



**MAKİNE ÖĞRENME Sİ TEKNİKLERİ KULLANILARAK ÇOCUKLUK
ÇAĞI DİKKAT EKSİKLİĞİ VE HİPERAKTİVİTE BOZUKLUĞUNUN
TAHMİN EDİLMESİNE YÖNELİK UZMAN SİSTEM TASARIMI**

Hanife GÖKER

**DOKTORA TEZİ
BİLİŞİM SİSTEMLERİ ANABİLİM DALI**

**GAZİ ÜNİVERSİTESİ
BİLİŞİM ENSTİTÜSÜ**

TEMMUZ 2019

Hanife GÖKER tarafından hazırlanan “MAKİNE ÖĞRENMESİ TEKNİKLERİ KULLANILARAK ÇOCUKLUK ÇAĞI DİKKAT EKSİKLİĞİ VE HİPERAKTİVİTE BOZUKLUĞUNUN TAHMİN EDİLMESİNE YÖNELİK UZMAN SİSTEM TASARIMI” adlı tez çalışması aşağıdaki jüri tarafından OY BİRLİĞİ ile Gazi Üniversitesi Bilişim Sistemleri Anabilim Dalında DOKTORA TEZİ olarak kabul edilmiştir.

Danışman: Doç. Dr. Hakan TEKEDERE

Sağlık Hizmetleri Meslek Yüksek Okulu, Gazi Üniversitesi
Bu tezin, kapsam ve kalite olarak Doktora Tezi olduğunu onaylıyorum



Başkan: Prof. Dr. Selda ÖZDEMİR

Özel Eğitim, Hacettepe Üniversitesi
Bu tezin, kapsam ve kalite olarak Doktora Tezi olduğunu onaylıyorum



Üye: Doç. Dr. Sami ŞAHİN

Bilgisayar ve Öğretim Teknolojisi Eğitimi, Gazi Üniversitesi
Bu tezin, kapsam ve kalite olarak Doktora Tezi olduğunu onaylıyorum



Üye: Dr. Öğr. Üyesi Atila BOSTAN

Bilgisayar Mühendisliği, Atılım Üniversitesi
Bu tezin, kapsam ve kalite olarak Doktora Tezi olduğunu onaylıyorum



Üye: Dr. Öğr. Üyesi Eylem DAYI

Özel Eğitim, Gazi Üniversitesi
Bu tezin, kapsam ve kalite olarak Doktora Tezi olduğunu onaylıyorum



Tez Savunma Tarihi: 18 /07 / 2019

Jüri tarafından kabul edilen bu tezin Doktora Tezi olması için gerekli şartları yerine getirdiğini onaylıyorum.

Doç. Dr. Aslıhan TÜFEKÇİ
Bilişim Enstitüsü Müdürü

ETİK BEYAN

Gazi Üniversitesi Bilişim Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu,

bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Hanife GÖKER

18/07/2019

MAKİNE ÖĞRENMESİ TEKNİKLERİ KULLANILARAK ÇOCUKLUK ÇAĞI
DİKKAT EKSİKLİĞİ VE HİPERAKTİVİTE BOZUKLUĞUNUN TAHMİN
EDİLMESİNE YÖNELİK UZMAN SİSTEM TASARIMI
(Doktora Tezi)

Hanife GÖKER

GAZİ ÜNİVERSİTESİ
BİLİŞİM ENSTİTÜSÜ

Temmuz 2019

ÖZET

Bu çalışma ile alan uzmanlarının, öğretmenlerin ve ebeveynlerin rahatlıkla kullanabileceği çocukluk çağı dikkat eksikliği ve hiperaktivite bozukluğunun öngörülmesine yönelik tanı çıkarımı yapabilen bir dinamik uzman sistem modeli geliştirilmiştir. Bu kapsamda, bozukluğun tanısına yönelik alan uzmanlarının karmaşık ve deneyim gerektiren karar verme süreci geliştirilen uzman sisteme aktarılmıştır. Çalışmada gereksinim analizi yapılarak çocukluk çağının en sık görülen psikiyatrik bozukluklarından olan dikkat eksikliği ve hiperaktivite bozukluğu çalışmanın konusu olarak seçilmiştir. Sistemi geliştirme sürecinde, çevik yazılım süreç modeli benimsenmiştir. Geliştirilen sistem bilgi tabanı, çıkarım mekanizması ve açıklama birimi olmak üzere üç temel kısımdan oluşmaktadır. Veri kümeleri nitelikler ve kayıtlar olmak üzere bilgi tabanına kaydedilmiştir. Nitelikler alan uzmanları (çocuk psikiyatristleri) tarafından belirlenirken, kayıtlar Gazi Hastanesi Çocuk Ruh Sağlığı ve Hastalıkları Anabilim Dalından alınan kliniksel hasta verilerinden oluşmaktadır. Geliştirilen sistemin çıkarım mekanizması kısmında Naive Bayes algoritması kullanılarak bilgi tabanının dinamik olarak yenilenmesinin sağlanması çalışmanın ayırt edici özelliğidir. Bu sayede sistem, daha önceden kayıtlı olmayan yeni bir durum ile karşılaştığında; mevcut kayıtlardan faydalanarak yeni kaydın hangi sınıfa ait olduğunu tahmin edebilmektedir. Gerçek veriler ile sistem eğitilmiş ve performansı test edilmiştir. Çalışmanın sonucunda sistemin performansının model başarımlarına (%95,55 doğruluk, 0,942 kesinlik, 0,98 duyarlılık, 0,925 özgüllük, 0,961 f ölçütü ve 0,99 roc değeri) göre oldukça yüksek olduğu tespit edilmiştir.

Bilim Kodu : 114602
Anahtar Kelime : Uzman sistem, makine öğrenmesi, naive bayes algoritması, dikkat eksikliği, hiperaktivite
Sayfa Adedi : 164
Danışman : Doç. Dr. Hakan TEKEDERE

EXPERT SYSTEM DESIGN FOR THE PREDICTION OF ATTENTION DEFICIT AND HYPERACTIVITY DISORDER IN CHILDHOOD USING MACHINE LEARNING TECHNIQUES

(Ph.D. Thesis)

Hanife GÖKER

GAZİ UNIVERSITY
INFORMATICS INSTITUTE

July 2019

ABSTRACT

In this study, a Dynamic Expert System which can be easily used by field experts, teachers and parents, was developed to predict attention deficit and hyperactivity impairment in childhood. In this context, the decision-making process, which requires complex and experienced field experts to diagnose the disease, has been transferred to the developed expert system. The subject of the study was determined as prediction of attention deficit and hyperactivity disorder, which is one of the most common psychiatric disorders of childhood. The Agile Model steps have been adopted while developing a dynamic expert system for predicting ADHD. The developed Dynamic Expert System consists of three basic parts, which are the knowledge base, the inference mechanism and the description unit. Data clusters are recorded as attributes and records in the knowledge base. While attributes are determined by field experts, records are composed of clinical patient data received from the Gazi Hospital, Department of Pediatric Mental Health and Diseases. Ensuring the dynamic renewal of the rule base is the most important characteristic of the study using the Naive Bayes Algorithm in the inference mechanism of the developed system. In this way, when the system encounters a new situation that is not previously encountered, it can take advantage of the existing records and guess which class the record belongs to. With real data, the system has been trained; and its performance was tested. As a result of this study, accuracy was determined to be 95,55%; precision was determined to be 0,955, recall was determined to be 0,953, specificity was determined to be 0,925, f-measure was determined to be 0,953 and roc area value was determined to be 0,987. It was observed that the performance of the system was quite high compared to the model performance criteria.

Science Code	: 114602
Key Words	: Expert system, machine learning, naive bayes algorithm, attention deficit, hyperactivity.
Page Number	: 164
Supervisor	: Assoc. Prof. Dr. Hakan TEKEDERE

TEŞEKKÜR

Çalışmalarım boyunca değerli yardım ve katkılarıyla beni yönlendiren, kıymetli tecrübelerinden faydalandığım danışmanım Doç. Dr. Hakan TEKEDERE'ye, tez izlemede öneri ve yardımlarını esirgemeyen Doç. Dr. Sami ŞAHİN ve Dr. Öğr. Üyesi Atila BOSTAN'a, ayrıca uzmanlık alanlarından faydalandığım Prof. Dr. Yasemen TANER ve Dr. Dicle BÜYÜKTAŞKIN'a, manevi destekleriyle beni hiçbir zaman yalnız bırakmayan çok değerli eşim Bahattin, kızım Zeynep Tuana ve oğlum Muhammed Ali'ye teşekkürü bir borç bilirim.



İÇİNDEKİLER

	Sayfa
ÖZET	iv
ABSTRACT.....	v
TEŞEKKÜR.....	vi
İÇİNDEKİLER	vii
ÇİZELGELERİN LİSTESİ.....	xi
ŞEKİLLERİN LİSTESİ	xi
RESİMLERİN LİSTESİ	xiv
SİMGELER VE KISALTMALAR.....	xv
1. GİRİŞ.....	1
2. KURAMSAL TEMELLER VE İLGİLİ ARAŞTIRMALAR.....	5
2.1. Dikkat Eksikliği / Hiperaktivite Bozukluğu.....	5
2.1.1. Tanım	5
2.1.2. Değerlendirme ve tanı kriterleri	5
2.1.3. Görülme sıklığı	7
2.1.4. DEHB'ye neden olan etmenler	8
2.1.5. Sınıflandırılması.....	9
2.1.6. Tedavisi	10
2.2. Uzman Sistemler	11
2.2.1. Uzman sistem tanımı.....	11
2.2.2. Uzman sistemlerin temel özellikleri	14
2.2.3. Uzman sistemin avantaj ve dezavantajları	14
2.2.4. Uzman sistem uygulama alanları	17
2.2.5. Uzman sistem bileşenleri ve tasarımı.....	18

Sayfa

2.3. Makine Öğrenmesi	23
2.3.1. Makine öğrenmesi kavramı	23
2.3.2. Makine öğrenmesinin veri madenciliği ile ilişkisi	23
2.3.3. Makine öğrenmesi ve veri madenciliğinin uzman sistemler ile ilişkisi	26
2.3.4. Makine öğrenmesi metotları	30
2.3.5. Makine öğrenmesi uygulama süreci	44
2.3.6. Makine öğrenmesi uygulama alanları	54
2.4. İlgili Çalışmalar	55
2.4.1. Uzman sistemlerin tıpta ve psikiyatride kullanımı ile ilgili literatür	55
2.4.2. Makine öğrenmesi algoritmalarının tıpta ve psikiyatride kullanımı ile ilgili literatür	58
2.4.3 Tıpta ve psikiyatride makine öğrenmesi algoritmalarının uzman sistemde kullanılması ile ilgili literatür	61
3. YÖNTEM	65
3.1. Sistem Gereksinimleri	67
3.1.1. Çalışma konusunun seçimi	67
3.2. Yazılım Gereksinimleri	67
3.2.1. Geliştirilen uzman sistemin genel özellikleri	68
3.3. Analiz	69
3.3.1. Bilgi tabanının oluşturulması	69
3.3.2. Yazılımın geliştirilmesinde kullanılan araç/ gereçlerin analizi	71
3.4. Tasarım	72
3.4.1. Bilgi tabanı tasarımı	72
3.4.2. Verinin eğitim ve test kümesine ayrılması	72
3. 5. Geliştirme	73

Sayfa

3.5.1. Kullanılan sınıflandırma algoritmasının seçimi	73
3. 6. Test ve Entegrasyon	74
3.6.1. Sistemin değerlendirilmesi.....	74
3. 7. İdame ve Bakım	75
4. DEHB’NİN TAHMİN EDİLMESİNE YÖNELİK GELİŞTİRİLEN UZMAN SİSTEM BİLEŞENLERİ VE BULGULAR	77
4.3. Sistemin kullanıcı yetki düzeyleri	91
4.4. Ebeveyn kullanıcı yetki düzeyi ve sistem başarımlı testi.....	93
4.4.1. Bilgi tabanı.....	93
4.4.2. Çıkarım mekanizması.....	94
4.4.3. Sistemin başarımlı değerlendirilmesi	96
4.4.4. Açıklama Birimi.....	100
4.5. Öğretmen kullanıcı yetki düzeyi	101
4.6. Uzman kullanıcı yetki düzeyi ve sistemin başarımlı testi	101
4.6.1. Bilgi tabanına yeni kayıt ekleme/ listeleme/ silme/güncelleme	101
4.6.2. Çıkarım mekanizması.....	105
4.6.3. Sistemin başarımlı değerlendirilmesi	111
4.1.3. Açıklama Birimi.....	115
5. TARTIŞMA VE SONUÇLAR	117
KAYNAKLAR	125
EKLER.....	153
EK-1. Naive Bayes algoritmasının C#.NET dili kodları	154
EK-2. KNN algoritmasının C#.NET dili kodları	156
EK-3. Gazi Üniversitesi Etik Komisyon izin belgesi	159
EK-4. Gazi Üniversitesi Sağlık Araştırma ve Uygulama Merkezi yasal izin belgesi	160

Sayfa

EK-5. Gazi Üniversitesi Çocuk Ruh Sağlığı ve Hastalıkları Anabilim Dalı kurum yetkilisi izin belgesi	161
ÖZGEÇMİŞ.....	162



ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 2.1. Geleneksel programlar ve uzman sistemler arasındaki farklar.....	13
Çizelge 2.2. Özellik seçme modelleri	42
Çizelge 2.3. Karışıklık matrisi	49
Çizelge 3.1. Kayıtlara ait yaş aralıkları ve cinsiyet dağılım bilgileri.....	71
Çizelge 4.1. Nitelikler ve alabileceği değerler ve referanslar	80
Çizelge 4.2. Veri dönüşümü sonrasında nitelikler ve aldığı yeni değerler	84
Çizelge 4.3. Niteliklerin sınıflara göre dağılımı	86
Çizelge 4.4. 10-kat çapraz geçerleme metodu kullanılarak doğrulanan modelin performans sonuçları (ebeveyn kullanıcı yetki düzeyi).....	96
Çizelge 4.5. 10-kat çapraz geçerleme metodu kullanılarak doğrulanan modelin örnek sayılarına göre karşılaştırma sonuçları (ebeveyn kullanıcı yetki düzeyi).....	97
Çizelge 4.6. Bağımsız bir test seti ile test edilen modelin performans sonuçları (ebeveyn kullanıcı yetki düzeyi).....	98
Çizelge 4.7. Bağımsız bir test seti ile test edilen modelin örnek sayılarına göre karşılaştırma sonuçları (ebeveyn kullanıcı yetki düzeyi)	99
Çizelge 4.8. 10-kat çapraz geçerleme metodu kullanılarak doğrulanan modelin performans sonuçları (uzman kullanıcı yetki düzeyi)	111
Çizelge 4.9. 10-kat çapraz geçerleme metodu kullanılarak doğrulanan modelin örnek sayılarına göre karşılaştırma sonuçları (uzman kullanıcı yetki düzeyi)	113
Çizelge 4.10. Bağımsız bir test seti ile test edilen modelin performans sonuçları (uzman kullanıcı yetki düzeyi)	113
Çizelge 4.11. Bağımsız bir test seti ile test edilen modelin örnek sayılarına göre karşılaştırma sonuçları (uzman kullanıcı yetki düzeyi)	115

ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 2.1. DEHB'nin tanımlanmasında kullanılabilecek bilgi kaynakları	6
Şekil 2.2. Yapay zekâ ve uzman sistemlerin amaçları	12
Şekil 2.3. Uzman sistemlerin çalışma prensibi	12
Şekil 2.4. Uzman sistemlerin genel yapısı	18
Şekil 2.5. İleriye doğru zincirleme kuralı.	20
Şekil 2.6. Geriye doğru zincirleme kuralı.	20
Şekil 2.7. Uzman sistem tasarlanırken izlenecek prosedürler.....	22
Şekil 2.8. Han, Kamber ve Pei'ye göre veri madenciliği sürecinde yer alan basamaklar. .	24
Şekil 2.9. Veri madenciliği ve uzman sistemler.	27
Şekil 2.10. Makine öğrenmesi metotları ve en çok kullanılan algoritmalar.	31
Şekil 2.11. KNN algoritmasının genel yapısı	34
Şekil 2.12. Dört boyutlu özellik uzayına sahip üç sınıftan oluşan bir karar ağacı yapısı ...	35
Şekil 2.13. Yapay sinir hücresinin genel yapısı	37
Şekil 2.14. Koordinat düzleminde kümeleme örneği.....	38
Şekil 2.15. Eğri uydurma örneği	40
Şekil 2.16. Özellik seçim modelleri ve en çok kullanılan algoritmalar	42
Şekil 3.1. Tez çalışma sürecinde izlenen çevik yazılım süreç model adımları.....	66
Şekil 3.2. DEHB bilgi tabanı oluşturma süreci	70
Şekil 4.1. Geliştirilen uzman sistemin genel yapısının akış şeması.....	78
Şekil 4.2. Tüm veri kümesine ait niteliklerin genel dağılımı.....	89
Şekil 4.3. DEHB sınıfına ait veri kümesindeki niteliklerin genel dağılımı	90
Şekil 4.4. DEHB olmayan sınıfına ait veri kümesindeki niteliklerin genel dağılımı	91
Şekil 4.5. Sistemde kullanıcı tipine göre yetki düzeyleri ve kullanım amaçları.....	92

Şekil	Sayfa
Şekil 4.6. 10-kat çapraz geçerleme metodu kullanılarak doğrulanan modelin Naive Bayes algoritmasına ait ROC eğrisi (ebeveyn kullanıcı yetki düzeyi)	97
Şekil 4.7. Bağımsız bir test seti ile test edilen modelin Naive Bayes algoritmasına ait ROC eğrisi (ebeveyn kullanıcı yetki düzeyi)	99
Şekil 4.8. 10-kat çapraz geçerleme metodu kullanılarak doğrulanan modelin Naive Bayes algoritmasına ait ROC eğrisi (uzman kullanıcı yetki düzeyi)	112
Şekil 4.9. Bağımsız bir test seti ile test edilen modelin Naive Bayes algoritmasına ait ROC eğrisi (uzman kullanıcı yetki düzeyi)	114



RESİMLERİN LİSTESİ

Resim	Sayfa
Resim 4.1. Giriş formu.....	82
Resim 4.2. Ebeveyn kullanıcı yetki düzeyi çıkarım mekanizması (Adım 1).....	84
Resim 4.3. Ebeveyn kullanıcı yetki düzeyi çıkarım mekanizması (Adım 2).....	84
Resim 4.4. Ebeveyn kullanıcı yetki düzeyi çıkarım mekanizması (Adım 3).....	85
Resim 4.5. Ebeveyn kullanıcı yetki düzeyi açıklama birimi	88
Resim 4.6. Bilgi tabanı oluşturma formu (Adım 1).	89
Resim 4.7. Bilgi tabanı oluşturma formu (Adım 2).	90
Resim 4.8. Bilgi tabanı oluşturma formu (Adım 3).	90
Resim 4.9. Bilgi tabanını Excel platformuna aktarma formu	91
Resim 4.10. Bilgi tabanını yazdırma formu.....	91
Resim 4.11. Bilgi tabanını görüntüleme/silme/güncelleme formu.	92
Resim 4.12. Uzman yetki düzeyi Naive Bayes çıkarım mekanizması formu (Adım 1).	93
Resim 4.13. Uzman yetki düzeyi Naive Bayes çıkarım mekanizması formu (Adım 2).	93
Resim 4.14. Uzman yetki düzeyi Naive Bayes çıkarım mekanizması formu (Adım 3).	94
Resim 4.15. Uzman yetki düzeyi Naive Bayes çıkarım mekanizması formu (Adım 4).	94
Resim 4.16. KNN çıkarım mekanizması formu (Adım 1).....	96
Resim 4.17. KNN çıkarım mekanizması formu (Adım 2).....	96
Resim 4.18. KNN çıkarım mekanizması formu (Adım 3).....	97
Resim 4.19. KNN çıkarım mekanizması formu (Adım 4).....	97
Resim 4.20. Uzman kullanıcı yetki düzeyi açıklama birimi	101

SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış bazı kısaltmalar açıklamaları ile birlikte aşağıda sunulmuştur.

Kısaltmalar	Açıklama
DEHB	Dikkat Eksikliği / Hiperaktivite Bozukluğu
APA	Amerikan Psikiyatri Birliği (American Psychological Association)
DSM-V	Mental Bozuklukların Tanısal ve İstatistiksel Elkitabı (Diagnostic and Statistical Manuel of Mental Disorders)
KNN	K-En Yakın Komşu Algoritması (K-Nearest Neighborhood)
YSA	Yapay Sinir Ağları Algoritması (Artificial Neural Networks)
SVM	Destek Vektör Makinesi Algoritması (Support Vector Machine)
MAP	En Büyük Sonrasal Sınıflandırma Yöntemi (Maximum A Posteriori Classification)
CADÖ-48	Conners Aile Derecelendirme Ölçeği
CÖDÖ-28	Conners Öğretmen Derecelendirme Ölçeği

1. GİRİŞ

Dikkat eksikliği ve hiperaktivite bozukluğu (DEHB) farklı ortamlarda ortaya çıkan, sosyal, akademik ve iş performansında zorluklara neden olan dikkat eksikliği ve aşırı hareketlilik belirtileri ile karakterize [1], çocukluk döneminin en sık görülen ve belirtileri sıklıkla ergen ve yetişkin dönemde de devam eden psikiyatrik bozukluklardandır [2, 3]. DEHB’i önemli bir konu yapan sebeplerden bir tanesi yaygınlığıdır [4]. Çocuk yaş grubunda yaygınlığı %3-9 olarak bildirilmiştir [5]. İkinci sebep ise ergenlikte %60-80 ve yetişkinlikte %40-60 gibi önemli bir oranda devam etmesidir [6]. Çocukluk döneminde başlayan DEHB büyük bir oranda erişkinlik döneminde de devam etmektedir [5]. DEHB’nin görülme sıklığı genel okul nüfusunun %5-7’si gibi oldukça yüksek bir orandır [7]. Bu oran her sınıfta en az 1-2 DEHB’li öğrencinin olabileceği anlamına gelmektedir [4].

DEHB kişiler arası ilişkilere, yaşama, okul ve iş dünyasına yansıyan çeşitli olumsuz etkileri nedeniyle toplumun önemli sorunlarından birisidir. DEHB sadece çocuğun yaşantısını değil hem ailesinin hem de sosyal çevresinde bulunan kişilerin de yaşantısını olumsuz yönde etkilemekte ve beraberinde aşılması güç zorluklar getirmektedir. Bu nedenle DEHB’nin çocuklukta erken tanısı ve uygun bütüncül tedavi yaklaşımlarının uygulanması hem bireysel sağlık hem de toplum sağlığı bakımından önemlidir [8]. Bu nedenle çocuk psikiyatrisinin en dikkat çeken konularından birisi olarak nitelendirilmektedir [9]. DEHB’nin erken tanı ve tedavisi çocuğun geleceği için kritik öneme sahiptir. Erken tanıya yardımcı inceleme arayışı çok eskidir [10]. Uzmanla teşhis ve tedavilerde kolaylık sağlayacak veya uzmanın olmadığı yerlerde hastalığa ön tanı koymak için geliştirilecek sistemlerin önemli olduğu açıktır. Son yıllarda özellikle uzman sistem, makine öğrenmesi teknikleri, karar destek sistemleri ve veri madenciliği yöntemleri gibi akıllı sistemler erken tanının konulmasına yardımcı olmak amacıyla tıp ve psikiyatride yaygın olarak kullanıldığı görülmektedir [11-13].

