarının düzenlenmesini gerektirmektedir. Bu düzenleme gereksinimi bilgiyi bir “girdi” olarak konumlandırma gerekliliğini doğurur. Bu girdi günümüzde teknolojik altyapıların etkisi ile işlenebilir halde bir “veri” olarak konumlanmıştır.

Veri kavramı; kaydedilmesine, analiz edilmesine ve yeniden düzenlenmesine izin verilen işlenememiş gereç olarak tanımlanmaktadır. Bir olayı *verileştirmek*, veriyi analiz edilebilecek bir formata dönüştürmektir. Verileştirme işleminin gelişmesinde; bilginin nasıl ölçüleceğinin ve nasıl kaydedileceğinin öğrenilmesi ile birlikte bilgisayarların gelişmesi ve veri miktarındaki artış etkili olmuştur (1).

Bilgisayar teknolojisinin gelişmesi ve bu gelişme ile birlikte depolanan veri boyutunun artışı verilerin değerlendirilmesi sürecine yeni bir boyut getirmiştir. Dolayısıyla boyutu artan verilerin değerlendirilmesinde kullanılan yöntemlerde değişiklikler görülmüştür. Artık verinin yönetimi, saklanması ve işlenmesi kadar, veriden değer elde etmek de gelişen rekabet koşullarında ön plana çıkmak için gereksinim haline gelmiştir. Bu aşamalar sonucunda büyük veri kavramı ortaya çıkmıştır (2).

Büyük veri kavramının gelişmesinde; verilerin depolanması ve analiz edilmesinde geleneksel yöntemlerle çözüme ulaşılamaması etkili olmuştur. Büyük veri; farklı formatlarda, hızlı ve büyük hacimde üretilen veriler” dir (3). Büyük veri aynı zamanda; farklı veri tabanlarından alınan (toplanan) verilerin depolanması ve analizi ile ilgili bir kavram olarak da tanımlanmaktadır (4).

Büyük verinin gelişmesinde; teknolojik alt yapı, yazılım hizmetleri, bu konuda bilgi ve becerilerin artması, politik düzenlemeler ve teşvikler etkili olmuştur. Gerek

teknolojideki gerekse ekonomideki hızlı değişimlerden kaynaklanan belirsizlikler, örgütlerde çeşitli değişimlerin meydana gelmesine yol açmaktadır. Dolayısıyla örgütler değişen koşullara uyum sağlayabilmek için, çeşitli kararlar almak zorunda kalmışlardır. Eğer ilgilenilen konu ya da sorun ile ilgili veriler bulunursa, doğru kararlar alma ihtimali de artmaktadır. Örgütlerin elinde olan veri ne kadar doğru ve ne kadar çok olursa, mevcut durumu ve ihtiyaçları anlama şansı da o kadar artmaktadır. Çünkü az miktarda verilerle çalışıldığında ulaşılamayacak bilgilere büyük miktarda verilerle çalışıldığında ulaşılabilmektedir (5). Büyük verinin analiz edilmesi; daha önce bilinmeyen bilgilere/ilişkilere ulaşılması, veriler arasında bilinmeyen bağlantılar kurulması, yeni hipotezler üretilerek test edilmesi, yeni amaçların oluşturulması açısından önemlidir.

Büyük veri kavramı çeşitli bileşenlerden oluşmaktadır. Başlangıçta 3 bileşen tanımlanırken, daha sonra günümüz ihtiyaçlarına göre bileşen sayısının 10'a yükseldiği görülmektedir. Bu bileşenler, büyük verinin ana özelliklerini yansıtmaktadır. Bunlardan; **çeşitlilik (variety)** yapısal ve yapısal olmayan verileri; **hız (velocity)** hem hızlı veri artışını hem de veri artışından dolayı ihtiyaç duyulan işlem artışını; **veri büyüklüğü (volume)** veri miktarındaki artışı, **gerçeklik (veracity)** verinin güvenli olmasını ve **değer (value)** ise verinin işlenmesinden sonra elde edilen sonucun bir değer taşımasını ifade etmektedir (6). Bu bileşenlerden özellikle “verinin değeri” yani kullanılabilirliği başka bir ifade ile karar almadaki konumu en önemli özelliklerinden birisidir. Daha sonra bu bileşenlere; oynaklık (volatility), geçerlik (validity), hassaslık (vulnerability), değişkenlik (variability) ve görselleştirme (visualization) ilave edilmiştir (7).

Büyük veri; eldeki verilerin gözlenmesi ve analiz edilmesi ile topluma faydalı öngörüler ya da önemli değeri olan mal ve hizmetler üretmek için bilgiden yeni yöntemlerle faydalanma becerisi yaratmaktadır. Örneğin; büyük veri bir hastalığın yayılmasını kestirmek ve önlemek için kullanılan bir araç olabilir. Aynı zamanda hastalıkların teşhis edilmesinde, tedavilerin önerilmesinde, hatta belki birisi gerçekten suç işlemekten önce suçluların tespit edilmesinde kullanılabilir (1).

Büyük veri hem bilimsel ve toplumsal olarak hem de ekonomik değer kaynağı olarak önemlidir. Bu nedenle büyük veri işletmelerden, bilime, sağlık hizmetine, hükümete,

eğitime, ekonomiye, beşeri bilimlere ve dolayısıyla toplumun bütünü üzerinde etkilidir (1). Ayrıca büyük veri; sağlık hizmetleri, ekonomi, güvenlik, halkla ilişkiler, kaynak yönetimi gibi çeşitli alanlarda verilen kararların iyileştirilmesini sağlayacak maliyet etkili yöntemler olarak da kullanılmaktadır (5). Büyük verinin kullanım alanları incelendiğinde; sağlık alanında; sağlık alışkanlıklarını belirlemede, hasta profili çıkarmada, hastalıkların tahmininde; pazarlama alanında; çapraz satış, konum tabanlı pazarlama, duygu analizi, eğilim analizi ve davranış analizinde; üretim alanında; tedarik zinciri, envanter yönetimi, lojistik de; kamu da temel ihtiyaç tespitinde, trafik sorunlarının çözümünde, yolların kullanım oranının belirlenmesinde, gürültü, hava ve su kirliliğini önlemede, istismar tespitinde, bankacılık ve sigortacılık da hilelerin, istismarın veya suistimallerin belirlenmesinde, müşteri tahminlemede ve risk analizlerinde kullanıldığı görülmektedir (3).

Büyük verilerin depolanması, farklı veritabanlarında yer alan verilerin birleştirilmesi ve analiz edilmesi ile birlikte geleneksel istatistiksel yöntemlerin yerini, büyük verilerin analizini gerçekleştiren farklı yöntemler almaya başlamıştır.

Geleneksel istatistiksel yöntemlerin çeşitli varsayımlara dayanması ve karmaşık matematiksel hesaplarda yetersiz kalması sınırlılıkları olarak kabul edilmektedir. Veri tabanlarının gelişmesi ve dolayısıyla depolanan verinin hacminin artması ile birlikte geleneksel istatistiksel yöntemlerin sınırlılıklarını ortadan kaldıracak yeni veri analiz yöntemlerine duyulan ihtiyaç, makine öğrenmesine dayalı yöntemlerin gelişmesini sağlamıştır. Makine öğrenmesi; veritabanından elde ettiği verileri kullanarak, tahminde bulunabilen yöntemlerdir. Makine öğrenmesi yöntemi, var olan bilgilerden modeller geliştirmektedir. Makine öğrenmesi ve bununla ilişkili yöntemleri kullanan alanın genel ismi de “veri madenciliği” ve “veriden bilgi keşfi (KDD)”dir. “Veriden bilgi keşfi”, veriden bilgi çıkarma sürecinin bütününe verilen isimdir. “Veri madenciliği” de bu sürecin adımlarından biridir. Bu yöntemlerin ve algoritmaların amacı; büyük veriden kullanışlı bilgiyi çıkarmak, ilgilenilen değişkenler arasındaki ilişkileri ortaya çıkarmak ya da fonksiyonlar yardımıyla sınıflama, kümeleme ya da öngörü yapmaktır (8-9).

1.1. Amaç ve Hipotez

Veri madenciliği çeşitli alanlarda kullanılmasına rağmen, özellikle sağlık alanında çeşitli zorluklarla karşılaşmaktadır. Sağlık alanında bilginin sürekli değişmesi, fazla miktarda yapısal olmayan veriye sahip olunması ve bu verilerin farklı ortamlarda bulunması verileri analiz etmeyi zorlaştıran faktörlerdir. Aynı zamanda sağlık hizmetlerinin en hızlı, en doğru, en yüksek kalitede ve ihtiyaca yanıt verecek şekilde sunulabilmesi için sağlık çalışanlarının en doğru ve güncel bilgiye ulaşması ve bu bilgiyi karar destek sistemlerinden faydalanarak kullanması gerekmektedir.

Sağlık alanında özellikle hastalıkların ya da hastalık alt tiplerinin sınıflanmasında zorlanması (gerekli sınıflama yapılamadığında ileri teknolojiye veya uzmanlığa ihtiyaç duyulması, hastaya getireceği riskler, kaynak israfı vb.) nedeni ile tüm bunlara gerek duymadan istatistiksel çözümleme yöntemlerinden en uygununu kullanmak, karar vericilere yardımcı olacaktır. Sınıflama ya da kümeleme sorununun yaşandığı durumlarda 'Kohonen öz örgütlemeli haritalama yöntemi' ile sınıflama ya da kümeleme yapılması sınıflama ve kümeleme problemini çözecektir.

Tezin amacı; veri madenciliğinde, sınıflama ve kümeleme amacı ile kullanılan 'Kohonen öz örgütlemeli haritalama yöntemi'ni kuramsal olarak tanıtmak, bu yöntemin özelliklerini incelenmek, psikotik hastalıkların alt türlerinin ilgili yöntem ile sınıflamak ya da kümelemek, sağlık alanında sınıflama ya da kümeleme gereksinimi olduğu durumlarda bu yöntemin kullanılabilirliğini göstermektir. Tezin hipotezi, bu yöntem sonucunda elde edilen sınıflama/kümeleme performansının (doğruluk oranının vb.) diğer klasik yöntemlere göre daha yüksek olacaktır.

Bu tez 6 bölümden oluşmaktadır. Bölüm 2’de “Genel Bilgiler” başlığı altında, veri madenciliğinin tanımı, süreci, kullandığı teknikler, tıbbi veri madenciliğinden; kümeleme analizi, aşamaları ve kümeleme yöntemleri’nden, yapay sinir ağları’ndan, Kohonen öz örgütlemeli haritalama yöntemi yapısı, bileşenleri, adımları ve algoritmasından bahsedilecektir. Bölüm 3’te gereç ve yöntem, Bölüm 4’de bulgular, Bölüm 5’te tartışma, bölüm 6 sonuç ve öneriler yer alacaktır.

2. GENEL BİLGİLER

2.1. Veri Madenciliği

Veri madenciliği, büyük veri setlerinden kullanılabilir, bilinmeyen, önemli ve anlamlı bilgiler çıkarmak için kullanılan çeşitli yöntemlerden oluşmaktadır. Geniş, dağınık veri setinde veri elemanları arasındaki ilişkileri bulmak için makine öğrenmesi algoritmalarını kullanmaktadır (8-10).

Veri madenciliği, görülmeyen örüntüleri bularak verinin daha kapsamlı olarak anlaşılmasını sağlamakta ve kestirim yapan modeller oluşturmaktadır. Böylece organizasyonların geleceğe yönelik kararlar vermelerinde, strateji belirlemelerinde ve rekabet güçlerini arttırmada yardımcı olmaktadır (11-12-13).

Veri madenciliği başka bir tanımda, önceden bilinmeyen, ancak yarar sağlama olasılığı yüksek olan bilginin keşfedilmesi olarak ifade edilmiştir (14). Ayrıca veri madenciliği; anlamlı örüntülerin bulunması için geniş veri kümeleri üzerine keşfetmek amacıyla yapılan çözümlemeler olarak da tanımlanmaktadır (15).

Veri madenciliği, iş zekası teknolojisi olarak ortaya çıkmıştır. İş verisindeki ilişkilerin ve yeni olayların keşfedilmesini sağlamaktadır (8).

Veri madenciliği; bilgi endüstrisinde ve toplumda, büyük miktarda verileri çözümlediği ve verileri bilgiye dönüştürdüğü için önemli bir yere sahiptir. Elde edilen bu bilgi; pazar araştırmalarından, dolandırıcılığın belirlenmesinde, satın alma davranış ve eğilimlerinin kestirilmesine, üretim kontrolünden, bilimsel araştırmalara kadar pek çok alanda kullanılabilmektedir (16-17).

Veri madenciliği; geleneksel istatistiksel yöntemlerden farklı olarak hipotez içermez, varsayımlara dayanmaz ve veriyi test seti ile eğitim seti olarak ikiye ayırarak, test ile eğitim setini değerlendirmek için farklı yöntemler kullanılır. Veri madenciliği aynı zamanda makine öğrenmesi, istatistik, örüntü tanıma, sinir ağları, görselleştirme gibi pek çok metodu kullanan disiplinler arası bir alandır (1-18-19).

Veri madenciliğinin; geleneksel istatistiksel yöntemlerin kullanılmayacağı durumlarda kullanılarak, veride bilinmeyen örüntüleri ortaya çıkarma gibi

avantajlarının yanında dezavantajları da bulunmaktadır. Keşfedilen bilginin kalitesi ve sonuçların yanlış yorumlanma riski veri madenciliğinde önemli konular arasındadır. Veri madenciliğinde; yanıltıcı korelasyonların, fazla sayıda değişken kullanılmasından dolayı geçerli olmayan modellerin üretilmesi ve veri setindeki önemli bulguların saklanması gibi sorunlarla karşılaşabilmektedir (20).

Veri madenciliği; veri analizi yapmak (veriyi keşfetmek), verileri tanımlamak, veri tabanının özelliklerini, veri seçimi için koşulları belirlemek, veri madenciliği fonksiyonlarını gerçekleştirmek, veriler arasındaki ilişkilerin kullanıcının bilgisine/deneyimine göre incelenmek, gerekiyorsa değişkenlerin hiyerarşik olarak bölümlere ayırmak (örneğin; yaş değişkeninin 20-39; 40-59; 60-89 olarak bölümlere ayırmak), bulunan örüntülerin ölçülmek (kolaylık, kesinlik-güven, kullanılabilirlik, yenilik açısından incelemek) ve keşfedilen örüntülerin tablolar, raporlar, grafikler, karar ağaçları vb araçlarla görselleştirilmek gibi görevleri yerine getirmektedir (16-21).

2.1.1. Veri Madenciliği Süreci

Veri madenciliği süreci; veri seçme, veri dönüşümü veri madenciliği modellerinin oluşturulması ve sonuçların yorumlanması aşamalarından oluşmaktadır. Veri seçme ve veri dönüşümü aynı zamanda veri ön işleme olarak da adlandırılır ve verinin hazırlanma aşamasıdır. Veriyi anlamak açısından önemlidir. Bu süreçte; veri tanımlanır, eksik ya da aykırı veri olup olmadığı incelenir, gerekiyorsa eksik veriler silinir, birden fazla veri seti varsa veriler birleştirilir ve verilerin birimleri farklı ise dönüşüm işlemi yapılır. Veri madenciliği başka bir ifade ile “modelleme aşaması”; tanımlayıcı ve öngörücü modeller olmak üzere ikiye ayrılır. Tanımlayıcı veri madenciliği; verinin genel özelliklerini yansıtır. Öngörücü veri madenciliği, kestirim yapabilmek için var olan veri üzerinden çıkarım yapar (16). Öngörücü modeller; sınıflama ve regresyonu; tanımlayıcı modeller ise; kümeleme ve birliktelik kurallarından oluşmaktadır. Çalışmanın amacına göre ilgili modelleme yöntemi uygulanmaktadır. Veri analiz edildikten sonra sonuçların daha anlaşılır olması açısından; sonuçlar görselleştirilir ve değerlendirilir. Ayrıca bu aşamada, eğer birden

fazla yöntem kullanıldı ise kullanılan algoritmaların performansı doğruluk, duyarlık ve seçicilik açısından değerlendirilir (22-23-8-24).

Veri madenciliğinin özellikleri incelendiğinde;

- Veri madenciliğinin bütünü sadece bir parçası olduğu,
- Kullanılan verinin hem seçilecek olan veri madenciliği yöntemini hem de sonucun güvenilirliğini etkilediği, dolayısıyla seçilen verinin sonuçlar üzerinde etkili olduğu,
- Sürecin doğrusal olmadığı, çeşitli geri bildirimler içerdiği,
- Elde edilen sonuç, belirli bir geçerlilik ve güvenilirliğe sahip değilse adımların tekrarlanması, sürecin baştan başlaması gerektiği,
- Kullanılan adımlarda görselleştirmenin önemli bir rol oynadığı, özellikle analiz sonuçlarının değerlendirilmesinde histogram ve saçılım grafiği gibi istatistiksel görselleştirme araçlarının ya da veri madenciliği yöntemlerine özgü görselleştirme metotlarının kullanılabileceği sonucuna varılmıştır (8).

2.1.2. Veri Madenciliği Modelleri (Teknikleri)

Verideki desen yapısının bilinmediği durumlarda, farklı desen türlerini araştırma ihtiyacı gelişebilmektedir. Bu nedenle farklı uygulamalara uyum sağlayan veri madenciliği sistemlerine ihtiyaç duyulmaktadır. Veri madenciliği modelleri, farklı desenleri araştırmaya yardımcı olmaktadır (16).

Veri madenciliği modelleri; kullanım amacına ve verinin türüne göre tanımlayıcı veri madenciliği ve öngörücü (kestirici) veri madenciliği olmak üzere 2'ye ayrılmaktadır. Tanımlayıcı veri madenciliği; verinin genel yapısını, durumunu ortaya çıkarmaya yönelik yöntemleri kullanmaktadır. Öngörücü modellerde ise veriler geleceğe yönelik kestiriminde bulunmak amacıyla kullanılır. Bu modellerde; öncelikle model geliştirilir, daha sonra farklı bir veride bu model uygulanarak, modelin başarısı kontrol edilir ve yeni veriler bu model üzerinden tahmin edilmeye çalışılır (25).

Veri Madenciliğinin Kullandığı Teknikler:

Tanımlama ve Ayrımlama: Tanımlamada; sınıfların özellikleri tanımlanır. Bu tanımlama; hedef sınıf olarak adlandırılan sınıfın verilerinin özetlenmesi, özelliklerinin belirlenmesi, hedef sınıfın farklı bir sınıfla karşılaştırılarak ayrımının yapılması yani verinin hem tanımlanması hem de ayırıcı özelliklerinin belirlenmesi aracılığıyla gerçekleştirilmektedir (26).

Birliktelik Analizi: Birliktelik analizi veride sıklıkla gerçekleşen, birlikte alınma, yapılma ya da oluşma gibi durumları belirlemeye çalışmaktadır. Bu yöntem bankacılık işlemlerinde, süpermarketlerde pazar sepeti analizi yönteminde, tıbbi tanı konulmasında, ürün birleştirmede, müşteri ilişkileri yönetiminde sıklıkla kullanılmaktadır (27).

Sınıflama ve Öngörü (Kestirim) Yöntemi: Sınıflama, tanımlanan bir modelin bulunma sürecidir. Sınıflamadaki amaç, olayları ya da nesneleri anlayabilmektir. Oluşturulan model, eğitim setinin analizine dayalıdır. Mevcut veriler kullanılarak, belirlenen bir özelliğe göre sınıflandırma yapılır ve yeni verinin hangi sınıfa ait olduğu belirlenir. Başlıca sınıflama yöntemleri; karar ağaçları, sinir ağları, Naive Bayes sınıflandırma, destek vektör makineleri ve k-en yakın komşuluk yöntemleridir. Öngörü yöntemi de sınıflamaya benzetmekle birlikte, geleceğe ya da duruma yönelik tahminde bulunmaya yöneliktir. Örneğin başlıca öngörü yöntemlerinden birisi regresyon analizidir. Regresyon analizi sıklıkla sayısal verilerin tahmini için kullanılmaktadır (16).

Kümeleme Analizi: Sınıflamadan farklı olarak, değişkenlerin hangi özelliklere göre kümeleneceği bilinmemektedir. Kümeleme sonucunda sınıf etiketleri oluşturulur. Kümelemede amaç; kümeleme işleminin küme içinde benzerliğin en fazla, kümeler arasında benzerliğin en az olacak şekilde gerçekleştirilmesidir (13).

Aşırı Değer Analizi: Bir veritabanı veriye uymayan gözlemleri de içerebilmektedir. Bazı durumlarda, başka bir ifade ile istisna (verinin gerçek yapısından ayrılan) olan bu verilere ihtiyaç duyulmaktadır. Bazı veri madenciliği yöntemlerinin amacı da bu istisna verileri ortaya çıkarmaktır. Örneğin dolandırıcılığın belirlenmesinde bu yöntemlere ihtiyaç duyulmaktadır (25).

Eğilim Analizi: Gözlemlerin zamanla değişen eğilimleri incelenmektedir. Zaman serisini içeren bu yöntem; benzerlik temelli veri analizi yapmaktadır ve periyodik örüntü eşlemesini kullanmaktadır (16).

2.1.3. Tıbbi Veri

Tıbbi veri, en zor veri türlerinden biridir. Çünkü, bu veri türü tıbbi muayene, hasta ile görüşme, laboratuvar verileri, doktorun gözlem ve yorumu, görüntüleme gibi farklı kaynaklardan elde edilmektedir. Dolayısıyla; hacmi büyük ve heterojen bir veridir. Verinin heterojen olması, yüksek kapasiteli veri depolama araçlarını ve bu tür verileri analiz edecek yeni araçları gerektirmektedir. Eğer depolanan veri, uygun analiz yöntemleri ile anlaşılır hale getirilmezse, faydalı şekilde kullanılamayacaktır. (28).

Sağlık alanında farklı türde veriler bulunmaktadır. Nitel veriler, nicel veriler, MRI/ Radyoloji gibi görüntü verileri, echo gibi ultrason verileri, zaman serisi verileri, genetik, microarray ve protein verileri örnek olarak verilebilir. Verinin türüne göre de uygun veri madenciliği yöntemi seçilmektedir (22).

Hastanelerin bilgi sistemleri; depolanan, büyük miktarda verilerden oluşmaktadır. Verinin global olarak da hızla önem kazanması; ortak bir terminolojinin oluşturulmasını, farklı veri kaynaklarından alınan verinin standartlaştırılmasını, heterojen verinin birleştirilmesini ve elektronik hasta kayıtlarında standartlaştırmayı gerektirmektedir (29).

Hasta kayıtları; anemnez, klinik ve laboratuvar parametrelerin yanı sıra araştırma sonuçlarından elde edilmektedir. Ancak eksik ya da yanlış girilen veriler, nadir görülen hastalık kayıtları, uygun olmayan değişkenlerin seçimi, farklı zamanlarda yapılan ölçümler değerlendirme yapmayı zorlaştırdığından, veriler değerlendirilirken bu faktörlere dikkat edilmelidir (29).

2.1.4. Tıbbi Veri Madenciliği

Sağlık hizmetlerinde veri madenciliği; tanı, tedavi ve tedavi için verilecek kararların örüntülerini belirlemek, tıbbi dolandırıcılığı belirlemek ve önlemek, tıbbi aletlerin kötüye kullanımını belirlemek, sağlık hizmetleri kalitesini geliştirecek

stratejiler belirlemek için kullanılmaktadır. Ayrıca yüksek kaliteli bir sağlık hizmeti sunarken, maliyetleri de azaltmayı da amaçlamaktadır (30).

Tıbbi verinin toplanmasının bir diğer amacı; toplum sağlığını geliştirmektir. Veri madenciliğinin tıp alanındaki aktiviteleri; tarama tanısı, tedavi, prognoz, izleme ve yönetimdir. Bu görevler, herhangi bir semptom olmaksızın bir hastada bilinmeyen hastalığın bulunması ile başlar ve toplum sağlığı hizmetlerini geliştirmek için kaynakların daha iyi yönetilmesini sağlar (22).

Yüksek ölüm oranına sahip olan, salgın oranı yüksek olan, testleri pahalı olan hastalıklarda, veri madenciliği kullanımı daha yaygındır. Kalp hastalığında ölüm oranı daha yüksek olmasına rağmen, kanser üzerine yapılan çalışma sayısı daha fazladır. Bunun nedeni hasta sayısının ve global ilginin artmasıdır. Görüntüleme; kanser ve kalp hastalığı gibi yüksek riskli hastalıkların erken ve doğru tanının konulmasında yaygındır. Bu durum da, algoritmaların geliştirilmesine ve microarray veri gibi yeni teknolojilerin geliştirilmesine yol açmaktadır. Ayrıca onkolojide, kardiyolojide tanı ve klinik bakımda, sonuçların öngörülmesinde, prostat kanserinin tanısı, görüntülenme yöntemleri ve progresyonunda sinir ağları da kullanılmaktadır (22).

Veri madenciliğine dair yapılan bu açıklamaların arkasından, çalışmanın ana hedefi olan Kohonen öz örgütlemeli haritalama yönteminin aynı zamanda bir kümeleme yöntemi olması nedeniyle ana hatlarıyla kümeleme analizine aşağıda değinilmiştir. Kümeleme yönteminin açıklanması çalışmanın ilerleyen bölümlerinde klasik kümeleme yöntemleriyle, Kohonen yönteminin sonuçlarının karşılaştırılmasında yol gösterici olacaktır.