Uzman sistemler, insan uzmanlığı gerektiren problemlerin çözümünde kullanılan yazılımlardır. Uzman sistem yazılımları, belli bir algoritmaya dayanmayan, kendi bilgi tabanı içerisinde, girilen veya önceden belli olan verilere göre arama yaparak bu veriye veya verilere uygun olan bilginin aktifleşmesini sağlayan ve bu aktifleşme sonucu yeni bir veri elde ederek aramaya devam eden bir sistem şeklinde çalışmaktadır [14]. Hastalıkların

erken tanısının konulmasında uzman sistemlerin yanında makine öğrenmesi algoritmaları da yaygın olarak kullanılmaktadır. Makine öğrenmesi algoritmaları bilgisayarların geçmiş bilgilerden elde edilen tecrübelerden yararlanarak, gelecekteki olayları tahmin etmesine ve modelleme yapmasına imkân veren bir yapay zekâ alanıdır. Bilgisayarın bir olay ile ilgili bilgileri ve tecrübeleri öğrenerek gelecekte oluşacak benzeri olaylar hakkında kararlar verebilmesi ve problemlere çözümler üretebilmesi için makine öğrenmesi algoritmaları kullanılmaktadır [15].

Psikiyatride, hem genel tanı amaçlı [16-18] hem de birçok farklı problem alanları için özelleştirilmiş uzman sistem tasarımları geliştirilmiştir [19-20]. Bu çalışmalara; epileptik krizin [21], yıkıcı davranış bozukluklarının [22], bellek kaybı hastalıklarının [23], obsesif kompulsif bozuklukların [24], Alzheimer hastalığının [25-26], uyku bozukluklarının [27-28], depresyon [29] ve kişilik bozukluklarının [30] tanısında uzman sistemlerin kullanılması örnek verilebilir. DEHB'nin tanımlanmasında uzman sistemlerin kullanımına yönelik Chittooran tarafından (1995) bir öncül çalışma tespit edilmiştir. Yapılan çalışmada hazır çıkarım aracı olan 1stClass Fusion programı kullanılmış, bu bozukluğun öngörülmesine yönelik özelleştirilmiş bir yazılım geliştirilmemiştir. 150 hastanın verileri girilerek sonuçları değerlendirilmiş %90 doğruluk oranı bulunmuştur [31]. Psikiyatri alanında geliştirilen uzman sistemlerin konu uzmanlarından bağımsız bir şekilde geliştirildiği, istenilen hedefe henüz ulaşamadığı belirtilmekte [32] ve geliştirilen sistemlerin sadece spesifik tıbbi bilgileri içerdiği gözükmemektedir [23-25]. Konu uzmanlarından bağımsız geliştirilen çalışmaların ne kadar güvenilir olduğu tartışmalıdır.

Psikiyatride makine öğrenmesi algoritmaları; psikiyatride Bayes ağlarının kullanılarak çocuk istismarının tanılanması ve çocuğun istismara uğrayıp uğramadığının tahmin edilmesi [33], Alzheimer hastalığı ve vasküler demansın ayırıcı tanısının tespitinde sinir ağlarını kullanılması [34], bipolar bozuklukta depresyonun tekrarlama olasılığının öngörülmesi [35], bilişsel bozuklukların tanısının konulması [36], Alzheimer ve hafif bilişsel bozuklukların sınıflandırılarak analiz edilmesi [37], genetik verilerin kullanılarak nikotin bağımlılığının öngörülmesi [38] ve demans ile hafif bilişsel bozukluk arasındaki ayırıcı tanının belirlenmesi [39] gibi amaçlar ile kullanılmıştır.

DEHB'ye yönelik çalışmalar incelendiğinde genellikle EEG, MRI, fNIRS gibi nörogörüntüleme belirteçlerinden yola çıkılarak DEHB'nin sınıflandırılmasına

odaklanıldığı [40-42] görülmüştür. Tenev ve diğerleri (2014), 117 yetişkin (67 DEHB, 50 kontrol) hasta verisi üzerinde yaptıkları çalışmalarında EEG sinyallerine dayalı olarak bireyin DEHB olup olmama durumunu ve DEHB alt tiplerini sınıflandırmışlardır [43]. Mohammadi ve diğerleri (2016) DEHB çocuklarını bilişsel bir görev yaparken EEG sinyallerini kullanarak normal çocuklardan ayırmak için bir yaklaşım önermektedir [44]. Yine benzer şekilde Peng, Lin, Zhang ve Wang (2013) çalışmalarında MRI verilerini kullanarak DEHB'nin sınıflandırılmasında makine öğrenmesi sınıflandırma algoritmalarını kullanmışlardır [45]. Fakat alan uzmanları DEHB değerlendirmesi yaparken her hasta için bu nörogörüntüleme belirteçlerini istememektedir. Alan uzmanları DEHB tanısını; ebeveynler ve öğretmenler tarafından doldurulan ölçeklerden elde edilen puanlar, çocuğun tıbbi ve gelişimsel öyküsü, aileyle ve çocukla psikiyatrik görüşmeler sonucunda elde edilen bilgileri analiz ederek koymaktadırlar [46-47]. Sonuç olarak bu nörogörüntüleme belirteçlerinin otomatik sınıflandırılabilmesi; tıp uzmanlarının analizlerinde ortaya çıkan hataları azaltabilir [48] fakat sadece tıp uzmanlarının kullanımı ile sınırlı ve anlamlıdır. Zaten bu belirteçlerin her hasta için istenmesi zaman, ekonomiklik ve kullanılabilirlik gibi birçok açıdan mümkün değildir. DEHB çocukluk çağının en sık görülen psikiyatrik bozukluklarından olmasına, çocukluk ve ergenlik döneminden sonra yetişkinlikte de devam etmesine ve tedavi edilmediğinde sosyal problemlere neden olmasına ve bu yüzden çocuk psikiyatrisinin en dikkat çeken konularından birisi olarak nitelendirilmesine [9] rağmen DEHB tanısına yönelik çalışmalar klinik düzeyle sınırlıdır. DEHB durumunun öngörülmesine yönelik alan uzmanlarının, ebeveynlerin ve öğretmenlerin klinikte, evde veya okulda rahatlıkla kullanabilecekleri bir yazılım bulunmamaktadır.

Bu çalışma ile çocuk psikiyatristlerinin alan uzmanlığı doğrultusunda bir dinamik uzman sistem modelinin tasarlanarak, alan uzmanlarının, öğretmenlerin ve ebeveynlerin rahatlıkla kullanabileceği, çocukta DEHB durumunun olup olmadığını tahmin edebilen bir erken uyarı sisteminin geliştirilmesi amaçlanmıştır. Uzman sistemlerin çıkarım mekanizmasında genellikle ileri doğru zincirleme ve geriye doğru zincirleme metotları kullanılmaktadır [23, 49-52]. Bu tez çalışmasında ise geliştirilen uzman sistemin çıkarım mekanizmasında farklı bir metot (Naive Bayes algoritması) denenmiştir. Bu metodun denenmesinin nedeni; bilgi tabanında daha önceden kayıtlı olmayan yeni bir durum ile karşılaşıldığında mevcut kayıtlardan faydalananarak, uzman sistemin yeni kaydın hangi sınıfa ait olduğunu tahmin edebilmesini sağlamaktır. Yani sistemde mevcut olan kayıtlar arasında aranan kayıt yoksa bile sistem çıkarımda bulunabilmektedir. Sonuç olarak bu çalışmada uzman sistemin

ıkarım mekanizmasında farklı bir metodun denenmesi, uzman sistem ve makine ğrenmesi algoritmalarının dikkat eksikliğı ve hiperaktivite bozukluğunda kullanılarak bir yazılımın geliştirilmesi hem uzman sistemler hem de psikiyatri disiplini açısından yürütölen alışmalara yenilik katmaktadır. Bu özellikleriyle alışmanın alana özgü modele olan ihtiyacı karşılamak ile birlikte diğerk tıbbi uzmanlık alanlarına da fikir vereceğı düşünölmektedir.



2. KURAMSAL TEMELLER VE İLGİLİ ARAŞTIRMALAR

Bu bölümde araştırmada kullanılan temel kuramsal açıklamalar, ilgili kavramlar, tanımlar ve araştırma ile ilgili yapılmış çalışma referansları sunulmuştur.

2.1. Dikkat Eksikliği / Hiperaktivite Bozukluğu

2.1.1. Tanım

DEHB dikkatsizlik ve/veya hiperaktivite/dürtüsellik ile karakterize, toplumsal ve okulla / işle ilgili etkinlikleri doğrudan olumsuz etkileyen, belirtileri en az altı ay sürmekte olan ve işlev kaybına yol açan nörogelişimsel bir bozukluktur [1]. DEHB; çocuk psikiyatrisi alanında en sık görülen bozukluklardan biridir [3].


DEHB tanısı bulunan çocukların aileleri çoğu zaman çocuklarının bebeklik döneminden itibaren aşırı hareketli olduğunu belirtmektedirler [53]. Fakat DEHB'nin bireyin yaş ve gelişim düzeyine uygun olmayan dikkat eksikliği ve aşırı hareketlilik davranışları genellikle 3-4 yaş arasında görülmektedir [4]. Buna rağmen nadiren belirtiler 5-6 yaşa kadar ortaya çıkmayabilir [54]. Amerikan Psikiyatri Birliği (American Psychological Association - APA), tanı ölçütleri başvuru elkitabına göre bu belirtilerin 12 yaşından önce ortaya çıkmış olması, son 6 aydır yaygın olarak görülmesi ve ev-okul gibi iki ayrı ortamda bu belirtilere rastlanması gerektiği belirtilmektedir [1]. DEHB tanısı bulunan çocukların bulunmayanlara göre okul başarılarının daha düşük olduğu ve daha fazla olasılıkla sınıf tekrarı yapmış oldukları bildirilmektedir [55-56]. Bu nedenle çocuklarda DEHB'nin fark edilmesi ve tanınması daha çok okul döneminde olmaktadır [57].

2.1.2. Değerlendirme ve tanı kriterleri

DEHB çocukluk çağının en sık görülen psikiyatrik bozukluğu olduğu için çocuk psikiyatrisine başvuran tüm olgularda DEHB “ön değerlendirmesi” (taraması) ve gerekirse değerlendirilmesinin yapılması son derece yararlıdır. DEHB ön değerlendirmesi sırasında DEHB'nin temel belirti alanlarını sorgulayan kısa bir görüşme yeterli olabilir. Dikkat eksikliğinin ön değerlendirmesinde; dikkati toplamada güçlük, ders çalışmama, ders başarısızlığı, dalgınlık, unutkanlık gibi dikkat eksikliği olan olgularda sık rastlanan

belirtiler sorgulanmalıdır. Hiperaktivite ve dürtüsellik ön değerlendirmesinde; sürekli hareket halinde olma, oturması gereken durumlarda içsel huzursuzluk (daha çok ergenlerde ve erişkinlerde), akranlarına göre daha fazla hareketli olma, çok konuşma, aşırı hareketlilik nedeniyle sorun yaşama, acelecilik, sırasını bekleyememe, isteklerini erteleyememe gibi hiperaktivite ve dürtüsellik olan olgularda sık rastlanan belirtiler sorgulanmalıdır. Eğer ebeveyn veya çocuk dikkat eksikliği, hiperaktivite ve dürtüsellik alanlarının birinde bile önemli düzeyde sorun yaşadıklarını belirtiyorlarsa DEHB için değerlendirme yapılmalıdır [46].

DEHB değerlendirmesi çocuk ve aileyle psikiyatrik görüşme yapılması, çocuğun gelişimsel ve tıbbi öyküsünün öğrenilmesi, öğretmenden bilgi alınması, eşlik eden tanıların değerlendirilmesi ve gereken inceleme ya da testlerin yapılmasını kapsamaktadır. Değerlendirmede ebeveynler, öğretmenler ve diğer özel kişilerden ölçekler yardımıyla bilgi toplanabilir. DEHB değerlendirilmesinde olgunun kendisi, ebeveynleri ve öğretmenleri tarafından bazı ölçeklerin kullanılması oldukça yararlıdır. Bu tür ölçekler önemli bir zaman ve maddi kayba neden olmadan olguların psikiyatrik değerlendirilmesinde ve DEHB tanısı konulmasında yardımcı olabilirler [46]. DEHB ya da diğer davranış sorunlarının tanısının konulması, olabildiğince fazla kaynaktan bilgi alınarak ve çeşitli değerlendirmeler sonucunda gerçekleştirilir. DEHB'nin tanılanmasında kullanılabilecek bilgi kaynakları Şekil 2.1'de verilmiştir [47]:



Şekil 2.1. DEHB'nin tanılanmasında kullanılabilecek bilgi kaynakları [47]

DEHB’de klinik belirtiler dikkat, yoğunluk, hareketlilik ve dürtü kontrolü alanlarındaki sorunlarla karakterizedir [58]. DEHB’de görülen bilişsel bozukluklar sıklıkla dikkati toplama güçlüğü, dikkat sürelerinin kısalığı, dikkatin kolaylıkla dağılabilir olması şeklinde ortaya çıkmaktadır. Bu çocuklar dikkat toplanmasını gerektiren görevleri yerine getirirken düşük performans göstermektedirler [59]. Üç yaş civarında belirtilerini göstermeye başlayan dikkat eksikliğinin tanısı genellikle ilkokul yıllarında konmaktadır [9]. Dikkat eksikliği belirtileri olup hiperaktivitesi bulunmayan çocuklar; öğrenme sorunu ve okul başarısızlığı yaşayana dek gözden kaçmakta ve tanılama süreci uzamaktadır [4].

DSM-V tanı ölçütlerine göre 9 belirtinin çocuklukta en az 6’sının, yaşı ileri gençlerde ve erişkinlerde (17 yaşında ve daha büyük) en az 5’inin bulunduğu durumlarda DEHB tanısından söz edilebilir. DEHB olan bireylerde genellikle 12 yaşından önce belirtileri gözlemlenir. Bu belirtiler en az 6 aydır görülmektedir. Ayrıca tanı koymak için, sorunların en az iki farklı ortamda ortaya çıkması gerekmektedir [1].

2.1.3. Görülme sıklığı

DEHB’nin görülme sıklığı ile ilgili araştırmaların sonuçları, kullanılan tanı ölçütleri ve yöntemlere göre farklılıklar göstermektedir. APA tarafından DEHB tanısı bulunan çocukların oranı %3-7 olarak tahmin edilmektedir [60]. Özmen’nin (2010) aktardığına göre, Lauth ve Schlottke (2001), DEHB’nin gelişim dönemlerine göre görülme sıklığını, okul öncesi dönemde (4-6 yaş) %3, okul çağındaki öğrencilerde (6-13 yaş) %3-7 ve ergenlikte (14-20 yaş) %6 olarak belirtmektedirler [61]. Çocuklarda en sık teşhis edilen psikiyatrik bozukluktur. DEHB dünya genelinde çocukların %5-12’sini etkilemektedir [62]. Ülkemiz’de yapılan bir çalışmaya göre okul çağı çocuklarında %5 oranında olduğu belirtilmektedir. Bu kadar sık görülen bir durumun tanınması ve bu çocuklara gereken psikiyatrik yardımın verilmesi çok önemlidir [63-64].

Erkeklerde sıklığı kızlardan fazla olup, erkek/kız oranı 3-5/1 arasında bildirilmektedir. Kızlarda DEHB’nin daha çok dikkatsizlik ve bilişsel zorluklarla seyretmesi, dürtüsellik ve saldırgan davranış sorunlarının daha az olması nedeniyle, gözden kaçtığı ya da önemsenmediği düşünülmektedir [65].

2.1.4. DEHB'ye neden olan etmenler

DEHB'ye neden olan etmenler kesin olarak bilinmemekle birlikte, çalışmalar genetik yatkınlıkla birlikte çevresel etkenlerin de katkısıyla oluşan, beyindeki yapısal ve işlevsel farklılıkların bulunduğu nörogelişimsel bir bozukluk olduğunu ortaya koymaktadır [63, 66-67].

Yapılan çalışmalarda DEHB'de genetik faktörlerin hastalığın aktarımında ciddi derecede etkili olduğu görülmektedir [68]. DEHB tanısı bulunan çocukların ailelerinde DEHB görülme sıklığı %20-%50 arasındadır. Bu sonuca göre DEHB tanısı alan bireylerin birinci dereceden akrabalarının DEHB görülme riski normal topluluğa kıyasla 4-10 kat fazladır [4]. Konuyla ilgili tek yumurta ve çift yumurta ikizlerinde yapılan karşılaştırma çalışmalarında tek yumurta ikizlerinin her ikisinde de DEHB görülme oranı %80-90, çift yumurta ikizlerinde her ikisinde de DEHB görülme oranı %30 olduğu [69] ve DEHB tanısı olan çocukların kardeşlerinin DEHB tanısı olmayan çocukların kardeşlerine göre daha fazla risk grubu içinde oldukları gözlemlenmiştir [70].

Çevresel etkenler incelendiğinde; Rutter, Cox, Tupling, Berger ve Yule düşük sosyoekonomik durum, yoğun evlilik sorunları, geniş aile, ebeveynlerin suça eğilimli olması, annenin psikopatolojisinin olması ve evlat edinilmiş olma olmak üzere altı ailesel risk faktörü olduğunu belirtmişlerdir [71]. Annenin gebelik öncesi ya da gebelik sırasında tıbbi ve duygusal sorunları bulunması, gebelikte sigara ve alkol kullanım öyküsü, doğum komplikasyonları, düşük doğum ağırlığı öyküsü ve çocuğun anne sütü alma süresinin az olması DEHB gelişim riskini artırdığı bildirilmiştir [72]. Biederman ve diğerleri DEHB tanısı bulunan çocukların aile yapılarının çoğunlukla düzensiz olduğunu, ebeveynlerden en az birinin bir psikopatolojiye sahip olduğunu ve bu olumsuz aile- çevre koşullarının var olan belirtileri kötüleştirdiğini belirtmişlerdir [73]. Bu çevresel etkenler DEHB'yi meydana getirmeseler bile, olumsuz sosyal nedenler bozukluğun gelişimini ve seyrini etkileyebilecek potansiyel riskler içermektedir [60, 74].

Ayrıca DEHB olan bireylerin beyinlerinde yapısal işlev farklılıkları bulunmaktadır. Dikkatin yoğunlaştırılması, sürdürülmesi, davranışların kontrol edilmesi, planlama yapılmasından sorumlu olan alanlarda ön bölge, beynin orta kısmında bulunan prefrontal korteks, alt motor ve duyu bölgeleri arasındaki iletişim ve yönetimi sağlayan yapıların ve

beyinciğin normal bireylerdekine oranla daha küçük ya da farklı bir simetride olması söz konusudur. Bu farklılıkların hastalığa neden olduğu düşünülmekte ancak bu incelemeler bir tanı aracı olarak kullanılmamaktadır [47].

2.1.5. Sınıflandırılması

DEHB; birleşik tip, dikkatsizliğin baskın olduğu tip ve aşırı hareketliliğin-dürtüsellüğün önde olduğu tip olmak üzere üç alt tip olarak sınıflandırılır.

Birleşik alt tipinde; DSM-V'e göre bireyin hem dikkatsizlik hem de aşırı hareketlilik ve dürtüsellik tanı kriterlerini son altı ay içinde karşılamış olması gerekir. Kız ve erkeklerde en sık görülen alt tiptir. Akranlarına göre aşırı derecede hareketlilik mevcut, aşırı konuşma her şeyi elleyip kurcalama, sırasını bekleyememe, düşünmeden davranma gibi dürtüsellik semptomlarından dolayı sosyal yaşantılarında sık sık problemler yaşarlar. En ufak bir şeyde dikkatleri hemen dağılır, dikkatini toparlamakta ve sürdürmekte güçlük yaşarlar [1].

Dikkatsizliğin baskın olduğu alt tipde; DSM-V'e göre bireyin son altı ay içinde dikkatsizlik tanı kriteri karşılamış, fakat aşırı hareketlilik ve dürtüsellik tanı kriteri karşılanmamıştır. Bu alt tipe bulunanlar dikkatini toparlamada, devam ettirmekte sorun yaşarlar [1]. Yapılan araştırmaların çoğunda DEHB dikkat eksikliği baskın tipin diğer alt tiplere oranla daha sık görüldüğü; dikkat eksikliği baskın tipi sırasıyla birleşik tipin ve hiperaktivite-dürtüsellik baskın tipin izlediği saptanmıştır. Kızlarda DEHB dikkat eksikliği baskın tip diğer alt tiplere oranla daha sık görülmektedir [75].

Aşırı hareketliliğin-dürtüsellüğün önde olduğu tipde; son altı ay içinde bireyin aşırı hareketlilik ve dürtüsellik tanı kriteri karşılanmış, dikkatsizlik tanı kriteri karşılanmamıştır. Bu alt tip erkeklerde daha sık görülmektedir [1].

Ayrıca; bu alt tiplerin dışında DEHB tanısı almak için eşiğin altında kalan vakalar veya bütün tanı ölçütlerini karşılamak için yeterli olanakların olmadığı kişiler için, "Başka türlü adlandırılmayan DEHB" olarak kodlanabilir. Ancak, DEHB'ye ilişkin semptomlar işlevsellikte bozulmaya yol açmış ve başka bir ruhsal bozukluk ile daha iyi açıklanabilir durumda olmamalıdır [1].

2.1.6. Tedavisi

DEHB çok önemli psikiyatrik, akademik ve sosyal sorunlara yol açabilen ciddi bir toplum sağlığı problemi olduğundan DEHB tanı ve tedavisi gün geçtikçe büyük önem kazanmaktadır [76]. Kandemir'in (2009) aktardığına göre; Barkley, Fischer, Edelbrock ve Smallish (1991), DEHB'nin erken tanısı konulduğunda kolaylıkla ve hızlı bir şekilde tedavi edilebilen bir bozukluk olduğunu ve tedaviye %90 gibi yüksek bir oranda cevap verdiğini bildirmektedir [77].

DEHB tedavisinde seçenekler ilaç tedavileri ve psikososyal-psikoterapötik yaklaşımlar olarak özetlenebilir. DEHB'de tedavi seçenekleri [78];

a) İlaç tedavileri

1. Psikostimülanlar
2. Atomoksetin
3. Diğer ilaç tedavileri

b) Psikoterapötik/Psikososyal Müdahaleler

1. Davranışçı yaklaşımlar
2. Aile/Ebeveyn Terapileri

DEHB tedavisinde en doğru yol her olguya kendi gereksinimine uygun bir tedavi uygulamaktır. Ancak, DEHB biyolojik nedenli bir hastalık olduğu için tedavisinde ilaç tedavisi en temel rolü oynar [46, 65, 79]. DEHB tedavisinde en sık kullanılan ilaç grubu stimülanlardır. Ülkemizde DEHB tedavisinde kullanılan birinci sıra ilaçlardan metilfenidat (Ritalin ve Concerta) ve atomoksetin bulunmaktadır [46]. İlaç kullanımı genellikle 6 yaşından sonra başlamaktadır. Ancak okul öncesi dönemde tedavinin ileriye dönük olumlu etkileri azımsanmamalı ve 6 yaş öncesinde psikoterapi ve psikososyal yöntemler ile tedaviye başlanmalıdır [80].