2.2. Kümeleme Analizi

Kümeleme analizi; grupları bilinmeyen gözlemleri ya da değişkenleri, sahip oldukları özelliklere göre benzer alt kümelere ayırma yöntemidir (31). Kümeleme, veri setinde küme yapısını ortaya çıkarır. Veri madenciliği açısından; verideki örüntüleri bulmak için kullanılan bir araç, istatistiksel açıdan ise verinin olasılıksal bir modele uygun hale gelmesini sağlayan bir yöntemdir (32).

Kümeleme analizi grupları kesin olarak bilinmeyen kişileri ya da değişkenleri; uzaklık fonksiyonlarını kullanarak, benzer kümelere bölmeyi sağlayan çok değişkenli bir istatistiksel analiz yöntemidir. Örneğin; kümelemenin psikiyatri alanında kullanımı ile hastalığın semptomlarına göre hastalar gruplara ayrılmakta böylece kişilerin hastalıklarının özelliklerine göre tedavi almaları sağlanmaktadır. Ya da pazarlama alanında farklı müşteri gruplarının belirlenmesinde kümeleme yönteminden yararlanılmaktadır (33-34-35).

Kümelemede her bir veri bir kümeye aittir. Amaç, benzer gözlemlerin ya da değişkenlerin aynı kümede yer almasını sağlayarak, küme içi benzerliğin fazla, kümeler arası benzerliğin mümkün olduğunca az olmasıdır. Küme içi ya da kümeler arası benzerliğin belirlenmesinde uzaklık hesapları kullanılmaktadır.

Kümeleme yönteminin gelişmesinde; veri sayısındaki hızlı artış ile birlikte verilerin daha anlaşılır hale getirilmesine ve özetlenmesine duyulan ihtiyaç etkili olmuştur (36).

Kümeleme çeşitli amaçlarla kullanılmaktadır. Bu amaçlar arasında; verinin yapısının belirlenmesi (veri hakkında fikir edinmek, hipotez üretmek vb) (37), bir verideki grupların tanımlanması, gözlemlerin ya da değişkenlerin kümelenmesi, boyut indirgeme, aykırı değerlerin belirlenmesi (31), değişkenlerin gözlemlerde saptanan değerlere göre ortak özellikleri açıkladığı düşünülen alt kümelere ayrılması ve gözlemlerin değişkenlerin özelliklerine göre sahip oldukları biyolojik veya tipolojik sınıflamayı ortaya çıkarması sayılabilir (38).

2.2.1. Kümeleme Analizinin Aşamaları

Kümeleme analizi; birkaç adımdan oluşmaktadır. İlk aşamada çalışmanın amacına göre; hangi değişkenlerin inceleneceği, kümeyi en iyi temsil eden özelliklerin ne olduğu belirlenir. Araştırılan konuya ilişkin, evrenden n sayıda birim ve p sayıda değişken seçilir, veri girişi yapılarak, veri matrisi oluşturulur (39). Ayrıca değişkenler belirlendikten sonra, değişkenlerin birbiri ile ilişkisinin olup olmadığı incelenir ve gerekirse benzer değişkenler veriden çıkarılır. Veri yapısı incelenerek, veride aşırı değerlerin olup olmadığına bakılır, veride standartlaştırma

yapılıp yapılmayacağına ve aşırı değer varsa veride kalmasının gerekli olup olmadığına karar verilir (31-40).

Verinin türüne göre kullanılacak “Benzerlik ya da Uzaklık Matrisleri” belirlenir. Benzerlik, iki değişken ya da iki birim arasındaki ilişkiyi; uzaklık ise farklılığı ifade etmektedir.

Kümeleme yöntemine karar verilir. Çalışmanın amacına ve küme sayısının bilinip bilinmemesine göre kümeleme yöntemlerinden biri seçilir ve kümeler oluşturulur.

Son aşamada ise, kümeleme sonuçları değerlendirilir. Farklı kümeleme yöntemleri kullanılarak, çıkan sonuçlar konunun uzmanları tarafından incelenebilir. Farklı uzaklık ölçüleri ve farklı kümeleme yöntemleri kümeleme sonuçlarını değiştirebileceğinden, konuya ilişkin kuramsal bilgi kullanılarak sonuçlar yorumlanmalıdır (31).

Kümeleme analizi sonuçları değerlendirilirken; en iyi kümeleme kriteri bulunmamasına rağmen, farklı kümeleme yöntemleri kullanılarak sonuçlar karşılaştırılabilir. Ayrıca sonuçlar değerlendirilirken; yanlış sınıflanan verilerin yüzdesi, kümeleme doğrulama/geçerlilik analizi, geçerlilik, istatistiksel metotlar ve hipotez testleri kullanılabilir (41).

2.2.2. Kümeleme Yöntemleri

Kümeleme analizinde çeşitli yöntemler kullanılmaktadır. Bu yöntemlerin amacı, kümeleri belirlemek ve kümelerin yapısını ortaya çıkarmaktır. Bu metotlardan hangisinin tercih edileceğine karar vermede;

1-Kümelerin şekli

2-Kümelerin birbirine benzerliği

3-Kümelerin büyüklüğü ve yoğunluğu

4-Gözlem sayısı etkili olmaktadır (42).

Kümeleme yöntemleri hiyerarşik kümeleme yöntemleri ve hiyerarşik olmayan kümeleme yöntemleri olmak üzere 2'ye ayrılmaktadır.

Hiyerarşik kümeleme yönteminde, gözlemler arasındaki uzaklık ölçüleri kullanılmaktadır. Başlangıçta bütün gözlemler ya da nesneler tek başına bir kümeyi temsil etmekte, daha sonra benzerlik ya da uzaklıklarına göre yakın olan gözlemler birleştirilmektedir (31-41). Hiyerarşik kümeleme yöntemi; veriler arasındaki bilinmeyen ilişkileri anlamak için kullanılabilir, ayrıca farklı büyüklükteki verilerin özetlenmesini de sağlamaktadır (43).

Hiyerarşik kümeleme algoritmaları, birleştirici ve ayırıcı kümeleme olmak üzere 2'ye ayrılmaktadır. Birleştirici metotlarda, her bir gözlem ya da birey ayrı bir kümeyi temsil etmekte ve benzerlik/uzaklık ölçümlerine göre gözlemler/bireyler birleşmektedir. Kümeleme, tüm gözlemler ya da kişiler tek grup olduğunda sona ermektedir. Optimum küme sayısına, tüm kümeleme sonuçları incelenerek karar verilmektedir (44-33). Hiyerarşik kümeleme yöntemleri; tek bağlantı yöntemi, tam bağlantı yöntemi, ortalama bağlantı yöntemi, ward yöntemi ve merkez yöntemidir (45).

Tek Bağlantı Yöntemi: Tek bağlantı yöntemi, en yakın uzaklığa sahip olan iki gözlemin bulunması ile başlar. Sonraki adımda, ilk iki gözlemin oluşturduğu kümeye en yakın gözlem bulunarak, ilk kümeye eklenir. Tek bir küme olana kadar, en büyük benzerliğe sahip her yeni gözlem var olan kümeye katılmaktadır. Bu yöntem en yakın komşuluk yöntemi denilmektedir (35).

Tam Bağlantı Yöntemi: İlk aşamada uzaklıklar matrisindeki en küçük uzaklık ile başlanır; ancak daha sonra kümeleme sürecinde oluşturulacak yeni iki küme arasındaki uzaklık olarak gözlemler arasındaki en büyük uzaklık kullanılmaktadır. Bu nedenle en uzak komşuluk yöntemi olarak da adlandırılır (31).

Ortalama Bağlantı Yöntemi: Ortalama bağlantı yöntemi, gözlemler arasındaki benzerliğin ortalamasına dayanmaktadır. Kümeleme kriteri, bir kümedeki tüm bireylerden elde edilen ortalama uzaklığın diğer kümedeki tüm bireylere olan ortalama uzaklığıdır (40).

Ward Yöntemi: En küçük varyans yöntemi olarak da bilinir. Bu metodun amacı, küme içindeki varyansı minimum yapmaktır. Bunun için hata kareler kriterini kullanır. Uzaklık ölçümünde Kare Öklid Uzaklığını kullanır (46).

Merkez Yöntemi: Aşırı değerlerden en az etkilenen aşamalı kümeleme yöntemidir. Ward yöntemi gibi bu yöntemde de genellikle kare Öklit uzaklığından yararlanılır (31).

Kümeleme analizinde pek çok hiyerarşik kümeleme yöntemi bulunmasına rağmen, bu yöntemlerden herhangi biri “en iyi yöntem” olarak adlandıramamakla birlikte, farklı kümeleme yöntemleri ya da farklı uzaklık fonksiyonları sonuçların farklı çıkmasına yol açmaktadır. Ayrıca, seçilen değişkenlerde sonuçlar üzerinde önemli bir etkiye sahiptir. Kümeleme analizi belirlenen değişkenin uygunluğuna karar verememekte dolayısıyla konuyla ilgili uzmanlık bilgisinin kümeleme analizinde önemli bir role sahip olduğu görülmektedir.

Ayırıcı algoritmalarda, tüm gözlemler ya da bireyler bir grup olarak başlar ve her gözlem ya da birey bir kümeye düşene veya istenen küme sayısına ulaşana kadar gruplara ayrılmaktadır (47).

Hiyerarşik olmayan kümeleme yöntemleri; gözlemleri, incelenen değişkenler açısından kendi içlerinde benzer ve kendi aralarında farklı kümelere ayırmayı sağlamaktadırlar. Bu yöntemlerde küme sayısı önceden belirlenmektedir. Hiyerarşik olmayan kümeleme yöntemleri; küme sayısının önceden belli olduğu ve veri setinin büyük olduğu durumlarda tercih edilmektedir (31).

K-ortalamlar, k-medoit, CLARA ve CLARANS gibi küme sayısını önceden belirleyen ve kümeleme sonuçlarını kaliteli hale getirmek için gözlemleri iteratif (yinelemeli) olarak yeniden düzenleyen hiyerarşik olmayan kümeleme algoritmaları bulunmaktadır. (43).

K-Ortalamlar Yöntemi: K-ortalamlar prototip temelli kümeleme yöntemlerinden biridir. Prototip temelli yöntemler veri nesnelerinin tek- seviye bölümlenmesini üretmekte ve prototipi küme merkezi (centroid) üzerinden tanımlamaktadır (44). K-

ortalamalar, küme ortalaması ile kümedeki her bir birim arasındaki karesel hatayı minimize eden bir algoritmadır. (48-37).

K-ortalamalar yönteminin adımları;

- “k” nesne için başlangıç noktaları seçmek,
- Her bir nesneyi en yakın olduğu merkeze atamak,
- Atanan her yeni nesne için ortalama değeri yeniden düzenlemek,
- 2. ve 3. adımları ortalamalar sabitlenene kadar tekrar etmektir (43).

Bu yöntemde; seçilen başlangıç noktası ve küme sayısı sonuçlar üzerinde etkili olmaktadır. Başlangıç noktası rasgele seçilebileceği gibi, farklı başlangıç noktaları denenerek de belirlenebilir. Küme sayısının belirlenmesinde de hiyerarşik kümeleme yöntemlerinden yararlanılabilmektedir (47-37-48).

Kohonen öz örgütlemeli haritalama yöntemi kümeleme analizi yaparken, yapay sinir ağlarını kullanmaktadır. Yöntemin yapay sinir ağlarını kullanmasının temel nedeni, insan beyninin çalışma şeklini taklit ederek girdiler arasındaki bilinmeyen ilişkileri ortaya çıkarmaktır. Bu bağlamda aşağıdaki bölümde yapay sinir ağlarından kısaca söz edilecektir.

2.3. Yapay Sinir Ağları

Bilgisayar teknolojilerinin gelişimi ile birlikte, bilgisayarlar günlük yaşamdan, iş yaşamına hayatımızda önemli bir yer tutmaktadır. Bilgisayarların gelişimi kısaca incelendiğinde, ilk olarak, 17. yüzyılda toplama ve çıkarma gibi sabit işlemler yapan makineler tasarlanmıştır. 1930-1940’larda “ilk dev elektronik beyinler” tasarlanmış ve yapılmıştır. 1943 yılında makinelerin düşünüp düşünemeyeceği sorusu ile Alan Turing tarafından yapay zekanın temelleri atılmıştır. Yapay zeka, bir makinenin insan gibi düşünüp, zeki davranışlar sergilemesini beklemektedir. Zekayı, durumlara uygun olarak esnek tepki vermek, belirsiz mesajlardan anlam çıkarmak, farklı durumların önemini ayırt etmek olarak düşünecek olursak; yapay zeka esnek olmayan makinelere esneklik kazandırmaya çalışan, bunu yaparken de uzun bir kurallar kümesini kullanan bir yöntemdir (49).

Yapay zeka; karar vermek, sorun çözmek, fikir yürütmek gibi çeşitli amaçlarla kullanılmaktadır.

Yapay zekanın kullandığı yöntemlerden birisi de yapay sinir ağlarıdır. Yapay sinir ağlarının çeşitli tanımları bulunmaktadır. Yapay sinir ağları; girdi ve çıktı arasındaki ilişkileri öğrenmeye dayanan matematiksel bir modeldir (50).

Yapay sinir hücresi, biyolojik sinir hücresini taklit etmektedir. Biyolojik sinir hücresinde olduğu gibi, yapay sinir hücresi de diğer hücrelerden aldığı sinyalleri toplar ve toplam sinyal belli bir eşiği aştığında, bu yapay sinir hücresi sinyalini bir başka sinir hücresine iletir (51).

Yapay sinir ağları; girdi katmanı, gizli katman ve çıktı katmanı olmak üzere 3 katmandan oluşmaktadır. Girdi tabakası, girdi nöronlarından oluşmaktadır. Girdiler, bu tabakadan, bir sonraki katmana, saklı katmana, iletilir. Çıktı katmanı da çıktıları dışarı ileten nöronlardır. Saklı katman; tek katmanlı ya da çok katmanlı olabilir. Çok katmanlı ağlar genellikle “çok katmanlı algılayıcı” olarak adlandırılır. Saklı katman diğer nöronlarla bağlantı halindedir (52).

Yapay sinir ağları öğrenmeyi gerçekleştirirken danışmanlı ve danışmansız olmak üzere 2 yöntem kullanmaktadır. Danışmanlı öğrenmede her bir girdiye hangi çıktının karşılık geldiği bellidir. Örneğin bir basketbol takımına seçilecek kişilerin (yaş, cinsiyet, kilo vb.) özellikleri ağı girilir ve “seçilebilir” “seçilemez” seçenekleri içeren 100 kişinin bilgileri eklenirse, ardından ağı girilecek 100 kişinin basketbol takımına seçilip seçilemeyeceği yapay sinir ağları tarafından belirlenebilmektedir. Danışmansız öğrenmede ise, girdilerin hangi çıktıya karşılık geldiği bilinmemektedir. Ağ herhangi bir girdiyi seçerek, diğer girdileri seçilen girdiye benzeyip benzememelerine göre sınıflamaktadır (53).

Yapay sinir ağları; sisteme girilen örnekleri kullanarak, genellemeler yapmakta ve daha önce görmediği örnekler ile karşılaştığında önceden öğrendiği bilgileri kullanarak, o örnekler hakkında karar verebilmektedir (54).

Yapay sinir ağları; başarılı hesaplamalar ve öngörüler yapabilmektedir (55).

Yapay sinir ağları; karar verme, sınıflama ve regresyon problemleri, kestirimde bulunma, olaylar arasındaki ilişkileri belirleme, ses ve yüz tanıma, bir sitemde ya da cihazda meydana gelebilecek arızaların tanımlanması, makro ekonomik tahminler,

tıbbi sinyallerin ve kanserli hücrelerin analizi, askeri uçakların uçuş yörüngelerinin belirlenmesi, banka kredilerinin değerlendirilmesi gibi amaçlarla kullanılmaktadır (56-50).

Yapay sinir ağları; Hebb net, algılayıcı (perceptron), geri yayılım (backpropagation net), Hopfield yapay sinir ağı modeli, Maren ve Kohonen öz örgütlemeli haritalama yöntemi gibi metotlar kullanılmaktadır.

Çalışmada Kohonen öz örgütlemeli haritalama yönteminin incelenmesinin nedeni; diğer modellerden daha yüksek doğruluk oranına sahip olup olmadığı araştırmaktır. Kohonen öz örgütlemeli haritalama yönteminin ana hatlarını oluşturan; veri madenciliği, kümeleme ve yapay sinir ağları kavramlarının açıklanmasının ardından, bir sonraki bölüm Kohonen öz örgütlemeli haritalama yöntemine ayrılmıştır.

2.4. Kohonen Öz Örgütlemeli Haritalama Yöntemi

Öz örgütlemeli haritalar; sinir ağlarının bir türüdür. Bu yöntem 1980'lerde Tuevo Kohonen tarafından geliştirilmiştir (57). Kohonen ağı; 1970'lerden itibaren sinir sisteminin biyolojik modellerine dayanan bir matematiksel özetleme yöntemine ve 1950'lere Morphogenesis modellerden dolayı Alan Turing'e dayanmaktadır (58).

Kohonen öz örgütlemeli haritalama yöntemi; temelde biyoloji ve matematiği kullanarak geliştirilmiştir (59). Bu yöntemde öğrenme işlevi, insan beyninin öğrenmesine benzemektedir. Beynin işlev görmesi hücreler arasındaki iletişim ile gerçekleşmektedir (60). Bu yöntemde de nöronlar arasında etkileşim bulunmaktadır. İnsan beyninde öğrenmenin gerçekleşebilmesi için nöronlar arası bağların kuvvetli olması gerekmektedir. Nöronlar arasındaki bağlar kuvvetlendikçe, tekrarlar arttıkça öğrenme o derece fazla olmakta ve hatta yeni bağlantılar oluşabilmektedir (60). Kullanılan yöntemde de, yineleme (iterasyon) sayısı fazla olmakta, yöntemin algoritması yineleme sayısı kadar tekrarlanarak öğrenme gerçekleşmekte ve yeni bir girdi ile karşılaşıldığında girdi, kendisine en çok benzeyen küme ya da sınıfa atanmaktadır.

Kohonen öz örgütlemeli haritalama yönteminde öğrenmenin amacı; ağıın belirli girdilere benzer yanıtlar vermek için çeşitli bölümlere ayrılmasıdır. Bu işlevi, insan

beyninin çalışma yöntemini taklit ederek yapmaktadır. İnsan beyinde görsel, işitsel veya diğer duyuşal bilgilerin işlendiđi bölgelerin serebral korteksin farklı bölümlerinde yer alması gibi Kohonen öz örgütlemeli haritalama yönteminde de girdinin özelliklerine göre ağ çeşitli kümelere ayrılmaktadır.

Öz örgütlemeli haritalama yöntemi, verideki benzer örüntüleri ortaya çıkaran bir yöntemdir. Öğrenmeyi, danışmansız öğrenme ile gerçekleştirir. Yani öğrenmeyi kendi kendine gerçekleştiren, ileri beslemeli bir yapay sinir ağıdır. İlgili konuyu öğrenirken, danışmana ihtiyaç duymaması en temel özelliklerinden biridir. Aynı zamanda yarışmacı bir öğrenme yöntemi kullanmaktadır. Yarışmacı öğrenmede, nöron aktivitesi, nöron ağırlığı ile girdi verisi arasındaki uzaklığın bir fonksiyonudur. Yarışmacı öğrenme algoritmasında çıkış nöronları aktive edilmek için birbirleri ile yarışır. Rasgele seçilen bir girdi, tüm nöronlarla karşılaştırılır ve en yakın uzaklığa sahip olan nöron bulunduğunda, yarışmacı öğrenme gerçekleşmiş olur ve en yakın uzaklığa sahip olan nöron “kazanan nöron” olarak adlandırılır. Bu yöntemde, kazanan nöron ve komşuları güncellenir. Sadece kazanan çıkış nöronu ve komşularının güncellendiğı bu süreç, bir yapay optimizasyon tekniğı olarak düşünülmektedir (58,61-64).

Öz örgütlemeli haritalama yönteminin yarışmacı öğrenme yöntemini kullanması ile diğer yapay sinir ağlarından farklılık göstermektedir ve girdilerin topolojik özelliklerini koruyarak komşuluk fonksiyonunu kullanmaktadır (58).

Büyük öz örgütlemeli haritalar, verinin özelliklerine göre oluşur. Kümeleme yapabilmektedir (58).

Kohonen öz örgütlemeli haritalama yöntemi, girdileri ağırlıklandırarak haritalamaya çalışır. Girdi verilerinin özelliklerini koruma ilkesi, öz örgütlemeli haritaların ana ilkesidir (57).

Nöronlar genellikle iki boyutlu ızgara yapısındadır ve haritalama ile yüksek boyutlu veriler bir düzlemde gösterilmektedir. Topolojik saklama özelliğı öz örgütlemeli haritalama yönteminin girdi vektörlerini benzer özellikte olmalarına göre gruplandırıdığı anlamına gelmektedir. Girdi uzayındaki birbirine yakın noktalar Kohonen öz örgütlemeli haritalama yöntemi içinde birbirine yakın olacak şekilde

haritalandırılır. Yani haritadaki grupların yerleşiminde, birbirine mekânsal olarak yakın gruplar (ya da kümeler) uzak olan gruplara göre birbirlerine daha çok benzemektedir (61, 65-69). Öz örgütlemeli haritalama yöntemi bu özelliği ile hem kümeleme yapmakta hem de birbirine yakın kümeleri görsel olarak sunmaktadır. Sonuçları görsel olarak sunması, kolay anlaşılabilen bir yöntem olmasını sağlamaktadır.

Öz örgütlemeli haritaların bir diğer özelliği, vektör sayısallaştırma değildir. Vektör sayısallaştırma veri sıkıştırma amacı ile kullanılır. Öz örgütlemeli haritalar, çok boyutlu verileri düşük boyutlu bir alanda sunmaktadır. Bu tür bir görselleştirme, yöntemin daha anlaşılır olmasını sağlamaktadır. Veriler sıkılaştırırken verilerin topolojik ilişkileri de korunmaktadır. Vektör sayısallaştırma ile aynı zamanda kümeler tanımlanmakta, harita düzenlenmekte ve girdinin dağılımı tanımlanmaktadır (57-70-63).

Öz örgütlemeli haritalama yöntemi genelleme yeteneğine sahiptir. Bu; ağın daha önce karşılaşmadığı girdileri tanımlayabilmesi veya kategorize edebilmesi anlamına gelmektedir. Yeni girdi haritada en çok benzediği gruba dahil edilmektedir. Ayrıca, haritanın eğitilmesine bağlı olarak, eksik veriler de öngörülebilmektedir (71).

Öz örgütlemeli haritaların az sayıda düğümden oluştuğunda k-ortalamlar yöntemine benzediği, ancak daha büyük sayıda düğüme sahip öz örgütlemeli haritaların veriyi topolojik olarak yeniden düzenlediği gösterilmiştir (58).

2.4.1. Kohonen Öz Örgütlemeli Haritalama Yönteminin Tanımı

Kendini düzenleyen harita (Self Organizing Map/SOM) ya da kendini düzenleyen özellik haritası (SOFM), düşük boyutlu veri üretmek amacıyla danışmansız öğrenme yöntemini kullanan bir yapay sinir ağı türüdür. Eğitim verisini kullanarak girdi uzayını daha anlaşılır bir şekilde sunmaktadır ve boyut azaltmayı sağlayan bir metottur (58).

Kohonen öz örgütlemeli haritalama yöntemi (Self Organizing Maps); özellik haritası, kendini örgütleyen eşleme, Kohonen ağı, öz düzenlemeli ağ yapısı, öz örgütlemeli harita ağı, kendi düzenlenen haritalar veya öz düzenleyici haritalar olarak da adlandırılmaktadır.

Öz örgütlemeli haritalama yöntemi, yapay sinir ağlarına dayanan matematiksel bir modeldir. Öğrenmeyi, insan beynini taklit ederek gerçekleştirmektedir. Girdiler matematiksel hesaplamalar sonucu, korteks görevini yapan bir bölgede toplanmakta, “kazanan sinir hücresi” de yine matematiksel hesaplamalarla belirlenmektedir (69, 72).

Öz örgütlemeli haritalama algoritması özel bir tekrarlamalı regresyon süreci olarak tanımlanabilir (70).

Öz örgütlemeli haritalama yöntemi; boyut azaltma, veri görselleştirme, kümeleme ve sınıflama amaçlarıyla kullanılabilmektedir (64).

Öz örgütlemeli haritalama yöntemi; çok boyutlu verileri iki boyutlu verilere indirgeyen, topolojik sıralı bir dönüşüm sağlayan, doğrusal olmayan bir uygulamadır. Bu özelliği ile örüntüsü ya da yapısı bilinmeyen veride, girdi ve çıktı arasındaki ilişkileri belirlemeye çalışmaktadır (64, 67, 73, 74).

Büyük verilerde, verinin dağılımının bilinmemesi ve verinin parametrik varsayımları karşılamamasından dolayı non-parametrik regresyon kullanılabilmektedir. Öz örgütlemeli haritalama yöntemi de, yapay sinir ağlarının, doğrusal olmayan regresyon yöntemlerini kullanan bir türüdür. Bu yöntem, doğrusal olmayan regresyon yöntemlerini kullanarak, girdi ve çıktı değişkenleri arasındaki ilişkileri bulmaktadır (70, 73).