DEHB'de ilaç tedavisinin yanında aile eğitimi ve davranış tedavisini de içeren çok yönlü tedavi yaklaşımları önerilmektedir. Bu yaklaşımlar aile, okul ve çocuk odaklı olmaktadır. Davranış tedavisinde; çocuğun düşünce ve davranışlarını tekrar şekillendirebilmek için istenen ve istenmeyen davranışların sonuçları gösterilir [79]. Anne baba eğitimi

çalışmalarında tedavinin sonunda çocuklarda DEHB'nin temel belirtilerinde ve eşlik eden karşı gelme ve yıkıcı davranışlarda azalma, anne babalarda iletişim becerilerinde değişiklikler, davranış kontrolü ve başa çıkma becerilerinde artış, strese azalma ve anne babalığa ilişkin özgüvende artış bildirilmiştir. En belirgin düzelmenin ilaç ve çok yönlü tedavi gruplarında görüldüğü belirtilmektedir [81].


2.2. Uzman Sistemler

2.2.1. Uzman sistem tanımı

Uzman Sistemler, yapay zekânın alt dallarından biridir. Bir uzman sistem, belirlenen problemin çözümü ile ilgili bir veya daha fazla uzmanın bilgi ve becerisini kullanan bir bilgisayar sistemidir [14]. Bu sistemler ele alındıkları alanla ilgili özelleşmiş bazı problemlerin çözümüne yönelik uzmanların bilgisini taklit etmeyi amaçlar ve her zaman bilgiye dayalı işlem yapan danışman bilgisayar programları olarak kabul edilir [82]. Nابیev ise uzman sistemi; bir konuda uzman kişi ya da kişilerce yapılabilen, yargılama ve karar verme işlerini modelleyebilen bilgisayar sistemleri olarak tanımlamaktadır. İyi geliştirilmiş bir uzman sistem, konusunda uzman olan kişilerin yapabildiği tasarım, planlama, teşhis etme, yorumlama, özetleme, genelleme, kontrol etme, tavsiyelerde bulunma gibi işlemleri taklit edebilir [83]. Kısaca; uzman sistemler uzmanlık gerektiren bir alanda bilgiyi aktarmak, yorumlamak ve çözüm üretmek için oluşturulmuş özel bilgisayar programlarıdır [84].


Uzman sistemler, uzman insanın çözebileceği karmaşık problemlerin çözümüne olanak sağlamaktadır. Belirli bir alanda sadece o alan ile ilgili bilgilerle donatılmış ve problemlere o alanda uzman bir kişinin getirdiği şekilde çözümler getirebilen bilgisayar programlarıdır. İyi tasarlanmış sistemler belirli problemlerin çözümünde uzman insanların düşünme işlemlerini taklit ederler. Uzman sistemler, uzmanın bilgilerine sahip olarak onun yerini almaya çalışır. Böyle bir sisteme sahip olmak kişiyi uzman yapmaz, fakat bir uzmanın yapacağı işin bir kısmını veya tamamını yapmasını sağlar [85]. Uzman sistemlerde programı kullanan kişi, uzman sistem programına gerçekleri vermekte ve karşılığında uzman tavsiyesi veya uzmanlık almaktadır [86].

Uzman sistemler temelde, yapay zekâ programlarından geliştirildikleri amaç yönüyle farklılaşmaktadır. Yapay zekâ programının amacı herhangi bir insanın çözebileceği problemleri çözmektir. Hâlbuki bir uzman sistemin amacı uzman bir insanın çözebileceği problemleri çözmektir. Örneğin satranç oyunu bir program olarak düşünüldüğünde ilk bakışta bir uzman sistem gibi gözükmektedir. Çünkü bu konuda uzman olan kişi iyi bir satranç oyuncusudur. Birçok hamleyi düşünmekte ve en iyi olduğunu düşündüğü hamleyi oynamaktadır. Oysa bilgisayardaki satranç programları geleneksel programlama teknikleri kullanılarak yazılmıştır. Olay hem çok basit hem de karışıktır. Basit olmasının nedeni her hamleye karşı bilgisayarın bütün hamleleri kapsayan bir sistem oluşturmasıdır. Olayın karmaşık olan yönü ise mümkün olan 10^{120} hamle içinden seçim yapmaktır [14].



Şekil 2.2. Yapay zekâ ve uzman sistemlerin amaçları [14]

Uzman sistemler belirli bir problem kümesi için uzman gibi davranan programlardır. Bir uzman sistem en basit haliyle bilgi tabanı ve çıkarım mekanizmasından oluşur. Şekil 2.3’de uzman sistemlerin temel çalışma prensibi gösterilmektedir:



Şekil 2.3. Uzman sistemlerin çalışma prensibi [86]

Uzmanlar problemleri çözerken bilgilerini ve deneyimlerini kullanırlar. Bu bilgi ve deneyimlerin bilgisayar tarafından anlaşılır olması ve bilgisayarda saklanması

gerekmektedir. Uzman sistemler, bilgi tabanında saklanan bu bilgileri kullanarak, insan karar verme sürecine benzer bir süreç ile problemlere çözüm üretirler [87].

Uzman sistemler için amaç, karar vermeye yardım eden bilgisayar tabanlı bir model oluşturmak ve sistemdeki belirsizliği modelleyebilmektedir. Modeli oluşturmak için kullanılan yazılım, direkt olarak karar verici tarafından kullanılmalı ve veri tabanı aracılığı ile diğer yazılım sistemleri ile ilişkili olmalıdır. Uzman sistemde çıkarım mekanizması olmalı ve bu bilgi sunuşunu yönetmek için, sistemi modüler olarak göstermelidir. Bu mekanizma çok sayıda modül ile çalışır ve modüller belirli bir düzende sunulabileceği gibi birbirinden tamamen bağımsız da olabilir [88]. Kısaca uzman sistemler daha kurallı ve rasyonel, objektif kararların alınması, insan gücünden tasarruf edilmesi, uzman kişilere olan bağımlılığın azaltılması, uzmanlık gerektiren alanlara herkesin belli oranlarda girebilmesi, her şeyden önemlisi doğru kararların alınarak hata oranlarının azaltılması amacıyla kullanılırlar [89].

Uzman sistemler ile geleneksel bilgisayar programlar arasındaki en temel farklar [90] Çizelge 2.1’de listelenmiştir:

Çizelge 2.1. Geleneksel programlar ve uzman sistemler arasındaki farklar [90]

Uzman Sistem	Geleneksel Program
Kararlar alır ya da karar desteği sunarlar	Algoritma uygulanıp, sonuçlar hesaplanır
Açıklayıcı bilgi sunabilir	İşlemleri gerçekleştirir
Kontrol mekanizması ve bilgi modüler yapıdadır ve birbirinden ayrılmış durumdadır.	Geliştirilmeye bağlıdır ve genellikle sistemlerde kontrol, veri, bilgi iç içe yapıdadır.
Sembolik karşılaştırmalar yapabilir.	Sayısal hesaplamalar gerçekleştirir.
Bilginin tam olmaması durumunda da çalışabilir.	Çalışmak için kesin bilgiye ihtiyaç duyar.
Sezgisel yöntemlere dayanır	Algoritmalara dayanır
Belirsizliği değerlendirebilir.	Belirsizliği değerlendiremez
Esnek bir yapıya sahiptir, geliştirme ve değiştirme düşük maliyet gerektirir.	Esnek bir yapıya sahip değildir, geliştirme ve değiştirme maliyetleri yüksektir.

Geleneksel programları; veritabanları ve algoritmalar oluştururken, uzman sistemleri bilgi tabanı ve çıkarım mekanizmaları oluşturmaktadır [91]. Uzman sistemleri geleneksel programlardan ayıran özellikleri; matematiksel ve sembolik bilgiyle akıl yürütmesi, deneyimsel ve algoritmik yöntemleri kullanması, problem alanında uzmanla beraber çalışması, problemin çözümüne yönelik verdiği yanıtların gerekçelerini anlaşılabilir kılması ve esnekliğini koruması olarak sıralanabilir [92]. Uzman sistemler kesinlikle makine aklını temsil etmez. Bir veya daha çok uzman kişinin muhakeme yeteneklerini taklit eder. Bu sistemler bilgisayarın yönetim karar mekanizmasına entegre edilmesi yaklaşımını benimser [93]. Sonuç olarak uzman sistemler, insan uzmanlığı gerektiren problemin çözümüne yönelik geliştirilen, bilgi tabanı ve çıkarım mekanizmasından oluşan yazılımlardır.

2.2.2. Uzman sistemlerin temel özellikleri

Uzman sistemlerin görevlerini tam olarak yapabilmesi için bazı özelliklere sahip olması gerekir. Bir uzman sistemde olması gereken temel özellikler aşağıdaki gibi sıralanabilir [94-96]:

- Hazırlanan uzman sistemin güvenilir olması yani hata vermemesi gerekir.
- Uzman sistem bir konuda verdiği sonucun aşamalarını sırası ile açıklayabilmelidir.
- Bir uzman sistem programı, sorulan sorulara uzmana yakın düzeyde cevap verebilmelidir.
- Tasarlanan sistemin, sorulan sorulara yönelik bir sonuca uygun bir sürede varabilmesi ve hatta uzman bir insandan daha çabuk karar verebilmesi beklenir.
- Problem çözümünde kullandıkları yaklaşımın hiyerarşik düzende olması ve bu çözümde en az uzman kadar iyi olması beklenir.
- Kesin veya tam olmayan bilgilerle baş edebilmeleri ve bunlar için de yaklaşık sonuç üretebilmelidir.

2.2.3. Uzman sistemin avantaj ve dezavantajları

Uzman sistemlerin kullanıldığı alana göre çok çeşitli yararları vardır. Uzman sistemlerin avantajlarından en temel olanları aşağıdaki gibi sıralanabilir [14, 97-98]:

1. Verimlilik artışı: Uzman sistemler insandan daha hızlı çalışır. Bu nedenle daha az işgücü ve daha az maliyet gerektirir. Sonuç olarak, uzman sistemlerin kullanımı verimlilik artışını sağlar.
2. Süreklilik: Uzman kişilerden farklı olarak, uzman sistemlerde unutkanlık yoktur ve sürekli aynı kapasite ile kullanılabilir.
3. Maliyet tasarrufu: Uzman sistemleri bir kere aldıktan sonra para ödenmemektedir. Oysa insan uzmanların özellikle sık ve belirsiz zamanlarda kullanılma maliyeti çok yüksek olmakta ve onlara devamlı maaş ödenmesi gerekmektedir.
4. Kalite düzeyinin yükselmesi: Uzman sistemler tutarlı ve uygun sonuçlar üreterek sistem kalitesine katkıda bulunur. Hata oranlarının çok düşük olması ve tutarlı karar verebilmesi kaliteyi yükseltmektedir. Bir uzman, ele alınan konu hakkında hata yapabilir ya da önemli bir ayrıntıyı gözden kaçırabilir. Oysa uzman sistem doğru olarak geliştirilirse, konu hakkındaki tüm detayları gözden geçirerek uygun sonuca ulaşır.
5. Uzmanlığın yaygınlaştırılması: Her yere bir insan uzmanın götürülebilmesi mümkün olmayabilir, zira ihtiyaç nispetinde uzman bulunmayabilir. Yeterli sayıda uzman olmayan alanlarda uzman sistemler oluşturmak sıkıntıları gidermektedir. Uzman sistemlerin kolayca kopyalanarak diğer uygun alanlara kullanılması, uzman sistemlerin yaygınlaştırılabilmesine imkân tanımaktadır. Oysa yeni bir uzman insanın yetiştirilmesi pahalı ve zaman alan bir süreçtir.
6. Eğitim verme: Açıklama yapma özelliği olmayan kullanıcılara, karşılaştıkları sorunların çözümleri ile ilgili bilgiler vererek onların eğitimini sağlamaktadır. Bu özellikle öğrencilerin eğitilmesi açısından önemlidir.
7. Sağlıklı öneri üretimi: Bazı uzmanlar ne kadar yetenekli olurlarsa olsunlar zaman kısıtlı olduğunda telaşa kapılmakta ve sağlıklı değerlendirme yapma özelliklerini yitirmektedirler. Böylece yanlış sonuçlara varma ihtimalleri artmaktadır. Bir bilgisayar programı için böyle bir durum söz konusu değildir, yani uzman sistemler problem alanlarında çözüme ulaşmak için verimli bir şekilde çalışırlar.
8. Kapsamlılık: Uzman sistemler, birçok uzmanın görüşlerini birleştirerek öneri kalitesini artırır.
9. Sonuçlardan yararlanma yeteneği: Çok miktarda veri olduğunda bile olabilecek tüm ilişkileri gözden geçirip farklı sonuçlar üretme yetenekleri vardır.

Uzman sistemlerin üstünlüklerinin yanı sıra dezavantajlarını da göz önüne almak gerekir. Uzman sistemlerde bilgi her zaman hazır olarak mevcut değildir. Uzmanlığı uzman kişilerden alabilmek zordur. Her uzmanın aynı olaya yaklaşımı farklı olabilir. Birden fazla uzman ile çalışılması çelişkili durumlar ortaya çıkarabilir, bu durumda problem alanını alt alanlara bölmek ve her alan için bir uzmandan yararlanmak daha uygun olabilir. Yüksek seviyede deneyimli bir uzman için dahi zaman baskısı altında durum hakkında saptamalarda bulunmak zordur. Uzmanın sunacağı gerçekler ve ilişkileri ifade etmek zordur. Uzman sistemi geliştirme zamanının uzun ve maliyetinin yüksek olması uygulamaları kısıtlayıcı bir etken olabilir. Ayrıca uzman sistemin alan sınırları daraldıkça daha iyi çalışırlar fakat bu sınır, uzman sistemin kullanımını gereksiz hale getirecek kadar da kısıtlanmamalıdır. Tüm bu sebeplerden dolayı da yöneticilerin uzman sistemi kabul etmeleri zor olabilir [99].

Uzman Sistemlerin dezavantajları aşağıdaki gibi sıralanabilir [14, 100-101]:

1. Uzmanlık bilgisinin olmayışı: Bazı konularda yetişmiş uzmanlara ulaşamamaktadır ve uzmanların çoğunun kendi bilgisini aktarmak için zamanı olmamaktadır.
2. Uzmanların bilgilerinin elde edilmesindeki güçlükler: Uzman sistemlerin tasarımında en güç olan nedenlerden en önde gelenidir. Uzmanlar sahip oldukları bilgileri çeşitli psikolojik sebepler nedeniyle vermeye yanaşmamaktadırlar. Bu sebeplerden işini kaybetme korkusu ve yeni teknolojiye olan şüphe gösterilebilir. Kısaca insanlardan bilgi almak zordur.
3. Aynı konuya uzmanlarının farklı bakış açılarına sahip olmaları: Her uzmanın konusuna yaklaşımı doğru olmakla birlikte farklı da olabilmektedir. Yalnız bir uzmandan elde edilen bilgilere dayanan uzman sistem yalnız o uzmanın probleme olan bakış açısını sergileyecektir, ama diğer bir uzman problemin çözümüne daha farklı açıdan ve belki de daha ekonomik veya daha doğru bir tutum sergileyebilir.
4. Uzman sistemlerin dar alanlara yönelik olması: Uzman sistemlerden verim alınması henüz yalnızca dar alanlarda kalmakla mümkündür. Hatta bazen bu alan çok dar olmak zorundadır. Bu alandan az da olsa dışarı çıkılması sistemin çalışmasını zorlaştırmaktadır.
5. Bilgi tabanının tasarımının zorluğu: Uzman sistemin sağlıklı çalışabilmesi için bilgi tabanının çok iyi oluşturulmuş olması şarttır. Bunun yapılması ise oldukça zordur. Bilgi her zaman okunabilir uygunlukta değildir. Bilgi ve kural tabanı oluşturulduktan

sonra uygulamada deęişiklik olması durumunda kural tabanı güncellenmek zorundadır.

6. Denetim mekanizmasının eksikliği: Uzman sistemler tanımlanan kuralların yönlendirmesine göre sonuç verirler. Pek çok uzman kişisel yöntemler ile çalışmaktadır ve onlar bu yöntemi açıklamakta zorluk çekmektedir. Bu durum tam doğrulukta çalışan uzman sistem oluşturmanın mümkün olamayacağı düşüncesine neden olmaktadır.
7. Maliyet yüksekliği ve zaman fazlalığı: Uzman sistemlerin ilk uygulama maliyeti yüksek olup geliştirilmesi uzun zaman almaktadır. Sonuç alındığında işletim maliyeti düşük olduğu için kuruluş için avantajlı olabilir ancak sonuç alınamazsa yapılan maliyet boşa gitmiş olacaktır.


2.2.4. Uzman sistem uygulama alanları

Uzman sistemler yorumlama, tahminleme, teşhis, tasarım, planlama, uyarma, onarma, eğitim, kontrol [102], çizelgeleme, izleme, sinyal yorumlama ve yapılandırma [82] gibi farklı alanlarda uygulanabilmektedir. Uzman sistemler birçok disiplin ve meslekte kullanılmaktadır. Bu tür sistemlerin uygulama alanlarını aşağıdaki gibi sınıflandırmak mümkündür [95]:

- Mevcut uzmanlık bilgisinin daha geniş alanlara yayılmasında,
- Karmaşık problem çözme işlemlerini hızlandırmada,
- Rutin ve nispeten kolay problemleri çözümleme yoluyla uzmanlara daha zor ve karmaşık problemleri çözümlmek için zaman kazandırmada,
- Herhangi bir nedenle işten ayrılma durumlarının sebep olabileceği bilgi kayıplarına, uzmanlık bilgilerini depolamak yoluyla engel olmada,
- Hiç kimsenin tek başına yeterli bilgiye sahip olmadığı durumlarda, birden fazla sayıda uzmanın bilgisinin ortak kullanılmasında,
- Bir veya birkaç uzmanın birçok kişiye bilgi vermesi gereken durumlarda kullanılırlar.

2.2.5. Uzman sistem bileşenleri ve tasarımı

Uzman sistemlerin genel yapısı kullanım alanlarına göre farklılık göstermekle birlikte basit bir uzman sistem temelde bilgi tabanı ve çıkarım mekanizmasından oluşmaktadır. Açıklama birimi uzman sistemin zorunlu bir birimi olmasa da geliştirilen birçok uzman sistem yapısında var olan bir birimdir [103]. Uzman sistemin yapısı Şekil 2.4’de verilmiştir:



Şekil 2.4. Uzman sistemlerin genel yapısı [14]

Uzman sistemlerin temel çalışma prensibinde kullanıcıdan alınan veriler, bilgi tabanındaki kurallar doğrultusunda çıkarım mekanizmasında yorumlanır ve üretilen sonuç açıklama birimi üzerinden kullanıcıya sunulur.

- **Bilgi Tabanı:** Problemin çözümü için gerekli bilgileri içerir. Uzman sistemlerde bilgiler kurallar halinde tutulmaktadır. Her kural bir ilişkiyi, bir emri, bir stratejiyi ya da bir sezgiyi ifade etmektedir. Kurallar “If Then” yapısındadır. Kuralın ilk bölümü doğru ise kuralın ikinci kısmı uygulanır [104]. Bilgi tabanı değerlendirmeyeyle ilgili kuralların ve

referans modelin, bilgisayarın çıkarım yapabileceği formata getirilmesini ve kaydedilmesini sağlar [105].


Uzman sistem için en büyük problem bilgilerin elde edilmesi ve değerlendirilmesidir. Uzmardan bilgi elde etme, karşılıklı görüşmeler gerektiren, uzun zaman alan, dikkat isteyen ve sistematik çalışmalar gerektiren bir işlemdir [106]. Bu nedenle, bir uzman sistemin gücünün önemli bir bölümünü bilgi tabanına yerleştirilen bilgi oluşturmaktadır. Ancak bu bilgi klasik veri tabanlarındaki gibi, bilgilerin toplanıp depolanması şeklinde olmayıp, temsil ettiği problemin yapısını yansıtarak, problemi anlamaya yönelik olarak ifade edilmelidir. Bu problemin yapısı ve problemi anlama özellikleri, geniş ölçüde bilginin ifade edilme şekline bağlıdır. Bilgiyi ifade etmenin pek çok yolu bulunmakla birlikte, en çok kullanılan ifade tekniklerinden bir tanesi kurallardır. Bilgi tabanı kurala dayalı ifade edilmiş kurala dayalı bir uzman sistemde; bilgi problem ile ilgili hükümler “facts” ve bu hükümleri yönlendirip yöneten kurallar ile ifade edilmektedir [107]. Literatürde uzman sistemlerin “bilgi tabanlı sistemler” olarak adlandırılmasının en önemli nedeni, uzman sistem geliştirilmesinde kullanılan bilginin öneminden kaynaklanmaktadır. Bir başka ifade ile uzman sistemlerin merkezini bilgi tabanı oluşturmakta ve uzman sistemin etkinliği bilgi tabanında bulunan bu bilgiden doğrudan etkilenmektedir [103].

Bilgi tabanı, problem hakkında ön bilgilerin bulunduğu veri tabanı ve uzman bilgisinin aktarıldığı kural tabanı bileşenlerinden meydana gelir. Veri tabanı, problemin o andaki durumunu anlatan gerçekler ve belirli bir ana kadar elde edilmiş nitelik-değer çiftlerinden oluşur. Kural tabanı ise belirli durumlarda çalışan ve “eğer – o halde” veya diğer bir yapıda tanımlanan kurallar topluluğudur. Kurallar, problemin ve sonuca ulaştıracak şartların düzgün şekilde ifade edildiği cümlelerdir [108].

- Çıkarım Mekanizması: Çıkarım mekanizması bilgi tabanına kayıtlı bilginin tercümesini yaparak bilgi tabanından sonuç çıkarır. Bir uzman sistemde bilgi tabanını kullanıp çözüm almayı gerçekleştiren, bu sayede de uzman sistemin karar vermesini sağlayan mekanizmadır [109]. Çıkarım mekanizması bilgi tabanını kullanır, bu kuralların yorumlanmasında genellikle ileriye doğru ve geriye doğru zincirleme teknikleri kullanılır.

İleriye doğru zincirleme tekniğinde problem en baştan başlayarak (if cümlesinden) sonuç kısmına (then) ulaşır. Bu yöntem tümevarım mantığı ile çalışır. Bütün kuralların şartı


sağlayıp sağlamadığı göz önünde tutularak sonuca ulaşılır. Eğer şartlar sağlıyor ise “then” kısmında yer alan yargı cümlesi doğrudur. Bu cümle şartlara göre elde edilen sonuçtur [110]. İleriye doğru zincirleme kuralının diyagramı Şekil 2.5’de verilmiştir:



Şekil 2.5. İleriye doğru zincirleme kuralı [110]

İleri zincirleme kuralı; belirtilen dayanak noktasından hareket ederek mümkün olan sonuçları bulmaya yarayan bir metottur. İleri zincirleme özellikle teşhis işlemlerinde kullanılır. Burada verilen her girdi için bir değerlendirme yapılarak mümkün olan tüm çıkışlar üretilmeye çalışılır. Mümkün olan çıktıların küçük olması durumlarının hepsi için ileriye zincirleme kullanılabilir. Yalnız bu işlemler esnasında geriye zincirleme işlemine gerek duyulmadığının anlaşılması lazımdır. Eğer çok fazla sonuç çıkarımı varsa ileriye zincirleme etkisiz kalabilir veya işlemi gerçekleştirmesi çok fazla zaman alabilir [111].

Geriye doğru zincirlemenin karar verme ünitesi; kuralın en son ifadesi “then” ifadesi ile başlamakta ve şart ifadesi olan “if” ifadesiyle bitmektedir. Bu kuraldaki zincirleme sistemi “tumdengelim” metoduna göre çalışmaktadır. Kural “then” ifadelerini tek tek inceleyerek çalışmaktadır [112]. Geriye doğru zincirleme kuralının diyagramı Şekil 2.6’de verilmiştir:



Şekil 2.6. Geriye doğru zincirleme kuralı [112]

Geriye doğru zincirleme yönteminde önceden bir hipotezin gerçek olduğu varsayılır ve bu hipotezi kanıtlayacak deliller aranır. Örneğin, mutfakta su kaçağı olduğu kabul edilip sonuç çıkarma aşında geriye doğru giderek kaçağın sebebi araştırılır. Hipotezin doğrulanması için “mutfakta problem” ve “dışarıdan su girişi yok” doğru olmalıdır. Eğer giriş ıslaksa ve banyo kuruyorsa “mutfakta problem” doğrulanır. “Dışarıdan su girişi yok” un doğrulanması için pencerenin kapalı olduğu tespit edilmelidir. Bu tip sebeplendirmeye

geriye doğru zincirleme denir. Çünkü “mutfakta su kaçağı” hipotezinden zincirleme kurallar izlenerek “giriş ıslak” gibi delillere ulaşılabilir [14].

Çıkarım mekanizmasında geriye doğru zincirleme kuralı metodunu kullanan bir uzman sistem, eğer belirtilen kural karşılanıyorsa daha az işlem yapar. Belirtilen kuralların uygulanmasıyla elde edilen mümkün sonuçların her birinin değerlendirilmesinden vazgeçilir. Geriye zincirleme metodu verinin çok büyük olduğu durumlarda oldukça faydalıdır [111].

- Kullanıcı Arayüzü: Kullanıcı arayüzü kullanıcı ile program arasında iletişimi sağlar. Kullanıcı arayüzü ile uzman sistemin bilgi tabanını kontrol etme, kural ekleme ve çıkarma gibi işlemler gerçekleştirilir [113]. Genellikle neden ve nasıl sorularına cevap veren bir açıklama ünitesini içerir. İlgili problem için göreve özgü veriye karşılık gelir [110]. Kısaca kullanıcı arabirimi kullanıcının uzman sistemin çalışması sırasında bilgisayarda gördüğü görüntüdür.


- Açıklama Birimi: Açıklama birimi uzman sistemleri diğer sistemlerden ayıran bir özelliktir. Açıklama biriminde kullanıcıya çeşitli yardımlar verilebilir, sorular açıklanabilir, uzman sistemin çıkardığı sonucu nasıl ve neden çıkardığı gösterilebilir.

Açıklama birimi tanımlanmış olan problemi çözüme ulaştırmak için kullanılmış olan uzman sistem mantığının kullanıcı tarafından anlaşılmasını sağlayan bölümdür. Bu birim sayesinde, hangi işlemin neden yapıldığını kavrayabilen kullanıcıların etkileşimli olarak sisteme gerektiğinde müdahale ederek mevcut duruma uygun güncellemeleri yapmaları ve kendi bilgi birikimlerini sisteme yansıtmaları mümkün olmaktadır. Kullanıcı, bilgisayarla etkileşim esnasında sisteme müdahale ederek ne yapıldığını ve neden böyle bir akıl yürütme izlendiğini sisteme sorabilir. Açıklama birimi bir uzman sistem yapısının zorunlu bir birimi olmayıp, sistemi kullanacak olan kullanıcıların sistemin çalışma şeklini kavraması, kolayca kullanım imkânı sağlaması ve kullanıcı müdahalesine imkân tanınması açısından geliştirilen birçok uzman sistem yapısında var olan bir birimdir [103].

Açıklama ünitesinde kullanıcıya çeşitli yardımlar verilir. Sorular açıklanır, uzman sistemin çıkardığı sonucun nasıl ve neden çıkarıldığı sunulur [114]. Bu ünite elde edilen sonuçların

kullanıcılara iletilmek üzere uzman sistem tarafından raporlandığı bölümdür. Raporun doğruluğu geri bildirim için önemlidir [113].

Uzman sistemler tasarlanırken kullanım alanına göre akış şemasındaki adımlar birbirinden farklılıklar gösterebilir. Fakat genel anlamda uzman sistemlerin tasarlanmasında takip edilecek prosedürler Şekil 2.7’de verilmiştir [115]:



Şekil 2.7. Uzman sistem tasarlanırken izlenecek prosedürler [115]

Uzman sistemler tasarlanırken uzmanlardan alınan veriler kullanılarak sonuç üretilir. Bu nedenle uzman sistem tasarlanırken problemin çözümüne yönelik kural tabanının oluşturulması sürecinde bilgisine başvurulmuş uzman kişilerin net bir biçimde kuralları ifade edebilmesi çok önemlidir.

2.3. Makine Öğrenmesi

2.3.1. Makine öğrenmesi kavramı


Makine öğrenmesi, bilgisayarların geçmiş bilgilerden elde edilen tecrübelerden yararlanarak, gelecekteki olayları tahmin etmesine ve modelleme yapmasına imkân veren bir yapay zekâ alanıdır. Bilgisayarın bir olay ile ilgili bilgileri ve tecrübeleri öğrenerek gelecekte oluşacak benzeri olaylar hakkında kararlar verebilmesi ve problemlere çözümler üretebilmesidir [15]. Makine öğrenmesi zaman içinde davranışların iyileştirilmesidir [116]. Makine öğrenmesi, örnek veri ya da geçmiş deneyimleri kullanarak bir başarımlı ölçütünü en uygun hale getirmek için bilgisayarları programlar. Bazı parametrelerle tanımlanmış bir modele sahip olduğumuzu düşünürsek “öğrenme”, eğitim verisi ya da geçmiş deneyimleri kullanarak bu modelin parametrelerini en uygun hale getirmek için bir bilgisayar programının yürütülmesi olarak tanımlanabilir. Model ise geleceğe yönelik tahminler yapmak için bir tahmin edici ya da veriden bilgi elde etmek için bir tanımlayıcı ya da her ikisi olabilir [117].

Makine öğrenmesi yöntemleri, geçmişteki veriyi kullanarak yeni veri için en uygun modeli bulmaya çalışırlar. Yeni gelen verileri de bu modele göre analiz ederler. Büyük miktarda verinin incelenip, içerisinden işe yarayan bilginin elde edilmesi işlemine veri madenciliği adı verilir [118]. Veri madenciliği, veri tabanında bilgi keşfi; çok büyük veri hacimleri arasında tutulan, anlamı daha önce keşif edilmemiş potansiyel olarak faydalı ve anlaşılır bilgilerin çıkarıldığı ve arka planda veri tabanı yönetim sistemleri, istatistik, yapay zekâ, makine öğrenmesi, paralel ve dağıtık işlemlerin bulunduğu veri analiz tekniğidir [119].

2.3.2. Makine öğrenmesinin veri madenciliği ile ilişkisi

Makine öğrenmesi ve veri madenciliği arasında doğrudan bir ilişki vardır. Veri madenciliği büyük veri yığınlarından oluşan veritabanı sistemleri içerisinde gizli kalmış bilgilerin çıkarılması işlemidir. Bu süreçte kümeleme, veri özetleme sınıflama kurallarının

öğrenilmesi, bağımlılık ağlarının bulunması, değişkenlik analizi ve anomali tespiti gibi farklı birçok teknik kullanılmaktadır [120]. Makine öğrenmesi ise veri madenciliği sürecinde uygulama aşamasında yer alabilir. Bu aşamada seçilen bir makine öğrenmesi tekniği veri seti üzerine uygulanarak sonuçlar elde edilir [121]. Veri madenciliği sürecinin basamakları aşağıda verilmiştir [122]:



Şekil 2.8. Han, Kamber ve Pei'ye (2011) göre veri madenciliği sürecinde yer alan basamaklar

Şekil 2.8'de gösterilen veri madenciliği sürecinin basamakları aşağıdaki adımları içerir [122]:

- Veri temizleme, gürültülü ve tutarsız verilerin çıkarılması basamağıdır.
- Veri bütünleştirme, birçok veri kaynağının bir araya getirilmesi işlemidir.
- Veri seçme basamağında, yapılacak analiz ile ilgili olan veriler belirlenir.
- Veri dönüşümü basamağında, verinin veri madenciliği yöntemine uygun dönüşümü gerçekleştirilir.

- e) Veri madenciliği basamağında verilerdeki örüntülerin belirlenmesi için veri madenciliği yöntemleri uygulanır.
- f) Model değerlendirme basamağında, bazı ölçütlere göre elde edilmiş ilginç örüntüler bulunur ve değerlendirilir.
- g) Bilgi sunumu basamağında, madenciliği yapılmış elde edilen bilgilerin kullanıcılara sunumu gerçekleştirilir.

Veri madenciliği; bilgisayar bilimini, makine öğrenmesini, veri tabanı yönetimini, matematiksel algoritmaları ve istatistiği birleştiren disiplinler arası bir alandır [123]. Veri üzerinde örüntü bulma bilgi keşfi için önemli bir süreçtir. Veri madenciliği çıkan bilgi ve bu bilgilerin değerlendirilmesi ile uğraşmaktadır. Makine öğrenmesi ise bu bilgiyi çıkarmayı sağlayan teknikler ve bu teknikleri kullanan bilgisayar programlarının kendilerini geliştirmesi ile ilgilenir [121].

Makine öğrenmesi ve veri madenciliğinin ayrıldığı temel nokta; makine öğrenmesi, bilgisayarlara bir problemi çözmek için verileri nasıl kullanacaklarını öğretmeye odaklanırken, veri madenciliğinin bilgisayarlara verilerdeki örüntüleri nasıl tanıyacaklarını öğretmeye odaklanmasıdır. Bu örüntüler daha sonra insanlar tarafından problemlerin çözümü için kullanılmaktadırlar. Veri madenciliği uygulamalarında, verideki örüntüleri keşfedebilmek için makine öğrenmesi algoritmaları kullanılmaktadır [124]. Makine öğrenmesi veri madenciliği sürecinde uygulama aşamasında yer alabilir. Bu aşamada seçilen bir makine öğrenmesi tekniği veri seti üzerine uygulanarak sonuçlar elde edilir [121].


Makine öğrenmesi çevresel durum gözlemleri ve geçiş tabanlı kuralların eşdeğer olduğu öğrenme işlerinin ve öğrenmenin otomasyonudur. Bu geniş bir sahadır, yani sadece örneklerden öğrenme değil aynı zamanda takviye öğrenimi ve öğretmenle öğrenim bu sahaya girmektedir. Bir öğrenme algoritması veri kaynakları ve onun beraberinde yer alan giriş bilgisi ve sonuçlardan oluşur. Makine öğrenmesi önceki örnekleri ve sonuçları inceler ve bu işleri nasıl yeniden yapacağını öğrenir ve yeni durumlar hakkında genellemeler yapar [106].

Makine öğrenmesi ile veri madenciliği arasındaki temel fark ve benzerlikler aşağıdaki gibi özetlenebilir:

- Veri madenciliği istatistik, bilgisayar bilimi, veri tabanı yönetimi ve makine öğrenmesi gibi alanları içine alan ve bu alanları birleştiren disiplinler arası daha genel bir kavramdır [123].
- Makine öğrenmesi bir ajanın gelişen performansı ile ilgiliyken, veri madenciliği anlaşılır bilginin bulunması ile ilgilidir [106]. Başka bir deyişle; makine öğrenmesi, genellikle eğer ortada bir problem var ve problemi çözmek için verilerin nasıl kullanılacağı veya bu problemin çözümünde yüksek performans ile nasıl tanımlama yapılacağı araştırılıyorsa kullanılmaktadır. Veri madenciliği ise genellikle eğer ortada bir veri ambarı var ve bu veri ambarı içinden gizli örüntülerin ortaya çıkarılması araştırılıyorsa kullanılmaktadır.
- Veri madenciliğinin uygulama aşamasında makine öğrenmesi algoritmaları kullanılabilir [124].
- Sinir ağı algoritmaları makine öğrenmesinin omurga parçasını ayakta tutmaktayken veri madenciliği ile de yakından ilgilidir, sinir ağı algoritmaları sayesinde bilginin ortaya çıkarılma çabası vardır [106].
- Makine öğrenmesi küçük veri setleri üzerinde de çalışabilir fakat veri madenciliği genellikle çok büyük, gerçek hayat veri tabanları ile ilgilidir. Bu nedenle etkinlik veri madenciliği için daha önemlidir [106].

2.3.3. Makine öğrenmesi ve veri madenciliğinin uzman sistemler ile ilişkisi

Veri madenciliğinin benzerlik gösterdiği alanlardan bir tanesi de uzman sistemler alanıdır. Ancak veri madenciliği bir uzman sistem yaklaşımı değildir. Her iki yöntem arasındaki fark Şekil 2.9'da grafiksel olarak gösterilmiştir. Fakat heyecan verici olan veri madenciliğinin uzman sistemleri besleyebilecek bir yaklaşım olmasıdır. Uzman sistemlerin en önemli sorunu olan kural tabanını oluşturacak olan kuralların elde edilmesi veri yoğun ortamlarda veri madenciliği yaklaşımları ile desteklenebilir. Örneğin kanser teşhisini amaçlayan bir uzman sistem geliştirilmesi amaçlanıyorsa uzman doktorlardan elde edilecek olan kurallar kanser veri tabanından elde edilebilecek verilerle çok daha zenginleştirilebilir. Bu şekilde çok daha güvenilir uzman sistemlerin oluşturulması mümkün olabilir [125].



Şekil 2.9. Veri madenciliği ve uzman sistemler [125]

Uzman sistemler insan uzmanlığı gerektiren problemlerin çözümüne yönelik geliştirilen [82-83], temelde bilgi tabanı ve çıkarım mekanizmasından oluşan [126-127] ve alan uzmanının düşünme biçimini taklit eden yazılımlardır [82, 128]. Uzman sistemi daha verimli ve etkili kılmak için veri madenciliği ve makine öğrenmesi algoritmaları kullanılmaktadır [129]. Literatür incelendiğinde uzman sistemlerin içinde makine öğrenmesi algoritmalarının sıklıkla kullanıldığı görülmektedir [130-132].

Uzman sistemler; kullanılan algoritmalara, kullanıldıkları alanlara, tasarlandıkları problem türlerine ve bilgi tabanı çeşitlerine göre birçok şekilde sınıflandırılabilirler. Uzman sistemler kullanıldıkları alanlara göre a) tanı amaçlı uzman sistemler b) hata ayıklayıcı ve çözüm önerici uzman sistemler c) yorumlayıcı uzman sistemler d) kontrol amaçlı uzman sistemler e) tasarım amaçlı uzman sistemler f) planlama amaçlı uzman sistemler ve g) eğitici unsurlu uzman sistemler olmak üzere yedi kategoriye ayrılır [85]. Problem türlerine göre a) deterministik ve b) stokastik problemlere yönelik tasarlanmış uzman sistemler olmak üzere ikiye ayrılır [133]. Bilgi tabanı tasarımına göre a) dinamik ve b) statik uzman sistemler olarak ikiye ayrılır [14]. Literatür incelendiğinde bu şekilde daha birçok uzman sistem sınıflandırma türleri mevcuttur [134, 123].

Kullanılan algoritmalara göre ise, uzman sistemin içinde hangi algoritma kullanılmış ise kullanılan algoritmaya göre uzman sistemler sınıflandırılmaktadır. Uzman sistemlerin içinde makine öğrenmesi algoritmaları, bilgi tabanında kuralların otomatik oluşturulması [104] ve modelleme aşamasında bilgi tabanından sonuçların elde edilmesi [132, 135-136] süreçlerinde kullanılmaktadır. Eğer uzman sistemin içinde bulanık mantık algoritması kullanılmış ise “Bulanık Uzman Sistem” [137-138], eğer yapay sinir ağları algoritması kullanılmış ise “Yapay Sinir Ağlarına Dayalı Uzman Sistem” [104, 139], eğer bayes veya markov ağları gibi olasılıksal bir algoritma kullanılmış ise “Olasılıksal Uzman Sistem” [135, 140-141] , sinir ağları ile bulanık mantık gibi en az iki makine algoritması birleştirilmiş ise “Hibrit Uzman Sistem” [21], kurallar kümesi if – then şeklinde ifade edilerek, ileriye doğru zincirleme veya geriye doğru zincirleme teknikleri kullanılmış ise “Kural Tabanlı Uzman Sistemler” [51, 142] gibi kullanılan algoritmalara göre uzman sistem türleri mevcuttur.

Uzman sistemin çıkarım mekanizmasında makine öğrenmesi algoritmaları kullanıldığında, yeni veriler üzerinde uzman kişi teker teker ilgilenecek sınıflandırmak zorunda kalmaz. Sistem elde ettiği öğrenme algoritmaları ve uzman tarafından öğretilen verileri kullanarak yeni veriler üzerinde yorum yapabilir ve kişinin acil ve acil olmayan durumlarını belirleyerek hem uzman kişinin yükünü azaltabilir hem de bireye acil durumda çok hızlı müdahale imkânı sunabilir [143]. Uzman sistemlerin bilgi tabanında, kuralların otomatik oluşturulması sürecinde de makine öğrenmesi algoritmaları kullanılabilir [144]. Alan uzmanından bilgi elde etme karşılıklı görüşmeler gerektiren, uzun zaman alan, dikkat isteyen ve sistematik çalışmalar gerektiren bir işlemdir. Bilginin elde edilmesine “bilgi kazanımı” denir. Araştırmacılar bilgi kazanımını, bir uzman sistemin geliştirilmesinde en büyük darboğaz olarak kabul etmektedir. Bu darboğazı aşmak için alternatif teknikler geliştirilmiştir. Geliştirilen bu tekniklerin amacı bilgi kazanımını otomatik hale getirmektir [145]. Bunlardan bir tanesi de makine öğrenmesi algoritmalarının kullanılmasıdır. Bilgi kazanımını otomatik hale getirmek için Apriori, FP Tree, GRI veya Karar ağaçları gibi birçok makine öğrenmesi algoritmaları kullanılabilir. Makine öğrenmesi algoritmalarından kural çıkarımında sıklıkla kullanılan Karar ağacı yaklaşımı, uzman sistemlerde bilginin aktarılması sürecinde kuralların geleneksel diller kullanılarak kodlanmasından daha pratik ve geçerli bir yol sunmaktadır [146]. Karar ağacı algoritmasının temel avantajı, çözümü görselleştirmesidir; ağaçtan herhangi bir yolu takip etmek kolaydır. Bir karar ağacı

tarafından keşfedilen ilişkiler, daha sonra bir uzman sistem geliştirilmesinde kullanılabilecek bir dizi kural olarak ifade edilebilir [104].

Kısaca uzman sistemler ile makine öğrenmesi arasındaki temel fark ve benzerlikler aşağıdaki gibi özetlenebilir:

- Uzman sistemler içinde veri madenciliğinin, makine öğrenmesi algoritmalarının, ileriye doğru zincirleme ve geriye doğru zincirleme tekniklerinin kullanılabildiği daha genel bir kavramdır. [104, 135-136].
- Literatür incelendiğinde sadece insan uzmanlığı gerektiren bir problemin çözümüne yönelik tasarlanan sistemlerin genel bir çatı başlığı altında uzman sistem olarak nitelendirildiği görülmektedir [132, 136, 147]. Bir başka deyişle makine öğrenmesi algoritmalarının kullanıldığı ve insan uzmanlığı gerektiren, hastalık tanı sistemleri gibi bir problemin çözümüne yönelik geliştirilmiş sistemler uzman sistem olarak görülmektedir. Hatta kullanılan makine algoritmasına göre uzman sistemler (bulanık uzman sistem, olasılıksal uzman sistem veya hibrit uzman sistem gibi) çeşitli sınıflara ayrılmaktadır [21, 137, 139, 140, 142].
- Uzman sistemler insan uzmanlığı gerektiren problemlerin çözümüne yönelik tasarlanırlar [82-83]. Makine öğrenmesi, diğer yapay zekâ teknikleri gibi her hangi bir insanın çözebildiği problem alanları içinde geliştirilebilirler [14].
- Uzman sistemler alan uzmanının düşünme biçimini taklit ederler [82, 128]. Bu nedenle geliştirilen uzman sistemlerin alan uzmanından bağımsız bir şekilde geliştirilmesi özellikle sağlık alanında uygun değildir.
- Uzman sistemlerde en temel olarak bilgi tabanının ve çıkarım mekanizmasının bulunması gerekmektedir [126-127].
- Uzman sistemlerde problemin çözümüne yönelik bir yazılımın geliştirilmesi beklenir [14, 82]. Fakat makine öğrenmesinde Weka, RapidMiner ve Tanagra gibi hazır araçlar kullanılarak modelleme yapabilir [148-149].
- Makine öğrenmesi algoritmaları çalışmalarında genellikle EEG, MRI, fNIRS gibi nörogörüntüleme belirteçler veya kan, idrar sonucu gibi biyobelirteçler gibi belirgin sonuçlar girdi olarak kullanılmaktadır [43, 45, 150]. Uzman sistemlerde alan uzmanının düşünme biçimini taklit etmesi nedeni ile alan uzmanının karar verme sürecinde kullandığı parametreler girdi olarak kullanılmaktadır [137, 151-152].

Bu tez çalışmasında DEHB'nin öngörülmesine yönelik geliştirilen bu sistem a) insan uzmanlığı gerektiren bir problemin çözümüne yönelik geliştirilmesi b) bilgi tabanı, çıkarım mekanizması ve açıklama biriminden oluşması, c) alan uzmanları ile işbirliğinin yapılması, d) bu bozukluğun ön tanısına yönelik alan uzmanlarının karar verme süreçlerini taklit etmesi ve e) bilgisayar yazılımının geliştirilmiş olması yönleriyle uzman sistem olarak belirtilmiştir. Çalışmada makine öğrenmesi algoritmalarının model başarımlarına göre karşılaştırmaları yapılarak en yüksek başarımları gösteren Naive Bayes algoritması geliştirilen sistemde kodlanmıştır. Bu bağlamda geliştirilen sistem, çıkarım mekanizmasında modelleme yaparken Bayesçi muhakemenin, Naive Bayes algoritmasının kullanılması nedeni ile olasılıksal tabanlı bir uzman sistemdir.


Sonuç olarak bir uzman sistemde a) problem türünün insan uzmanlığı gerektiren bir problem olması b) en az bilgi tabanı ve çıkarım mekanizmasından oluşması c) alan uzmanından bağımsız bir şekilde geliştirilmemiş olması d) alan uzmanının düşünme biçimini taklit etmesi ve e) bu şartları taşıyan bir bilgisayar yazılımının geliştirilmiş olması beklenilse de [14, 126, 128], insan uzmanlığı gerektiren bir problemin çözümüne yönelik tasarlanmış olan sistemlerin uzman sistemler şeklinde genel bir çatı altında isimlendirildiği de görülmektedir [153-155].