Öz örgütlemeli harita, nöronlar ya da düğümler olarak adlandırılan bileşenlerin toplamıdır. Her bir düğümle ilişkili olarak; girdi verisi vektörleri ile aynı boyutta bir ağırlık vektörü ve harita alanındaki bir konum vardır. Düğümler genellikle altıgen ya da dörtgen ızgara (grid) şeklindedirler. Öz örgütlemeli haritalar; yüksek boyutlu girdileri, düşük boyutlu haritaya indirgeyen haritalardır (58).

Ağın başlıca 2 tür öğrenme yöntemi bulunmaktadır. İlki danışmanlı öğrenme metodudur. Bu yöntemde her bir girdi için hedef çıktı bellidir. Ağ, öğrenme sırasında ve öğrenmeden sonra hedef çıktıları kullanarak uygun çıktıları nasıl üreteceğini öğrenir. İkinci metot, danışmansız öğrenmedir. Ağ, herhangi bir yardım almadan hedef çıktıyı kendisi bulmaktadır. Bunu başarmanın yolu, ortak özellikleri bulunan

girdi verilerini sınıf üyesi olarak tanımlamak ve ağ tarafından girdi örüntülerinin ortaya çıkartılmasını sağlamaktır. Danışmansız sistemin sınıflaması yarışmacı öğrenmeye dayalıdır. Yarışmacı öğrenmede çıktı nöronları aktif hale gelmek için birbirleri ile yarışır. Sonuçta yalnızca bir tanesi etkinleşir (aktif hale gelir). Aktif hale gelen nöron, “kazanan hepsini alır nöron” ya da “kazanan nöron” olarak adlandırılır. Böyle bir yarış, nöronlar arasındaki engelleme bağlantıları nedeniyle ortaya çıkabilir. Bu sürecin sonucunda, nöronlar kendi kendilerine organize olur ve ağın bu türüne “öz örgütlemeli haritalama yöntemi” denir (64).


Öz örgütlemeli haritalama yöntemi, sonuçları görsel olarak sunarken, girdilerin konumlarını ve birbirleri ile yakınlıklarını da korumaktadır. Bunun nedeni nörobiyolojik çalışmalara dayanmasıdır. Nörobiyolojik araştırmalar; çeşitli görsel girdilerin (görsel, işitsel, motor vb), organize bir şekilde serebral korteksin uygun bölümlerinde haritalandığını göstermiştir. Öz örgütlemeli haritalama yönteminde yapay topografik haritalama oluşturmanın amacı; nörobiyolojik yapıyı taklit ederek kendi kendine organize olan, topografik haritaları oluşturmaktır (64).

Veri madenciliğinde Kohonen map’in kullanılmasının nedenleri;

- Sembolik bir yöntem yerine sayısal bir yöntem olması
- Parametrik olmayan bir yöntem olması,
- Verinin dağılımı konusunda herhangi bir bilgi olmadığı durumda kullanılabilmesi,
- Bilinmeyen yapıları belirleyebilmesi ve bunu yaparken danışmansız (unsupervised) bir öğrenme yöntemi ile gerçekleştirebilmesidir (73).

2.4.2. Kohonen Öz Örgütlemeli Haritalama Yönteminin Yapısı

Öz örgütlemeli haritalama yöntemi iki katmanlı bir yapıya sahiptir. İlk katman girdi katmanıdır. Girdi vektöründeki her bir elemanı içermektedir. İkinci katman ise çıktı katmanıdır. Çıktı katmanı, harita düğümlerinden oluşmaktadır. Her bir harita düğümü her bir girdi düğümüne bağlıdır. Örneğin; Şekil 2.1’de; 4*4 node (düğüm) ağı ve $4*4*3=48$ bağlantı görülmektedir. Çıktı tabakasındaki işlem sayısı; haritanın başlangıç şekli ve büyüklüğüne bağlı olarak, kullanıcı tarafından belirlenmektedir. Öz örgütlemeli haritalama yönteminin, yapay sinir ağlarından farklı olarak, saklı bir katmanı bulunmamaktadır (57, 67, 69, 73, 75).



Şekil 2. 1. Kohonen Öz Örgütlemeli Haritalama Yönteminin Yapısı

Öz örgütlemeli haritalama yönteminde harita düğümlerinin birbiri ile ilişkisi bulunmamaktadır. Her bir harita düğümü farklı bir koordinattadır. Her bir harita düğümü farklı bir kümeyi temsil etmektedir. Düğümler 2 boyutlu bir yapıda sunulduğundan, sonuçları görselleştirmek kolaydır. Böylece; ağda herhangi bir çıktı kümesini temsil eden bir düğümü referans vermek kolaydır ve düğümler arasındaki uzaklıklar hesaplanabilir (57).

Öz örgütlemeli haritalama yönteminin bir diğer özelliği zeki eğriler oluşturulmasıdır. Verilerin çok boyutlu olması, doğrusal olmaması, eğri çizildiğinde tüm vektörleri ya da düğümleri içine almaması nedeniyle; veri yapısına uygun olarak, tüm veri noktalarını içine alan, eğriler oluşturulmaktadır. Eğri böylece bütün verileri kapsamaktadır. Bu eğrilere de “zeki eğriler” denilmektedir (73).

Öz örgütlemeli haritalama yönteminde “elastik bir ağ” bulunmaktadır. Düğümler bu elastik ağ içerisine yerleştirilmiştir. Veriyi sürekli fonksiyona benzetmek için, referans vektörler (düğümler) aracılığı ile “elastik ağ”ın düğümleri tanımlanarak, haritanın topolojik yerleşimi sağlanır. Her bir düğüm (node), referans vektörler tarafından temsil edilmektedir. Referans vektörler bir sıra halinde dizilirler ve birbirleri ile etkileşim halindedirler. Bu durum, ağın elastik yapısını yansıtmaktadır. Ayrıca ağın esnek yapısı sayesinde, düğümler arasındaki ilişkiler tanımlanabilmektedir. Öz örgütlemeli haritalama yöntemi aynı zamanda yapay bir sinir ağıdır. Sinir ağları açısından düşünüldüğünde, bu etkileşim nöronlar arasında olmaktadır (70).

Regresyonda bazı matematiksel fonksiyonlar, girdi değerlerinin dağılımına uygun konuma getirilmektedir. Regresyon yöntemleri temel olarak; en küçük kareler yöntemi ve toplam kareler yöntemi olarak ikiye ayrılmaktadır. Öz örgütlemeli haritalama yöntemi daha çok toplam en küçük kareler yöntemine benzemektedir (70, 73).

Öz örgütlemeli haritalama yönteminin iki önemli özelliği bulunmaktadır. Bunlardan biri, topolojik bir harita oluşturulurken regresyonu kullanması, diğeri bazı nöronların, girdi uzayında kendi sinyal alanlarının dedektörlerine ya da dekodeerlerine dönüşmesidir. Bu dekodeerler ağ üzerinde, ağın özelliklerini bilmeksizin, bu özellikleri kendisi belirleyerek, sıra ile oluşurlar. Bu süreç sonunda öz örgütlemeli haritalama algoritması uygulanmaktadır (70).

Öz örgütlemeli haritalama yönteminin yapısal özelliklerinden birisi de komşuluk kavramıdır. Komşuluk fonksiyonu nöronların diğer nöronlarla ne kadar sağlam bağlandığını göstermektedir. Kabarcık komşuluk fonksiyonu, Gauss komşuluk fonksiyonu gibi çeşitli komşuluk fonksiyonları bulunmaktadır (70). Öz örgütlemeli

haritalama algoritması komşuların yerlerinde değişiklik olmadığında sona ermektedir (63, 67).

2.4.3. Kohonen Öz Örgütlemeli Haritalama Yönteminin Bileşenleri

Öz örgütlemeli haritalama yöntemi; başlıca 4 parçadan oluşmaktadır. Bunlar: başlangıç, yarış, işbirliği ve adaptasyon'dur. *Başlangıç* olarak bağlantıları ağırlıklandırmak için küçük rasgele sayılar seçilir. Yarış bileşeninde; her bir girdi verisi için nöronların değeri hesaplanır, en yakın uzaklığa sahip olan nöron kazanan olarak adlandırılır. Yarış bileşeninde; yarışmayı kazanan nöron, haritadaki yerini alır. Her bir komşu nöronun birbiri ile ilişkisi vardır ve bu ilişki komşu nöronlar arasında ilişki/dayanışma olarak değerlendirilir. Bu çıkarımın temeli nörobiyolojik çalışmalara dayanmaktadır. Nörobiyolojik çalışmalara göre; etkilenen nöronlarda yanal etkileşimler keşfedilmiştir. Adaptasyon bileşeninde ise; bir nöronun diğer nöronlarla yarışı sonucunda “kazanan nöron” olarak adlandırıldığında hem kendisinin hem komşularının ağırlıklarının güncellenmesi, adaptasyon süreci olarak adlandırılmaktadır. Kazanan nöronun etrafındaki nöronlar, kazanan nörona benzemeye başlar, bu durum da adaptasyonun bir şeklidir (64).

2.4.4. Kohonen Öz Örgütlemeli Haritalama Yönteminin Adımları

Kohonen öz örgütlemeli haritalama yöntemi çeşitli aşamalardan oluşmaktadır. Bu yöntemin ilk aşamaları; veri madenciliğinin aşamalarına benzemektedir. Amacın belirlenmesi, verinin uygun hale getirilmesi gibi aşamalardan sonra öz örgütlemeli haritalama yönteminin algoritmasına geçilmektedir. Bu yöntem aşağıdaki aşamalardan oluşmaktadır:

1-Amacın Belirlenmesi

Amaçların belirlenmesi; doğru yöntemin kullanılması ve sonuçların doğru yorumlanması açısından önemlidir. Örneğin; öz örgütlemeli haritalama yöntemi; sınıflama, kümeleme, veri azaltma, veri görselleştirme, hipotez testi, karar destek (decision-support), öngörü gibi çeşitli uygulamalara sahiptir. Belirlenen amaca göre uygun yöntem seçilir. Yine amaca bağlı olarak, öz örgütlemeli haritalama yönteminin yanında başka yöntemler de kullanılabilir.

2-Verinin Kaynağını Belirlemek ve Yüksek Kaliteli Veri Seçmek

Verinin kaliteli olması; genel durumu yansıtması, sonuçların genellenebilirliği açısından önemlidir. Örneğin internetten alınan her bilgi doğru olmayabilir. Bu nedenle kaynakların güvenilirliği iyi araştırılmalıdır. Bazen veriler birkaç farklı kaynaktan da bulunabilir.

3-Verinin Kapsamının Belirlenmesi ve Değişkenlerin Seçimi

Verinin kapsamı ve değişkenlerin seçimi amaca göre belirlenmektedir. Amaca uygun verilerin seçilmesi, doğru sonuçların alınması açısından önemli olduğundan, gerekirse uzman görüşü alınmalıdır. Veriler seçilirken, uygun göstergelerin belirlenmesine özen gösterilmelidir. Verinin kapsamı belirlendikten sonra veri seçerken; sonuç üzerinde en çok etkili verilerin seçilmesine ve amaçla ilişkili verilerin seçilmesine dikkat edilmelidir. Hem ilişkisiz verilerin hem de konu ile ilgili olduğu halde kullanılmayan verilerin sonuçları önemli derecede etkileyeceği unutulmamalıdır.

4-Değişkenlere Ön İşlem Uygulanması

Veri analizinde, değişkenlere ön işlem uygulanması özellikle sinir ağlarında önemli bir yere sahiptir. Bu aşamada; veriler standartlaştırılabilir, dönüşüm uygulanabilir veya öncelikli veriler seçilebilir. Eğer veriler farklı ölçüm birimlerine sahipse standartlaştırma işlemi yapılmaktadır. Bu işlem; standart sapma ya da aralık temel alınarak yapılabilir. Veri dönüşümünde ise logaritmik dönüşüm ya da sigmoid dönüşüm uygulanabilir. Öncelikli verinin seçilmesinde de; ya bir değişkene öncelik verilerek o değişken ağırlıklandırılır ve haritalama sürecinde o değişkene öncelik verilir, ya da bir değişkenin daha az etkili olduğu düşünülüyorsa, o değişkene daha düşük bir ağırlık verilerek haritalama işlemi devam ettirilir.

5-Sistemi Temsil Edecek Örnek Verinin Kullanımı

Sinir ağlarında eğitim setinin kullanılması; “uygun” bir prototip girdi vektörünün seçilmesi haritalamanın sonucu üzerinde etkilidir. Aykırı değerlerin belirlenmesi ve bu aykırı değerlerin veriyi temsil edici nitelikte olup olmadığının belirlenmesi, öz örgütlemeli haritalama yönteminin sonucu üzerinde etkilidir. Çünkü girdi değişkenlerinde aykırı değerlerin bulunmasından etkilenmektedir.

Öz örgütlemeli haritalama yönteminde iki aşamalı eğitim önerilmektedir. Birinci eğitim döngüsünde, girdi verisinin kabaca yapısı incelenir. İkinci aşama da girdiler arasındaki ufak farklar anlaşılmasına çalışılır. Öğrenme aşamaları gerçekleştirilirken; farklı öğrenme oranları ve komşuluk büyüklükleri (neighborhood size) kullanılarak da sonuçlar karşılaştırılabilir.

6-Kümeleme ve Görselleştirme Yöntemlerinin Seçimi

Öz örgütlemeli haritalama yöntemi tek başına kullanılabileceği gibi, başka yöntemlerle (örneğin; genetik algoritmalar) birlikte de kullanılabilir. Öz örgütlemeli haritalama yönteminde temsil edilen kümelerin ana özelliklerinin ne olduğu, karar vermede ya da tahmin yürütmede yeni bulunan örüntülerin nasıl kullanılacağı açıklanmalıdır. Yani öz örgütlemeli haritalama yönteminin süreç sonrası aşaması da önemli bir yere sahiptir.

7- Görüntü Büyüklüğü, Harita Oranı ve Gerekli Ayrıntı Derecesinin Belirlenmesi

Harita büyüdükçe ayrıntısı artar, girdi vektörleri daha büyük düğümlere yayılır. Harita küçüldükçe, daha büyük kümeler içerebilir veya daha fazla girdi vektörü daha küçük düğümlere yerleşebilir. Haritanın kullanım amacına bağlı olarak, haritanın büyüklüğüne karar verilir. Düğümlerin daha küçük sayıda olması, daha yüksek genelleme özelliğine sahip olduğunu gösterir. Eğer veri gürültülü veriye sahipse, düğümlerin küçük sayıda olması daha kullanışlı olabilir.

8-Optimal (En Uygun) Kümeleme ve Görselleştirme İçin Haritanın Ayarlanması

Öz örgütlemeli haritalama algoritması çalıştıktan sonra; düğümlerin sayısı, düğümlerin ortalama değerleri ve küme sayısı incelenebilir. Küme eşiği ya da küme büyüklüğü artırılarak ya da azaltılarak, elde edilen sonuçlar değerlendirilebilir. Daha büyük bir eşik değeri küme sayısını azaltacak; daha küçük bir eşik değeri kümeyi daha ayrıntılı gösterecektir.

9-Sonuçların Yorumlanması, Kümelerin ve Düğüm Değerlerinin Kontrol Edilmesi

Harita oluşturulduktan sonra, haritanın geçerliliği kontrol edilir. Uzman görüşüne başvurulabilir, her bir kümenin tanımlayıcı istatistikleri incelenebilir, kümelerin ortalama değerleri gösterilebilir, kümelerin istenen büyüklükte olup olmadığı, veri dönüşümünün ya da daha fazla önem verilen bazı verilerin daha fazla ağırlıklandırılmasının gerekip gerekmediği incelenebilir. Bu aşamada hem uzman görüşünden yararlanılır hem de veriler ayrıntılı olarak incelenir.

10- Harita Etiketlerinin Tanımlanması

Araştırmanın amacına ve girdilerin özelliklerine göre; girdi vektörleri ve kümeler isimlendirilir.

11-Kümeler Arası Farkları Gösteren Sonuçların Özetlenmesi

Öz örgütlemeli haritalama yöntemi sonuçlandıktan sonra, sonuçların nasıl kullanılacağı önemlidir. Bu aşamada; her kümenin tanımlayıcı istatistikleri, girdi vektörlerinin toplamı, en küçük ve en büyük değerleri incelenir.

12-Sonuçların Değerlendirilmesi

Öz örgütlemeli haritalama yönteminde çıkan sonuçlar, performans ölçüleri ile değerlendirilir. Ayrıca farklı yöntemler uygulandığında, elde edilen sonuçlar da karşılaştırılabilir, küme sayısı, kümeler arasındaki farklılık derecesi incelenebilir. Küme sayısının değişmemesi de (kararlılığı) sonuçların güvenilir olduğunu göstermektedir (67).

2.4.5. Kohonen Öz Örgütlemeli Haritalama Yönteminin Algoritması

Öz örgütlemeli haritalama algoritması başlıca 6 adımdan oluşur.

- Her bir düğüme rasgele bir ağırlık değeri atanır.
- Eğitim setinden rasgele bir vektör seçilerek, ağa girişi yapılır.
- Ağıdaki her bir düğüm, ağırlıkları girdi vektörüne en çok benzeyecek şekilde hesaplanmak üzere incelenir. Kazanan düğüm, en iyi eşleşen düğüm (Best Matching Unit (BMU)) olarak adlandırılır (Eşitlik 2.1).
- En iyi eşleşen düğümün (BMU) komşuluğunun yarıçapı hesaplanır. Bu değer başlangıçta büyük alınır (Genellikle ağın yarıçapı olarak alınır). Bu değer ağın yarıçapı olarak belirlenir ve her bir adımda azalır (Eşitlik 2.2a, Eşitlik 2.2b).
- BMU'nun yarıçapı içinde bulunan her bir düğüm, girdi vektörüne daha çok benzetilmek için düzenlenir (Eşitlik 2.3a, Eşitlik 2.3b). BMU'ya yakın olan düğümlerin ağırlıkları değiştirilir (Eşitlik 2.3c).
- Bu işlemler, algoritmanın 2. adımından itibaren, yineleme sayısı kadar tekrarlanır (57).

$$(Girdiden\ uzaklık)^2 = \sum_{i=0}^n (I_i - W_i) \quad (2.1.)$$

i=Girdi Vektörü

W=Düğümün Ağırlık Vektörü

n=Ağırlıkların sayısı

$$\sigma(t) = \sigma_0 e^{(-\frac{t}{\lambda})} \quad (2.2a.)$$

t=Yinelemenin sırası

λ = Zaman sabiti (Eşitlik 2b)

σ_0 =Harita yarıçapı

$$\lambda \text{ (Zaman Sabiti)} = \text{Toplam Yineleme sayısı} / \text{Harita Yarıçapı} \quad (2.2b.)$$

$$W(t+1)=W(t)+ \Theta(t) L(t) (I(t) - W(t)) \quad (2.3a.)$$

$$L(t)= L_0 e^{(-\frac{t}{\lambda})} \quad (2.3b.)$$

$$\Theta(t)= e^{((en iyi eşleşen düğümden uzaklık)^2 / (2\sigma^2 (t)))} \quad (2.3c.)$$

Öz örgütlemeli haritalama yönteminde bazı değerler araştırmacı tarafından belirlenmektedir. Bu değerlerden birisi de öğrenme oranıdır. Öğrenme oranı, 0 ile 1 arasında değişen bir değerdir. Süreç esnasında araştırmacı tarafından belirlenir. Öğrenme oranı başlangıçta büyük bir değer alınıp, daha sonra küçültülebilir. Örneğin; çalışmanın başında 0.9 gibi büyük bir değer alabilir. Ancak kümelerin sıralanma aşamasından sonra, bu değer 0.2 olabilir. Bu değerın etkili seçilmesinde deneyim önemlidir (57, 70, 71).

Komşuluk fonksiyonu; BMU (nöron u) ile başka bir nöron arasındaki uzaklığa bağlıdır. En basit şekli ile, BMU'ya yeterince yakın olan nöronlar 1'e, diğer nöronlar 0'a eşittir. Genellikle Gaussian komşuluk fonksiyonu tercih edilmektedir. Fonksiyonel formdan farklı olarak, komşuluk fonksiyonu zamanla azalmaktadır. Komşuluğun büyüklüğü de araştırmacı tarafından seçilmektedir. Bu değerın çok küçük olmaması önerilmektedir. Eğer küçük bir değer verilirse, harita oluşmayacaktır. Ancak bu değerın çok büyük olmasından da kaçınılmalıdır. Bu seferde süreç, uzun zaman alacaktır (58, 63,71.).

Öz örgütlemeli haritalama algoritmasının kaç kez tekrarlanacağı da sonucu etkileyen önemli bir faktördür. İstatistiksel olarak doğru bir sonuca ulaşmak için, tekrar sayısının ağ sayısının en az 500 katı olması gerekmektedir (70). Öz örgütlemeli haritalama yönteminin başarılı sonuç vermesinde önemli diğer parametreler; komşuluk, öğrenme oranı ve ağırlık vektörünün başlangıç değeridir (74).

Girdi değişkeninin normalleştirilmesi önerilmektedir. Girdinin normalleştirilmesi genel bir ilke olmamasına rağmen, sonucun doğruluğunu arttırdığı düşünülmektedir. Çünkü referans vektör, aynı aralıkta sonuçlar üretmeye eğilimlidir (70).

Kohonen yönteminin ana bileşenlerini açıkladıktan sonra çalışmanın uygulama aşamasına geçmeden önce, kullanılan veri setinin psikotik hastalıkları içermesi nedeniyle ruh sağlığı ve bozukluklarının tanımı ve sınıflandırılmasına değinilmiştir.

2.5. Ruh Sağlığı ve Bozukluğunun Tanımlanması

Ruhsal bozukluk; kişinin düşünce, algı, eylem ve duyularını yansıtan özelliklerin birleşimi olarak tanımlanabileceği gibi duygusal, davranışsal ve sosyal olarak normallik olarak da tanımlanabilmektedir (76). Klinik olarak ruh sağlığı normal bireyleri tanımlamak için; çevreye uyum sağlayabilme, bireyde aşırı bunaltının ya da başka psikiyatrik belirtinin olmaması, id-ego-süper ego arasındaki dengenin sağlanması gibi kriterler getirilmiştir (77).

Ruh sağlığı; çocukluktan yetişkinliğe hayatın her aşamasında önemli bir yer tutmaktadır. Ruh sağlığı; kişilerin nasıl hissettiği, düşündüğü ve davrandığı ile ilgili bir kavramdır (76).

Ruh sağlığı; kişiler arası ilişkilerde, okul ve iş gibi aktivitelerde, değişime uyum sağlama ve sorunlarla başa çıkabilmede etkili davranmayı sağlamaktadır. Ruh sağlığı bozukluğu, tüm ruhsal rahatsızlıkları içermektedir. Davranış, duygu ve düşüncede değişiklik; aile, iş ve sosyal aktivite de sorunlar ile kendini göstermektedir. Ruh sağlığı; ilişkiler, kişisel ve duygusal iyilik hali ve topluma katkıda bulunmada etkilidir (78).

2.5.1. Ruh Sağlığı ve Bozukluklarının Sınıflandırılması

Hastalıkları iyileştirme ve tedavi yöntemleri geliştirebilmek için; hastalıkların tanımlayıcı özelliklerinin belirlenmesi ve sınıflandırılmasının yapılması gerekmektedir. Hastalıkların sınıflandırılmasının yapılması aynı zamanda hastalıkların sıklık ve yaygınlıklarını belirlemek, hastalıkları daha ayrıntılı incelemek açısından da önemlidir (77).

Psikiyatrik hastalıkların sınıflandırılmasında; Dünya Sağlık Örgütü tarafından geliştirilen ICD sürümleri ile Amerikan Psikiyatri Birliği tarafından geliştirilen DSM sürümleri kullanılmaktadır.

DSM IV ve ICD formları psikiyatride ortak bir dilin ve tanımlama-sınıflandırma alanında uluslararası bir dizgenin oluşturulması açısından önemlidir (77).

Resmi psikiyatrik sınıflandırmaların birincisi; Uluslararası İstatistik Enstitüsü'nün 1938'de yayınladığı ILCD-5'tir. Bu bir sınıflamadan çok istatistik amaçlarla geliştirilmiş bir ölüm nedenleri istatistiğidir. Ölüm nedenleri arasında 3 ruhsal bozukluk yer almaktadır. İlk ruhsal bozukluklar sınıflaması, 1948 yılında ICD-6 ile yapılmış ve 27 ruhsal hastalık kategorisine yer verilmiştir (79). Zamanla ICD sürümleri yenilenmiş ve günümüzde ICD-10 (Güncel Sürüm, 2007) güncel sürümü kullanılmaktadır.

DSM sürümlerinin birincisi 1952 yılında yayımlanmıştır. ICD, DSM'den farklı olarak yalnız ruhsal bozukluklar ile değil, tüm tıbbi hastalıkları kapsayan bir sınıflamadır. Öncelikli amacı; ölüm ve hastalık istatistikleri ile bunların tüm dünyadaki dağılımını araştırmaktır (79). DSM sürümleri de zamanla güncellenmiş ve 2013 yılında DSM-5 yayımlanmıştır.