2.3.4. Makine öğrenmesi metotları

Makine öğrenmesi metotları geçmişteki verileri kullanarak veriye en uygun modeli bulmaya çalışırlar. Yeni gelen verileri de bu modele göre analiz ederler. Makine öğrenmesi metotlarını aşağıdaki gibi sınıflandırmak mümkündür [117]:

- Sınıflandırma
- Kümeleme
- Eğri Uydurma (Regresyon)
- Özellik Seçimi
- İlişki Belirleme

Makine öğrenmesi metotları ve en çok kullanılan algoritmalar Şekil 2.10'da gösterilmiştir:



Şekil 2.10. Makine öğrenmesi metotları ve en çok kullanılan algoritmalar

Bu çalışmada makine öğrenmesi metotlarından sınıflandırma yönteminin kullanılması nedeni ile diğer yöntemlere göre bu yöntem, kullanılan algoritmalar ile birlikte daha ayrıntılı bir biçimde açıklanmıştır.

1- Sınıflandırma:

Sınıflandırma en yaygın uygulanan yöntemlerden biridir. Sınıfı tanımlanmış mevcut verilerden yararlanarak sınıfı belli olmayan verilerin sınıfını tahmin etmek için kullanılır. Sınıflama iki adım içeren bir işlemdir Birinci adımda tahmin için kullanılacak bir model oluşturulmaktadır. İkinci adımda, oluşturulan bu model sınıfı belli olmayan veriler üzerinde uygulanarak sınıflar tahmin edilmektedir [122]. Bilinmeyen veri kümelerinin özellikleri incelenerek daha önce tanımlanmış olan sınıflardan hangisine atanacağına karar verilir. Burada sınıfların sayısı ve tanımlamaları daha önceden bilinmektedir. Sınıfı bilinmeyen yeni örnekler bu sınıflara atanır. Sınıflandırma danışmanlı öğrenme olarak da bilinir [156]. Sınıflandırma veri tabanındaki gizli örüntüleri ortaya çıkarmakta kullanılır. Verilerin sınıflandırılması işleminde belirli bir süreç izlenir. Öncelikle var olan veri tabanının bir kısmı eğitim amacıyla kullanılarak sınıflandırma kurallarının oluşturulması

sağlanır. Daha sonra bu kurallar yardımıyla yeni bir durum ortaya çıktığında nasıl karar verileceği belirlenir [157].

Sınıflandırma uygulamalarına; kredi kartı harcamasının sahtekârlık olup olmadığına karar verilmesi, kredi başvurularının değerlendirilmesi, yazı tanıma, ses tanıma, akademik bir çalışmanın çalıntı olup olmadığına tespiti, kanserli hücrelerin tespiti, isimsiz bir metnin yazarının tespiti gibi örnekler verilebilir [158].

Her veri kümesinde mükemmel çalışan bir algoritma olmadığından birçok sınıflandırma algoritması geliştirilmiştir. Literatürde sıklıkla kullanılan sınıflandırma algoritmaları aşağıdaki gibidir:

- Naive Bayes Algoritması
- K- En Yakın Komşu Algoritması
- Karar Ağaçları Algoritması
- Yapay Sinir Ağları Algoritması
- Destek Vektör Makinesi Algoritması

Naive Bayes Algoritması:

Veri madenciliği uygulamalarında kullanılan Naive Bayes algoritması sınıflandırma problemlerinde sıkça kullanılan etkili ve basit bir yöntemdir. Naive Bayes sınıflandırma, belirlenen sınıflardaki değişkenlerin bağımsız olduğunu varsaymaktadır. Bu sınıflandırıcı yüksek miktardaki değişkenler ve büyük veri setleriyle ilgilenmektedir [159]. Naive Bayes Sınıflandırıcısının çalışma prensibi aşağıdaki gibidir [157]:

$$P(C_i|X) = \frac{P(X|C_i) P(C_i)}{P(X)} \quad (2.1)$$

$P(C_i|X)$, örnek X 'in sınıf C_i 'de olma olasılığıdır. $P(X|C_i)$ ise sınıf i 'deki bir örneğin X olma olasılığıdır. Herhangi bir örneğin X olma olasılığı $P(X)$ ile gösterilmiştir. $P(X)$ değeri tüm sınıflar için aynı olduğu için yok sayılabilir. Bu durumda denklem (2.2)'deki gibi olacaktır.

$$P(C_i|X) = P(X|C_i) P(C_i) \quad (2.2)$$

Naive Bayes sınıflandırma algoritması, özelliklerin birbirinden bağımsız olduğu varsayılan Bayes teoreminin basitleştirilmiş halidir. (2.2)'deki ifadede bütün özellikler bağımsız olduğu durumda hesap karmaşıklığını azaltmak için denklem (2.3)'deki gibi yazılabilir.

$$P(X|C_i) = \prod_{k=1}^n P(X_k|C_i) \quad (2.3)$$

Bu değerler içinden en büyük olanı seçilerek bilinmeyen örneğin bu sınıfa ait olduğu belirlenmiş olur.

$$\arg \max_{C_i} \{ P(X|C_i) P(C_i) \} \quad (2.4)$$

Sonrasal olasılıkları kullanan yukarıdaki ifade, en büyük sonrasal sınıflandırma yöntemi (Maximum A Posteriori Classification = MAP) olarak ta bilinir. O halde sonuç olarak (2.3)'den dolayı, Bayes sınıflandırıcısı olarak aşağıdaki bağıntı kullanılabilir:


$$C_{MAP} = \arg \max_C \prod_{k=1}^n P(X_k|C_i) \quad (2.5)$$

Naive Bayes Algoritması, Bayes karar teorisine dayanan bağımsız değişkenler arasındaki ilişkiyi analiz eden olasılıksal bir sınıflandırıcıdır. Bu algoritma sürekli veri ile çalışmaz, verilerin kategorik veri olması gerekir. Bu nedenle sürekli değerleri içeren nitelikler kategorik veri haline dönüştürülmelidir. Örneğin niteliklerden birini yazılı notu değişkeni olduğunu varsayalım. Yazılı notu değişkeninin aldığı değerler {45,5; 50; 85; 90,5} olsun. Bu sürekli değerler “0-49” arası “BİR”, “50-60” arası “İKİ”, “61-69” arası “ÜÇ” gibi yazılı notu aralıklarına dönüştürülmelidir.

Naive Bayes sınıflandırıcısının çoğu durumda iyi sonuç vermesi, gerçekleşmesinin kolay olması yüksek doğruluk, kesin ve hızlı sonuçlar üretmesi, algoritmanın basit ve anlaşılabilir olması avantajları arasında sayılabilir. Gerçek hayatta değişkenler birbiri ile bağımlıdır. Bu nedenle niteliklerin birbirinden bağımsız olduğu varsayımına dayanması Naive Bayes sınıflandırıcısının dezavantajıdır.

K- En Yakın Komşu Algoritması:

K- En Yakın Komşu (K-Nearest Neighborhood- KNN) algoritması, yeni bir veri geldiğinde var olan öğrenme verisi üzerinde sınıflandırma yapan eğitilmiş öğrenme algoritmasıdır. Algoritma, yeni bir veri geldiğinde, onun en yakın “k” komşusuna bakarak bu verinin sınıfına karar verir. Her sınıfın özelliklerinin önceden belirlenmiş olması çok önemlidir. Yeni gelen verinin daha önceki verilerden k tanesine yakınlığına bakılır. Bu iki veri arasındaki mesafe çeşitli uzaklık fonksiyonları kullanılarak hesaplanır. Manhattan uzaklık fonksiyonu, minkowski uzaklık fonksiyonu, öklid uzaklık fonksiyonu içerisinde en çok tercih edilen fonksiyon öklid uzaklık fonksiyonudur. En yakın mesafe neresi ise yeni veri o sınıfa atanır [160]. Şekil 2.11’de KNN algoritmasının genel yapısı görülmektedir:



Şekil 2.11. KNN algoritmasının genel yapısı [160]


KNN algoritması, sınıflandırma problemini çözen denetimli öğrenme yöntemleri arasında yer alır. Yöntemde; sınıflandırma yapılacak verilerin öğrenme kümesindeki normal davranış verilerine benzerlikleri hesaplanarak; en yakın olduğu düşünülen k verinin ortalamasıyla, belirlenen eşik değere göre sınıflara atamaları yapılır. Önemli olan, her bir sınıfın özelliklerinin önceden net bir şekilde belirlenmiş olmasıdır. Yöntemin performansını k en yakın komşu sayısı, eşik değeri, benzerlik ölçümü ve öğrenme kümesindeki normal davranışların yeterli sayıda olması kriterleri etkilemektedir [161].

Karar Ağaçları Algoritması:

Karar ağaçları, sınıflama, karar teorisi, kümeleme ve tahminsel fonksiyonlarda kullanılmaktadır. Karar ağaçlarını oluşturacak verideki değişkenler kategorik veya sürekli

olabilirler. Eldeki verilerden yola çıkarak birçok farklı karar ağacı oluşturmak mümkündür. Amaç en uygun ağacı oluşturmak olsa da zaman ve farklı kısıtlardan dolayı her zaman bu mümkün olmayabilir. Her ne kadar en uygun olmasa da doğruluk derecesi uygun bir ağacı sağlayacak etkin algoritmalar geliştirilmiştir [162]. Karar ağaçları bilgi keşfi sırasında pek çok test gerçekleştirerek, hedefi tahmin etmede en iyi sırayı bulmaya çalışırlar. Her bir test karar ağacındaki dalları oluşturur ve bu dallar da diğer testlerin gerçekleşmesine neden olur. Bu durum, test işleminin bir yaprak düğümünde sonlanmasına kadar devam eder. Kökten hedef yaprağa kadar olan yol, hedefi sınıflandıran “kural” olarak adlandırılır. Kurallar “eğer-sonra” (if-then) yapısındadır [163]. Karar ağaçları esas itibarı ile kural çıkarma algoritmalarıdır. Bu algoritmalar bir veri kümesinden kullanıcıların çok kolay anlayabileceği (if-then) türündeki kuralları bir ağaç yapısında türetebilirler [125].

Bir karar ağacı, Şekil 2.12’de görüldüğü üzere karar ağaçlarının yapısını temsil eden düğümlerden, dallar ve yapraklardan oluşur. Ağacın üst düğümü kök düğüm olarak adlandırılır; içindeki düğümler değişkenlerin değerleri üzerine ifa edilmiş olan testleri temsil ederler; dallar testler üzerindeki farklı sonuçları ve yaprak düğümleri örneklerin sınıfını temsil eder [164]. Eğitim verilerine ait öznitelik bilgilerinden yararlanılarak bir karar ağacı yapısı oluşturulmasında temel prensip verilere ilişkin bir dizi sorular sorulması ve elde edilen cevaplar doğrultusunda hareket edilerek en kısa sürede sonuca gidilmesi olarak ifade edilebilir. Bu şekilde karar ağacı sorulara aldığı cevapları toplayarak karar kuralları oluşturur. Ağacın ilk düğümü olan kök düğümünde verilerin sınıflandırılması ve ağaç yapısının oluşturulması için sorular sorulmaya başlanır ve dalları olmayan düğümler ya da yapraklar bulunana kadar bu işlem devam eder [165].



Şekil 2.12. Dört boyutlu özellik uzayına sahip üç sınıftan oluşan bir karar ağacı yapısı[165]

Karar düğümü, veriye uygulanacak test olarak tanımlanır. Her düğüm bir özellikteki testi gösterir. Test sonucunda ağacın dalları oluşur. Dalları oluştururken veri kaybı yaşanmaması için verilerin tümünü kapsayacak sayıda farklı dal oluşturulmalıdır. Dal; testin sonucunu gösterir. Elde edilen her dal ile tanımlanacak sınıfın belirlenmesi amaçlanır. Ancak dalın sonucunda sınıflandırma tamamlanamıyorsa tekrar bir karar düğümü oluşur. Karar düğümünden elde edilen dalların sonucunda sınıflandırmanın tamamlanıp tamamlanmadığı tekrar kontrol edilerek devam edilir. Dalın sonucunda bir sınıflandırma elde edilebiliyorsa yaprak elde edilmiş olur. Yaprak, verileri kullanarak elde edilmek istenen sınıflandırmanın sınıflarından birini tanımlar. Başlangıçta bütün öğrenme örnekleri kök düğümde, örnekler seçilmiş özelliklere tekrarlamalı olarak bölündükten sonra ağacı temizlemek (tree pruning) için gürültü ve istisna kararları içeren dallar belirlenir ve kaldırılır [166].

Karar ağacı temelli analizlerin yaygın olarak kullanıldığı alanlar şunlardır [167]:

- Belirli bir sınıfın olası üyesi olacak elemanların belirlenmesi,
- Çeşitli vakaların yüksek, orta, düşük risk grupları gibi çeşitli kategorilere ayrılması,
- Parametrik modellerin kurulmasında kullanılmak üzere çok sayıdaki değişkenden en önemlilerinin seçilmesi,
- Gelecekteki olayların tahmin edilebilmesi için kurallar oluşturulması,
- Sadece belirli alt gruplara özgü olan ilişkilerin tanımlanması,
- Kategorilerin birleştirilmesi ve sürekli değişkenlerin kesikli değişkenlere dönüştürülmesidir.


Karar ağaçlarını oluşturmak için geliştirilmiş farklı yöntemler bulunmaktadır. Bu yöntemler arasında sıkça kullanılanlar CHAID, CART, ID3 ve C4.5 algoritmalarıdır [168].

Yapay Sinir Ağları Algoritması:

Yapay Sinir Ağları (Artificial Neural Networks-ANN), insan beyinde gerçekleşen öğrenme yolu ile yeni bilgiler türetebilme ve keşfedebilme gibi yetenekleri herhangi bir yardım almadan otomatik gerçekleştirmek amacı ile biyolojik sinir ağlarından esinlenilerek geliştirilen bilgisayar sistemleridir [116, 169]. Kısaca ANN insan beyinden esinlenerek geliştirilmiş, ağırlıklı bağlantılar aracılığı ile birbirine bağlanan işlem elemanlarından

oluşan paralel ve dağıtılmış bilgi işleme yapılarıdır. En önemli özelliği, deneyimlerden yararlanarak öğrenebilmesidir [169].

ANN algoritmasında modelin yapılandırılması süreci kavramsal olarak bir kısım veri setinin yapay sinir ağına gönderilmesiyle başlar ve yapay sinir ağı bir çıktı değeri tahmin eder. Bu tahmin değeri ve gerçek değer karşılaştırılır. Eğer tahmin doğru ise ağ başka bir faaliyet göstermez. Eğer tahmin yanlış ise yapay sinir ağı, kestirimin kalitesini arttırmak için hangi iç parametrelerin ne şekilde düzeltileceğini belirlemede kendi kendini analiz eder. Bu parametre ayarlamaları yapıldıktan sonra yapay sinir ağı veri setinin başka bir bölümünü alır ve süreci tekrar eder [170]. Şekil 2.13’de Yapay sinir hücresinin genel yapısı görülmektedir:



Şekil 2.13. Yapay sinir hücresinin genel yapısı [171]

ANN, beynin çalışmasını taklit ederek analizde öğrenme gerçekleştikten sonra diğer gözlemlerden ortaya çıkarılacak sonuçlarla modelleme yapabilir [172].

Destek Vektör Makinesi Algoritması:


Destek Vektör Makinesi (Support Vector Machine – SVM), verileri optimal olarak iki kategoriye ayıran n – boyutlu bir hiperdüzlem oluşturmaktadır. SVM modelleri yapay sinir ağlarıyla yakından ilişkilidir. Sigmoid bir kernel fonksiyonu kullanan SVM üzerine kurulmuş bir uygulamasıdır. Destek vektör makinesi orijinal olarak kendine has

formüllerle düzlemi iki ayrı sınıfa direkt olarak ayırabilir. SVM; öğrenme, sınıflandırma, kümeleme, yoğunluk tahmini ve son olarak da veriden regresyon kuralları üretmek için kullanılan bir eğitime algoritmasıdır. SVM algoritmasında amaç, veri noktalarını mümkün olduğu kadar iyi sınıflandıran ve iki sınıf noktaya ayıran optimum ayırıcı düzlemin bulunmasıdır. Diğer bir ifadeyle, iki sınıf arasındaki uzaklığın maksimum olduğu durumun bulunması amaçlanmaktadır. Bu sınıflandırma mantığının temel taşları ise, her iki sınıfın uç noktalarında bulunan ve eğitime örneklerinin arasından seçilen destek vektörleridir [174].

2- Kümeleme:

Kümeleme; heterojen bir veri grubunun, küme adı verilen homojen alt gruplara bölünmesi olarak tanımlanabilir [119]. Aynı kümedeki elemanlar birbirleriyle benzerlik gösterirken, başka kümelerin elemanlarından farklıdırlar [175]. Değişik özellikler gösteren bu elemanlar, kendi içinde benzerlik gösteren alt gruplara ve kümelere ayrılırlar. Sınıflandırmadan farkı ise, kümelemede özellikleri önceden belirlenmiş sınıfların olmamasıdır. Örneğin, birbirinden farklı müzik tarzlarını beğenen kişiler kümesi, aynı zamanda farklı alt kültür gruplarını da gösteriyor olabilir [176].

Kümeleme algoritmaları, küme oluşturma stratejisine ve kullanılan veri türüne göre farklılık gösterirler. Kümeleme yöntemlerinin çoğu veriler arasındaki uzaklıkları yani veriler arasındaki benzerlik ya da farklılıkları kullanırlar [177]. Birimler arası uzaklıklar için Euclidyen, Standardize Euclidyen, Manhattan Mahalanobis, Kareli Euclidyen, Minkowski veya Canberra ölçüleri kullanılabilir [178]. Şekil 2.14’de kümeleme örneği gösterilmektedir:



Şekil 2.14. Koordinat düzleminde kümeleme örneği [179]

Kümeleme analizinin uygulama aşamaları aşağıdaki gibi verilebilir [180]:

- a) Birim ya da değişkenlerin doğal sınıflamaları hakkında kesin bilgilerin bulunmadığı popülasyonlardan alınan n sayıda birimin p sayıda değişkenine ilişkin gözlemler elde edilir (Veri matrisinin belirlenmesi).
- b) Birimlerin / değişkenlerin birbirleri ile olan benzerliklerini ya da farklılıklarını gösteren uygun bir benzerlik ölçüsü ile birimlerin/ değişkenlerin birbirlerine uzaklıklarının hesaplanır (Benzerlik ya da farklılık matrislerinin belirlenmesi).
- c) Uygun kümeleme yöntemi (algoritma) yardımı ile benzerlik ve farklılık matrislerine göre birimlerin / değişkenlerin uygun sayıda kümelere ayrılır.
- d) Elde edilen kümelerin yorumlanması ve bu kümeleme yapısına dayalı olarak kurulan hipotezlerin doğrulanması için gerekli analitik yöntemler uygulanır.

Kümeleme analizi, diğer veri madenciliği uygulamaları için veri ön işleme de verinin azaltılması için kümeleme merkezinin kullanılması ve veri setinin dağılımını anlamak için kullanılmaktadır. Ayrıca Kümeleme analizi; doküman demetlenmesi, kullanıcı ve kullanıcı davranışlarını demetlenmesi ve sapan verilerin belirlenmesi için de kullanılabilir [180]. Kümeleme analizinde en çok kullanılan algoritmalar; K-Means, K-Medoids, OPTICS, DBSCAN, CobWeb algoritmalarıdır.


3- Eğri uydurma (Regresyon analizi):

Yaygın kullanılan bir modelleme tekniğidir. Doğrusal, doğrusal olmayan ve lojistik modelleme alternatifleri imkânı vardır. Bağımsız değişken olarak anılan tahmin edici değişkenlerin, bağımlı değişken denilen tahmin edilecek değişken değerini belirleyecek ağırlıklandırmaları içerecek bir bağımsız değişkenler birleşimidir [181].

Süreklilik gösteren değerleri tahmin etmek için kullanılan fonksiyonlardır. Regresyon ile amaç girdiler ile çıktıyı ilişkilendirecek modeli oluşturup, en iyi tahmine ulaşmaktır. Girdiler “bağımsız değişken”, sonuç “bağımlı değişken” olarak adlandırılır. Sonucun alacağı değer genellikle bir güvenlik aralığı içinde belirtilir. Girdiler, çözülecek probleme göre bir veya birden fazla olabilir. Örneğin; bir inşaat firması konut satışlarının, faaliyet gösterdiği bölgede elde edilen toplam gelir ile ilişkili olduğunu düşünüyorsa, sadece bölgesel gelire dayalı bir model oluşturarak, bölgesel gelirdeki değişime göre satacağı ev

sayısını tahmin etme yoluna gidebilir. Ancak gerçek hayatta çözülecek problemlerin hemen hepsinde doğru tahmine ulaşmak için birden fazla girdiden faydalanmak gereklidir. Bu noktada önemli olan konu, sonucun doğru tahmin edilmesine girdilerin ayrı ayrı yaptıkları katkıdır. Bazı durumlarda sonuca katkısı limitli olan girdileri modelden çıkarmak, daha etkin bir model oluşturmak için önemli bir gerekliliktir. Finansal tahminler, zaman serisi tahminleri, biyomedikal ve ilaç reaksiyonları, konut fiyatı değerlendirmeleri, müşterinin yaşam çevrimi boyunca yarattığı değer ve atmosferdeki CO₂ oranının tahmin edilmesi uygulama alanlarından bazılarına örnek verilebilir [166].

Şekil 2.15’de eğri uydurma örneği gösterilmektedir:



Şekil 2.15. Eğri uydurma örneği [117]

Şekil 2. 15’de X eksenı hava sıcaklığını, Y eksenı de deniz suyu sıcaklığını göstermektedir. Şekil 2.15 incelendiğinde hava sıcaklığına bağılı olarak deniz suyu sıcaklığının tahmin edilmesi ve buna bağılı olarak giriş ile çıkış arasındaki fonksiyonun eğrisi gösterilmektedir.

4- Özellik seçimi:

Özellik seçimi (feature selection); Veriye ait birçok özellikten verinin kümesinin veya sınıfının değerlerini belirleyen özelliklerin belirlenmesidir [117]. Özelliklerin alt kümeleri seçilirken doğruluktan ödün vermeden seçilmelidir. Özellik seçiminde ilgisiz ve gereksiz veriler silinerek yüksek boyutu indirgemek hedeflenmektedir [182]. Özellik seçimi yalnızca arama uzayını küçültmekle kalmayıp, sınıflama işleminin kalitesini de artırır [183].


Veri seti çok büyük olduğunda veri madenciliği uygulamaları çok zaman almakta hatta bazı algoritmaların uygulanması oldukça zorlaşmaktadır. Orijinal veri setinin özelliklerini koruyan ancak hacim olarak daha küçük veri seti elde etmek için özellik seçimi algoritmaları kullanılmaktadır. Böylece indirgenmiş veri seti üzerinde veri madenciliği daha etkili olmakta ve hemen hemen orijinal veri seti ile aynı analitik sonuçları vermektedir. Başka bir ifadeyle özellik seçimi, kümeleme veya regresyon işlemleri için kullanılacak özelliklerin belirlenmesi aşamasında, tüm özellik kümesi sütunlarından bağımlı değişkenle olan ilişkiyi açıklamada, ilgisiz sütunların elenmesi ve açıklayıcı gücü yüksek sütun alt kümelerinin belirlenmesi işlemidir. Özellik seçimi genel olarak doğruluk ve ölçeklenebilirlik için kullanılmaktadır. İlk bakışta, veri kümesindeki tüm özelliklerin analize konu edilmesiyle, sınıflandırma veya bağımlı değişkeni açıklayan regresyon algoritmalarının başarılı sonuçlar vereceği akla gelmektedir. Oysa bu düşünce pek çok özellik içeren veri kümelerinde her zaman doğru olmayabilir. Veri kümesindeki her özellik bağımlı değişken hakkında açıklayıcı ya da tahminleyici bilgi taşımayabilir. Dolayısıyla özelliklerin tahminleyici bilgi taşıma durumuna göre ayırt edilip analize konu edilmesi gerekir [122].