Bilgi teknolojisindeki gelişmeler, verideki büyük miktarda ve çeşitte artış, veri tabanlarının büyümesi ve depolanabilen verideki artış; hem DSM ve ICD gibi tanımlama sistemlerinin aralıklarla gerçekleşen revizyonlarında etkili olmakta hem de çeşitliliği artan verileri birleştirecek, veriler arasındaki ilişkileri ortaya çıkaracak ve analiz edecek yeni yöntemlere ihtiyaç duyulmuştur.

Sözü edilen gelişmeler ve değişimlerle birlikte kullanılmaya başlanan yöntemlerden birisi de yapay zeka yöntemidir. Yapay zeka; insanların düşünme, genelleme, problem çözme yeteneklerini kullanarak, sorunlara çözümler bulmaktadırlar. Yapay zekanın kullandığı yöntemlerden biri; yapay sinir ağlarıdır. Yapay sinir ağları; öngörü, sınıflama ve kümeleme amacı ile kullanılmaktadır. Yapay sinir ağları pek çok alanda kullanılmakla birlikte, sağlık açısından kullanımı düşünüldüğünde; yeni tanımlanan bir hastalığın özelliklerinin belirlenmesinde, aynı hastalığın farklı alt türlerinin sınıflandırılmasında, hastalıklarda uygulanan farklı tedavi yöntemlerinin

sonuçlarının karşılaştırılmasında, hastalığa uygun tedavi yöntemlerinin geliştirilmesinde, ya da hastalığı başlangıç aşamasında tanımlayarak erken tedavi alınmasının sağlanmasında etkilidir.

Ruh sağlığı ve hastalıkları açısından da bahsi geçen yöntemlerin kullanılması önemli bir yere sahiptir. Çünkü ruh sağlığı sistemleri yapısı, süreçleri ve doğası gereği karmaşık bir yapıya sahiptir. Dolayısıyla ruh sağlığı sisteminin anlaşılmasını kolaylaştıracak görsel araçlara ve ileri yöntemler kullanılarak geliştirilecek karar destek sistemlerine gereksinim duymaktadır (80).

Ayrıca psikiyatride tanı grupları oldukça geniş ve heterojen bir yapıya sahiptir. Örneğin şizofrenide birbirinden farklı semptomlarla tanı konulmaktadır. Benzer faktörler ve semptomlar farklı ruhsal problemlere yol açtığından, hastalıklara tanı koymak daha karmaşık bir süreç olur (81). Bunun yanında ruhsal hastalıklara tanı koymada kullanılan standart bir biyolojik test bulunmamaktadır. Tanılar; klinik beceri ve görüşe dayalıdır. DSM V ya da ICD 10 gibi tanı sistemleri, ölçekler, yapılandırılmış görüşmeler psikiyatrik rahatsızlıklara ilişkin tanı koymada standardizasyonu arttırmaya çalışmaktadır Bu nedenlerle psikiyatrik hastalıklara ilişkin tanıları oluşturmak için kümeleme veya sınıflama yöntemlerine ihtiyaç duyulmaktadır (82)

Ruhsal hastalıklar; bireyler, aileler ve toplum üzerinde etkilidir. Ruhsal hastalıklar yeti yitimine ya da sakatlığa yol açabilmektedir. Bu nedenler ruhsal hastalıklara doğru tanı koyulması; klinik uygulamada ve tedavinin başarılı olmasında önemlidir (83).

Ruh sağlığı problemlerine erken tanı koyulması da hastalığın başlangıç aşamasında tedavi edilmesini ve hastaların yaşam kalitesinin yükselmesinde önemli bir yere sahiptir. Yapay sinir ağları ve makine öğrenme teknikleri; hastalıklara tanı koymak ve tıbbi problemleri analiz etmek için kullanılmaktadır (81).

Kısaca sağlık alanında veri analiz yöntemlerine duyulan gereksinim ve önemi birlikte düşünüldüğünde, alan yazında Kohonen öz örgütlemeli haritalama yönteminin pek çok alanda kullanıldığı ve etkili sonuçlar alındığı ifade edilmektedir.

3. GEREÇ VE YÖNTEM

Bu tez çalışmasında; 'Şizofreni ve diğer psikotik bozukluklarda faktör yapısı' başlıklı uzmanlık tezinin verileri kullanılmıştır. Bu veriler psikotik rahatsızlığı olan 300 bireye aittir. Ancak çalışmada eksik verilerden dolayı 268 bireyin verisi kullanılmıştır. Psikotik rahatsızlığı olan kişiler çalışmanın evrenini; Hacettepe Üniversitesi Tıp Fakültesi Hastanesi Psikiyatri Servisi'nde, Bakırköy Ruh ve Sinir Hastalıkları Eğitim ve Araştırma Hastanesi Psikoz Kliniklerinde, Gülhane Askeri Tıp Akademisi Psikiyatri Servisi'nde ve Ankara Numune Eğitim ve Araştırma Hastanesi Psikiyatri Kliniği'nde 2001-2002 yılları arasında izlenmiş hastalar ise çalışmanın örneklemini oluşturmaktadır. Bu veride çeşitli semptomlar ile psikiyatri kliniklerine başvurmuş olan hastalara ait sosyo-demografik bulgular (cinsiyet, medeni durum, eğitim yılı, hastalığın başlama yaşı, hastaneye yatma süresi, hastanede kalma süresi, son alevlenme, GAF geçen ay, GAF geçen yıl) ile PANSS (Pozitif ve Negatif Sendrom Ölçeği), SANS (Negatif Belirtileri Değerlendirme Ölçeği) ve SAPS (Pozitif Belirtileri Değerlendirme Ölçeği) ölçeklerine ait madde puanları bulunmaktadır. Verideki değişkenler arasından yüksek korelasyona sahip olan değişkenler (ilaç dozu, yaş, ilaca başlama yaşı, SANS toplam skor) çalışmadan çıkarılmıştır. Veri toplama formu Ek-2'de verilmiştir.

Verileri incelenen hastalar akut psikoz veya psikotik belirtilerde alevlenme nedeniyle hastaneye yatırılan veya yatış sırasına alınan, DSM-IV tanı sistemine göre şizofreni, şizofreni ile ilişkili bir bozukluk (şizofreniform bozukluk, şizoafektif bozukluk), kısa psikotik bozukluk, psikotik belirtileri olan afektif bozukluk, madde kullanımı veya tıbbi bir rahatsızlığa bağlı psikotik bozukluk tanısı konmuş hastalardır.

Bu tez çalışmasının etik kurul onayı; Hacettepe Üniversitesi Girişimsel Olmayan Klinik Araştırmalar Etik Kurulu tarafından 12 Temmuz 2017 tarih ve GO-17/628-29 karar numarası ile onay almıştır.

Çalışmaya alınan kişilerin sosyodemografik özellikleri Tablo 3.1'de verilmiştir.

Tablo 3.1. Çalışmaya Alınan Kişilerin Sosyodemografik Özellikleri

	Ort. ± S.Sapma	Min.-Max.
Eğitim Yılı	9,37±0,25	0-19
Hastalığın Başlama Yaşı	25,51 ±0,54	13-72
Hastaneye Yatma Sayısı	3,26±0,23	1-25
Hastanede Kalma Süresi	10,23±1,17	0-157
Son Alevlenme	2,07±0,15	0-14
GAF Geçen Ay	21,59±0,55	1-50
GAF Geçen Yıl	56,12±1,30	10-95
SAPS Toplam Skor	47,58±1,13	8-103
PANSS Pozitif Toplam Skor	26,44±0,43	12-45
PANSS Negatif Toplam Skor	19,25±0,55	7-46
PANSS Genel Psikopatoloji Toplam Skor	41,96±0,54	21-73
PANSS Toplam Skor	87,66±1,03	47-143
	Sayı	%
Cinsiyet		
Kadın	116	43,1
Erkek	152	56,5
Medeni Durum		
Bekar	164	61,0
Evli	104	38,7

Bu tez çalışması, tanımlayıcı türde bir araştırmadır.

Psikotik bozuklukların sınıflandırılması için geliştirilen tanı sistemleri psikotik bozuklukları çeşitli alt tiplere ayırmaktadır. Alt tiplerin ayırımında kullanılan belirti ve bulguların, Kohonen öz örgütlemeli haritalama yöntemi ile sınıflandırılması, tanının istatistiksel olarak analiz edilmesi ve klasik kümeleme algoritmaları ile klinik tanıların karşılaştırılması hedeflenmektedir. Bu tez çalışmasında da psikotik hastalık tanıların kümelenmesinde Kohonen öz örgütlemeli haritalama yöntemi incelenerek, tanıtılmaktadır.

Kümeleme ve sınıflama yöntemleri R programında “Kohonen paketi (R. Wehrens and L.M.C. Buydens, Self- and Super-organising Maps in R: the kohonen package J. Stat. Softw., 21(5), 2007)” kullanılarak uygulanmıştır. Kohonen öz örgütlemeli haritalama yönteminin, sağlık verisi üzerinde kümeleme performansı araştırılmış ve Kohonen öz örgütlemeli haritalama yönteminin sonucu klasik kümeleme yöntemleri (k-ortalamlar yöntemi ve hiyerarşik kümeleme yöntemi) ile karşılaştırılmıştır. Kümeleme performansları; kümeleme indeksleri kullanılarak değerlendirilmiştir. R

programının Kohonen paketinde; komşuluk yarıçapı 0,67; öğrenme oranı 0,05 ve iterasyon sayısı 100 olarak alınmıştır.

Kohonen öz örgütlemeli haritalama yönteminin sınıflama performansı ise doğru sınıflama oranı ve kappa katsayısı kullanılarak incelenmiştir.

Bu tez çalışması; Hacettepe Üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimi tarafından TYL-2018-17163 proje numarası ile desteklenmektedir.

3.1. Kümeleme Analizi Sonuçlarını Değerlendirmek için Kullanılan İndeksler

Kümeleme analizinin sonuçlarını değerlendirmede kullanılan indeksler, iki faktör arasındaki benzerlikleri göstermektedir. Kullanılan kümeleme yönteminin sonucu ile gerçek kümenin sonucu karşılaştırılmaktadır. Hem kullanılan kümeleme yöntemi sonucunun hem de gerçek küme sonucunun incelenen durum açısından pozitif olması n_{11} , her iki yöntemde de incelenen durumun negatif olması n_{00} ile gösterilmektedir (84).

Birinci Yönteme Ait Gözlem Sayıları	İkinci Yönteme Ait Gözlem Sayıları	
	0	1
0	n_{00}	n_{01}
1	n_{10}	n_{11}

Oluşturulan kümelerin birbirine benzerliği, dolayısıyla kurulan modelin doğruluğu 4 indeksle belirlenecektir.

Rand İndeksi (Rand Benzerlik Ölçütü): Rand tarafından 1971 yılında, küme çiftleri arasındaki benzerlik ya da farklılıklara dayanarak kümeleme problemleri için geliştirilmiş bir ölçüdür. Her iki kümede de benzer yanıt veren (n_{11}) ve farklı yanıt veren (n_{00}) çiftlerin oranı, sınıflar arasındaki benzerliği yansıtmaktadır (85). İndekste yüksek değer, kümeler arasında yüksek uyum göstermektedir. 0-1 arasında değer almaktır (86). Rand indeks formülü Eşitlik 3.1.'de verilmiştir.

$$\frac{n_{11} + n_{00}}{n_{11} + n_{00} + n_{01} + n_{10}} \quad (3.1.)$$

Fowlkes ve Mallows İndeksi: Fowlkes ve Mallows tarafından 1983 yılında geliştirilen, olasılık tablolarına dayanan bir kümeleme değerlendirme yöntemidir. İki hiyerarşik kümeleme arasındaki benzerliği ölçmekte ve hiyerarşiklerdeki farklı kesişim kombinasyonlarını karşılaştırmaktadır (85). Rand indeksinin küme sayısı arttıkça, 1'e yakın değer verdiği sonucundan yola çıkarak geliştirilmiştir (87). Fowlkes ve Mallows indeks formülü Eşitlik 3.2.'de verilmiştir.

$$\frac{n_{11}}{\sqrt{(n_{11} + n_{01})(n_{11} + n_{10})}} \quad (3.2.)$$

Wallace İndeksi: Wallace tarafından 1983 yılında geliştirilen yöntem, iki kümedeki benzer çiftlerin sayısının olası tüm durumlara bölünmesidir (88).

Wallace 10 indeksi; her iki yöntemde de benzer olan gözlem sayılarının, her iki yöntemde de benzer gözlem sayısı ile ilk yöntemde benzer olan fakat ikinci yöntemde farklı olan gözlem sayısının toplamına bölünmesi ile elde edilir. Wallace 10 indeks formülü Eşitlik 3.3.'de verilmiştir.

$$\frac{n_{11}}{n_{11} + n_{10}} \quad (3.3.)$$

Wallace 01 indeksi ise; her iki yöntemde de benzer olan gözlem sayılarının, her iki yöntemde de benzer gözlem sayısı ile ikinci yöntemde benzer olan fakat birinci yöntemde farklı olan gözlem sayısının toplamına bölünmesi ile elde edilir. Wallace 01 indeks formülü Eşitlik 3.4.'de verilmiştir.

$$\frac{n_{11}}{n_{11} + n_{01}} \quad (3.4.)$$

Jaccard İndeksi: Downton and Brennan tarafından 1980 yılında geliştirilen, benzerliği ölçmek için her iki bölümdeki benzerliği değerlendiren bir yöntemdir (89). Kategorik verilerde kullanılmaktadır (90). Benzerliği hesaplamak için iki

kümedeki kesişen eleman sayısı birleşimin eleman sayısına bölünmektedir (91). İki kümeleme sonucunda da negatif olan durumları (n_{00}) gözardı etmektedir. Rand indeksinden farklı olarak, yanlış sınıflama için yüksek değer üretmez (86). 0-1 arasında değer almaktadır. Yüksek değer, yüksek doğruluk oranı anlamına gelmektedir (86). Jaccard indeks formülü Eşitlik 3.5.'te verilmiştir.

$$\frac{n_{11}}{n_{11} + n_{01} + n_{10}} \quad (3.5.)$$



4. BULGULAR

DSM ve ICD sistemleri, ruhsal bozuklukları farklı kategorileri göz önünde bulundurarak ele almış ve sınıflandırmışlardır. Ancak ruhsal bozuklukların somut göstergelerinin olmaması, tanıların belirtilere dayalı olarak koyulması kategorileri bazı durumlarda birbirinden ayırmayı zorlaştırmaktadır. Hiçbir kategorinin tanımına uymadığı halde hasta olduğu kesin olan, iki kategorinin bazı özelliklerini bir arada gösteren fakat hiçbir psikiyatrik rahatsızlığın ölçütlerini tam olarak karşılamayan hastalar da bulunmaktadır. Bu durum tanı gruplarının bazı durumlarda yetersiz kaldığını göstermektedir (55). Bu nedenle; kullanılan veride DSM-IV tanı kriterlerine göre 13 psikiyatrik rahatsızlığa ilişkin veri bulunmasına rağmen, farklı tanı grupları oluşturularak, sonuçları değerlendirilecektir.

Çalışmada verileri kullanılan hastalar; akut psikoz veya psikotik belirtilerde alevlenme nedeniyle hastaneye yatırılan veya yatış sırasına alınan, DSM-IV tanı sistemine göre şizofreni, şizofreni ile ilişkili bir bozukluk (şizofreniform bozukluk, şizoafektif bozukluk), kısa psikotik bozukluk, psikotik belirtileri olan afektif bozukluk, madde kullanımı veya tıbbi bir rahatsızlığa bağlı psikotik bozukluk tanısı konmuş hastalardır.

Kümeleme Sonuçları


Kümeleme bölümünde hastaların tanıları bilinmeden, yalnızca kaç tanı grubu oluşturulacağı bilgisi ile yapılan analizlerin sonuçları verilecektir. Analiz sonuçlarından önce, oluşturulan tanı grupları belirtilmiştir. Bu tanı grupları gereç yöntem bölümünde belirtilen değişkenler yardımı ile, Kohonen öz örgütlemeli haritalama yöntemi ile kümelendiğinde; değişkenlerin alt kümelerdeki dağılımı (kümeler belirlenmeden önce ve sonraki halleri ile) ve alt kümelere düşen kişi sayıları elde edilmiştir. Daha sonra kümeleme indeks sonuçları ile; Kohonen öz örgütlemeli haritalama yöntemi, K-ortalamlar ve hiyerarşik kümeleme yöntemlerinin kümeleme performansları değerlendirilmiştir.

Kümeleme 1 Sonuçları

Bu analizde yer alan tanı grupları Tablo 4.1’de belirtilmiştir. Bu grupta şizofreni türleri bir grup oluşturmuş, diğer gruplarda rahatsızlıklar farklı gruplar halinde ele alınmıştır.

Tablo 4. 1. Kümeleme Bir Bölümünde Yer Alan Tanı Grupları

1.Grup	Paranoid şizofreni, ayrışmamış şizofreni, dezorganize (dağınık) şizofreni ve katatonik şizofreni (şizofreni grubu)
2.Grup	Psikotik mani ve karışık psikotik rahatsızlık
3.Grup	Şizofreniform Bozukluk
4.Grup	Şizoaffektif Bozukluk
5.Grup	Sanrılı Bozukluk
6.Grup	Başka Türü Adlandırılmayan Bozukluk
7.Grup	Psikotik Depresyon
8.Grup	Bipolar Psikotik Depresyon
9.Grup	Maddeye ya da Tıbbi Duruma Bağlı Bozukluk




Şekil 4.1. Kümeleme 1'e Göre Değişkenlerin Alt Kümelerdeki Dağılımı

Şekil 4.1’de 10*10 boyutlu bir Kohonen öz örgütlemeli harita ağı ile değişkenlerin (cinsiyet, medeni durum, eğitim yılı, hastalığın başlama yaşı, hastaneye yatma süresi, hastanede kalma süresi, son alevlenme, GAF geçen ay, GAF geçen yıl, SAPS toplam skor, PANSS Pozitif toplam skor, PANSS negatif toplam skor, PANSS genel psikopatoloji toplam skor, PANSS toplam skor) 100 alt kümeye dağılımı görülmektedir. Izgara boyutu seçilirken, çeşitli boyutlar (6*6, 8*8 gibi) denenmiştir. Ancak düğümlerdeki değişkenlerin özellikleri 10*10’luk ızgara boyutunda daha ayrıntılı gözüktüğünden, 10*10’luk ızgara boyutunun kullanılmasına karar verilmiştir. Ayrıca değişkenlerin alt kümelerdeki dağılımını gösteren şekil, ‘özellik haritası’ olarak da adlandırılmaktadır.

Şekil 4.1’de yer alan özellik haritasının altında, kullanılan değişkenler ile her bir değişkeni temsil eden renkler görülmektedir. Değişkenlerin alt gruplardaki dağılımı incelendiğinde; her düğümün içinde kullanılan değişkenlerin olduğu ve değişkenin ilgili düğümdeki ağırlığının çubukların boyutundaki büyüme ile ifade edildiği görülmektedir. Örneğin; sol taraftaki alt kümelerde; ölçek skorlarına ilişkin değişkenlerin, sağ taraftaki alt kümelerde ise cinsiyet, medeni durum, eğitim yılı gibi sosyo-demografik değişkenlerin daha ağırlıklı olduğu görülmektedir. Ayrıca değişkenlerin sıralaması da her düğüm için aynıdır.

Oluşturulan tüm kümelerde; değişkenlerin özellikleri sabit kaldığından ve değişkenlerin alt kümelerdeki dağılımı sabit kaldığından “Değişkenlerin Alt Kümelerdeki Dağılımı”na ilişkin şekil değişmemiştir. Bu nedenle ilgili şekle sadece “1. Kümeleme” sonuçlarında yer verilmiştir. Ayrıca değişkenlerin alt kümelerdeki dağılımını gösteren şekil, ‘özellik haritası’ olarak da adlandırılmaktadır.

Şekil 4.2’de yer alan özellik haritasında, verilerin 9 kümeye ayrıldığı görülmektedir.



Şekil 4.3. Kümeleme 1’e Göre Düğüm Frekansları

Şekil 4.3’te; alt kümelere düşen kişi sayıları görülmektedir. Şeklin sol köşesindeki çubuklar, kişi sayısını göstermektedir. Renkler koyudan açığa doğru değişmekte ve açık renkli düğümlerin daha fazla gözlem içerdiği görülmektedir. Gri renkte olan düğümler, boş kümeleri ifade etmektedir. Şekil, her bir kümeleme için elde edilmiştir ve yorumu değişmemektedir.

4.1. Kümeleme İndeks Sonuçları

Elde edilen Kohonen öz örgütlemeli haritalama yöntemi sonuçları gerçek tanı grupları ile karşılaştırıldığında bulunan indeks sonuçları aşağıda Tablo 4.2’de verilmiştir.

Tablo 4.2. Kohonen Öz Örgütlemeli Haritalama Yöntemi, K-Ortalamalar ve Hiyerarşik Kümeleme Yöntemlerine Ait İndeks Sonuçları

Yöntemler	Rand İndeksi	Fowlkes ve Mallows İndeksi	Wallace 10 İndeksi	Wallace 01 İndeksi	Jaccard İndeksi
Kohonen Öz Örgütlemeli Haritalama	0,6379	0,2344	0,3423	0,1606	0,1226
K- ortalamalar	0,6302	0,2258	0,3234	0,1577	0,1185
Hiyerarşik Kümeleme	0,4588	0,5050	0,3389	0,7526	0,3049

1. kümeleme sonuçları incelendiğinde; Rand indeksinde Kohonen öz örgütlemeli haritalama yöntemi ve k-ortalamalar yönteminin benzer sonuçlar vermesine rağmen, Kohonen öz örgütlemeli haritalama yönteminin Rand indeksinde en yüksek sonucu verdiği görülmektedir.

Fowlkes ve Mallows indeksinde; Kohonen öz örgütlemeli haritalama yöntemi ve k-ortalamalar yönteminin benzer sonuçlar verdiği, ancak hiyerarşik kümeleme yönteminin en yüksek sonucu verdiği görülmektedir.


Wallace 10 indeksinde, tüm yöntemlerden elde edilen sonuçlar birbirine benzemesine rağmen, Kohonen öz örgütlemeli haritalama yönteminin en yüksek sonucu verdiği görülmektedir.

Wallace 01 ve Jaccard indekslerinde en başarılı sonucu, hiyerarşik kümeleme yönteminin verdiği görülmektedir.

Kümeleme 2 Sonuçları


Tablo 4.3. Kümeleme İki Bölümünde Yer Alan Tanı Grupları

1.Grup	Psikotik depresyon, psikotik mani, bipolar psikotik depresyon, karışık psikotik rahatsızlık
2.Grup	Paranoid şizofreni
3.Grup	Ayrışmamış Şizofreni
4.Grup	Dezorganize (Dağınık) Şizofreni
5.Grup	Katatonik Şizofreni
6.Grup	Şizofreniform Bozukluk
7.Grup	Şizoaffektif Bozukluk
8.Grup	Sanrılı Bozukluk
9.Grup	Başka Türü Adlandırılmayan Bozukluk
10.Grup	Maddeye ya da Tıbbi Duruma Bağlı Bozukluk



Şekil 4.4. Kümeleme 2'ye Göre Değişkenlerin Alt Kümelerdeki Dağılımı

Şekil 4.4 ile verilen özellik haritasında, 10*10 Kohonen öz örgütlemeli haritalama yönteminin verileri 10 kümeye ayırdığı görülmektedir. Birinci kümeleme sonucundan farkı; sol köşedeki kümenin 2'ye bölünmesidir.



Şekil 4.5. Kümeleme 2'ye Göre Düğüm Frekansları

Şekil 4.5'de; düğümlere düşen kişi sayıları görülmektedir.

Kümeleme İndeks Sonuçları

Elde edilen Kohonen öz örgütlemeli haritalama yöntemi sonuçları gerçek tanı grupları ile karşılaştırıldığında bulunan indeks sonuçları Tablo 4.4'de verilmiştir.

Tablo 4.4. Kohonen Öz Örgütlemeli Haritalama Yöntemi, K-Ortalamlar ve Hiyerarşik Kümeleme Yöntemlerine Ait İndeks Sonuçları

Yöntemler	Rand İndeksi	Fowlkes ve Mallows İndeksi	Wallace 10 İndeksi	Wallace 01 İndeksi	Jaccard İndeksi
Kohonen Öz Örgütlemeli Haritalama	0,6908	0,1846	0,2471	0,1379	0,0971
K- ortalamlar	0,6855	0,1962	0,2510	0,1533	0,1052
Hiyerarşik Kümeleme	0,5613	0,3097	0,2446	0,3922	0,1774

Rand indeksinde en yüksek sonucu az farkla da olsa Kohonen öz örgütlemeli haritalama yönteminin; en düşük sonucu ise hiyerarşik kümeleme yönteminin verdiği görülmektedir.

Fowlkes ve Mallows indeksinde en başarılı sonucu hiyerarşik kümeleme yönteminin verdiği görülmektedir.

Wallace indeksinde ise tüm yöntemlerde benzer sonuçlar elde edilmiş olup, az farkla k-ortalamlar yönteminin daha iyi sonuç verdiği gözlenmiştir.


Wallace indeksi ile Jaccard indeksinde en başarılı sonuç, hiyerarşik kümeleme yöntemi tarafından elde edilmiştir.