Veri madenciliği, örüntü tanıma, makine öğrenmesi uygulamalarında, örneklem sayısı ve nitelik sayısı çok önemlidir. Genellikle sınıflayıcının doğru karar vermesinde, örneklem ve nitelik sayısı ne kadar artarsa o kadar doğru sonuç vereceği düşünülse de hatanın artması ile makinenin aşırı öğrenme olasılığından dolayı hem örneklem sayısı hem de nitelik sayısının optimum sayıda olması etkindir. Nitelikler içinden, optimum sayıya ulaşmak, işlem karmaşıklığını azaltmak, daha kısa sürede sonuca ulaşmak, hesaplama hata olasılığını düşürmek ve daha doğru genelleme yapabilmek için özellik seçme işlemi yapılabilir.

Özellik seçme işlemi, çoğunlukla boyut indirgemek için yapılır. Özellik seçiminde, özellikler ayırt edici ise seçilir. Özellik seçimi yapılırken, mevcut nitelikler arasından bazılarını seçebilir veya mevcut özelliklerin lineer birleşimlerinden yeni özellik çıkarma işlemi yapılabilir.

Özellik seçme algoritmaları genel olarak filtre modeli, sarmal modeli ve gömülü olmak üzere üç ana başlık altında sınıflandırılır [184].

Özellik seçim modelleri ve bu modellerde en çok kullanılan algoritmalar Şekil 2.16’da gösterilmiştir:



Şekil 2.16. Özellik seçim modelleri ve en çok kullanılan algoritmalar

Literatürde ele alınan özellik seçim modelleri Çizelge 2.2’de özetlenmektedir:

Çizelge 2.2. Özellik seçim modelleri [185]

Özellik Seçme Modeli	Avantaj	Dezavantaj
Filtre Modeli	Hızlı, sınıflandırma algoritmasından bağımsız	Başarı oranı diğer modellere göre düşük
Sarmal Modeli	Başarı oranı yüksek, uygulanması kolay	Yavaş, işlem yükü fazla
Gömülü Modeli	İşlem yükü az, başarı oranı yüksek	Karar ağaçlarından bağımsız olarak kullanılamaması

Filtre modeli özellikler arası korelasyon/artıklık ve özelliklerin sınıf etiketleri vektörü ile ilişkilerini temel alan bir seçim kriteri yardımıyla özellikleri sıralayan ya da ağırlıklandıran algoritmalarıdır. Sarmal modeli ise bir özniteliğin seçimi ya da elenmesi kararını sınıflandırma algoritmalarının başarımlarını göz önünde bulundurur. Bu nedenle seçilen özellik kümeleri ile yüksek başarımlar elde edilebilir. Ancak her bir özellik seçimi ya da elenmesi aşamasında veri kümesi eğitimi ve testi gerçekleştirdikleri için zamanın kısıtlı olduğu problemlerde tercih edilmemektedirler [186]. Gömülü özellik seçme algoritmaları sınıflandırma algoritmasının içinde gömülü olarak bulunan özellik seçme algoritmalarıdır [187].

5- İlişki belirleme (Birliktelik kuralları):

Veri tabanı içinde yer alan kayıtların birbirleriyle olan ilişkilerini inceleyerek, hangi olayların eş zamanlı olarak birlikte gerçekleştirebileceklerini ortaya koymaya çalışan veri madenciliği yöntemleri bulunmaktadır. Bu ilişkilerin belirlenmesiyle birliktelik kuralları elde edilir [188].

Birliktelik kurallarının en yaygın kullanıldığı alan süpermarket uygulamalarıdır. Bu uygulamalar, literatürde market sepeti analizi olarak geçmektedir. Market sepeti analizi, hangi ürünleri bir arada aldıkları bilgisini ortaya çıkararak müşteri alışkanlıkları analizlerinde, promosyon çalışmalarında, mağazanın düzenlenmesinde, stokların kontrolünde, etkili satış stratejilerinin geliştirilmesinde fayda sağlamaktadır [189]. Eğer X malını alanların Y malını da çok yüksek olasılıkla aldıklarını biliyorsanız ve eğer bir müşteri X malını alıyor ama Y malını almıyorsa o potansiyel bir Y müşterisidir. Eğer elimizdeki veride mallar için sadece satın alındı/alınmadı bilgisi varsa, sepet analizinde mallar arasındaki bağıntı, destek ve güven kıstasları aracılığıyla hesaplanır. İki mal, X ve Y, için destek ve güven tanımları şöyledir [117]:

$$\text{Destek} : P(X \text{ ve } Y) = \frac{\text{X ve Y mallarını satın almış müşteri sayısı}}{\text{Toplam müşteri sayısı}} \quad (2.6)$$

$$\text{Güven} : P(X|Y) = P(X \text{ ve } Y)/P(Y) = \frac{\text{X ve Y mallarını satın almış müşteri sayısı}}{\text{Y malını satın almış müşteri sayısı}} \quad (2.7)$$

Destek veride bu bağıntının ne kadar sık olduğunu, güven de Y malını almış bir kişinin hangi olasılıkla X malını alacağını söyler. Bağıntının önemli olması için her iki değerin de olabildiğince büyük olması gerekir.

Birliktelik kurallarını bulmak için yaygın olarak Apriori, FP Tree, CHARM ve GRI algoritmaları kullanılmaktadır.

2.3.5. Makine öğrenmesi uygulama süreci

Makine öğrenmesi modelinin uygulanması için gerekli adımlar aşağıdaki ana başlıklar altında incelenebilir [190]:

1. Veri toplama
2. Veri ön işleme
 - a. Veri temizleme
 - b. Veri dönüştürme
 - c. Veriyi eğitim ve test kümelerine ayırma
3. Eğitim verisi üzerinde modelin kurulması
4. Test verisi üzerinde modelin değerlendirilmesi
5. Performans tatmin edici bulunduğu takdirde gerçek uygulamaya geçilmesi, modelin sunumu

Yukarıda verilen adımlar incelendiğinde makine öğrenmesi uygulama süreci ile veri madenciliği uygulama süreci arasındaki adımların benzer olduğu görülmektedir. Makine öğrenmesinin veri madenciliği ile yakın ilişkisi dikkate alındığında bu adımların zaten örtüşmesi gerektiği sonucu ortaya çıkmaktadır.

1. Veri toplama:

Veri toplama basamağında, kullanılacak veri ele alınan probleme uygun bir biçimde temin edilir. Veri toplama aşamasında farklı kaynaklardan yararlanılabilmektedir. Verinin toplama süreci, veriyi anlama sürecidir.

Veri toplama süreci; a) başlangıç verilerinin toplanması, b) toplanan verinin tanımlanması ve ihtiyaçları karşılayıp karşılayamayacağının değerlendirilmesi, c) çalışmanın gerçekleştirilebilmesi için veri anlamında eksikliklerinin tespit edilmesi, yani verinin keşfinin yapılması ve d) dalışmada kullanılacak olan verilerin tam mı, doğru mu, eksik var mı, hata içeriyor mu gibi verinin kalitesinin belirlenmesi şeklinde tanımlanabilir [166].

2. Veri önışleme:

Makine öğrenmesi tekniklerinin uygulanabilmesi için öncelikle verinin temizlenmesi ve ön işlemeden geçirilmesi gerekir. İşlenmemiş ham veri genellikle tam değildir, gürültölüdür ve tutarsızlıklar içerir, neticede analizde kullanılması zor bir veridir. Orijinal verinin temsili bir alt kümesini almak anomalileri tespit etmek, gürültüyü ayıklamak, verinin eksik ya da kayıp kısmını telafi ve tamir için yollar bulmak, tutarsızlıkları ortadan kaldırmak, normalize etmek ve bazı gereksiz nitelikleri çıkartmak sıklıkla uygulanan ön işlemlerdir. Bu önışlemlerden sonra makine algoritmaları uygulanabilir [191]. Veri önışleme basamakları řu şekilde sıralanabilir [190]:

- a. Veri temizleme
- b. Veri dönüřtürme
- c. Veriyi eğitim ve test kümelerine ayırma

a. *Veri temizleme:*

Veri temizleme işlemleri gürültölü verilerin elimine edildiđi, diđer verilerden aykırı deđerlerin saptandıđı ve tutarsızlıđın kaldırıldıđı, kayıp verilerin yani boş hücrelerin çıkartıldıđı, yaklaşımdır [192]. Bu adımda eksik veriler doldurulur, sapan verilerin tespiti yapılarak sapan veriler atılır ve verilerdeki tutarsızlıkların giderilir.

Eksik veriler doldurulurken, verinin kategorik veya nümerik olması durumuna dikkat edilmelidir. Eğer eksik veri kategorik bir veri ise, eksik deđer, “k” gibi genel bir deđerle doldurulabilir veya regresyon analizi veya kümeleme analizi yapılarak en uygun deđerle doldurulabilir. Fakat niteliđe ait eksik veri sayısı fazla ise, nitelik veri tabanından çıkarılmalıdır. Eksik veri nümerik bir veri ise, eksik verilerin doldurulması için farklı yöntemlerden bazıları ařađıda açıklanmaktadır [157]:

- Eksik değer içeren kayıtlar atılabilir.
- Niteliğin diğer örneklerdeki ortalaması ile eksik değer doldurulabilir.
- Niteliğin, aynı sınıfa ait tüm örneklerin ortalaması ile eksik değer doldurulabilir.
- Eksik değer, regresyon analizi veya kümeleme analizi yapılarak en uygun değerle doldurulabilir.

b. Veri dönüştürme:

Veriyi daha anlaşılabilir hale getirmek için, verinin normalize edilmesi ve genelleme işleminin yapılmasıdır. Makine öğrenmesi algoritmalarının çalışabildikleri veri türleri farklılık gösterebilmektedir. Bazı makine öğrenmesi algoritmaları kategorik veriler ile çalışırken bazıları sürekli veriler ile çalışır. Bununla birlikte özelliklerin alabileceği değerlerin büyüklüğü algoritmaların çalışmasını etkiler. Çok büyük değerlere sahip veri kümeleri (0,1) veya (-1,1) aralıkları arasında ölçeklendirilebilir. Ayrıca farklı veri kaynaklarından alınan özelliklerin birimleri farklılık gösterebilir. Bu durumlarda; veriler çalışılacak algoritmaya göre kategorik veya sürekli veriye, çok büyük değere sahip veri kümeleri (0,1) veya (-1,1) aralıkları arasına ve birimler birbirine dönüştürülmesi gerekmektedir. Veriler normalize edilirken (verilerin (0,1) veya (-1,1) aralıklarına dönüştürülmesi) en çok kullanılan tekniklerin başında z-score veya min-max teknikleri gelir. Z skorlarına dönüştürme oransal ya da aralıklı ölçekle elde edilen ve normal dağılım gösterdiği varsayılan verilere uygulanan ve en çok tercih edilen bir dönüştürme yöntemidir [180].

Değerler $Z_i = \frac{X_i - \bar{X}}{S}$ biçiminde Z skorlarına dönüştürülür. Formülde $\bar{X}$ değerlerin aritmetik ortalaması, S standart sapmasını temsil etmektedir.

Min – Max tekniğinde yani verilerin $0 \leq X \leq 1$ aralığına dönüştürme işleminde, heterojen yapıda değerlerin ve aşırı uçlarda değerlerin yer aldığı durumlarda değerleri pozitif ve 0 – 1 aralığında değişecek biçime dönüştürmek için tercih edilen bir dönüştürme yöntemidir.

Dizide en büyük değer X_{max} , en küçük değer X_{min} olmak ve değişim genişliği (range) $R = X_{max} - X_{min}$ olarak hesaplanmaktadır. Min – Max dönüştürme işlemi $X_i = \frac{X_i - X_{min}}{R}$ biçiminde yapılır.

Kısaca veriyi bazı durumlarda veri madenciliği çözümlemelerine aynen katmak uygun olmayabilir. Kullanılan modele uygun olacak şekilde verilerin tanımlama veya gösterim şeklinin değiştirilmesi gerekebilir. Örneğin bazı örneklerde 0/1 şeklinde tanımlanmış bir verinin evet/hayır şekline dönüştürülmesi modelin sağlıklı bir şekilde işlemesi için kritik olabilir [193].

c. *Veriyi eğitim ve test verisine ayırma:*

Modelin öğrenmesi, eğitim seti kullanılarak gerçekleştirildikten sonra, test kümesi ile modelin doğruluk derecesi belirlenir. Modelin doğruluk derecesi belirlenirken bazı yöntemler kullanılmaktadır. Bu yöntemlerden bazıları aşağıda özetlenmiştir:

Geçerlilik yöntemi (Simple validation): Oluşturulan modelin doğruluğunun test edilmesinde kullanılan en basit yöntem basit geçerlilik yöntemidir. Bu yöntemde tipik olarak verilerin %5 ile %33 arasındaki bir kısmı test verileri olarak ayrılır. Geriye kalan kısmı üzerinde algoritmalar uygulanarak, modelin öğrenimi gerçekleştirilir. Test verileri ile test işlemi yapılır. Bir sınıflama modelinde yanlış olarak sınıflanan olay sayısının, tüm olay sayısına bölünmesi ile hata oranı, doğru olarak sınıflanan olay sayısının tüm olay sayısına bölünmesi ile ise doğruluk oranı hesaplanır (Doğruluk Oranı = 1- Hata Oranı) [167].

Çapraz geçerlilik (Cross validation): Sınırlı miktarda veriye sahip olunması durumunda çapraz geçerlilik yöntemi kullanılabilir. Bu yöntemde veri kümesi rastgele olarak iki eşit parçaya ayrılır. İlk aşamada a parçası üzerinde model eğitimi ve b parçası üzerinde test işlemi, ikinci aşamada ise b parçası üzerinde model eğitimi ve a parçası üzerinde test işlemi yapılarak elde edilen hata oranlarının ortalaması kullanılır [167].

K-kat çapraz geçerkleme (K-Fold cross validation): Birkaç bin veya daha az satırdan meydana gelen küçük veri tabanlarında, verilerin k gruba ayrıldığı k katlı çapraz geçerlilik yöntemi kullanılabilir. Veri seti rastgele k adet gruba ayrılır. Literatürü incelediğimizde,

genellikle n değerin 10 olarak seçildiği görülmektedir. Bu yöntemde, ilk aşamada birinci grup test, diğer gruplar öğrenim için kullanılır. Bu süreç her defasında bir grubun test, diğer grupların öğrenim amaçlı kullanılması ile sürdürülür. Sonuçta elde edilen on hata oranının ortalaması, kurulan modelin tahmini hata oranı olacaktır [167].

BootStrapping: Bootstrapping küçük veri kümeleri için modelin hata düzeyinin tahmininde kullanılan bir başka tekniktir. Çapraz geçerlilikte olduğu gibi model bütün veri kümesi üzerine kurulur. Veri kümesinden yerine koyma yöntemi ile örnekler seçilerek öğrenme kümesi oluşturulur. İşlem genellikle 200 ile 1000 arası tekrarlanır ve elde edilen performans değerlerinin ortalaması model değerlendirilir [167, 194].

Holdout yöntemi: Belli sayıda örnek test veri seti için ayrılır, geriye kalan örnekler eğitim veri seti olarak kullanılır. Eğitim veri seti kullanılarak model oluşturulur ve test veri seti kullanılarak model değerlendirilir. Eğer veri dağılımı dengeli ise, veri setindeki örnek sayısı ve her sınıfa ait örnek sayısı fazla ise holdout yöntemi kullanılabilir [194].

3. Modelin kurulması:

Bu aşamada analize uygun hale getirilen verilerle birçok model kurularak en iyi model seçilmeye çalışılır. En iyi performansı verecek olan model ve algoritmanın tespit edilmeye çalışıldığı bu süreçte muhtemel tüm modeller kurulup karşılaştırılmalıdır [195]. Modellerin kurulması aşamasındaki değişkenlerin arasındaki ilişki düzeyleri gerektiğinden fazla ise, daha anlamlı olan değişkeni modele almak faydalı olacaktır. Model seçiminin tamamlanmasından sonra eğer en doğru modelin seçildiği biliniyorsa bir sonraki adım olan modelin değerlendirilmesi aşamasına geçilebilir [196].

4. Modelin değerlendirilmesi:

Model elde edilmesi beklenen hedefleri karşılamaya yeterli bulunduğu zaman, süreç bazlı daha geniş bir perspektiften değerlendirme yapılır. Bu değerlendirme sürecinde modelin doğru kurulup kurulmadığı, gelecekte kullanılabilecek farklı verilerin neler olabileceği, modelin genişletilmesi gibi konuları içerir [197].

Modelin değerlendirilmesinde kullanılan en basit yöntem geçerlilik testidir. Geçerlilik testi büyük veri yığınları için yapılacaksa basit geçerlilik, küçük veri yığınları için yapılacaksa çapraz geçerlilik testi kullanılır. Basit geçerlilik testinde verilerin %5'lik ile %33'lük arasındaki bir kısmı test verisi olarak kullanılır. Çapraz geçerlilik testinde ise veriler rastgele iki eşit parçaya ayrılır. İlk olarak ayrılan birinci parça üzerinde modelin eğitimi ve ikinci parça üzerinde modelin test işlemi yapılır. Daha sonra ikinci parça üzerinde modelin eğitimi ve birinci parça üzerinde modelin test işlemi yapılır. Her iki işlem sonucunda ulaşılan hata oranlarının ortalaması kullanılır. Kurulan modelin doğruluk derecesi ne kadar yüksek olursa olsun gerçek dünyayı tam anlamıyla modellediğini garanti edebilmek mümkün değildir [198].

Model başarımlar ölçütleri:

Makine öğrenmesi uygulama sürecinde sınıflandırma, kümeleme veya birliktelik kuralı çıkarma uygulamalarında kullanılan algoritmaların performansını ölçmek ve en iyi performansı gösteren algoritmayı seçmek gerekir.

Modelin başarısı, doğru sınıfa atanan örnek sayısı ve yanlış sınıfa atılan örnek sayısı nicelikleriyle alakalıdır. Test sonucunda ulaşılan sonuçların başarımlar bilgileri karışıklık matrisi (confusion matrix) ile ifade edilebilir. Karışıklık matrisinde satırlar test kümesindeki örneklere ait gerçek sayıları, kolonlar ise modelin tahminlemesini ifade eder [199]. Karışıklık matrisi Çizelge 2.3'de verilmiştir:

Çizelge 2.3. Karışıklık matrisi

		Öngörülen Sınıf	
		Sınıf=1	Sınıf=0
Doğru Sınıf	Sınıf=1	TP (True positive)	FN (False negative)
	Sınıf=0	FP (False pozitive)	TN (True negative)

TP, sınıflandırıcı tarafından 1.sınıfa atanan birimlerden gerçekte 1. sınıfına ait olanların oranını gösterir. FP, sınıflandırıcı tarafından 1. sınıfına atandığı halde gerçekte 1. sınıfına ait olmayan birimlerin oranını gösterir. Karışıklık matrisi, yakınsaklık matrisi olarak da adlandırılır. Doğru olarak sınıflandırılan örneklerin sayısı bu matrisin diyagonal

elemanlarının toplamına eşittir. Karışıklık matrisinden elde edilen bu sayılarla çeşitli ölçütler hesaplanır [200-201]. Algoritmaların performans değerlendirmesi için en temel model başarımlar ölçütleri; doğruluk, kesinlik, duyarlılık ve f ölçütüdür. Modelin başarısı ölçülürken, yukarıda verilen doğruluk, duyarlılık, kesinlik ve F ölçütlerinin dışında, ayrıca ROC area ve kappa istatistiği değerleri de ölçüt olarak kullanılmaktadır.

a. Doğruluk- Hata oranı (Accuracy- Error rate):

Doğruluk ölçütü, tüm veri içinde doğru tahmin edilenlerin oranını ölçmeye imkân tanır. Bütün hata tiplerini dikkate alarak, pozitif ve negatif örnekleri aynı derecede önemsemeyi sağlar [200]. Bir sınıflama modelinde doğru olarak sınıflanan olay sayısının (TP+TN), tüm olay sayısına (TP+TN+FP+FN) bölünmesi ile ise doğruluk oranı hesaplanır. Hata oranı ise bu değer 1'e tamlayanıdır (*Doğruluk Oranı = 1-Hata Oranı*). Diğer bir ifadeyle yanlış sınıflandırılmış örnek sayısının (FP+FN), toplam örnek sayısına (TP+TN+FP+FN) oranıdır [167].

$$\text{Doğruluk} = \frac{TP+TN}{TP+FP+FN+TN} \quad (2.8)$$

$$\text{Hata Oranı} = \frac{FP+FN}{TP+FP+FN+TN} \quad (2.9)$$

b. Kesinlik (Precision, Keskinlik):

Kesinlik, sınıfı 1 olarak öngörülen True Pozitif örnek sayısının, sınıfı 1 olarak öngörülen tüm örnek sayısına oranıdır [199].

$$\text{Kesinlik} = \frac{TP}{TP+FP} \quad (2.10)$$

c. Duyarlılık (Recall, Sensitivity, Anma, Geri çağırım):

Duyarlılık, doğru sınıflandırılmış pozitif örnek sayısının, toplam pozitif örnek sayısına oranıdır [199].

$$\text{Duyarlılık} = \frac{TP}{TP+FN} \quad (2.11)$$

$$\text{TP rate} = \frac{TP}{TP+FN} \quad (2.12)$$

TP rate (TP oranı) gerçek pozitif değerlerinin oranını göstermektedir. “Recall” değeri (2.11) ile “TP rate” (2.12) değeri aynı tanımlamaya sahiptir [202-203]. Roc eğrisi çizilirken dikey ekseninde TP rate değeri verilmektedir [204].

d. F-Ölçütü:

Kesinlik ve duyarlılık ölçütleri tek başına anlamlı bir karşılaştırma sonucu çıkarmamıza yeterli değildir. Her iki ölçütü beraber değerlendirmek daha doğru sonuçlar verir. Bunun için f-ölçütü (F) tanımlanmıştır. F-ölçütü, kesinlik (K) ve duyarlılığın (D) harmonik ortalamasıdır [199, 205].

$$F = \frac{2 * D * K}{(D + K)} \quad (2.13)$$

e. Özgüllük (Specificity, Seçicilik):

Özgüllük, gerçek negatif verilerin model tarafından doğru tespit edilme başarımını gösterir. Model tarafından negatif olarak doğru sınıflandırılmış veri sayısının test verisi içinde yer alan gerçek negatif verilere oranıdır [206-207].

$$\text{Özgüllük} = \frac{TN}{TN+FP} = 1 - \text{FP rate} \quad (2.14)$$

$$\text{FP rate} = \frac{FP}{TN+FP} \quad (2.15)$$

FP rate (FP oranı) gerçek değeri negatif olmasına karşın pozitif olarak tahmin edilenlerin oranıdır. Roc eğrisi çizilirken yatay ekseninde yanlış pozitif değerlerinin oranı verilir [204].

f. Kappa istatistik değeri:

Veri madenciliği uygulamalarında kappa istatistiği, sınıflandırma algoritmasının doğruluğu ile tesadüfî tahminde bulunan rastgele bir sınıflandırma algoritmasının doğruluğunun karşılaştırılması amacıyla kullanılmaktadır. Kappa istatistiği, yapılan tahminin doğruluk ölçüsüdür. Doğruluk ölçütüne alternatif olarak, kappa istatistiği de kullanılabilir. Kappa istatistik değeri 1'e yaklaştığında tesadüfün ötesinde bir uyum olduğunu, 0'a yaklaştığında ise uyumsuzluğun olduğunu gösterir. Kappa istatistik değeri Çizelge 2.3' deki karışıklık matrisi dikkate alınarak aşağıdaki adımlar sırası ile izlenerek hesaplanmaktadır [208-209]:

$$P_o = (TP+TN) / (TP+FP+FN+TN) \quad (2.16)$$

$$P_{sınıfl} = [(TP+FN) / (TP+FP+FN+TN)] * [(TP+FP) / (TP+FP+FN+TN)] \quad (2.17)$$

$$P_{sınıf0} = [(FP+TN) / (TP+FP+FN+TN)] * [(FN+TN) / (TP+FP+FN+TN)] \quad (2.18)$$

$$P_e = P_{sınıfl} + P_{sınıf0} \quad (2.19)$$

$$Kappa = (P_o - P_e) / (1 - P_e) \quad (2.20)$$

Landis ve Koch (1977), kappa istatistik değerinin 0,4'ün üzerinde olması durumunda ölçümün tesadüfî olmadığını, uyum kabul edilebileceğini, kappa istatistik değerinin 0,6 ile 0,8 arasında olması önemli bir derecede uyum olduğunu, 0,8 ile 1 arasında olması ise neredeyse mükemmel bir uyumun olduğunu gösterdiğini söylemektedir [210].

a. ROC alanı (ROC area)

ROC eğrisi, dikey ekseninde doğru pozitif oranı (TP rate), yatay ekseninde yanlış pozitif oranı (FP rate) gösteren bir grafikdir [204, 211]. ROC eğrisi (0,0) ile (1,1) arasında artan bir fonksiyondur. ROC analizi ile başarısı değerlendirilen bir modelin yararsız mı yoksa çok iyi mi olduğuna kararı verilebilir [212].

Roc area değeri TP rate (T): $\rightarrow y(x)$ ve FP rate (T): $T \rightarrow x$ olmak üzere;

$$A = \int_{x=0}^1 \text{TPrate}(\text{FPrate}^{-1}(x)) dx = \int_{-\infty}^{\infty} \text{TPrate}(\text{FPrate}'(T)) dT = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} I(T' > T) f_1(T') f_0(T) dT' dT = P(X_1 > X_0) \quad (2.21)$$

şeklinde hesaplanmaktadır. X_1 olumlu durum için puanları temsil ederken X_0 olumsuz durum için puanları temsil etmektedir. f_0 ve f_1 ise olasılık yoğunluklarını ifade etmektedir [213-214].

Hosmer, Lemeshow ve Sturdivant (2013), modelin başarısının ölçümü konusunda ROC area değeri $\leq 0,5$ olması durumunda ölçümün “Başarısız”, $0,5 < \text{ROC area değeri} < 0,7$ arasında olması “Zayıf”, $0,7 \leq \text{ROC area değeri} < 0,8$ arasında olması “Kabul edilebilir”, $0,8 \leq \text{ROC area değeri} < 0,9$ arasında olması “Mükemmel” ve ROC area değeri $\geq 0,9$ ise “Olağanüstü” olduğunu söylemektedir [215]. ROC area değerinin de kappa istatistik değeri gibi 1’e yakın olması istenir. Sonuç olarak, ROC area değeri ne kadar büyük olursa o kadar iyi bir uyum söz konusu olmaktadır.

5. Modelin Dağıtımı / Kullanılması:

Kurulan ve geçerliliği kabul edilen model doğrudan bir uygulama olabileceği gibi, bir başka uygulamanın alt parçası olarak kullanılabilir. Kurulan modeller risk analizi, kredi değerlendirme, dolandırıcılık tespiti gibi kurumsal uygulamalarda doğrudan kullanılabileceği gibi, otomatik olarak sipariş verilmesini sağlayacak bir uygulamanın içine gömülebilir [167].

Modelin kullanılması aşamasında [216];

- Bulguları yayınlama,
- Uygulama sürecini planlanması ve geliştirilmesi,
- Modelin uygulanmaya alınması,
- Sonuçların operasyonel CRM sistemi ile entegre edilmesi,
- Bakım ve güncelleme için süreçlerin tasarlanması,
- Projenin gözden geçirilmesi,
- Sonraki süreçlerin planlanması yapılır.

2.3.6. Makine öğrenmesi uygulama alanları

Makine öğrenmesi, eğitim, finans ve meteoroloji gibi birçok alanda geçmişte bulunan veriler üzerinde uygulanarak gelecekte olabilecek durumların tahminleri ve verilerin sınıflandırmaları yapılabilmektedir. Bu tahminlerin en önemli özelliği, gerçekleşmesi uzun sürebilen ve gerçekleştikten sonra geri dönülmez sonuçlar üretebilen olayların önceden öngörülmesidir. Veri madenciliğine paralel olarak makine öğrenmesi teknikleri birçok alanda uygulanmaktadır. Aşağıda makine öğrenmesinin uygulandığı alanlar özetlenmiştir [15]:

- Astronomik verilerin otomatik sınıflandırılması
- Tıpta hastalıkların semptomlarla tespiti
- Veri madenciliği ve analizi (ekonomi, finans ve pazarlama)
- Enerji Sistemleri
- Uçuş eğitimlerinde strateji geliştirme
- Çimento dayanıklılık tahmini
- Doğal dil işleme ve öğretme
- Türkçe sözcük anlamı açıklama
- Karar ağaç yapılarının modellenmesi
- Tıbbi verilerin sınıflandırılması
- Yazılım efor büyüklüğünün tahmin edilmesi
- Kanseri türlerinin sınıflandırılması ve teşhisi
- İlaç tasarımı
- Metinlerin otomatik olarak sınıflandırılması
- Kredi riski hesaplaması
- Kredi kartı çalınmasının tespiti
- Üretim hatalarının tespiti
- Teknik direktörler için sporcu performansı analizi
- Haber ve web aramalarının özelleştirilmesi
- Sürücülerden bağımsız araba kullanımı

2.4. İlgili Çalışmalar

Literatürde sağlık alanında birçok farklı problem alanları için makine öğrenmesi algoritmalarını kullanan yazılımlar ve uzman sistemler geliştirilmiştir. Bu uzman sistemler ve makine öğrenmesi algoritmalarını içeren yazılımlar kullanılarak insan uzmanlığı gerektiren problemlerin çözümünde karar verme işlemlerini modelleyebilmekte, etkili, hızlı ve doğru kararlar verilebilmektedir. Bu çalışmalardan bazıları; tıpta ve psikiyatride uzman sistemlerin kullanılmasına yönelik çalışmalar, makine öğrenmesi algoritmalarının kullanılmasına yönelik çalışmalar ve makine öğrenmesi algoritmalarının uzman sistemde kullanılmasına yönelik çalışmalar olmak üzere üç başlık altında özetlenmiştir.

2.4.1. Uzman sistemlerin tıpta ve psikiyatride kullanımı ile ilgili literatür

İlgili literatür incelendiğinde hem ulusal hem de uluslararası çalışmalarda sağlık alanında uzman sistemler kullanılarak çeşitli tanı sistemleri oluşturulmuştur.

Sethi (2016), “Diyabet Tanı: Diyabet Tip-II Tanısında Uzman Sistem” isimli yaptığı çalışmada, diyabetli hastaların tanısına yönelik uzman sistem tasarlamış, bu sistem üzerinde J48 Graft, Random forest, Random tree ve Multi-boost classifier gibi algoritmaları kullanarak model başarımleri ölçütlerini karşılaştırmıştır. Hastalığın ön tanısına yönelik geliştirilen modelin çok büyük bir oranda (%96 oranında) doğru sonuç ürettiği sonucuna varmıştır [217].

Yapılan diğer bir çalışmada, Babalık ve Güler (2007) boğaz enfeksiyonlarının teşhis ve tedavisine yönelik bir uzman sistem geliştirmişlerdir. Geliştirilen sistemin çıkarım motorunda geri zincir algoritması kullanılmıştır. Bilgi tabanına 76 adet kural kaydedilmiştir. Geliştirilen uzman sistemin, hekimlerin karar vermesinde, eğitilmesinde ve hasta bilgilerinin arşivlenmesinde kullanılabileceği bildirilmiştir [218].

Yılmaz’ın 2012 yılında yaptığı “Demir eksikliği anemisi teşhisi için bir bulanık uzman sistem tasarlanması” isimli yüksek lisans tezinde bulanık uzman sistem ile demir eksikliği anemisinin seviyesini tespit etme ve bu sayede uzman hekimlere uygulayacakları tedavi öncesinde tam tanı koymalarına destek verici bir sistem tasarlamıştır. Sistem tasarımının

gerçekleme sürecinde: Gerçek hasta bireylerden alınan kayıtlar incelenmiş, uzman hekimle birlikte girişler bulanıklaştırılarak bulanık kural tabanı oluşturulmuştur [219].

Konuyla ilgili bir başka çalışma Keleş ve Keleş tarafından 2008 yılında yapılmıştır. Çalışma kapsamında tiroit hastalığının ön tanısında kullanılmak üzere bir uzman sistem tasarlanmıştır. Sistemde bulanık uzman sistem kullanılarak bulanık kurallar üretildiği ve bu sistemin aynı zamanda tıp öğrencilerinin eğitiminde de kullanılabileceği belirtilmiştir. Geliştirilen modelin tiroit hastalığının ön tanısının konulmasını %95,33 doğruluk oranında açıklayabildiği sonucuna varılmıştır [220].

Başçıftçı ve İncekara (2011) geliştirdikleri web ara yüzü bulanık girişli uzman sistem tasarımı ile mikrobiyoloji laboratuvarı tetkiklerini analiz etmişlerdir. Tahlil değer aralıklarına (düşük, normal, yüksek) göre risk faktörlerinin belirlenmesi ve kullanıcının anlamını bilmediği terimlerin anlaşılacak şekilde kullanıcıların bilgisine sunulmuştur. Geliştirilen uzman sistemde mikrobiyoloji laboratuvarı tetkiklerinin analizi normal sistemlerden farklı olarak kullanıcı kesin analiz sonuç değerlerini sisteme gireceği için bireysel etkiler ortadan kalkmış ve daha doğru sonuçlar alındığı belirtilmiştir [221].

Psikiyatride uzman sistemlerin kullanımı ile ilgili; Fernando, Henskens ve Cohen (2011) yaptıkları çalışmalarında psikiyatrik tanının konulmasına yönelik uzman sistem temelli bir model önermektedirler. Tıbbi uzman sistemlerin uzun zamandır kullanılmasına rağmen istenilen hedefe ulaşamadığı ve alanlara özgü modellerin eksikliği belirtilmektedir. Çalışma kapsamında psikiyatride alana özgü kullanılmak üzere teşhis çıkarımı yapabilen bir uzman sistem modeli geliştirilmiştir [32].

Benzer bir şekilde Nunes, Pinheiro ve Pequeno tarafından 2009 yılında psikolojik rahatsızlıkların teşhisinde kullanılmak üzere bir uzman sistem geliştirilmiştir. Çalışma kapsamında psikotik bozukluklar, duygudurum bozuklukları, anksiyete bozuklukları, antisosyal kişilik, çoklu kişilik ve bağımlılık gibi psikolojik rahatsızlıkların erken teşhisine yardımcı olmak ve psikolojik rahatsızlıklara yönelik bilgilerin yapılandırılarak bilgi tabanının oluşturulması amaçlanmıştır [222].

Cha ve Romli (2010) stres yönetimi alanına yönelik bir uzman sistem geliştirmişlerdir. Geliştirilen uzman sistem bir psikolog gibi davranarak psikoloğun rolünü sanal olarak

taklit etmektedir. Psikoloğun, danışanın stres ve kişilik ilgi düzeyini belirlemek için kullandığı yöntemin kuralları uzman sisteme entegre edilmiştir. Geliştirilen kural tabanlı uzman sistem ile stres yönetimi için çözüm ve öneri sunulması sağlanmaktadır. Çalışmanın stres yönetiminde gerekli zaman ve insan gücünün azaltılmasına yardımcı olacağı düşünülmektedir [223].

Manalu, Abbas, Gaol ve Trawiński (2017) şizofreni semptomlarının erken saptanmasına yardımcı olacak bir uzman sistem geliştirmişlerdir. Sistemdeki kurallar, psikiyatrist bilgilerini temsil eder ve bir hastanın şizofreni hastası olup olmadığını değerlendirmek için kullanır. Çalışmada şizofreni hastalığının erken tanısında kullanılmak üzere 48 adet kural oluşturulmuştur. Bilgi tabanı hastaya soru formunda gösterilmekte ve hastadan gelen cevaplar doğrultusunda erken tanı konulmaktadır [224].

Yapılan diğer bir çalışmada, Windriyani, Kom, Wiharto, Kom ve Sihwi (2013) alkol bağımlılığı, panik atak, sosyal fobi, depresyon gibi çeşitli psikiyatrik bozuklukların tanısına yönelik bir uzman sistem geliştirmişlerdir. Geliştirilen sistemin çıkarım motorunda ileri zincirleme yöntemi kullanılmıştır. Sistemde 100 hastanın verisi kullanılmıştır. Geliştirilen uzman sistemin, %96 doğruluk oranı ile çalıştığı bildirilmiştir [225].

Al-Wahaibi, Al-Hajry, Al-Bahrani ve Al-Busaidi (2016) otizm spektrum bozukluğunun erken saptanmasına yardımcı olacak bir uzman sistem geliştirmişlerdir. Çocukta otizm spektrum bozukluğuna yönelik şüpheleri bulunan ebeveynlerin kullanması amacıyla sistemin tasarlandığı belirtilmiştir. Sistem “düşük düzeyde otizm”, “orta düzeyde otizm”, “yüksek düzeyde otizm”, “Asperger bozukluğu” ve “Çocuk Disintegratif bozukluğu” olmak üzere beş tanıyı kapsamaktadır. Çalışmada kural tabanını alan uzmanı oluşturmuş ve test etmiştir. Sistemi daha sonra 25 kullanıcı denemiş ve bu kullanıcılar sistemin esnekliği, kullanım kolaylığı, tanı koymadaki başarısı gibi sistem hakkındaki görüşleri çalışmada sunulmuştur [226].

Marakakis, Vassilakis, Kalivianakis ve Micheloyiannis (2005) epilepsinin erken tanısında kullanılmak üzere bir uzman sistem modeli tasarlamışlardır. Çalışmada kural tabanı alan uzmanları tarafından oluşturulmuştur. Alan uzmanının sistemin bilgi tabanını kullanıcı dostu bir arayüzle güncelleyebileceği belirtilmektedir. Geliştirilen uzman sistem test

edilirken üç alan uzmanının tanıları ile sistemin tanı öngörüsü karşılaştırılmış sistemin %83,3 doğruluk oranı ile çalıştığı bildirilmiştir [227].

Konu ile ilgili literatür incelendiğinde tıpta ve psikiyatride uzman sistemlerin kullanımı ile ilgili çeşitli çalışmalar bulunmaktadır. Bu çalışmaların şizofreni tanısı, tiroit hastalığının tanısı veya epilepsinin tanısı gibi sadece tek hastalığın tanısında kullanıldığı görülmektedir.

2.4.2. Makine öğrenmesi algoritmalarının tıpta ve psikiyatride kullanımı ile ilgili literatür

Makine öğrenmesi algoritmaları her alanda yaygın olarak kullanılmaktadır, özellikle medikal tanılamada birçok uygulaması vardır. Tıpta teşhis ve tedavilerde uzmana kolaylık sağlayacak, uzmanın olmadığı yerlerde hastalığa ön tanı koymak için geliştirilecek sistemlerin önemli olduğu görülmektedir. İlgili literatür incelenerek makine öğrenmesinin tıpta ve psikiyatride kullanılmasına yönelik bazı çalışmalar özetlenmiştir:

Aydın (2011), “Kalp Ritim Bozukluğu Olan Hastaların Tedavi Süreçlerini Desteklemek Amaçlı Makine Öğrenmesine Dayalı Bir Sistemin Geliştirilmesi” adlı yaptığı çalışmada makine öğrenmesi teknikleri kullanılarak bir tıp bilişimi uygulaması geliştirilmiştir. Bu uygulamayla kalp ritim bozukluğu olan hastaların tedavi süreçlerine yardımcı olmak amacıyla öğrenmeye dayalı bir sistem gerçekleştirilmiştir. Geliştirilen sistemde, makine öğrenmesi algoritması olarak KNN algoritması kullanılmış ve yapılan tahminlerde yüksek oranda doğruluk sağladığı tespit edilmiştir [228].

Dreiseitl ve diğerleri, deri lezyonlarının tanısında makine öğrenmesi yöntemlerini kullanmışlardır. Çalışmada, pigment deri lezyonu tanısına yönelik beş makine öğrenmesi algoritmasını (KNN, lojistik regreyon, ANN, karar ağaçları ve SVM) 1619 kayıt üzerinde karşılaştırmışlardır. Bu veri seti üzerinde lojistik regresyon, ANN ve SVM algoritmalarının yaklaşık aynı doğrulukta sonuç ürettiği (0,82%), karar ağaçları ve KNN algoritmalarının ise performanslarının bu algoritmalara göre daha düşük olduğu (0,79%) sonucuna varmışlardır [229].

Çentik (2013) yaptığı doktora çalışmasında, uykuda periyodik hareket bozukluğu teşhisi konulmuş farklı yaş ve cinsiyetten 153 bireyin polisomnografi kayıtları üzerinde, makine

öğrenmesi yöntemleri denenmiştir. Çalışmada özellikler dijital sinyal işleme yöntemleri (Dalgacık ve Fourier) ve istatistiksel yöntemler kullanılarak elde edilip veri tabanında saklanmıştır. Veri tabanında saklanan özellikler, farklı makine öğrenmesi algoritmaları kullanılarak uykuda periyodik hareket bozukluğunun olup olmadığı sınıflandırılmıştır. Çalışma sonucunda makine öğrenmesi algoritmalarıyla, %79 gibi yüksek bir oranla sınıflandırılabilceği tespit edilmiştir [230].

Soliman, Fares, Elhefnawi ve Al-Hefnawy (2016) Parkinson hastalığının erken tanısına yönelik makine öğrenmesi modelleri geliştirmişlerdir. Araştırmada 10 tıp merkezinden alınan veri kümesi kullanılmıştır. Bu hastalığın ayırt edici tanısına yönelik en uygun modeli geliştirmek için filtreleme (Filter) ve sarmal (Wrapper) özellik seçme teknikleri karşılaştırılmıştır. Çalışmada sınıflandırma modellerinin hızlı ve daha doğru karar vermesi amacı ile özellik sayısının azaltılması ve en önemli ölçümlere odaklanmak gerektiği vurgulanmaktadır [231].

Benzer bir çalışma ise, Demircioğlu ve Bilge (2015) tarafından yumurtalık kanseri veri kümesindeki gen ifadelerinin analiz edilmesi üzerine yapılmıştır. Çalışma kapsamında veri kümelerindeki binlerce özellik bilgisinin Fisher korelasyon ve Welch t testi ile boyut indirgenmiş diğer bir deyişle ilgili özellikler seçilmiş, KNN ve SVM sınıflandırma yöntemlerinin farklı parametreleri detaylı bir şekilde incelenmiştir. Yapılmış uygulamalar ışığında yumurtalık kanseri verilerinin çeşitli özellik seçme ve sınıflandırma yöntemleri ile modellenerek algoritmaların doğruluk oranları incelenip karşılaştırılmıştır [232].

Sorias 2014 yılında yaptığı çalışmasında, psikiyatrik tanının makine öğrenmesi algoritmalarından Bayes ağlarının kullanılmasına ilişkin yeni bir model önermektedir. Bu modelin betimsel yaklaşımın ötesine geçilmesine ve etiolojiye ilişkin bilgilerin, eşlik eden özelliklerin ve laboratuvar incelemelerinin tanı koymakta kullanılmasına fırsat verdiğini belirtmektedir. Psikiyatri alanında Bayes ağlarının kullanılmasına ilişkin bu model ile boyutsal bir tanı (bir olasılık değeri) konulduğu için hem kategori yaklaşımının bilinen sakıncalarını taşımadığını hem de tanının kesinlik derecesini belirtilmesine imkân verdiği savunulmaktadır. Üstelik bunun mevcut düzeni hiç değiştirmeden yapılabileceğini ve mevcut kullanılan düzenden çok daha iyi sonuç alınabileceğini belirtmiştir [233].

Benzer bir şekilde Suhasini, Palanivel ve Ramalingam (2010) çalışmalarında psikiyatrik problemlerin tanısında makine öğrenmesi algoritmalarını kullanarak bir model geliştirmişlerdir. Çalışmada makine öğrenmesi sınıflandırma algoritmalarından RBF Network algoritması kullanılmıştır. Önerilen uzman sistem modelinde 400 adet hastanın veri kümesi üzerinde %98,75 doğruluk oranı elde edilmiştir [234].

Psikiyatride makine öğrenmesi algoritmalarının kullanımı ile ilgili bir diğer çalışma Sumathi ve Poorna tarafından 2016 yılında yapılmıştır. Çalışmada makine öğrenme teknikleri kullanılarak çocukların akıl sağlığı sorunlarının tahmin edilmesi sağlanmıştır. Mental bozuklukların makine öğrenmesi algoritmalarının kullanılarak erken tanısının tahmin edilebilmesi ile birlikte hastanın yaşam kalitesinin artırılması ve erken tedavi adımlarının uygulanması süreçlerindeki önemi vurgulanmıştır. Çalışmada 60 adet veri seti üzerinde en çok kullanılan makine öğrenmesi algoritmalarının performansları karşılaştırılmıştır [235].

De la Fuente, Bengoetxea, Navarro, Bobes ve Alarcón (2011) psikiyatride Bayes ağlarını Borderline kişilik bozukluğunun semptomları arasındaki bağımlılıkları ortaya çıkarmakta kullanarak, objektif nörobiyolojik değişkenlerin bu hastalığın tanısında kullanılabileceği sonucuna varmışlardır [236].

Bir başka çalışmada Bayes ağlarına dayanan bir çıkarım modeli oluşturularak kişilerin depresyona girme olasılığı hesaplanmıştır. Geliştirilen modelin prototip uygulaması yapılmış ve sistemin depresyon tanısı koymada oldukça faydalı olduğu sonucuna varılmıştır [237].

Birçok hastalığın erken tanısında olduğu gibi epileptik nöbet tespitinde de makine öğrenmesi algoritmaları birçok çalışmada kullanılmış ve etkili sonuçlar ürettiği tespit edilmiştir [238]. Bu çalışmalardan bazıları epileptik nöbet tespitinde EEG sinyallerini kullanmışlardır. Shoeb ve Guttag (2010) yaptıkları çalışmalarında 24 hastanın EEG sinyal verilerini kullanarak %96 doğruluk oranı ile epileptik nöbetlerin tespitinin yapılabildiğini belirtmişlerdir [239]. Epileptik nöbetlerin erken tanısının belirlenmesine yönelik benzer bir çalışma Guo, Rivero, Dorado, Rabunal ve Pazos tarafından 2010 yılında yapılmıştır. Çalışmada ANN algoritması kullanılmış ve yüksek doğruluk oranı ile çalıştığı bildirilmiştir [240].