Kümeleme 3 Sonuçları

Bu analizde yer alan tanı grupları Tablo 4.5'te belirtilmiştir. Şizofreni türleri ile şizofreniform bozukluk ve şizoaffektif bozukluk bir grup oluşturmuş, psikotik bozukluklar birleştirilerek ayrı bir grup oluşturmuş, diğer rahatsızlıklar ayrı gruplar halinde değerlendirilmiştir.


Tablo 4.5. Kümeleme Üç Bölümünde Yer Alan Tanı Grupları

1.Grup	Paranoid şizofreni, Ayrışmamış Şizofreni, Dezorganize (Dağınık) Şizofreni, Katatonik Şizofreni, Şizoaffektif Bozukluk, Şizofreniform Bozukluk
2.Grup	Psikotik depresyon, psikotik mani, karışık psikotik rahatsızlık, bipolar psikotik depresyon
3.Grup	Sanrılı Bozukluk
4.Grup	Başka Türlü Adlandırılmayan Bozukluk
5.Grup	Maddeye ya da Tıbbi Duruma Bağlı Bozukluk



Şekil 4.6. Kümeleme 3'e Göre Değişkenlerin Alt Kümelerdeki Dağılımı

Şekil 4.6'daki özellik haritasında; verilerin 5 kümeye ayrıldığı; Şekil 4.7'de Düğüm Frekansları görülmektedir.



Şekil 4.7. Kümeleme 3'e Göre Düğüm Frekansları

Kümeleme İndeks Sonuçları

Elde edilen Kohonen öz örgütleme haritalama yöntemi sonuçları gerçek tanı grupları ile karşılaştırıldığında bulunan indeks sonuçları Tablo 4.6'da verilmiştir.

Tablo 4.6. Kohonen Öz Örgütlemeli Haritalama Yöntemi, K-Ortalamlar ve Hiyerarşik Kümeleme Yöntemlerine Ait İndeks Sonuçları

Yöntemler	Rand İndeksi	Fowlkes ve Mallows İndeksi	Wallace 10 İndeksi	Wallace 01 İndeksi	Jaccard İndeksi
Kohonen Öz Örgütlemeli Haritalama	0,5166	0,3930	0,4887	0,3159	0,2374
K- ortalamlar	0,5140	0,3961	0,4850	0,3236	0,2408
Hiyerarşik Kümeleme	0,4928	0,6742	0,4834	0,9405	0,4690

Rand indeksinde en başarılı sonucu Kohonen öz örgütlemeli haritalama yönteminin verdiği görülmektedir.

Fowlkes ve Mallow indeksinde en iyi sonucu hiyerarşik kümeleme yönteminin verdiği görülmektedir.

Wallace 10 indeksinde 3 yönteminde birbirine benzer sonuçlar verdiği görülmektedir.


Wallace 01 ve Jaccard indekslerinde hiyerarşik kümeleme yönteminin daha iyi sonuçlar verdiği özellikle Wallace 01 indeksinde 1'e yakın bir değer elde edilmiştir.

Kümeleme 4 Sonuçları

Bu analizde yer alan tanı grupları Tablo 4.7'de belirtilmiştir. Şizofreni türleri ile şizofreniform bozukluk bir grup oluşturmuş, psikotik bozukluklar birleştirilerek ayrı bir grup oluşturmuş, diğer rahatsızlıklar ayrı gruplar halinde değerlendirilmiştir.


Tablo 4.7. Kümeleme Dört Bölümünde Yer Alan Tanı Grupları

1.Grup	Paranoid şizofreni, Ayrışmamış Şizofreni, Dezorganize (Dağınık) Şizofreni, Katatonik Şizofreni, Şizofreniform Bozukluk
2.Grup	Şizoaffektif Bozukluk
3.Grup	Psikotik depresyon, psikotik mani, bipolar psikotik depresyon, karışık psikotik rahatsızlık
4.Grup	Sanrılı Bozukluk
5.Grup	Başka Türü Adlandırılmayan Bozukluk
6.Grup	Maddeye ya da Tıbbi Duruma Bağlı Bozukluk



Şekil 4.8. Kümeleme 4'e Göre Değişkenlerin Alt Kümelerdeki Dağılımı

Yukarıdaki Şekil 4.8'deki özellik haritasında, verinin 6 gruba ayrıldığı görülmektedir.



Şekil 4.9. Kümeleme 4'e Göre Düğüm Frekansları

Kümeleme İndeks Sonuçları

Elde edilen Kohonen öz örgütlemeli haritalama yöntemi sonuçları gerçek tanı grupları ile karşılaştırıldığında bulunan indeks sonuçları aşağıda Tablo 4.8'de verilmiştir.

Tablo 4.8. Kohonen Öz Örgütlemeli Haritalama Yöntemi, K-Ortalamlar ve Hiyerarşik Kümeleme Yöntemlerine Ait İndeks Sonuçları

Yöntemler	Rand İndeksi	Fowlkes ve Mallows İndeksi	Wallace 10 İndeksi	Wallace 01 İndeksi	Jaccard İndeksi
Kohonen Öz Örgütlemeli Haritalama	0,5325	0,3345	0,4435	0,2524	0,1917
K- ortalamlar	0,5398	0,3011	0,4473	0,2028	0,1621
Hiyerarşik Kümeleme	0,4576	0,6455	0,4443	0,9378	0,4316

Rand indeksinde en başarılı sonucu Kohonen öz örgütlemeli haritalama yöntemi ile k-ortalamlar yönteminin verdiği görülmektedir.

Fowlkes ve Mallows indeksinde en başarılı sonucun hiyerarşik kümeleme ile elde edildiği, Wallace 10 indeksinde 3 yöntemde de benzer sonuçlar elde edildiği görülmektedir.

Wallace 01 indeksinde oldukça yüksek bir değerle hiyerarşik kümeleme yöntemi başarılı bir sonuç vermiştir.


Jaccard indeksinde de hiyerarşik kümeleme en yüksek değeri vermiştir.

Kümeleme 5 Sonuçları

Bu analizde yer alan tanı grupları Tablo 4.9’da belirtilmiştir. Şizofreni türleri ile şizofreniform bozukluk ve şizoaffektif bozukluk bir grup oluşturmuş; psikotik bozukluklar birleştirilerek ayrı bir grup oluşturmuş ve sanrılı bozukluk, başka türlü adlandırılmayan bozukluk, maddeye ya da tıbbi duruma bağlı bozukluk birleştirilerek bir grup oluşturulmuştur.


Tablo 4.9. Kümeleme Beş Bölümünde Yer Alan Tanı Grupları

1.Grup	Paranoid şizofreni, Ayrışmamış Şizofreni, Dezorganize (Dağınık) Şizofreni, Katatonik Şizofreni, Şizoaffektif Bozukluk, Şizofreniform Bozukluk
2.Grup	Psikotik depresyon, psikotik mani, karışık psikotik rahatsızlık, bipolar psikotik depresyon
3.Grup	Sanrılı Bozukluk, Başka Türü Adlandırılmayan Bozukluk, Maddeye ya da Tıbbi Duruma Bağlı Bozukluk



Şekil 4.10. Kümeleme 5'e Göre Değişkenlerin Alt Kümelerdeki Dağılımı

Şekil 4.10'daki özellik haritasında; verilerin 3 kümeye ayrıldığı; Şekil 4.11'de Düzüm Frekansları görölmektedir.



Şekil 4.11. Kümeleme 5'e Göre Düzüm Frekansları

Kümeleme İndeks Sonuçları

Elde edilen Kohonen öz örgütlemeli haritalama yöntemi sonuçları gerçek tanı grupları ile karşılaştırıldığında bulunan indeks sonuçları Tablo 4.10'da verilmiştir.

Tablo 4.10. Kohonen Öz Örgütlemeli Haritalama Yöntemi, K-Ortalamlar ve Hiyerarşik Kümeleme Yöntemlerine Ait İndeks Sonuçları

Yöntemler	Rand İndeksi	Fowlkes ve Mallows İndeksi	Wallace 10 İndeksi	Wallace 01 İndeksi	Jaccard İndeksi
Kohonen Öz Örgütlemeli Haritalama	0,5044	0,4853	0,4812	0,4894	0,3203
K- ortalamlar	0,5106	0,4879	0,4874	0,4883	0,3226
Hiyerarşik Kümeleme	0,4946	0,6785	0,4850	0,9495	0,4728

Rand indeksinde en başarılı sonucu Kohonen öz örgütlemeli haritalama yönteminin verdiği görülmektedir.

Fowlkes ve Mallow indeksinde en iyi sonucu hiyerarşik kümeleme yönteminin verdiği görülmektedir.

Wallace 10 indeksinde 3 yönteminde birbirine benzer sonuçlar verdiği görülmektedir.

Wallace 01 ve Jaccard indekslerinde hiyerarşik kümeleme yönteminin daha iyi sonuçlar verdiği özellikle Wallace 01 indeksinde 1'e yakın bir değer elde edilmiştir.

Kümeleme 5'te Kohonen Öz Örgütlemeli Haritalama Yönteminden alınan sonuçlar incelendiğinde; Fowlkes ve Mallow, Wallace 10, Wallace 01 ve Jaccard indekslerinde diğer kümeleme yönteminden daha başarılı sonuçlar elde edilmiştir. Küme sayısı azaldıkça ve kümelerdeki gözlem sayısı arttıkça, Kohonen yönteminin daha iyi sonuçlar verdiği görülmektedir.

4.2. Sınıflama Sonuçları

Sınıflama bölümünde hastaların tanıları ve kaç tanı grubuna ayrılacağı bilgisi kullanılarak; DSM IV tanı kriterleri ile Kohonen öz örgütlemeli haritalama yöntemi ile yapılan analizlerin sonuçları verilmiştir. Tanı grupları bilinerek Kohonen öz örgütlemeli haritalama yöntemi ile sınıflama yapıldığında Tablo 4.9’da yer alan sonuçlar elde edilmiştir.


Sınıflama 1 Sonuçları

Veriler 9 sınıfa ayrılmıştır. 5 sınıfın (1, 2, 3, 5, 6) tamamı doğru tahmin edilmiştir. En başarısız sınıflama 8. sınıfta görülmüştür. 8. sınıf olan “bipolar psikotik depresyon”un, şizofreniform ve şizoaffectif bozuklukla karıştığı gözlenmiştir. Sınıflardaki gözlem sayısı arttıkça, doğru sınıflama oranının da yükseldiği görülmektedir.

Tablo 4.11. Sınıflama 1’e Göre Kohonen Öz Örgütlemeli Haritalama Yöntemi ile Elde Edilen Sınıflama Sonucu

		DSM IV Tanı Kriterleri								
		1	2	3	4	5	6	7	8	9
Sınıflama Sonucu	1	130	0	0	0	0	0	0	0	0
	2	0	70	0	0	0	0	0	0	0
	3	0	0	17	1	0	0	1	2	3
	4	0	0	0	6	0	0	1	2	0
	5	0	0	0	0	1	0	0	0	0
	6	0	0	0	0	0	2	0	1	0
	7	0	0	0	0	0	0	14	0	1
	8	0	0	0	0	0	0	0	4	0
	9	0	0	0	2	0	0	1	1	6
Toplam		130	70	17	9	1	2	17	10	10

Doğruluk oranı %92, kappa katsayısı %90 ve güven aralığı; 0,8915- 0,9568 olarak bulunmuştur.



Şekil 4.12. Sınıflama 1'e Göre Kohonen Öz Örgütlemeli Haritalama Yöntemi Özellik Haritası

Şekil 4.12'de Kohonen öz örgütlemeli haritalama yöntemi tarafından oluşturulan sınıflar görülmektedir. Özellikle 1. ve 2. sınıfların belirgin olduğu görülmektedir. Diğer sınıflarda, tek sınıfın özelliğinden ziyade, birkaç sınıfın bir arada olduğu dikkat çekmektedir.


Sınıflama 2 Sonuçları

Veriler 10 sınıfa ayrılmıştır. Aşağıdaki tabloda; en yüksek yoğunluğa sahip olan 1, 2 ve 3. kümelerin hatasız sınıflama yaptığı görülmektedir. 5. grup olan katatonik şizofreninin, dezorganize şizofreni ile karıştığı, şizofreniform bozukluğun (6. grup) katatonik şizofreni ile karıştığı dikkat çekmektedir. Başka türlü adlandırılmayan bozukluğa (9. grup) sahip bireyler, dezoragnize şizofreni olarak sınıflandırılmıştır.

Tablo 4.12. Sınıflama 2'ye Göre Kohonen Öz Örgütlemeli Haritalama Yöntemi ile Elde Edilen Sınıflama Sonucu

		DSM IV Tanı Kriterleri									
		1	2	3	4	5	6	7	8	9	10
Sınıflama Sonucu	1	98	0	0	0	0	0	0	0	0	0
	2	0	74	0	0	0	0	0	0	0	0
	3	0	0	42	0	0	0	0	0	0	0
	4	0	0	0	17	3	0	4	0	2	0
	5	0	0	0	0	10	1	2	1	0	1
	6	0	0	0	0	0	0	0	0	0	0
	7	0	0	0	1	0	0	3	0	0	0
	8	0	0	0	0	0	0	0	0	0	0
	9	0	0	0	0	0	0	0	0	0	0
	10	0	0	0	0	0	0	0	0	0	9
Toplam		98	74	42	18	13	1	9	1	2	10

Doğruluk oranı %94, kappa katsayısı %93 ve güven aralığı 0,9094-0,9683 olarak bulunmuştur.



Şekil 4.13. Sınıflama 2'ye Göre Kohonen Öz Örgütlemeli Haritalama Yöntemi Özellik Haritası

Şekil 4.13'de; 1, 2 ve 3. sınıfların daha net ayırt edildiği, ancak bu kümelerin bazı düğümlerinde farklı rahatsızlıklarında az da olsa görüldüğü dikkati çekmektedir. Diğer rahatsızlıkların, birden fazla rahatsızlığın bir arada görüldüğü, daha karmaşık bir yapıya sahip olduğu görülmektedir.


Sınıflama 3 Sonuçları

Tablo 4.13’de, 3. sınıf dışında tüm sınıfların doğru sınıflandığı görülmektedir. 3. sınıfı temsil eden sanrılı bozukluk tanısının, başka türlü adlandırılmayan bozukluk ve maddeye ya da tıbbi duruma bağlı bozukluk tanıları ile karıştığı görülmektedir.

Tablo 4. 13. Sınıflama 3’e Göre Kohonen Öz Örgütlemeli Haritalama Yöntemi ile Elde Edilen Sınıflama Sonucu

		DSM IV Tanı Kriterleri				
		1	2	3	4	5
Sınıflama Sonucu	1	157	0	0	0	0
	2	0	98	0	0	0
	3	0	0	1	0	0
	4	0	0	1	1	0
	5	0	0	1	0	9
Toplam		157	98	3	1	9

Doğruluk oranı %99, kappa katsayısı %99 ve güven aralığı 0,9733-0,9991 olarak bulunmuştur.



Şekil 4.14. Sınıflama 3'e Göre Kohonen Öz Örgütlemeli Haritalama Yöntemi Özellik Haritası

Şekil 4.14 incelendiğinde; 1., 2. ve 5. sınıfa ait grupların belirgin olduğu, diğer gruplarda birkaç rahatsızlığın bir arada bulunduğu görülmektedir.


Sınıflama 4 Sonuçları

Tablo 4.14'deki sınıflama sonucu incelendiğinde; 5. ve 6. sınıflar dışında diğer grupların hatasız sınıflandığı görülmektedir. Başka türlü adlandırılmayan bozukluğun (5. sınıf); şizoaffektif bozukluk ve sanrılı bozukluk ile karıştığı; maddeye ya da tıbbi duruma bağlı bozukluğa (6. sınıf) ait gözlemlerden birinin yanlışlıkla şizoaffektif bozukluk olarak sınıflandığı dikkati çekmektedir.

Tablo 4.14. Sınıflama 4'e Göre Kohonen Öz Örgütlemeli Haritalama Yöntemi ile Elde Edilen Sınıflama Sonucu

		DSM IV Tanı Kriterleri					
		1	2	3	4	5	6
Sınıflama Sonucu	1	148	0	0	0	0	0
	2	0	9	0	0	1	1
	3	0	0	98	0	0	0
	4	0	0	0	1	1	0
	5	0	0	0	0	0	0
	6	0	0	0	0	0	9
Toplam		148	9	98	1	2	10

Doğruluk oranı %99, kappa katsayısı %98 ve güven aralığı 0,9676 - 0,9977 olarak bulunmuştur.



Şekil 4.15. Sınıflama 4'e Göre Kohonen Öz Örgütlemeli Haritalama Yöntemi Özellik Haritası

Şekil 4.15 incelendiğinde; 1., 3 ve 6. sınıfa ait grupların belirgin olduğu, diğer gruplarda birkaç rahatsızlığın bir arada bulunduğu görülmektedir.


Sınıflama 5 Sonuçları

Tablo 4.15'de, tüm sınıfların doğru sınıflandığı görülmektedir.

Tablo 4. 15. Sınıflama 5'e Göre Kohonen Öz Örgütlemeli Haritalama Yöntemi ile Elde Edilen Sınıflama Sonucu

		DSM IV Tanı Kriterleri		
		1	2	3
Sınıflama Sonucu	1	157	0	0
	2	0	98	0
	3	0	0	13
Toplam		157	98	13

Doğruluk oranı 1, kappa katsayısı 1 ve güven aralığı 0.9863- 1 olarak bulunmuştur.



Şekil 4.16. Sınıflama 5'e Göre Kohonen Öz Örgütlemeli Haritalama Yöntemi Özellik Haritası

Şekil 4.16 incelendiğinde; tüm sınıfların belirgin olduğu, bazı düğümlerde iki ya da üç grubun birlikte yer aldığı görülmektedir.

5. TARTIŞMA

Bu çalışma, Kohonen öz örgütlemeli haritalama yöntemini incelemek, kümeleme ve sınıflama performanslarını diğer yöntemlerle karşılaştırmak ve Kohonen öz örgütlemeli haritalama yöntemini sağlık alanında uygulamak amacıyla yapılmıştır.

Literatürdeki çalışmalar incelendiğinde; Kohonen öz örgütlemeli haritalama yönteminin; finansman, tarım, sağlık, kimya, bilgisayar, planlama gibi pek çok alanda uygulandığı görülmektedir. Philippopoulos, Deligiorgi ve Kouroupetroglou (92) atmosfer sirkülasyonun tipinin sınıflandırması; Burnap ve diğerleri (93) siber saldırılardan dolayı kötü yazılım örneklerini ayırt etmek; Jardin ve Severin (94) finansal başarısızlığı öngörmek; Mostafa (95) ülkelerin ekolojik ayak izlerini kümelemek ve ekolojik ayak izlerini etkileyen faktörleri ortaya çıkarmak; Konate ve diğerleri (96) kayaları sınıflandırmak; Hausfeld, Valente ve Formisano (97) fMRI verilerini görselleştirmek ve kodlamak; Hu ve Yan (98) ilaç ve toksinlerin potansiyellerini öngörmek; Mostafa (99) organ bağışında bulunanların profili ile organ bağışında etkili olan psikolojik ve bilişsel faktörleri ortaya çıkarmak; Foroutan, Zimbelman (100) mars ve uydu görüntülerinde yüksek çözünürlük sağlamak, görüntüyü iyileştirmek, görüntü analizini iyileştirmek; Taşkın ve Emel (101) perakendecilik sektöründe işletme müşterilerini kümelemek, Reis ve Taşdemir (102) fındık alanlarını belirlemek; Nouri ve Şengör (103) öz örgütlemeli haritalama yöntemi ile farklı yaklaşımları sınamak, Oğuzlar (104) suçlu profilini ortaya çıkarmak; İdil (105) kanser hastalıklarını sınıflandırmak; Olszewski (106) telekomünikasyon dolandırıcılığını tespit etmek; Palamara, Piglione ve Piccinini (107) iş kazalarını analiz etmek; Roh, Jung ve Hong (108) OECD ülkelerindeki 10-19 yaş arasındaki kişilerde yaş, cinsiyet ve zamana bağlı intihar oranı örüntülerini belirlemek amacıyla, Kohonen öz örgütlemeli haritalama yöntemini kullanmışlardır.

Kohonen öz örgütlemeli haritalama yönteminin performansını artırmak için; Ballabioa, Vasighi ve Filzmoser (109) Kohonen öz örgütlemeli haritalama yönteminin parametrelerinin sınıflama performansı üzerindeki etkileri belirlemek; Melssen, Wehrens ve Buydens (110) Öklid ve Tanimoto uzaklık ölçümlerinin

Kohonen öz örgütlemeli haritalama yönteminin sonuçlarına etkisini incelemek amacıyla çalışma yapmışlardır.

Çalışmanın bu bölümünde, kümeleme analizi sonucunda elde edilen bulgular ile diğer çalışmalardan elde edilen bulgular karşılaştırılarak tartışılmıştır.

Bu çalışmada kullanılan veriler, psikotik rahatsızlığa sahip kişilerden oluşan, 268 kişiye ait verilerdir. Veride 12 psikotik hastalığa ilişkin veri bulunmasına rağmen, farklı sayılarda kümeler oluşturularak sonuçları değerlendirilmiştir. Toplamda 4 küme/sınıf oluşturulmuş olup, küme/sınıf sayıları; 5, 6, 9 ve 10'dur.

Öncelikle oluşturulan 4 farklı kümenin, kümeleme sonuçları incelendiğinde; Kohonen öz örgütlemeli haritalama yönteminin; rand indeksi dışında, diğer indekslerde en yüksek sonuca "Kümeleme 3"te ulaştığı görülmektedir.

Kohonen öz örgütlemeli haritalama yöntemi en yüksek Rand indeksini "Kümeleme 2" de elde etmiştir. Rand indeksi, küme sayısı arttıkça daha başarılı sonuçlar verdiği için, küme sayısının (10 küme) en fazla olduğu 2. kümede, daha az sayıda grup içeren kümelerle karşılaştırıldığında Rand indeksi daha yüksek değer almıştır.

K-ortalamalar ile hiyerarşik kümeleme yöntemlerinin, oluşturulan 4 küme sonucunda elde ettiği değerler incelendiğinde; her iki yöntemde de rand indeksi dışında en başarılı sonuçlara "Kümeleme 3"te ulaşıldığı görülmektedir.

"Kümeleme 3"te hiyerarşik kümeleme sonuçları incelendiğinde; bazı indekslerde (Fowlkes ve Mallow, Wallace 01, Jaccard) diğer kümelere göre daha iyi sonuçlar verdiği, diğer indekslerde de (Rand, Wallace 10) diğer yöntemlere benzer sonuçlar verdiği görülmektedir.

İncelenen 3 kümeleme yönteminin de, genel olarak en başarılı sonuçlara 'Kümeleme 3'te ulaştığı görülmektedir. Daha önce de ifade edildiği gibi psikiyatrik rahatsızlıkların kendine has doğasından kaynaklı, farklı hastalık grupları farklı kümeleri oluşturmuştur. En başarılı sonuçların elde edildiği 'Kümeleme 3'e ait gruplar incelendiğinde; şizofreni türleri ile şizofreniform bozukluk ve şizoaffektif bozukluğun bir grup olarak, affektif psikozların ayrı bir grup olarak birleştirildiği ayrıca diğer rahatsızlıkların (Sanrılı bozukluk, başka türlü adlandırılmayan

bozukluk, maddeye ya da tıbbi duruma bağlı bozukluk) ayrı grupları oluşturduğu görülmüştür. Burada oluşturulan kümelerin birbiri ile benzer özellikler taşıması ve kümeleri temsil eden hastalıklar arasındaki ayrımların daha belirgin olmasından dolayı, daha yüksek başarı oranı elde edildiği, ya da incelenen yöntemlerin daha az sayıda kümelerden oluşan grupları başarılı bir şekilde kümelediği düşünülebilir.

Oluşturulan kümeler grup sayıları açısından incelendiğinde; Rand indeksi dışında grup sayısı arttıkça, elde edilen sonuçlarda başarı oranının, daha az sayıda gruplarda elde edilen sonuçlara oranla düştüğü görülmektedir. Kohonen öz örgütlemeli haritalama yönteminin, 9 gruptan oluşan “Kümeleme 1” de yer alan, Fowlkes ve Mallow indeksinde 0,23 değeri elde edilmişken, 10 gruptan oluşan “Kümeleme 2”de aynı indeksin 0,18 değerini elde ettiği görülmektedir. Aynı şekilde k-ortalamlar yönteminde de, 9 gruptan oluşan “Kümeleme 1” de yer alan, Fowlkes ve Mallow indeksinde 0,22 değerinin, 10 gruptan oluşan “Kümeleme 2”de aynı indeksinde 0,19’a gerilediği görülmektedir. Kümelerdeki grup sayıları arttıkça kümeleme yönteminden elde edilen başarı oranının düşmesi; örneklem sayısının azlığına bağlanabilir. Özellikle bazı hastalıklarda (örneğin; katatonik şizofreni) gözlem sayısının az olmasından dolayı da, ilgili kümeleme yöntemlerinin grupların özelliklerini ortaya çıkarmakta zorlandığı düşünülebilir.

Kümeleme sonuçları incelendiğinde; “Kümeleme 1”, “Kümeleme 2” ve “Kümeleme 3” te Kohonen öz örgütlemeli haritalama yönteminin, “Kümeleme 4”te k-ortalamlar yönteminin daha yüksek değer aldığı görülmektedir. Ancak değerler daha ayrıntılı incelendiğinde her iki yöntemde de elde edilen sonuçların birbirine çok yakın olduğu, benzer performanslar gösterdikleri görülmektedir. Llanos ve diğerleri (111) de yaptıkları çalışmada k-ortalamlar ve Kohonen öz örgütlemeli haritalama yönteminin benzer sonuçlar vermesine karşın, Kohonen öz örgütlemeli haritalama yönteminin az da olsa daha iyi sonuç verdiğini belirtmişlerdir. Palamara, Piglione ve Piccinini (107) Kohonen öz örgütlemeli haritala ile k-ortalamlar yöntemlerinin sonuçlarını aynı bulmuşlardır. Arroyo ve diğerleri (112); Baçao, Lobo ve Painho (113) Kohonen öz örgütlemeli haritalama ile k-ortalamlar yöntemlerinin sonuçlarının nerdeyse aynı olduğunu belirtmişlerdir.

Philippopoulos, Deligiorgi ve Kouroupetroglou (92) çalışmalarında Kohonen öz örgütlemeli haritalama yöntemi ile k-ortalamlar yöntemi arasındaki uyum %50 ile %85 arasında değişmiştir. Mostafa (95)'nın çalışmasında Kohonen öz örgütlemeli haritalama yönteminin kümeleme sonuçları k-ortalamlar yönteminden daha başarılı bulunmuş. Mostafa (95), Mostafa (99) ve Chen, Ribeiro, Vieira, Chen (114) Kohonen yönteminin kümelemenin kalitesini geliştirdiği ifade etmiştir. Segev ve Kantola (115) Kohonen öz örgütlemeli haritalama yönteminin k-ortalamlar yönteminden daha iyi sonuç verdiğini belirtmiştir. Roh, Jung ve Hong (108) Kohonen öz örgütlemeli haritalama yöntemi ile birlikte k-ortalamlar yönteminin kullanılmasının yüksek boyutlu verilerde saklanan örüntüleri bulmak açısından etkili olduğunu belirtmişlerdir. Ayrıca Kohonen öz örgütlemeli haritalama yönteminin k-ortalamlar yöntemine göre avantajı veriyi görselleştirme özelliğidir.

Kohonen öz örgütlemeli haritalama yöntemi sonuçları ile hiyerarşik kümeleme sonuçları karşılaştırıldığında; “Kümeleme 1” de Kohonen öz örgütlemeli haritalama yöntemi, Rand ve Wallace 10 indekslerinde hiyerarşik kümeleme yönteminden daha yüksek sonuçlar elde edilmiştir. “Kümeleme 1”de Kohonen öz örgütlemeli haritalama yönteminde Rand index sonucu 0.63 iken hiyerarşik kümeleme yönteminde 0.45; Kohonen öz örgütlemeli haritalama yönteminde Wallace 10 indeks sonucu 0.34 iken, hiyerarşik kümeleme yönteminde 0.33 bulunmuştur. 4 kümeleme sonucunda da, Kohonen öz örgütlemeli haritalama yöntemi Rand ve Wallace 10 indekslerinde hiyerarşik kümelemeden daha başarılı sonuçlar elde etmiştir. Rand indeks sonuçlarında Kohonen öz örgütlemeli haritalama yönteminin başarı oranı daha yüksek iken, Wallace 10 indeks sonuçlarında iki yöntemden elde edilen değerler birbirine çok yakın olmakla birlikte, Kohonen öz örgütlemeli haritalama yönteminde az da olsa daha yüksek olduğu görülmektedir. Ancak elde edilen 4 kümeleme sonucu incelendiğinde, diğer indekslerde (Fowlkes ve Mallows İndeksi, Wallace 01, Jaccard) hiyerarşik kümeleme yönteminin, Kohonen öz örgütlemeli haritalama yönteminden daha iyi sonuçlar verdiği dikkat çekmektedir. Kinnunen Sidoroff, Tuononen, Fränti (116) kümeleme yöntemlerini karşılaştırdıkları çalışmalarında; kümelerdeki gözlem sayısı azaldığında; hiyerarşik kümeleme yönteminin doğruluk oranının Kohonen öz örgütlemeli haritalama yönteminin doğruluk oranından daha yüksek olduğunu belirtmişlerdir. Bu çalışmanın verilerinde

de bazı kümelerdeki gözlem sayısının az olması, Kohonen öz örgütlemeli haritalama yönteminin beklenen başarıyı gösterememesinde etkili olabilir.

Hiyerarşik kümeleme yönteminin özellikle Wallace 01 indeksinde diğer yöntemlere göre oldukça yüksek değerler aldığı görülmektedir. Hiyerarşik kümeleme yöntemi Wallace 01 indeksinde en yüksek değeri, “Kümeleme 3” te 0.94 değeri ile almış, ancak “Kümeleme 4”te de aynı indekste 0.93 değerine ulaşmıştır. Hiyerarşik kümeleme yöntemi, Wallace 01 indeksinde en düşük değeri (0.39) “Kümeleme 2” de almıştır. “Kümeleme 2”nin 10 gruptan oluştuğu görülmektedir. Küme sayısının fazla olmasının ve kümelere düşen gözlem sayısının az olmasının bu sonuca neden olduğu düşünülebilir.

Palamara, Piglione ve Piccinini (107); kazaları sınıflandırmak için Kohonen öz örgütlemeli haritalama yöntemi ile k-ortalamlar yöntemini iki aşamalı bir yaklaşımla birlikte kullandıkları çalışmada; Kohonen öz örgütlemeli haritalama yöntemi ve k-ortalamlar yönteminin ortalama ağırlıklı doğruluk oranı %92 iken, hiyerarşik kümeleme sonucunda elde edilen ortalama ağırlıklı doğruluk oranı %69 bulunmuştur. Bu çalışmada elde edilen sonuçlar incelendiğinde; indekslere göre yöntemlerin sonuçlarında farklılık görülmekle birlikte, Palamara, Piglione ve Piccinini (107)’nin çalışmalarında olduğu gibi Kohonen öz örgütlemeli haritalama yöntemi ile hiyerarşik kümeleme sonuçları arasında kümeleme performansı açısından büyük bir fark görülmektedir. Bu durum veri yapılarına, veri büyüklüklerine bağlanabileceği gibi Kohonen öz örgütlemeli haritalama yönteminin k-ortalama ile birlikte kullanılmasından da kaynaklanabilir. Literatürde Kohonen öz örgütlemeli haritalama yönteminin başka yöntemlerle birlikte kullanıldığında daha başarılı sonuçlar verdiğine dair sonuçlar bulunmaktadır.

Mangiameli, Chen, West (114)’in, Kohonen öz örgütlemeli haritalama yöntemi ile hiyerarşik kümeleme yöntemlerinin kümeleme performanslarını karşılaştırdıkları çalışmada; Kohonen öz örgütlemeli haritalama yönteminin doğruluk oranı %82.5, tek bağlantı yönteminin doğruluk oranı %33.1, tam bağlantı yönteminin doğruluk oranı 45.2, ortalama bağlantı yönteminin doğruluk oranı %36.6, merkezi bağlantı yönteminin doğruluk oranı %34, Ward yönteminin doğruluk oranı 50.4, k-en yakın komşuluk yönteminin doğruluk oranı %33.2 bulunmuştur. Kohonen öz örgütlemeli

haritalama yöntemi küme elemanlarını, veri setinin %64'ünde diğer hiyerarşik kümeleme yöntemlerinden daha doğru belirlemiştir. Ayrıca çalışmada verilerin %75.8'inde kullanılan hiçbir hiyerarşik kümeleme yönteminin Kohonen öz örgütlemeli haritalama yönteminden daha iyi performans göstermediği belirtilmiştir. Arroyo ve diğerlerinin (112) yaptığı çalışmada; Kohonen öz örgütlemeli haritalama yöntemi, k-ortalamlar ve hiyerarşik kümeleme yöntemleri uygulanmış olup, hiyerarşik kümelemenin başarılı sonuç vermediği belirtilmiştir. Pastukhov ve Prokofiev (117)'in yaptıkları çalışmada; yukarıda belirtilen çalışmada olduğu gibi Kohonen öz örgütlemeli haritalama yöntemi, k-ortalama ve hiyerarşik kümeleme yöntemleri uygulanmış; hata oranları (Kohonen öz örgütlemeli haritalama yöntemi: 0.11; hiyerarşik kümeleme yöntemi: 0.22; k-ortalamlar: 0.23) incelendiğinde en başarılı sonucu Kohonen öz örgütlemeli haritalama yönteminin verdiği belirtilmiştir.

Çalışmanın bu bölümünde şimdiye kadar kümeleme analizi sonuçları tartışılmış olup, çalışma da aynı zamanda Kohonen öz örgütlemeli haritalama yöntemi ile sınıflama analizi de yapıldığından, sınıflama analizi sonucunda elde edilen bulgular ile diğer çalışmalardan elde edilen bulguların tartışmasına geçilmiştir.

Sınıflama analizinde de, kümeleme analizinde olduğu gibi psikotik rahatsızlığa sahip kişiler 4 farklı sisteme göre sınıflara ayrılmış ve sınıflama sonuçları karşılaştırılmıştır.

“Sınıflama 1” incelendiğinde; veriler 9 gruba ayrılmıştır. Gözlem sayısı fazla olan gruplarda, gözlemlerin tamamının doğru sınıflandığı görülmektedir. Gözlemlerin yanlış sınıflandığı gruplar, gözlem sayısı az olan sınıflardır. Örneğin 8. sınıfın 10 kişiden oluştuğu ancak yöntemin bu kişilerden 4'ünü doğru sınıflayabildiği görülmektedir. 9. sınıfta da 10 kişi olmasına rağmen, 6 kişinin doğru sınıflandırıldığı görülmektedir. Ancak gözlem sayısının daha az olduğu 5. sınıf (1 kişi) ve 6. sınıfın (2 kişi), 8. ve 9. sınıftan daha az sayıda gözleme sahip olmasına rağmen doğru sınıflama yapabildiği dikkati çekmektedir. Bu durum hastalık örüntülerindeki farklılıktan, ilgili gruplara ilişkin özelliklerin daha belirgin olmasından kaynaklanıyor olabilir. “Sınıflama 1” sonucunda doğru sınıflama %92, kappa katsayısı %90 ve güven aralığı; 0.8915- 0.9568 olarak bulunmuştur. “Sınıflama 1” e ait; Kohonen öz örgütlemeli haritalama yöntemi tarafından elde edilen özellik

haritası incelendiğinde; gözlem sayıları fazla olan 1. ve 2. sınıfların konumlarının ve kapladıkları alanın net anlaşıldığı, ancak diğer sınıflarda bazı düğümlerde birden fazla hastalığın bir arada bulunduğu görülmektedir. Bu durumun; sınıf sayısının fazla olmasına ve bazı sınıflarda gözlem sayısının az olmasından kaynaklanabileceği düşünülmektedir.

“Sınıflama 2” incelendiğinde; veriler 10 gruba ayrılmıştır. Sınıflama 1’den daha yüksek sınıflama performansına sahiptir. En yüksek prevalansa sahip olan 1., 2. ve 3. kümelerin hatasız sınıflama yaptığı görülmektedir. 5. grup olan katatonik şizofreninin, dezorganize şizofreni ile karıştığı, şizofreniform bozukluğun (6. sınıf) katatonik şizofreni ile karıştığı dikkat çekmektedir. Bu duruma katatonik şizofreni tanısı koyulan kişi sayısının az olması neden olmuş olabilir. Ayrıca başka türlü adlandırılmayan bozukluğa (9. sınıf) sahip bireyler de dezorganize şizofreni olarak sınıflandırılmıştır. 7. sınıf (şizoaffektif bozukluk) da, 9 kişiden 3’ünün doğru sınıflandığı görülmektedir. Doğruluk oranı %94, kappa katsayısı %93 ve güven aralığı 0.9094, 0.9683 olarak bulunmuştur. “Sınıflama 2” e ait; Kohonen öz örgütlemeli haritalama yöntemi tarafından elde edilen özellik haritası incelendiğinde; ilk 3 sınıfın konumlarının ve şekillerinin daha belirgin olduğu, diğer sınıflarda bazılarının sadece bir düğüme görüldüğü (örneğin; 10. sınıf), bazılarının da birden fazla hastalığa sahip kişileri kapsayan daha karmaşık bir yapıya sahip görülmektedir. Az gözleme sahip olan sınıflardaki gözlem sayısının artışı ile sınıfların da daha belirgin olabileceği düşünülmektedir.

“Sınıflama 3” incelendiğinde; veriler 5 gruba ayrılmıştır. 3. sınıf dışında diğer sınıflarda tüm gözlemlerin doğru sınıflandırıldığı görülmektedir. 3. sınıfa (sanrılı bozukluk) ait tanının, başka türlü adlandırılmayan bozukluk ve maddeye ya da tıbbi duruma bağlı bozukluk tanıları ile karıştığı görülmektedir. Bu durumun sanrılı bozukluk tanısına ilişkin verinin azlığından mı yoksa tanılama ile ilgili bir sorundan mı kaynaklandığı araştırılmalıdır. 3. sınıfa (sanrılı bozukluk) ait gözlem sayısı 3, 4. sınıfa (başka türlü adlandırılmayan bozukluk) ait gözlem sayısı 1 olup, 1 gözleme sahip olan sınıfın bu gözlemi doğru sınıflarken, 3 gözleme sahip veride düşük performans göstermesinin nedeni araştırılmalıdır. Doğruluk oranı %99, kappa katsayısı %99 ve güven aralığı 0.9733-0.9991 olarak bulunmuştur. Sınıflama

performansı açısından oldukça yüksek bir başarı sağlandığı görülmektedir. “Sınıflama 3”e ait Kohonen öz örgütlemeli haritalama yöntemi tarafından elde edilen özellik haritası incelendiğinde; sınıf sayısı azaldıkça ve sınıflardaki gözlem sayıları arttıkça özellik haritasının daha belirgin olduğu, grupların daha net anlaşıldığı görülmektedir. Şekil ayrıntılı incelendiğinde; 1., 2. ve 5. sınıfa ait grupların belirgin olduğu, diğer gruplarda birkaç rahatsızlığın bir arada bulunduğu görülmektedir.

“Sınıflama 4” incelendiğinde; veriler 6 gruba ayrılmıştır. İlk 3 grupta tüm gözlemler doğru sınıflanmıştır. “Sınıflama 3”ten farklı olarak, “Sınıflama 4”te, ‘sanrılı bozukluk’ grubunun doğru sınıflandığı dikkat çekmektedir. 5. (Başka türlü adlandırılamayan bozukluk) ve 6.(maddeye ya da tıbbi duruma bağlı bozukluk) grupta yanlış sınıflama yapılmıştır. Başka türlü adlandırılamayan bozukluğun, şizoaftif bozukluk ve sanrılı bozukluk ile karıştığı; maddeye ya da tıbbi duruma bağlı bozukluğa ait gözlemlerden birinin yanlışlıkla şizoaftif bozukluk olarak sınıflandığı görülmektedir. “Sınıflama 4”te de sınıflama oranı yüksek bulunmuştur. Doğruluk oranı %99, kappa katsayısı %98 ve güven aralığı 0.9676-0.9977 olarak bulunmuştur. “Sınıflama 4” e ait; Kohonen öz örgütlemeli haritalama yöntemi tarafından elde edilen özellik haritası incelendiğinde; 1., 3 ve 6. sınıfa ait grupların belirgin olduğu, diğer gruplarda birkaç rahatsızlığın bir arada bulunduğu görülmektedir.

Bu çalışmada Kohonen öz örgütlemeli haritalama yönteminin sınıflama performansı incelendiğinde; sınıflama performanslarının yüksek olduğu görülmektedir. Grup sayısının fazla olduğu 1. ve 2. sınıfta; daha az sayıda gruba ait olan 3. ve 4. sınıfa göre daha düşük oranda başarı sağlanmıştır. Ancak yine de diğer sınıflara göre düşük olan sınıflama doğruluk oranının %94 olduğu göz önünde bulundurulursa, bu yöntemin sınıflama performansının yüksek olduğu düşünülmektedir.

Literatürde Kohonen öz örgütlemeli haritalama yöntemini sınıflama amacıyla kullanan çalışmalar incelendiğinde; aşağıdaki sonuçlar elde edilmiştir:

Vasighi ve Kompany-Zareh (118) sınıflama performanslarını karşılaştırdıkları çalışmalarında; danışmanlı Kohonen öz örgütlemeli haritalama yönteminin;

öğrenmeli vektör kuantalama ve karar destek makinelerinden daha güçlü bir sınıflama yöntemi olduğunu belirtmişlerdir.

Burnap, French, Turner ve Jones (93) tarafından yapılan çalışmada; makine öğrenmesi yöntemleri kullanılarak, yüksek doğruluk oranı ile kötü yazılımların ayırt edilmesi amaçlanmıştır. Daha önce makine öğrenmesi yöntemleri kullanılarak yapılan çalışmalar ile Kohonen öz örgütlemeli haritalama yöntemi kullanılarak yapılan çalışmanın verileri karşılaştırıldığında; Kohonen öz örgütlemeli haritalama yöntemi kullanılarak yapıldığında sınıflama doğruluk oranının % 7.24 ile %25.68 arasında artış gösterdiği sonucuna ulaşılmıştır. Novaes ve diğerleri (119) de yaptıkları çalışmada, Kohonen öz örgütlemeli haritalama yönteminin doğru sınıflama oranını %89; Foroutana, Zimbelman (100) ise Kohonen öz örgütlemeli haritalama yönteminin doğru sınıflama oranını %98 bulmuşlardır. Borges ve diğerleri (120) de yaptıkları çalışmada Kohonen öz örgütlemeli haritalama yönteminin doğru sınıflama yüzdesinin %83.8 ile %95.7 arasında değiştiği sonucuna ulaşmışlardır.

Jardin ve Severin (90), finansal başarısızlığa sahip şirketleri öngörmek amacıyla yaptıkları çalışmada, finansal olarak başarısız şirketleri sınıflamışlardır. Bu çalışmada Kohonen öz örgütlemeli haritalama yönteminin 1 yıllık periyotta doğru sınıflama oranı %81.3, 3 yıllık periyotta %81.2 ve 6 yıllık periyotta %78.6 bulunmuştur.

Hausfeld, Valente, Formisano (97) tarafından MRI verilerin görselleştirmek ve kodlamak için Kohonen öz örgütlemeli haritalama yönteminin uygulandığı çalışmada; danışmanlı Kohonen öz örgütlemeli haritalama yöntemi orta ve büyük sayıda özelliklerde (250-1000 veya daha fazla voxels) k-en yakın komşuluk yönteminden; küçük ve orta dereceli özelliklerde (100-600 vowels) destek vektör makinelerinden daha iyi sonuç vermiştir. Ancak daha büyük sayıda özelliklerde (N800 voxels) de destek vektör makinelerinden daha kötü sonuç vermiştir. Bu sonuç, Kohonen öz örgütlemeli haritalama yönteminin büyük verilerde daha iyi sonuç verdiğini savunan çalışmalarla çelişmektedir.

Konate ve diğerlerinin (96) kayaların sınıflandırılmasında Kohonen öz örgütlemeli haritalama yöntemi ile ileri beslemeli sinir ağlarını karşılaştırmışlardır. Doğru sınıflama oranı eğitim setinde Kohonen öz örgütlemeli haritalama yönteminde %78.8 ile %83.12 arasında, ileri beslemeli sinir ağlarında %70.21 ile %92.32 arasında değişmektedir. Test setinde ise doğru sınıflama oranı Kohonen öz örgütlemeli haritalama yönteminde %77.44 ile %82.75 arasında, ileri beslemeli sinir ağlarında %45.18 ile %86.53 arasında değişmektedir. İleri beslemeli sinir ağları ile Kohonen öz örgütlemeli haritalama yöntemi karşılaştırıldığında; Kohonen öz örgütlemeli haritalama yöntemi daha iyi sonuç vermiştir. Kohonen öz örgütlemeli haritalama yöntemi ortalama %79.86, ileri beslemeli sinir ağları ortalama %72.84 oranında başarılı sonuç vermiştir.

Hu ve Yan (98) ilaç ve toksinlerin potansiyellerini öngörmek için, sınıflama modeli oluşturdukları çalışmalarında; Kohonen öz örgütlemeli haritalama yöntemi ile destek vektör makineleri yöntemlerini kullanmışlardır. Veri seti, rhabdomyolysis içeren 186 ilaç ve toksin ile rhabdomyolysis içermeyen 117 ilaç içermektedir. Eğitim setinde Kohonen öz örgütlemeli haritalama yönteminin doğru sınıflama oranı %93.3, destek vektör makinelerinin doğru sınıflama oranı %95.2 iken test setinde Kohonen öz örgütlemeli haritalama yönteminin doğru sınıflama oranı %84.5, destek vektör makinelerinin doğru sınıflama oranı %84.9'dur. Sonuç olarak iki yöntemde de benzer sonuçlar elde edildiği ve her iki yönteminde sınıflamada başarılı olduğu düşünülmüştür.

Yan, Nie, Wang, Wang (26) 512 Aurora-A ve B inhibitör bileşikler toplanan çalışmada, Kohonen öz örgütlemeli haritalama yöntemi ve destek vektör makinelerinin kullanılarak, veri üç sınıfa ayrılmıştır. Kohonen öz örgütlemeli haritalama yönteminde modelin doğruluğu %92,2, destek vektör makinelerinde %93.8 bulunmuştur. İki yönteminde birbirine benzer performans gösterdiği görülmektedir.

Tez çalışmasının bu bölümünde; Kohonen öz örgütlemeli haritalama yönteminin genel olarak kullanım alanları ve sonuçları hakkında bilgi verdikten sonra, literatür incelendiğinde; Kohonen yönteminin sağlık alanında özellikle de ruh sağlığı ve

hastalıkları alanında kullanımının diğer alanlarla karşılaştırıldığında daha sınırlı olduğu görülmektedir.

Ruh sağlığı alanında Kohonen öz örgütlemeli haritalama yönteminin kullanıldığı çalışmalar incelenecek olursa; Fekihal ve Yousif (121) tarafından Kohonen yönteminin ruhsal hastalıkları sınıflandırılmasında, Kazas ve Margaliot (83) ruhsal bozuklukları topolojik olarak görselleştirmesi ve kümelenmesinde, Skupin, Biberstine ve Börner (122) metin madenciliğinde Kohonen öz örgütlemeli haritalama yöntemi kullanılarak tıbbi bilginin görselleştirilmesinde, Honkela, Leinonen, Lonka ve Raika (123) Kohonen öz örgütlemeli haritalama yönteminde çıkarımsal öğrenmeyi sağlamada, Sumathi ve Poorna (81) çocuklarda ruhsal rahatsızlıklara tanı koymada, Schilithz, Kale, Gama ve Nobre (124) farklı risk gruplarındaki çocukların profillerini tanımlamada, Chung ve diğerleri (80) ruh sağlığı planlamasında karar desteği sağlama ve hastalıkları tiplendirme amacıyla Kohonen öz örgütlemeli haritalama yöntemini kullanmışlardır.

Ayrıca ruhsal hastalıklara tanı koymak için Kohonen öz örgütlemeli haritalama yöntemi dışında başka yöntemlerin de kullanıldığı görülmektedir. Diederich, Al-Ajmi, Yellowlees (82) ruh sağlığı hastalıklarını tanımlamak için destek vektör makinelerini, Dabek, Filip, and Jesus J. Caban (125) anksiyete, davranış bozukluğu, depresyon ve travma sonrası stres bozukluğunun gelişmesini öngörmek amacıyla sinir ağlarını, Imianvan ve Obi. (126) bipolar rahatsızlığa tanı koymak için fuzzy mantık yöntemini, Lopes ve diğerleri (127) ruhsal bozukluk faktörlerini analiz etmek için çok katmanlı algılayıcıyı, Mabruk ve Joachim (121) kümeleme ve sınıflama teknikleri kullanılarak psikiyatrik bozuklukları belirlemek için metin madenciliğini kullanmışlardır.

Ruhsal rahatsızlıklarla ilgili yapılan çalışmalar incelendiğinde, k-ortalamlar yönteminin de kullanıldığı görülmektedir. Loo ve diğerleri (128) majör depresyonun alt tiplerini belirlemek, Bhojrah ve diğerleri (78) şizofreni hastalarının genç akrabalarında bilişsel eksiklikleri belirlemek, Lee ve diğerleri (129), baba yaşına bağlı şizofrenide alt tipleri belirlemek, Hall ve diğerleri (130) şizofreni ve bipolar bozuklukta beyin fonksiyonlarında farklı örüntüleri kümelemek, Bell ve diğerleri (131) şizofreni de bilişsel, nörokognitif ve demografik alanlardaki farklılıkları ortaya çıkarmak, Deckersbach ve diğerleri (132) bipolar bozuklukta klinik profili belirlemek amacıyla k-ortalamlar yöntemini kullanmışlardır.

6. SONUÇ ve ÖNERİLER

6.1. Sonuçlar

Kohonen öz örgütlemeli haritalama yöntemi, etkili bir kümeleme tekniğidir (133). Genel olarak kümeleme amacıyla kullanılmasına rağmen sınıflamada yapabilmektedir.

Kohonen öz örgütlemeli haritalama yöntemi; sinir ağları algoritmaları içerisinde en güçlü öğrenme stratejilerin biri olarak değerlendirilmektedir (109).

Kohonen öz örgütlemeli haritalama yönteminin; çıkarımsal öğrenmeye katkı sağladığı belirtilmektedir. Bireylerin öğrenme sürecini kendilerinin aktif katılımı ile bilgiyi keşfederek, araştırarak elde etmelerini, ilgilenilen alanla ilgili kavramsal ilişkileri yorumlayabilmelerini sağlamaktadır (123).

Kohonen yöntemi diğer yöntemlerden farklı olarak; doğrusal olmayan, çok boyutlu verileri, iki boyuta indirgemekte, değişkenler arasındaki ilişkileri ortaya çıkarmaktadır. Yöntemin bu özelliği konunun kavranmasını kolaylaştırmaktadır.

Bu tez çalışmasında elde edilen sonuçlar incelendiğinde, Kohonen öz örgütlemeli haritalama yönteminde sınıflama açısından yüksek değerler elde edilmiştir. Ancak kümeleme performansı diğer kümeleme yöntemleri ile karşılaştırıldığında, tüm indekslerde yüksek başarı elde edemediği görülmektedir. Bir indeks (Rand indeksi) dışında, diğer indekslerde ya benzer sonuçlar elde edildiği ya da diğer yöntemlerin Kohonen öz örgütlemeli haritalama yönteminden daha başarılı sonuçlar elde edildiği dikkat çekmektedir. Bu sonucun elde edilmesinde; örneklem sayısının az olması ve küme/sınıf sayısının fazla olmasının etkili olduğu düşünülmektedir. Sonuçlar incelendiğinde; “Kümeleme 3” te kümeleme ve sınıflama başarı oranının daha yüksek olduğu görülmektedir. “Kümeleme 3” te küme sayısının daha az olduğu görülmektedir. Küme sayısı azaldıkça, yöntemin başarısının arttığı ve tabloların anlaşılabilirliğinin arttığı söylenebilir.

Kohonen öz örgütlemeli haritalama yöntemi; büyük verileri hızlı analiz etmesi, verideki bilinmeyen ilişkileri ortaya çıkarması ve veri görselleştirmeadaki başarı nedeniyle tercih edilmektedir. Kohonen yönteminde; her bir nöronun (ya da düğümün) ayrı bir kümeyi temsil etmesi, her birinin renklerinin farklı olması,

kümeler arasındaki uzaklıkların görülebilmesi ve komşuluk ilişkisi sayesinde, konum olarak birbirine yakın kümelerin arasındaki benzerliğin bir göstergesi olması, sonuçların daha anlaşılır olması açısından önemlidir.

6.2. Öneriler:

1. Kohonen öz örgütlemeli haritalama yönteminin kendine has özelliklerinin (harita büyüklüğü, öğrenme oranı, komşuluk oranı, nöron büyüklüğü vb.), alınacak sonuç üzerinde etkili olduğu göz önünde bulundurulmalıdır. Nöron büyüklüğünün Kohonen öz örgütlemeli haritalama yönteminin sınıflama performansı üzerinde etkili olduğu (134); harita büyüklüğünün sınıflamanın doğruluğunu etkileyen faktörlerden birisi olduğu (93), eğitim algoritması, öğrenme oranı ve ağırlık şeklinin sonuçlar üzerinde etkili olduğu (109), kullanılan uzaklık ölçümüne (örneğin; Öklid ya da Tanimoto) göre sonuçların değiştiği belirtilmektedir. Bu nedenle; Kohonen öz örgütlemeli haritalama yönteminin özellikleri göz önünde bulundurularak, parametrelere farklı değerler verilmesi (örneğin nöronları farklı şekillerle incelemek, farklı uzaklık ölçümleri ya da öğrenme oranları kullanmak vb.) ve elde edilen sonuçların incelenerek, hangi sonucun kullanılacağına, konunun uzmanı kişilerle karar verilmesi önerilmektedir.
2. Kohonen öz örgütlemeli haritalama yönteminin pek çok alanda uygulanmakla birlikte sağlık alanında (özellik ruh sağlığı alanında) yapılan çalışma sayısının daha az olması nedeniyle sağlık alanında daha fazla uygulama yapılması, daha büyük veride uygulanması önerilmektedir.
3. Literatürde Kohonen yönteminin başka yöntemlerle birlikte uygulandığında daha başarılı sonuçlar verdiğine dair bilgiler bulunmaktadır. Bu nedenle Kohonen yönteminin başka yöntemlerle birlikte kullanılması da önerilmektedir.
4. Kohonen öz örgütlemeli haritalama yönteminin hızlı ve maliyetinin düşük olmasından dolayı, veri analiz yöntemi olarak kullanılması önerilmektedir.

7. KAYNAKÇA

1. Mayer-Schönberger V, Cukier K. Büyük veri. İstanbul: Paloma Yayınevi; 2013.
2. Venkatram, K. Geetha, M.A. Review on Big Data&Analytics-Concepts, Philosophy, Process and Applications. Cybernetics and Information Technologies. 2017;17 (2): 3-27.
3. Terzi R, Sağıroğlu Ş, Demirezen U. Büyük veri ve açık veri: temel kavramlar. Sağıroğlu Ş, Koç O, editörler. Büyük veri ve açık veri analitiği: yöntemler ve uygulamalar kitapçığı. Ankara: Grafiker Yayınları; 2016.
4. Erl T, Wajid K, Buhler P. Big data fundamentals, concepts, drivers & techniques. Indiana: Arcitura Education Inc; 2016.
5. Hilbert M. Big data for development: from information-to knowledge societies. Rochester, NY: Social Science Research Network; 2013. <http://ssrn.com/abstract=2205145>.
6. Zorlu, E. Big data [Internet]. 2014 [Erişim Tarihi 11 Nisan 2017]. Erişim adresi: <https://emrezorlu.com/tag/big-data-5v/>
7. Firican, G. The 10 vs of big data [Internet]. 2017 [Erişim Tarihi 24 Ocak 2018]. Erişim Adresi: <https://tdwi.org/articles/2017/02/08/10-vs-of-big-data.aspx>.
8. Sumathi S, Sivanandan SN. Introduction to data mining and its applications. Berlin: Springer; 2016.
9. Mehta, J., & Gawande, A. D. A purpose of data mining in banking sector. International Journal of Advance Research in Computer Science and Management Studies. 2015; 3(3): 407-411.
10. Huebner, R.A. A Quantitative analysis of organizational factors that relate to data mining success [PhD thesis]. United States: Capella University; 2017.

11. Nisbet R, Elder J, Miner G. Handbook of statistical analysis and data mining applications. USA: Academic Press; 2009.
12. Wook, M., Zawiyah, M. Y., & Mohd Zakree Ahmad, N. Data Mining Technology Adoption in Institutions of Higher Learning: A Conceptual Framework Incorporating Technology Readiness Index Model and Technology Acceptance Model 3. Journal of Applied Sciences. 2014; 14(18): 2129-2138.
13. Sotomane, C. Factors affecting the use of data mining in Mozambique: Towards a framework to facilitate the use of data mining [Master thesis]. Sweden: Stockholm University; 2014.
14. Piatetsky-Shapiro G, Fawley WJ. Knowledge discovery in databases. Boston: AAAI/MIT Press; 1991.
15. Ögüt, S. Veri Madenciligi kavramı ve gelişim süreci [Internet]. 2009 [Erişim Tarihi 1 Aralık 2013]. Erişim adresi: http://www.sertacogut.com/blog/wp-content/uploads/2009/03/sertac_ogut__veri_madenciligi_kavrami_ve_gelisim_sureci.pdf
16. Han J, Kamber M. Data mining: concepts and techniques. 2th ed. USA: Elsevier; 2006.
17. Yücel O. Development of A Data Mining Software on Higher Educational Data [Yüksek lisans tezi]. İstanbul: Boğaziçi Üniversitesi; 2012.
18. Coenen, F. Data mining: past, present and future. The Knowledge Engineering Review. 2011; 26(1): 25-29.
19. Fayyad, U., & Stolorz, P. Data mining and KDD: Promise and challenges. Future Generation Computer Systems. 1997; 13(2-3): 99-115.
20. Coy P. He who mines data may strike fool's gold. BusinessWeek. 1997; 3531:40.
21. Hand D, Mannila H, Smyth P. Principles of data mining. england: a bradford book. Boston: MIT Press; 2001.

22. Esfandiari N, Babavalian R.M, Moghadam E.A, Tabar V.K. Knowledge Discovery in Medicine: Current Issue and Future Trend. *Expert Systems with Applications*. 2014; 41: 4434-4463.
23. Giudici P. *Applied data mining: statistical methods for business and industry*. New York & London: Wiley; 2003.
24. Edelstein HA. (Ed.) *Introduction to data mining and knowledge discovery*. 3th ed. Maryland: Two Crows Corporation; 1999.
25. Kaddouri A. *The role of human expertise in enhancing data mining*. Capella University; 2011.
26. Yan A, Nie X, Wang K, Wang M. Classification of Aurora kinase inhibitors by self-organizing map (SOM) and support vector machine (SVM). *Eur J Med Chem*. Elsevier; 2013;61:73–83.
27. Farboudi, S. *Tıp Bilişiminde İstatistiksel Veri Madenciliği [Yüksek lisans tezi]*. Ankara: Hacettepe Üniversitesi; 2009.
28. Cios J. K, Moore W. G. Uniqueness of Medical Data Mining. *Artificial Intelligence in Medicine*. 2002; 26: 1-24.
29. Lavrac N. Selected Techniques for Data Mining in Medicine. *Artificial Intelligence in Medicine*. 1999; 16: 3-23.
30. Desikan P, Hsu KW, Srivastava J. Data mining for healthcare management [Internet]. 2011 [Erişim Tarihi 28 Kasım 2017]. Erişim adresi: <http://siam.omnibooksonline.com/2011datamining/data/papers/WS06.pdf>
31. Alpar R. *Uygulamalı çok değişkenli istatistiksel yöntemler*. 4. Baskı. Ankara: Detay Yayıncılık; 2013.
32. Mirkin B. *Clustering for data mining a data recovery approach, computer science and data analysis series*. London: Chapman&Hall/CRC; 2005.
33. Cornish, R. Statistics: 3.1 cluster analysis [Internet]. 2007 [Erişim Tarihi 12 Kasım 2017]. Erişim adresi: www.statstutor.ac.uk/resources/uploaded/clusteranalysis.pdf

34. Velmurugan T. Performance Based Analysis Between K-Means and Fuzzy C-Means Clustering Algorithms for Connection Oriented Telecommunication Data. *Applied Soft Computing*. 2014; 19; 134-146.
35. Aldenderfer MS, Blashfield RK. Cluster analysis. London: Sage Publications; 1984.
36. Everitt BS, Landau S, Leese M, Stahl D, et al. Cluster analysis. London: Wiley; 2011.
37. Jain A.K. Data Clustering: 50 Years Beyond K-means. *Pattern Recognition Letters*. 2010; 31; 651-666.
38. Korkmaz M. Alacahan NB. Taştan SB. Perakende Gıda market Mağazacılığında Tüketici Talebi, Akademik Bakış Dergisi, Sayı 35, sayfa:1-22. 2013. <http://tip.baskent.edu.tr/kw/upload/600/dosyalar/cg/sempozyum/ogrsmmpzsnm13/13.P9.pdf>.
39. Akın Koldere Y. Veri Madenciliğinde Kümeleme Algoritmaları Ve Kümeleme Analizi [Doktora tezi]. İstanbul: Marmara Üniversitesi; 2008.
40. Yalçın N. Kümeleme Analizi ve Uygulaması [Yüksek lisans tezi]. Elazığ: Fırat Üniversitesi; 2013.
41. Abonyi J, Feil B. Cluster analysis for data mining and system identification. Germany: Birkhauser; 2007.
42. Erar B. Mixture Model Cluster Analysis Under Different Covariance Structures Using Information Complexity [Master thesis]. Knoxville: Tennessee Üniversitesi; 2011.
43. Cai R., Zhang Z., Tung A.K.H., Dai C., Hao Z. A General Framework of Hierarchical Clustering and Its Applications. *Information Sciences*. 2014; 272; 29-48.
44. Irmak S. Veri Madenciliği Yöntemleri ile Sağlık Sektörü Veritabanlarında Bilgi Keşfi: Tanımlayıcı ve Kestirimci Model Uygulamaları [Doktora tezi]. Antalya: Akdeniz Üniversitesi; 2009.

45. Tryfos P. Methods for Business Analysis and Forecasting: Text and Cases. Chapter 16: Cluster Analysis. John Wiley and Sons, New York; 1997.
46. Yazdanoğlu D. Comparing Clustering Methods Based on Lyfestyle Trends [Yüksek lisans tezi]. İstanbul: Bahçeşehir Üniversitesi; 2011.
47. Andritsos P. Scable Clustering of Categorical Data and Applications [PhD thesis]. Toronto: Toronto Üniversty; 2004.
48. Tzortzis, G., Likas, A. The MinMax K-Means Clustering Algorithm. Pattern Recognition. 2014; 47: 2505-2516.
49. Hofstadter D. Gödel, escher, bach: bir ebedi gökçe belik. İstanbul: Pinhan Yayıncılık; 2011.
50. Jafarzadeh S. A Probabilistic Dynamic Security Assessment of Large Power Systems Using Artificial Neural Networks [Master thesis]. İstanbul: Istanbul Technical University; 2017.
51. Ataseven B. Yapay Sinir Ağları İle Öngörü Modellemesi. Öneri Dergisi. 2013; 10(39): 101-115.
52. Taşhan B. Road Lane Detection System With Convolutional Neural Network [Master thesis]. İstanbul: The Republic Of Turkey Bahçeşehir University; 2017.
53. Artificial neural networks technology [Internet]. 2016 [Erişim Tarihi: 12 Aralık 2017]. Erişim adresi: <http://www.psych.utoronto.ca/users/reingold/courses/ai/cache/neural3.html>
54. Şengöz, N. Yapay sinir ağları [Internet]. 2017 [Erişim Tarihi: 11 Aralık 2017]. Erişim adresi: www.derinogrenme.com/2017/03/04/yapay-sinir-aglari
55. Ergezer H, Dikmen M, Özdemir E. Yapay sinir ağları ve tanıma sistemleri [Internet]. 2003 [Erişim Tarihi: 11 Aralık 2017]. Erişim adresi: http://www.elyadal.org/PiVOLKA/06/PiVOLKA_06_05.pdf
56. Ağyar Z. Yapay Sinir Ağlarının Kullanım Alanları ve Bir Uygulama. Mühendis ve Makine Dergisi. Yıl Belirtilmemiş; 56(662): 22-23.

- (http://www1.mmo.org.tr/resimler/dosya_ekler/1e0e9686a06655f_ek.pdf?dergi=1533)
57. Guthikonda S, Kohonen M. Self-organizing maps. Ohio: Wittenberg University Press; 2005.
 58. Self-organizing map [Internet]. 2011 [Eriřim Tarihi: 2 Aralık 2017]. Eriřim adresi: <https://en.wikipedia.org/index.php?q=aHR0cHM6Ly9lb3dpcGVkaWEub3JnL3dpa2kvU2VsZi1vcmdhbml6aW5nX21hcA>
 59. Kohonen networks [İnternet]. 1996 [Eriřim Tarihi: 21 Nisan 2018]. Eriřim adresi: <https://page.mi.fu-berlin.de/rojas/neural/chapter/K15.pdf>
 60. Ersoy E, Karal Ö. Yapay Sinir Ağları ve İnsan Beyni. İnsan ve Toplum Bilimleri Arařtırma Dergisi. 2012; 1(2): 188-205.
 61. Herbert J. A New Approach to Competitive Learning in self-Organizing Maps [Master of Science]. Canada: University of Regina; 2006.
 62. Chaudhary V, Bhatia R.S, Ahlawat A. K. A Novel Self-Irganizing Map Learning Algorithm with Nearest and Farthest Neuron. Alexandria Engineering Journal. 2014; 53:827-831.
 63. Demirhan A. Beyin MR Görüntülerinin Dalgacık Dönüřümü ve Öz Örgütlemeli Harita Ağları Kullanılarak Bölütlenmesi [Doktora tezi].Ankara: Gazi Üniversitesi; 2012.
 64. Pourkia J. A Self-Organizing Map Approach for Hospital Data Analysis [Master of Science]. Carbondale: Southern Illinois University; 2014.
 65. Ghaseminezhad M.H, Karami A. A novel self-organizing map (SOM) neural network for discrete groups of data clustering. Applied Soft Computing. 2011; 11: 3771–3778.
 66. Kohonen T. Essentials of the self-organizing map. Neural Networks. 2013; 37: 52-65.

67. Deboeck G, Kohonen T. Visual explorations in finance with self-organizing maps. 2th ed. London: Springer; 2000. Introduction, Self-organizing maps; xxxiv-xxxvi.
68. Valovaa I, Georgievb G , Gueorguievac N, Olsona J. Initialization Issues in Self-organizing Maps. Procedia Computer Science. 2013; 20: 52 – 57.
69. Bulut E. Öz Örgütlemeli (Kohonen) Haritalar ile Yer Seçimi ve Kaynak Ataması Probleminin Çözümü ve Bir Uygulama [Yüksek lisans tezi]. İstanbul: İstanbul Üniversitesi; 2008.
70. Kohonen T. Self organizing maps. 3th ed. London: Springer; 2001. Chapter 3, The basic SOM; 105-176.
71. Deboeck G, Kohonen T. Visual explorations in finance with self-organizing maps. 2th ed. London: Springer; 2000. Chapter 15, Best practices in data mining using self-organizing maps; 203-229.
72. Guerrero J, Marcelli D, Soria-Olivas E, Mari F, Martinez J, Bech I, et al. Self-Organizing Maps: A New Way to Screen the Level of Satisfaction of Dialysis Patients. Expert systems with applications. 2012; 39: 8793-8798.
73. Deboeck G, Kohonen T. Visual explorations in finance with self-organizing maps. 2th ed. London: Springer; 2000. Chapter 11, The SOM Methodology; 159-167.
74. Shieh S-L, Liao I-E. A new approach for data clustering and visualization using self organizing maps. Expert Systems with Applications. 2012; 39:11924-11933.
75. Sarıdoğan M. Öz Örgütlemeli (Kohonen) Haritalar ile Esnek Üretimde Yer Alan Otomatik Güdümlü Araçların (OGA) Rotalarının Belirlenmesi [Yüksek lisans tezi]. İstanbul: İstanbul Üniversitesi; 2009.
76. Yousif JH, Fekihal MA. Neural Approach for Determining Mental Health Problems. J Comput. 2012;4(1):6–11.
77. Öztürk O. Ruh Sağlığı ve Bozuklukları. 9. Baskı. Ankara: Nobel Tıp Kitabevleri; 2002. Bölüm XIV, Ruhsal Bozukluklarda Tanı ve Sınıflandırma; 183, 202.

78. Bhojraj TS, Francis AN, Montrose DM, Keshavan MS. Grey matter and cognitive deficits in young relatives of schizophrenia patients. *Neuroimage*. Elsevier; 2011;54:S287–92.
79. Sorias S. Bilimsel Devrimler ve Yeni Kraepelincilik. *Klinik Psikiyatri*. 2011; 14: 51-58.
80. Chung Y, Salvador-Carulla L, Salinas-Pérez JA, Uriarte-Uriarte JJ, Iruin-Sanz A, García-Alonso CR. Use of the self-organising map network (SOMNet) as a decision support system for regional mental health planning. *Heal Res policy Syst. BioMed Central*; 2018;16(1):35.
81. Sumathi MR, Poorna B. Prediction of mental health problems among children using machine learning techniques. *Int J Adv Comput Sci Appl. SCIENCE & Information Sai Organization Ltd 19 Bolling Rd, Bradford, West Yorkshire, England*; 2016;7(1):552–7.
82. Diederich J, Al-Ajmi A, Yellowlees P. Ex-ray: Data mining and mental health. *Appl Soft Comput*. Elsevier; 2007;7(3):923–8.
83. Kazas G, Margaliot M. Visualizing the topology of mental disorders using self-organizing feature maps * [Internet]. p. 1–21. Available from: <https://www.eng.tau.ac.il/~michaelm/kazas.pdf>
84. Package ‘profdpm’ [Internet]. 2015 [Erişim Tarihi: 21 Nisan 2018]. Erişim Adresi: <https://cran.r-project.org/web/packages/profdpm/profdpm.pdf>.
85. Clustering Algorithms and Evaluations [Internet]. Yıl belirtilmemiş [Erişim Tarihi: 21 Nisan 2018]. Erişim Adresi: <http://www.ims.uni-stuttgart.de/institut/mitarbeiter/schulte/theses/phd/algorithm.pdf>.
86. Ansari Z, Azeem M.F., Ahmed W, Babu A.W. Quantitative Evaluation of Performance and Validity Indices for Clustering the Web Navigational Sessions. *World of Computer Science and Information Technology Journal (WCSIT)*. 2011; 1 (5): 217-226.

87. Tanju Ö. Cluster Based Model Diagnostic for Logistic Regression [The Degree of Master of Science]. Ankara: Middle East Technical University; 2016.
88. Denœud L, Guénoche A. Comparison of distance indices between partitions. In *Data Science and Classification* (pp. 21-28). Springer, Berlin, Heidelberg; 2006.
89. Downton M, Brennan T. Comparing classifications: an evaluation of several coefficients of partition agreement. *Class Soc Bull* 1980; 4(4):53–54
90. Demirkan M. Kategorik ve Kategorik Olmayan Verilerden Oluşan Veri Setleri için Kortalama Tabanlı Bir Yaklaşım [Yüksek Lisans Tezi]. İstanbul: Beykent Üniversitesi; 2014.
91. Sivri E.Ş. Veri Madenciliği/E-Ticaret İçin Ürün Tavsiye Sistemi Geliştirilmesi [Yüksek Lisans Tezi]. İstanbul: İstanbul Ticaret Üniversitesi; 2015.
92. Philippopoulos K, Deligiorgi D, Kouroupetroglou G. Performance Comparison of Self-Organizing Maps and k-means Clustering Techniques for Atmospheric Circulation Classification. *methods*. 13:14.
93. Burnap P, French R, Turner F, Jones K. Malware classification using self organising feature maps and machine activity data. *Comput Secur. Elsevier*; 2018;73:399–410.
94. du Jardin P, Séverin E. Forecasting financial failure using a Kohonen map: A comparative study to improve model stability over time. *Eur J Oper Res. Elsevier*; 2012;221(2):378–96.
95. Mostafa MM. A psycho-cognitive segmentation of organ donors in Egypt using Kohonen's self-organizing maps. *Expert Syst Appl. Elsevier*; 2011;38(6):6906–15.
96. Konaté AA, Pan H, Fang S, Asim S, Ziggah YY, Deng C, et al. Capability of self-organizing map neural network in geophysical log data classification: Case study from the CCSD-MH. *J Appl Geophys. Elsevier*; 2015;118:37–46.
97. Hausfeld L, Valente G, Formisano E. Multiclass fMRI data decoding and visualization using supervised self-organizing maps. *Neuroimage. Elsevier*; 2014;96:54–66.

98. Hu X, Yan A. In silico prediction of rhabdomyolysis of compounds by self-organizing map and support vector machine. *Toxicol Vitr.* Elsevier; 2011;25(8):2017–24.
99. Mostafa MM. Clustering the ecological footprint of nations using Kohonen's self-organizing maps. *Expert Syst Appl.* Elsevier; 2010;37(4):2747–55.
100. Foroutan M, Zimbelman JR. Semi-automatic mapping of linear-trending bedforms using 'self-organizing maps' algorithm. *Geomorphology.* Elsevier; 2017;293:156–66.
101. Taşkın Ç, Emel GG. Veri madenciliğinde kümeleme yaklaşımları ve Kohonen ağları ile perakendecilik sektöründe bir uygulama. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilim Fakültesi Derg.* 2010;15(3).
102. Reis S, Taşdemir K. Fındık alanlarının kendini örgütleyen eşlemlerle (self organizing maps) belirlenmesi. III. Uzaktan Algı ve Coğrafi Bilgi Sistemleri Sempozyumu, 11-13 October 2010, Gebze.
103. Nouri F, Şengör NS. Öz-düzenlemeli Ağ Yapısı ile Farklı Yaklaşımların Sınanması Testing Different Approaches by Self Organizing Map. *ELECO '2012 Elektrik - Elektronik ve Bilgisayar Mühendisliği Sempozyumu*, Bursa, 29 Kasım - 01 Aralık 2012; 557-561. http://www.emo.org.tr/ekler/b68ce4b5e1e39c5_ek.pdf
104. Oğuzlar A. Kümeleme Analizinde Yeni Bir Yaklaşım: Kendini Düzenleyen Haritalar (Kohonen Ağları). *Atatürk Üniversitesi İktisadi ve İdari Bilim Derg.* 2005;19(2).
105. İdil NB. Gen ifade verileri ile işlemsel kanser sınıflandırılması. *Başkent Üniversitesi Fen Bilimleri Entitüsü*; 2009.
106. Olszewski D. Fraud detection using self-organizing map visualizing the user profiles. *Knowledge-Based Syst.* Elsevier; 2014;70:324–34.
107. F, Piglion F, Piccinini N. Self-Organizing Map and clustering algorithms for the analysis of occupational accident databases. *Saf Sci.* Elsevier; 2011;49(8–9):1215–30.

108. Roh B-R, Jung EH, Hong HJ. A Comparative Study of Suicide Rates among 10–19-Year-Olds in 29 OECD Countries. *Psychiatry Investig. Korean Neuropsychiatric Association*; 2018;15(4):376.
109. Ballabio D, Vasighi M, Filzmoser P. Effects of supervised Self Organising Maps parameters on classification performance. *Anal Chim Acta. Elsevier*; 2013;765:45–53.
110. Melssen W, Wehrens R, Buydens L. Supervised Kohonen networks for classification problems. *Chemom Intell Lab Syst. Elsevier*; 2006;83(2):99–113.
111. Llanos J, Morales R, Núñez A, Sáez D, Lacalle M, Marín LG, et al. Load estimation for microgrid planning based on a self-organizing map methodology. *Appl Soft Comput. Elsevier*; 2017;53:323–35.
112. Arroyo, V. et al. Definition and diagnostic criteria of refractory ascites and hepatorenal syndrome in cirrhosis. *Hepatology*, 1996; 23(1), 164-176.
113. Bação F, Lobo V, Painho M. Self-organizing maps as substitutes for k-means clustering. In *International Conference on Computational Science*, 2005; (pp. 476-483). Springer, Berlin, Heidelberg.
114. Chen N, Ribeiro B, Vieira A, Chen A. Clustering and visualization of bankruptcy trajectory using self-organizing map. *Expert Syst Appl. Elsevier*; 2013;40(1):385–93.
115. Segev A, Kantola J. Identification of trends from patents using self-organizing maps. *Expert Syst Appl. Elsevier*; 2012;39(18):13235–42.
116. Kinnunen T, Sidoroff I, Tuononen M, Fränti P. Comparison of clustering methods: A case study of text-independent speaker modeling. *Pattern Recognit Lett. Elsevier*; 2011;32(13):1604–17.
117. Pastukhov AA, Prokofiev AA. Kohonen self-organizing map application to representative sample formation in the training of the multilayer perceptron. *St Petersburg Polytech Univ J Phys Math. Elsevier*; 2016;2(2):134–43.

118. Vasighi M, Kompany-Zareh M. Classification ability of self organizing maps in comparison with other classification methods. *MATCH Commun Math Comput Chem*. 2013;70:29–44.
119. Novaes CG, da Silva Romão IL, Santos BG, Ribeiro JP, Bezerra MA, da Silva EGP. Screening of *Passiflora L.* mineral content using principal component analysis and Kohonen self-organizing maps. *Food Chem. Elsevier*; 2017;233:507–13.
120. Borges C, Gómez-Carracedo MP, Andrade JM, Duarte MF, Biscaya JL, Aires-de-Sousa J. Geographical classification of weathered crude oil samples with unsupervised self-organizing maps and a consensus criterion. *Chemom Intell Lab Syst. Elsevier*; 2010;101(1):43–55.
121. Fekihal MA, Yousif JH. Self-organizing map approach for identifying mental disorders. *Int J Comput Appl [Internet]. International Journal of Computer Applications*, 244 5 th Avenue,# 1526, New York, NY 10001, USA India; 2012;45(7). Available from: <https://www.eng.tau.ac.il/~michaelm/kazas.pdf>
122. Skupin A, Biberstine JR, Börner K. Visualizing the topical structure of the medical sciences: a self-organizing map approach. *PLoS One. Public Library of Science*; 2013;8(3):e58779.
123. Honkela T, Leinonen T, Lonka K, Raike A. Self-organizing maps and constructive learning. In: *Proceedings of the International Conference on Educational Uses of Communication and Information Technologies, ICEUT*. 2000. p. 339–43.
124. Schilithz AOC, Kale PL, Gama SGN, Nobre FF. Risk groups in children under six months of age using self-organizing maps. *Comput Methods Programs Biomed. Elsevier*; 2014;115(1):1–10.
125. Dabek F, Caban JJ. A neural network based model for predicting psychological conditions. In *International Conference on Brain Informatics and Health*, 2015; (pp. 252-261). Springer, Cham.
126. Imianvan AA, Obi JC. Fuzzy cluster means expert system for the diagnosis of Tuberculosis. *Glob J Comput Sci Technol*. 2011.

127. Lopes CRS, Ludermir TB, de Souto MCP, Ludermir AB. Neural networks for the analysis of common mental disorders factors. In: Neural Networks, 2002 SBRN 2002 Proceedings VII Brazilian Symposium on. IEEE; 2002. p. 114.
128. Loo HM, Cai T, Gruber MJ, Li J, Jonge P, Petukhova M, et al. Major depressive disorder subtypes to predict long-term course. *Depress Anxiety*. Wiley Online Library; 2014;31(9):765–77.
129. Lee H, Malaspina D, Ahn H, Perrin M, Opler MG, Kleinhaus K, et al. Paternal age related schizophrenia (PARS): latent subgroups detected by k-means clustering analysis. *Schizophr Res*. Elsevier; 2011;128(1):143–9.
130. Hall M-H, Smoller JW, Cook NR, Schulze K, Lee PH, Taylor G, et al. Patterns of deficits in brain function in bipolar disorder and schizophrenia: a cluster analytic study. *Psychiatry Res*. Elsevier; 2012;200(2):272–80.
131. Bell MD, Johannesen JK, Greig TC, Wexler BE. Memory profiles in schizophrenia: categorization validity and stability. *Schizophr Res*. Elsevier; 2010;118(1):26–33.
132. Deckersbach T, Peters AT, Sylvia LG, Gold AK, da Silva Magalhaes PV, Henry DB, et al. A cluster analytic approach to identifying predictors and moderators of psychosocial treatment for bipolar depression: Results from STEP-BD. *J Affect Disord*. Elsevier; 2016;203:152–7.
133. Pastukhov AA, Prokofiev AA. Clustering algorithms application to forming a representative sample in the training of a multilayer perceptron. *St Petersburg Polytech Univ J Phys Math*. Elsevier; 2017;3(2):127–34.
134. Bungum L, Gambäck B. Self-Organizing Maps for Classification of a Multi-Labeled Corpus. International Institute of Information Technology Trivandrum, India; 2015.

8. EKLER

EK-1

Hastanın Adı, Soyadı:	Tarih:
Hastanın Yaşı ve Cinsiyeti:	Değerlendiren:

GLOBAL DEĞERLENDİRME ÖLÇEĞİ (GAS)

Mental sağlık-hastalık'ın varsayımsal sürekliliği üzerinde psikolojik, toplumsal ve mesleki işlevselliği göz önünde bulundurunuz. Fiziksel (ya da çevresel) kısıtlamalara bağlı işlevsellik bozulmalarını bu kapsam içinde değerlendirmeyiniz.

Kod	(Not: Uygun düştüğünde ara kodları da kullanınız, örn. 45, 68, 72.)
91-100	Çok çeşitli etkinlik alanlarında üst düzeyde işlevsellik, yaşam sorunları hiçbir zaman denetim dışı kalmıyor gibi görünmektedir, birçok olumlu niteliği olduğu için başkalarınca aranan biridir. Herhangi bir semptomu yoktur.
81-90	Hiç belirti olmaması ya da çok az belirti olması (örn. sınavdan önce hafif bir anksiyete duyma), tüm alanlarda işlevselliğin iyi olması, çok çeşitli etkinliklerle ilgilenme ve bunlara katılma, toplumsal yönden etkindir, genellikle yaşamı doyumludur, günlük sorunlar ya da kaygılardan öte sorun ya da kaygıların olmaması (örn. aile bireyleriyle ara sıra olan tartışmalar).
71-80	Semptomlar varsa bile bunlar gelip geçicidir ve psikososyal stres kaynaklarına verilen beklenen tepkilerdir (örn. aile tartışmasından sonra düşüncelerini belirli bir konu üzerinde yoğunlaştırmada zorluk çekme); toplumsal, mesleki ya da okuldaki işlevsellikte hafif bir bozulma olmasından daha ileri bir durum yoktur (örn. geçici olarak okulda geri kalma).
61-70	Birtakım hafif semptomlar (örn. depresif duygudurum ve hafif insomnia) YA DA toplumsal, mesleki ya da okuldaki işlevsellikte birtakım zorlukların olması (örn. ara sıra okuldan kaçmalar ya da ev içinde hırsızlık yapma), ancak genelde oldukça iyi bir biçimde işlevselliğini sürdürür, anlamlı kişiler arası ilişkileri vardır.
51-60	Orta derecede semptomlar (örn. donuk duygulanım ve çevresel konuşma, ara sıra gelen panik atakları) YA DA toplumsal, mesleki ya da okuldaki işlevsellikte orta derecede bir zorluğu vardır (örn. az sayıda arkadaşı vardır, çalışma arkadaşları ile çatışmaları vardır).
41-50	Ağır semptomlar (örn. intihar düşünceleri, ağır obsesyonel törensel davranışlar, sık sık mağazalardan mal çalma) YA DA toplumsal, mesleki ya da okuldaki işlevsellikte ciddi bir bozukluk vardır (örn. hiç arkadaşı yoktur, işini koruyamaz).
31-40	Gerçeği değerlendirmede ya da iletişimde bazı bozukluklar vardır (örn. konuşması kimi zaman mantıksız, çapraşık ya da konuşulan konuyla ilgisizdir) YA DA iş/okul, aile ilişkileri, yargılama, düşünme ya da duygudurum gibi birçok alanda temel birtakım bozukluklar vardır (örn. depresif bir kişi arkadaşlarından kaçır, ailesini ihmal eder ve çalışmaz; çocuk yaşta olan bir kişi kendinden daha küçükleri döver, evde hep karşı gelir ve okulda başarısızdır).
21-30	Davranışları hezeyanlar ve varsanıllardan oldukça etkilenir YA DA iletişim ya da yargıda ciddi bir bozukluk vardır (örn. bazen enkoherandır, ileri derecede uygunsuz bir biçimde davranır, intihar düşünceleriyle uğraşır durur) YA DA hemen tüm alanlarda işlevselliği kötüdür (örn. bütün gün yataktan çıkmaz; işi, evi ya da arkadaşları yoktur).
20-11	Kendisini ya da başkalarını yaralayacak olma tehlikesi zaman zaman vardır (örn. açıkça ölüm beklentisi olmadan intihar girişimleri; sıklıkla şiddete başvurur; manik eksitasyon) YA DA ara sıra kişisel bakımın en temel gereklerini bile yerine getiremez (örn. dışkı sürer) YA DA iletişimde ileri derecede bir bozukluk vardır (örn. ileri derecede enkoherandır ya da mutizm içindedir).
1-10	Kendisini ya da başkalarını ağır bir biçimde yaralayacak olma tehlikesi sürekli vardır (örn. yineleyen şiddet gösterileri) YA DA kişisel bakımın en temel gereklerini sürekli olarak yerine getiremez YA DA açıkça ölüm beklentisi içinde ciddi intihar eylemi.
0	Bilgi yetersiz

PUAN

EK-2: VERİ TOPLAMA FORMU

<i>SOSYO-DEMOGRAFİK VERİLER</i>
Yaş
Cinsiyet ☐ Kadın ☐ Erkek
Medeni Durum ☐ Bekar ☐ Evli ☐ Dul ☐ Boşanmış ☐ Ayrılmış
Eğitim
Hastalığın Başlama Yaşı
Hastaneye Yatış Sayısı
Hastanede Kalma Süresi (Hafta Olarak)
İlacın Başlangıç Dozu
Hastalığın En Son Alevlendiği Tarih (Ay olarak)
DSM-IV Tanısı

EK-3: POZİTİF VE NEGATİF SEMPTOM ÖLÇEĞİ (PANNS)

		Yok	Çok hafif	Hafif	Orta	Orta/ağır	Ağır	Çok ağır
Pozitif belirtiler	P1.sanrılar							
	P2.düşünce dağınıklığı							
	P3. Varsanılar							
	P4.taşkınlık							
	P5.büyüklik duyguları							
	P6.şüphencilik/kötülük görme							
	P7.düşmanca tutum							
Negatif belirtiler	N1.duygulanımda küntleşme							
	N2.duygusal içe çekilme							
	N3.ilişki kurmada güçlük							
	N4.pasif/kayıtsız biçimde kendini toplumdan çekme							
	N5.soyut düşünme güçlüğü							
	N6.konuşmanın kendiliğinden ve akıcı olmasının kaybı							
	N7.steriotipik düşünme							
Genel psikopatoloji ölçeği (g)	G1.bedensel kaygı							
	G2.anksiyete							
	G3.suçluluk duyguları							
	G4.gerginlik							
	G5.manyerizm ve vücut duruşu							
	G6.depresyon							

	G7.motor yavaşlama							
	G8.işbirliği kuramama							
	G9 olağandışı düşünce içeriği							
	G10.yönelim bozukluğu							
	G11.dikkat azalması							
	G12.yargılama ve içgörü eksikliği							
	G13.irade bozukluğu							
	G14.dürtü kontrolsüzlüğü							
	G15.zihinsel aşırı uğraşı							
	G16.aktif biçimde sosyal kaçınma							

EK-4: POZİTİF BELİRTİLERİ DEĞERLENDİRME ÖLÇEĞİ (SAPS)

0: YOK 1:ŞÜPHELİ 2:HAFİF 3:ORTA 4:BELİRGİ 5:ŞİDDETLİ

VARSANILAR:

1. İşitme varsanıları

Hasta başkalarının duymadığı sesler, gürültüler veya başka sesler duyduğunu bildirir.

0 1 2 3 4 5

2. Yorumlayıcı sesler

Hasta, davranış ve düşüncelerini yorumlayan sesler duyduğunu bildirir.

0 1 2 3 4 5

3. Aralarında konuşan sesler

Hasta, iki veya daha fazla kişinin aralarında konuştuklarını bildirir.

0 1 2 3 4 5

4. Somatik ve dokunma varsanıları

Hasta, vücudunda acayip fizik duyumsamalar olduğunu bildirir.

0 1 2 3 4 5

5. Koku varsanıları

Hasta, başkalarının fark etmediği olağandışı kokular duyduğunu bildirir.

0 1 2 3 4 5

6. Görme varsanıları

Hasta, gerçekte var olmayan şekil veya insanlar görür.

0 1 2 3 4 5

7. Varsanıların bütünsel derecelendirilmesi

Bu derecelendirme varsanının süresi ve ciddiyeti ve hastanın yaşamına olan etkisi göz önüne alınarak yapılmalıdır.

0 1 2 3 4 5

HEZEYANLAR:

8. Kötülük görme hezeyanları

Hasta kendisine komplo hazırlandığına veya bir yolunu bulup kötülük yapılacağına inanır.

0 1 2 3 4 5

9. Kıskançlık hezeyanları

Hasta, eşinin bir başkası ile ilişkisi olduğuna inanır.

0 1 2 3 4 5

10. Suçluluk ve günahkarlık hezeyanları

Hasta bazı kötü, günahkar veya affedilmez şeyler yaptığına inanır.

0 1 2 3 4 5

11. Büyüklik hezeyanları

Hasta, özel güç veya yeteneklerinin varlığına inanır.

0 1 2 3 4 5

12. Dinsel hezeyanlar

Hasta, dinsel nitelikli yanlış inançları ile aşırı uğraşır.

0 1 2 3 4 5

13. Somatik hezeyanlar

Hasta, her nasılsa vücudunun hasta, anormal olduğuna inanır.

0 1 2 3 4 5

14. Alınma hezeyanları

Hasta, önemsiz işaret ve olayları üzerine alır veya özel anlamlar çıkarır.

0 1 2 3 4 5

15. Kontrol edilme hezeyanları

Hasta, his ve karakterlerinin bazı dış güçlerce kontrol edildiğini hisseder.

0 1 2 3 4 5

16. Düşünce okuma hezeyanları

Hasta, insanların düşüncelerini okuyabildiğini veya düşüncelerini bildiğini hisseder.

0 1 2 3 4 5

17. Düşünce yayılması

Hasta, düşüncelerinin yayınlandığını hisseder böylece kendisi ve diğerleri bunları duyabilir.

0 1 2 3 4 5

18. Düşünce sokulması

Hasta, düşüncelerinin kendisinin olmadığını, dışarıdan aklına sokulduğuna inanır.

0 1 2 3 4 5

19. Düşünce çekilmesi

Hasta, düşüncelerinin kafasından alındığına inanır.

0 1 2 3 4 5

20. Hezeyanlarının bütünsel derecelendirilmesi

Bu derecelendirme, hezeyanların süresi ve ısrarlılığı ve hastanın yaşamına olan etkisi göz önüne alınarak yapılmalıdır.

0 1 2 3 4 5

GARİP DAVRANIŞ:**21. Giyim ve görünüş**

Hasta olağandışı tarzda giyinir veya diğer garip şeylerle görünüşünü değiştirir.

0 1 2 3 4 5

22. Sosyal ve cinsel davranış

Hasta, olağan sosyal normlara göre uygunsuz şeyler yapabilir. Ör; ortalıkta mastürbasyon

0 1 2 3 4 5

23. Saldırganlık ve taşkın davranış

Hasta, sıklıkla önceden tahmin edilemeyen saldırgan ve taşkın davranışlar gösterebilir.

0 1 2 3 4 5

24. Tekrarlayıcı veya stereotipleşmiş davranış

Hasta, tekrar tekrar yapmak zorunda olduğu tekrarlayıcı hareketler veya merasimler geliştirebilir.

0 1 2 3 4 5

25. Garip davranışın bütünsel değerlendirilmesi

Bu derecelendirme, davranış tipi ve sosyal normlardan sapma miktarını yansıtmalıdır.

0 1 2 3 4 5

POZİTİF FORMAL DÜŞÜNCE BOZUKLUĞU:**26. Düşüncenin raydan çıkması (Derailment)**

Fikirlerin bir diziden diğerine dolaylı, bağlantılı ya da bağlantısız olarak kayıp gittiği konuşma şekli.

0 1 2 3 4 5

27. Teğetleme (Tangentiality)

Dolaylı veya konu dışı tarzda sorulara yanıt verme

0 1 2 3 4 5

28. Dikişsizlik (Incoherence)

Zaman zaman esas olarak anlaşılmayan konuşma şekli.

0 1 2 3 4 5

29. Mantık dışılık

Mantık olarak izlenemeyen sonuçlar çıkarılan konuşma şekli

0 1 2 3 4 5

30. Çevresel konuşma (Circumstantiality)

Hedef düşünceye ulaşması çok dolambaçlı olan ve geciken konuşma şekli.

0 1 2 3 4 5

31. Basınçlı konuşma

Hastanın konuşması hızlı ve durdurulması güçtür. Konuşma miktarı normalden çok fazladır.

0 1 2 3 4 5

32. Çelinebilir konuşma (Distractible speech)

Hasta, konuşma akımını kesen yakın uyaranlarca çelinebilir.

0 1 2 3 4 5

33. Klang çağrışım

Kelime seçimine anlamsal ilişkilerden daha çok seslerin yön verdiği konuşma şekli.

0 1 2 3 4 5

34. Pozitif formal düşünce bozukluğu

Bu bütünsel derecelendirme anormalliği derecesini ve kişinin ilişki kurma yeteneğini etkileme derecesini yansıtmaktadır.

0 1 2 3 4 5



EK-5 NEGATİF BELİRTİLERİ DEĞERLENDİRME ÖLÇEĞİ (SANS)

0: YOK 1:ŞÜPHELİ 2:HAFİF 3:ORTA 4:BELİRGİN 5:ŞİDDETLİ

AFFEKTİF DÜZLEŞME VEYA KÖRLEŞME:

1. Değişmeyen yüz ifadesi
2. 0 1 2 3 4 5
3. Azalmış kendiliğinden hareketler
4. 0 1 2 3 4 5
4. Anlamlı jestlerin yokluğu
5. 0 1 2 3 4 5
5. Affektif yanıtsızlık
6. 0 1 2 3 4 5
6. Sesteki esnekliğin yokluğu
7. 0 1 2 3 4 5
7. Global olarak affektif düzleşme
8. 0 1 2 3 4 5

Alt ölçek Toplam:

ALOGİA:

8. Konuşma yoksulluğu
9. 0 1 2 3 4 5
9. Konuşma içeriğinin yoksulluğu
10. 0 1 2 3 4 5
10. Blokaj
11. 0 1 2 3 4 5
11. Yanıt verme süresinin uzaması
12. 0 1 2 3 4 5
12. Global olarak alogia
13. 0 1 2 3 4 5

Alt ölçek Toplam:

İSTEKSİZLİK-APATİ:

13. Üst baş özeni ve temizliği
14. 0 1 2 3 4 5
14. İş ve okulda sebatlılık
15. 0 1 2 3 4 5
15. Fizik enerjisinin azalması
16. 0 1 2 3 4 5
16. Global olarak apati
17. 0 1 2 3 4 5

Alt ölçek Toplam:

ANHEDONİ-ASOSYALLİK:

17. Yaratıcı ilgi ve etkinlik
0 1 2 3 4 5
18. Cinsel etkinlik
0 1 2 3 4 5
19. Yakınlık ve dostluk kurma yeteneği
0 1 2 3 4 5
20. Arkadaş ve akranlarla ilişkiler
0 1 2 3 4 5
21. Global olarak anhedoni
0 1 2 3 4 5

Alt ölçek Toplam:**DİKKAT:**

22. Sosyal dikkatsizlik
0 1 2 3 4 5
23. Testler esnasındaki dikkatsizlik
0 1 2 3 4 5
24. Global olarak dikkat
0 1 2 3 4 5

Alt ölçek Toplam:

EK-6 ETİK KURUL KARAR ÖRNEĞİ



T.C.
HACETTEPE ÜNİVERSİTESİ
Girişimsel Olmayan Klinik Araştırmalar Etik Kurulu

Sayı : 16969557 -1066

Konu :

ARAŞTIRMA PROJESİ DEĞERLENDİRME RAPORU

Toplantı Tarihi : 12 TEMMUZ 2017 ÇARŞAMBA
Toplantı No : 2017/17
Proje No : GO 17/628 (Değerlendirme Tarihi: 12.07.2017)
Karar No : GO 17/628- 29

Üniversitemiz Tıp Fakültesi Biyoistatistik Anabilim Dalı öğretim üyelerinden Yrd. Doç. Dr. Sevilay KARAHAN' ın sorumlu araştırmacı olduğu, Prof. Dr. M. Kazım YAZICI, Doç. Dr. Hatice Özdemir REZAKI ile birlikte çalışacakları ve Ash BOZER' in yüksek lisans tezi olan, GO 17/628 kayıt numaralı, "*Kohonen Öz Örgütlemeli Haritalama Yöntemi ile Psikiyatri Hastalıklarının Kümeleneşmesi*" başlıklı proje önerisi araştırmanın gerekçe, amaç, yaklaşım ve yöntemleri dikkate alınarak incelenmiş olup, etik açıdan uygun bulunmuştur.

- | | |
|---|--|
| 1. Prof. Dr. Nurlen AKARSU (Başkan) | 10. Prof. Dr. Oya Nuran EMİROĞLU (Üye) |
| 2. Prof. Dr. Sevdâ F. MÜFTÜOĞLU (Üye) | 11. Yrd. Doç. Dr. Özay GÖKÖZ (Üye) |
| 3. Prof. Dr. M. Yıldırım SAĞLAM (Üye) | 12. Doç. Dr. Gözde GİRGİN (Üye) |
| 4. Prof. Dr. Necdâ SAGLAM (Üye) | 13. Doç. Dr. Fatma Visal OKUR (Üye) |
| 5. Prof. Dr. Hatice Doğan BUZOĞLU (Üye) | 14. Doç. Dr. Can Ebru KURT (Üye) |
| 6. Prof. Dr. R. Köksal ÖZGÜL (Üye) | 15. Yrd. Doç. Dr. H. Hüsrev TURNAGÖR (Üye) |
| 7. Prof. Dr. Ayşe Lale DOĞAN (Üye) | 16. Öğr. Gör. Dr. Müge DEMİR (Üye) |
| 8. Prof. Dr. Elmas Ebru YALÇIN (Üye) | 17. Öğr. Gör. Meltem ŞENGEL (Üye) |
| 9. Prof. Dr. Mintaze Kerem GÜNEL (Üye) | 18. Av. Meltem ONURLU (Üye) |

9. ÖZGEÇMİŞ

1. KİŞİSEL BİLGİLER

ADI, SOYADI:	Aslı Çiftci
DOĞUM TARİHİ ve YERİ:	1981/Ankara
HALEN GÖREVİ: Ankara Üniversitesi Tıp Fakültesi Etik Kurulu YAZIŞMA ADRESİ: Ankara Üniversitesi Tıp Fakültesi Dekanlık Binası Etik Kurul Bürosu TELEFON: 03125958227 E-MAIL: aslibozer81@gmail.com	

2. EĞİTİM

YILI	DERECESİ	ÜNİVERSİTE	ÖĞRENİM ALANI
2000-2004	-	Ankara Üniversitesi Sağlık Yönetimi Bölümü	Lisans
2005-2007	-	Ankara Üniversitesi Sosyal Psikiyatri Anabilim Dalı	Yüksek Lisans
2013-halen	-	Hacettepe Üniversitesi Biyoistatistik Anabilim Dalı	Yüksek Lisans
2014-halen	-	Ankara Üniversitesi Sağlık Yönetimi Bölümü	Doktora

3. AKADEMİK DENEYİM

GÖREV DÖNEMİ	ÜNVAN	BÖLÜM	ÜNİVERSİTE
-			

4. ÇALIŞMA ALANLARI

ÇALIŞMA ALANI	ANAHTAR SÖZCÜKLER
-	