Garcia-Perez, Violante ve Cervantes-Perez (1998) Alzheimer hastalığı ve vasküler demansın ayırıcı tanısının tespitinde sinir ağlarını kullanmışlardır. Çalışma kapsamında makine öğrenmesi algoritmalarından yapay sinir ağları ile ayırt edici tanının %100 güven ile elde edilebileceğini rapor etmişlerdir [34]. Benzer bir çalışma ise, Zhang ve diğerleri (2011) tarafından Alzheimer ve hafif bilişsel bozuklukların sınıflandırılarak analiz edilmesi üzerine yapılmıştır. Çalışmada SVM algoritması ve 10-kat çapraz geçerlilik yöntemi kullanılmıştır. Çalışmanın sonucunda hastalığın %93,2 doğruluk oranı ile sınıflandırılabilirdiği tespit edilmiştir [37].

Hoexter ve diğerleri (2013) obsesif kompulsif semptom şiddetinin öngörülmesine yönelik makine öğrenmesi yöntemlerini kullanmışlardır. Çalışmada, 37 hastanın manyetik rezonans görüntüleme (MRI) veri kümesi üzerinde destek vektör regresyon algoritması kullanılmıştır. Obsesif kompulsif semptom şiddetinin tahmin edilebileceği sonucuna varmışlardır [241]. Obsesif kompulsif bozukluğunun öngörülmesine yönelik benzer bir çalışma Askland ve diğerleri tarafından 2015 yılında yapılmıştır. Bu çalışmada 296 hasta verisi üzerinde Random Forest Regression (Rastgele ormanlar) algoritması kullanılmıştır. Çalışmanın bulgularında %95 bootstrap güven aralığı ve %24,6 hata oranı olduğu bildirilmiştir [242].

2.4.3 Tıpta ve psikiyatride makine öğrenmesi algoritmalarının uzman sistemde kullanılması ile ilgili literatür

Uzman sistem, insan düşüncesini ve akıl yürütmesini bazı kurallara dönüştürerek taklit eden bilgisayar yazılımlarıdır. Medikal tanılamada uzman sistemin kullanımı, hekimlerin yüksek doğrulukla karar verme süreçlerine yardımcı olur [243]. Uzman sistemi daha verimli ve etkili kılmak için veri madenciliği ve makine öğrenmesi algoritmaları kullanılmaktadır [129]. Tıpta ve psikiyatride makine öğrenmesinin uzman sistemde kullanılmasına yönelik bazı çalışmalar özetlenmiştir:

Bashir, Qamar ve Khan (2011), “WEBMAC: Web tabanlı bir klinik uzman sistemi” adlı yaptıkları çalışmada medikal alanda makine öğrenmesi tekniklerini kullanarak bir uzman sistem uygulaması gerçekleştirmişlerdir. Bu uygulamayla veri toplama, veri ön işleme, sınıflandırma algoritmasının eğitimi, test edilmesi ve hastalık sınıflandırması adımlarından oluşan makine öğrenmesine dayalı bir uzman sistem geliştirilmiştir. Geliştirilen klinik

uzman sistemin denenmesi karaciğer hastalığı veri seti, kalp hastalığı veri seti, meme kanseri veri seti tümör veri seti gibi UCI makine öğrenmesi veri deposunda bulunan bilinen veri kümeleri ile gerçekleştirilmiştir. Geliştirilen klinik uzman sistem sonuçları analiz edildiğinde daha yüksek sınıflandırma ve tahmin doğruluğu ile sistemin kullanılabileceği sonucuna varılmıştır [129].

Doğantekin, Doğantekin ve Avcı (2011) tiroit hastalığının tanısının tespitinde Diskrimant analizi ve makine öğrenmesi sınıflandırma algoritmalarından SVM algoritması temelli bir uzman sistem tasarlamışlardır. Önerilen sistemde %91, 86 sınıflandırma doğruluk oranı ile tiroit hastalığının ön tanısının konulabileceği rapor edilmiştir [244].

Benzer bir çalışma ise, Karabatak ve İnce (2009) tarafından meme kanserinin saptanması için yapılmıştır. Çalışma kapsamında makine öğrenmesi birliktelik kuralları algoritmalarından Apriori algoritması ve sınıflandırma algoritmalarından sinir ağlarına dayalı bir uzman sistem modeli önermişlerdir. Uzman sistemin %95,6 doğruluk oranı ile çalıştığı tespit edilmiştir [245].

Sigut, Piñeiro, Gonzalez ve Torres (2007) Alzheimer hastalığının sınıflandırılmasına yönelik makine öğrenmesi sınıflandırma algoritmalarının kullanıldığı uzman sistem geliştirmişlerdir. Çalışmada 78 adet (42 tane Alzheimer hastası ve 36 tane sağlıklı birey olmak üzere) gerçek veriler çalışılmış ve sistem test edilmiştir [246].

Kaya ve Tekin (2012) epileptik nöbetlerin tespiti için aşırı öğrenme makinesi tabanlı bir uzman sistem geliştirmişlerdir. Çalışmada epileptik EEG sinyallerinin sınıflandırılmasında aşırı öğrenme makinesi (Extreme learning machine=ELM) algoritması kullanılmıştır. ELM, tek gizli katmanlı ileri beslemeli bir yapay sinir ağı modelidir. Geliştirilen uzman sistemin doğruluk oranının %100 olduğu rapor edilmiştir [231].

Epileptik nöbetlerin tespitinde benzer bir çalışma Swami ve diğerleri tarafından 2014 yılında yapılmıştır. Çalışma kapsamında EEG sinyallerinin sınıflandırılmasında SVM algoritması kullanılarak epileptik nöbetlerin otomatik tespitine yönelik bir uzman sistem geliştirmişlerdir. Geliştirilen sistemin duyarlılık (sensitivity) oranı %99,53 ve özgüllük (specificity) oranı %98,8 olarak bulunmuştur [247].

Motlagh, Bidgoli ve Fard (2017) depresyon bozukluğunun tanısına yönelik web tabanlı bir uzman sistem geliştirmiştir. Geliştirilen sistemde hastalığın sınıflandırılması işleminde bulanık mantık algoritması kullanılmıştır. Çalışmada 238 katılımcıdan elde edilen veri kümesi üzerinde işlem yapılmıştır. Çalışma sonucunda sistemin duyarlılık oranının %79 ve özgüllük oranının %98 olduğu tespit edilmiştir [138].

Masri ve Jani (2012) mental bozuklukların tanısına yönelik yaptıkları çalışmalarında bulanık uzman sistem temelli bir model önermektedirler. Çalışmada bulanık mantık ve genetik algoritma kullanılmıştır. Mental bozuklukların tanısında kullanılmak üzere geliştirdikleri MeHDES isimli sistemin kullanışlı, yararlı ve ekonomik olduğunu bildirmişlerdir [248].

Bir başka çalışmada Ojeme, Mbogho ve Meyer tarafından 2016 yılında yapılmıştır. Çalışmada, klinik depresif bozukluklara ilişkin Bayes ağlarına dayalı olasılıksal çıkarım modelini içeren bir uzman sistem geliştirilmiştir. Geliştirilen sistemde 1090 adet kayıt ve 21 nitelik kullanılmıştır. Bayes ağlarını içeren algoritmaların TAN (Tree Augmented Naive Bayes), NB (Naive Bayes), ANB (Augmented Naive Bayes), MB (Markov Blanket), AMB (Augmented Markov Blanket) ve MAMB (Minimal Augmented Markov Blanket)) performans bulguları karşılaştırılmıştır. En iyi performansa sahip algoritmanın TAN algoritması (roc değeri= 89,9676, precision değeri = 94,8624) olduğu saptanmıştır [135].

İlgili literatür incelendiğinde hem uzman sistemlerin hem de makine öğrenmesi algoritmalarının sağlık alanında kullanılmasına yönelik çok sayıda çalışma olduğu hatta giderek bu çalışma sayısının arttığı görülmektedir. Hastalıkların ön tanısının konulmasının hastalığın teşhis ve tedavisinde önemli katkılar sağlayacağı açıktır.

Bu çalışmada yukarıda verilen çalışmalardan farklı olarak; DEHB'e yönelik kural tabanının oluşturulması, oluşturulan bu kural tabanı üzerinde makine öğrenmesi algoritmalarının karşılaştırılması ve bozukluğun erken teşhisini sağlayan bir uzman sistem tasarımının geliştirilmesi amaçlanmaktadır.



3. YÖNTEM


Bu bölümde, çalışma kapsamında kullanılan materyal ve metotlar tanıtılmıştır. Kullanılan algoritmanın, örneklemin, özelliklerin, araçların, eğitim ve test verilerinin seçilmesi işlemlerinden bahsedilmiştir.

Yazılım geliştirme yaşam döngüsü, yazılım sistemlerini geliştirmek ve yönetmek için kullanılan bir süreçtir. Genel olarak bu süreç, ön geliştirme analizinden yazılımın test ve değerlendirilmesine kadar çeşitli aşamaları içerir. Ayrıca yazılım geliştirme yaşam döngüsü; yazılımın gelişim sürecini planlamak ve kontrol etmek için genel bir çerçeve sunmaktadır [249]. Proje geliştirme sürecinde kaliteli bir yazılım ürününün geliştirilmesi, proje maliyetinin düşürülmesi ve döngü süresinin azaltılması amaçlanmaktadır. Bu nedenle projede yapılacak faaliyetler belli bir sırayı izler [250]. Kısaca yazılımın hem üretim hem de kullanım süreci boyunca geçirdiği tüm aşamalar yazılım geliştirme yaşam döngüsü olarak tanımlanır [251]. Yazılım geliştirme yaşam döngüsünün daha aktif ve en iyi sonucu vermesi için yazılım geliştirme süreç modelleri kullanılmaktadır.

Yazılım geliştirme süreç modelleri, yazılım geliştirme yaşam döngüsünde belirtilen süreçleri organize eden, kendi içerisinde hangi sırada ya da düzende ve nasıl uygulanacağını tanımlayan modellerdir [252]. Bu yazılım süreç modelleri temelde; düzenleyici süreç modelleri, birleşik süreç modelleri ve çevik modeller olmak üzere üçe ayrılırlar [253]. Bu yazılım süreç modellerinden en çok kullanılan çevik yazılım süreç modelidir [254-255]. Çevik modelleme; yazılım geliştirme sürecinde etkili, verimli ve pratik bir şekilde modelleme oluşturmaya yönelik bir yöntem olarak tanımlanmaktadır. Çevik yazılım süreç modeli, geliştirilecek yazılımı küçük parçalara ayırarak yazılımın geliştirilmesini öngörür. Bu modelde yazılım geliştirilirken kullanıcı ile uyumlu bir şekilde çalışır ve kullanıcıdan alınan geri bildirimlere göre yazılım yeni şeklini alır [256].

Çevik yöntemlerde, yazılım geliştirme faaliyetleri yinelemeli safhalar halinde uygulanır. Bu yinelemeler sonucunda kullanılabilir yazılım ortaya çıkarılır ve kullanıcıların geri bildirimleri ışığında ve varsa değişen gereksinimler doğrultusunda geliştirme süreçleri tekrarlanır. Bu yinelemeli süreçler kullanıcının tam olarak istediği ürün ortaya çıkana kadar sürdürülür. Çevik süreç modelinde; scrum, extreme programming (XP), dynamic systems development methodology (DSDM) ve adaptive software development (ASD) en çok

kullanılan yöntemlerdir. Her çevik yöntemin kendine özgü prensipleri olsa da çevik süreç modelinin şemsiyesi altında belirlenen kişiler arasında etkileşim, iş birliği, değişim ve yinelenmeli süreçler gibi genel özellikler mevcuttur [257]. Bu tez çalışmasında çevik yazılım süreç model adımları [258] benimsenmiş ve tez çalışma sürecinde izlenen bu adımlar Şekil 3.1’de verilmiştir:



Şekil 3.1. Tez çalışma sürecinde izlenen çevik yazılım süreç model adımları

Geliştirilen uzman sistem yazılımı son haline gelinceye kadar kullanıcıların geri bildirimleri doğrultusunda sistem gereksinimleri, yazılım gereksinimleri, analiz, tasarım, kodlama, test-entegrasyon ve idame-bakım adımları yinelenmiştir.

3.1. Sistem Gereksinimleri

Yazılımın başlangıcında uygulanan aşamadır. Bu aşamada sistemin gereksinimleri kabataslak olarak çıkartılır, yazılımın amacı ve kapsamı, personel, donanım ve sistem gereksinimleri belirlenir [259]. Tez çalışmasının bu adımında; çalışmanın hedeflerinin tespit edilmesi ve çalışmanın konusunun belirlenmesi işlemleri yapılmıştır.

Çalışmada DEHB'ye yönelik bilgi tabanının oluşturulması, oluşturulan bu bilgi tabanı üzerinde makine öğrenmesi algoritmalarının doğruluk oranlarının karşılaştırılması ve DEHB durumunun öngörülmesini sağlayan bir uzman sistem modelinin geliştirilmesi hedeflenmektedir.

3.1.1. Çalışma konusunun seçimi

Çalışmanın konusu gereksinim analizi yapılarak en yaygın görülen çocukluk çağı psikiyatrik bozukluklarından DEHB çalışmanın konusu olarak seçilmiştir. DEHB'nin çalışma konusu olarak seçilmesinin sebepleri;

- Yaygınlık; çocukluk döneminin en sık görülen bozukluklarından (%3-9) olması [5, 65],
- Ergenlikte (%50-80) ve yetişkinlikte (%30-50) önemli oranda devam etmesi [4],
- Sadece DEHB olan kişiyi değil aile, sosyal çevre gibi geniş bir kitleyi de etkilemesi [8],
- Hem bireysel sağlık hem de toplumsal sağlık bakımından önemli olması [8],
- DEHB semptomlarının kontrol altına alınabilir olması şeklinde sıralanabilir.

3.2. Yazılım Gereksinimleri

Bu kısımda geliştirilecek yazılımın gereksinimleri belirlenir, yazılım modüllere ayrılır ve yazılım projelendirilir. Tez çalışmasının bu adımında geliştirilecek yazılımın modüllere ayrılmasın ve geliştirilen uzman sistem yazılımının genel özelliklerinin planlanması yapılmıştır.

Çalışmada geliştirilen uzman sistemin bilgi tabanının oluşturulması, bilgi tabanı güncelleme, listeleme ve silme işlemleri, çıkarım mekanizması ve raporlama işlemleri gibi küçük parçacıklara ayrılması, kullanıcı yetki düzeyleri, kullanıcı yetki düzeyine ait alt bileşenlerin belirlenmesi ve sistemin modüllerinin kabataslak olarak belirlenmesi işlemleri bu adımda gerçekleştirilmiştir.

3.2.1. Geliştirilen uzman sistemin genel özellikleri

Geliştirilen uzman sistemin genel özellikleri aşağıda verilmiştir:

a) Sistem hangi amaçlar için kullanılabilir?

Geliştirilen uzman sistem; a) DEHB'nin belirtilerine yönelik kural tabanının oluşturulması, b) bilimsel araştırmalar için veri toplanma ve c) DEHB bulunma riski olduğu düşünülen bireylerin erken tanısının sağlanması amaçları için kullanılabilir.

b) Sistemin içeriği nasıl geliştirilmiştir?

Uzman sistemler; alan uzmanlarının düşünme süreçlerini ve izledikleri akış şemasını taklit ederler. Bu nedenle geliştirilen uzman sistemin içeriği alan uzmanını sanal olarak taklit edebilmesi için APA'nın 2013 yılında yayımladığı DSM-V kılavuzundan elde edilen güncel bilgilerin analiz edilmesi ve alan uzmanlarından (çocuk psikiyatristleri) alınan bilgiler doğrultusunda geliştirilmiştir.

c) Sistem hangi yaş aralığındaki bireylere uygulanabilir?

Geliştirilen uzman sistem DEHB bulunma riski olduğu düşünülen okul çağı yaş grubundaki bireylerin kullanımına uygundur.

d) Sistem kaç kişi üzerinde test edilmiştir?

Geliştirilen uzman sistemin standardizasyon işleminde Gazi Hastanesi Çocuk Ruh Sağlığı ve Hastalıkları Anabilim Dalından alınan 450 adet kliniksel hasta verisi kullanılmıştır.

e) Sistem kimler tarafından kullanılabilir?

Geliştirilen uzman sistem DEHB bulunma riski olduğu düşünülen bireyin ebeveynleri, öğretmenleri (sınıf veya rehber öğretmeni) ve alan uzmanları (çocuk psikiyatristleri) tarafından kullanılabilir.

3.3. Analiz


Analiz aşaması; belirlenmiş sistem ve yazılım gereksinimlerinin analiz edilmesi, sistemin fizibilite çalışmasının yapılması, sistemin ne yapıp ne yapmayacağını kısıtlamalar göz önüne alınarak belirlenmesi, bu bilginin kullanıcılar tarafından doğrulanması ve proje planının analiz edilmesi adımlarından oluşur [260]. Analiz basamağında; bilgi tabanının ve yazılımın geliştirilmesinde kullanılacak araç-gereçlerin analiz edilmesi işlemleri yapılmıştır.

3.3.1. Bilgi tabanının oluşturulması

Uzman sistemlerde problemin çözümünde kullanılan kurallar bilgi tabanında yer alır. Bilgi tabanı dört farklı yol ile oluşturulabilir [261-263];

- a) Alan uzmanlarının bilgisinin kullanılması,
- b) Geçmiş verilerin kullanılması,
- c) Mevcut kuralların kullanılması,
- d) Herhangi bir ön bilgi olmadan kuralların rastgele oluşturulması

Mevcut çalışmalar incelendiğinde bilgi tabanının oluşturulmasında; verilen bu dört yoldan en çok, alan uzmanlarının bilgisinin [137, 151-152], geçmiş verilerin [132, 264-266] ve hem alan uzmanlarının bilgisinin hem de geçmiş verilerin birlikte [267-268] kullanıldığı görülmüştür. Bu çalışmada bilgi tabanı oluşturulurken hem çocuk psikiyatristlerin alan bilgisi hemde geçmişteki veriler kullanılmıştır. Bilgi tabanının oluşturulmasında izlenen adımlar Şekil 3.2’de verilmiştir:



Şekil 3.2. DEHB bilgi tabanı oluşturma süreci

Bilgi tabanı nitelikler ve kayıtlar olmak üzere iki kısımdan oluşmaktadır. Nitelikler, yazılımda hangi giriş parametrelerinin kullanacağı bilgisini içerir. Bu nitelikler APA'nın 2013 yılında yayımladığı DSM-V kılavuzundan elde edilen güncel bilgilerin analiz edilmesi doğrultusunda alan uzmanları tarafından belirlenmiştir. Geliştirilen uzman sistem DEHB'nin öngörülmesine yönelik çocuk psikiyatristinin rolünü sanal olarak taklit etmektedir. Bu nedenle çocuk psikiyatristlerinin DEHB tanısına karar verirken kullandıkları bu tanı ölçütleri, izledikleri akış ve düşünme süreçleri geliştirilen sisteme aktarılmıştır.

Geliştirilen uzman sistemin eğitilmesinde ve test edilmesinde kullanılan kayıtlar ise, Gazi Hastanesi Çocuk Ruh Sağlığı ve Hastalıkları Anabilim Dalından alınan 450 adet kliniksel hasta verilerinden oluşmaktadır. Bu kayıtlar, Gazi Hastanesi Çocuk Ruh Sağlığı ve Hastalıkları Polikliniğine okulla ilgili uyum sorunları, ergenlik sorunları, ders başarı durumunun düşük olması gibi sorunlarla başvuru yapan, klinik inceleme ve testler sonucunda, DEHB tanısı alan (200 DEHB) ve bu değerlendirmeler sonucunda DEHB veya herhangi bir psikiyatrik bozukluk tanısı almayan (250 DEHB olmayan) çocuklara ait bilgileri içermektedir. Bu kayıtlara ait yaş aralık ve cinsiyet dağılımı bilgileri Çizelge 3.1'de yer almaktadır.

Çizelge 3.1. Kayıtlara ait yaş aralıkları ve cinsiyet dağılım bilgileri

		<i>f</i>	%
Cinsiyet	Kız	184	40,9
	Erkek	266	59,1
Yaş aralıkları	3-6	52	11,6
	7-10	266	59,1
	11-14	90	20,0
	15-18	42	9,3

Çizelge 3.1’de görüldüğü gibi, toplanan kliniksel hasta verilerindeki 450 kayıt incelendiğinde, çocukların yaş aralıkları 3-18 arasında dağılım göstermektedir. Çocukların 184’ü kız, 266’sı erkektir.

Uygulamalarda, veri kümesinin büyüklüğünden ziyade veri kümesinin temsil edebilirliği önemlidir. Ele alınan ne kadar çok nitelik varsa, o kadar çok örneklem (kayıt) sayısına gereksinim duyulmaktadır [269]. İlgili literatür incelendiğinde örneklem büyüklüğünün 42 [265], 100 [267], 180 [270], 380 [271] ve 800 [272] gibi erişilebilen örnek sayısına göre farklılık gösterdiği gözlemlenmiştir. Çalışmada kullanılan 450 örnek sayısı; öznelilik ile örneklem büyüklüğü arasındaki ilişkiyi karşılamakta ve yapılan çalışmalardaki örneklem büyüklüğü ile örtüşmektedir.

Bu çalışmanın bilgi tabanı Gazi Hastanesi Çocuk Ruh Sağlığı ve Hastalıkları Anabilim Dalından alınan 450 adet kliniksel hasta verileri ile sınırlıdır. Ayrıca, niteliklerin belirlenmesi süreci aynı Anabilim Dalında görev yapan 2 ve Özel Eğitim Bölümünde görev yapan 1 olmak üzere toplam 3 alan uzmanı ile sınırlıdır.

3.3.2. Yazılımın geliştirilmesinde kullanılan araç/ gereçlerin analizi

Yazılım, Microsoft Visual Studio 2012 C#.Net kullanılarak geliştirilmiştir. Veri tabanı tasarımı için, ilişkiyel veri tabanı modeline uygun olan MSSQL 2005 veri tabanı kullanılmıştır. Veri tabanı tasarımı, veri temizleme, eksik değer problemi çözme ve veri dönüştürme işlemlerinde kullanılan SQL komutları için, SQL Server Management Studio

Express programından yararlanılmıştır. Bilgi tabanında yer alan veriler, ilk önce WEKA programında veri önışleme basamakları gerçekleştirilmiştir. Daha sonra WEKA programında, tüm sınıflandırma algoritmaları uygulanmış, en iyi sonuç veren algoritmalar C# programlama dilinde kodlanarak, bu problemin çözümüne yönelik özelleştirilmiş bir yazılım gerçekleştirilmiştir.

3.4. Tasarım

Tasarım; bu aşamada kararlar verilir, seçimler yapılır, örneğin yazılımın ekranları, ekranlarda neler bulunacağı, hangi ekranlara nasıl geçileceği, fonksiyonel olarak hangi adımların oluşturulacağı, hatta yazılımın bileşenleri ve modülleri bu aşamada tasarlanır. Bir sonraki adım olan geliştirmeye bütün kararlar verilmiş olarak geçilmesi beklenir. Geliştirme aşamasında herhangi bir soru veya karar bırakılmaz [273].

Çalışmada geliştirilen yazılımın ekranları, ekranda bulunması gereken nesnelerin seçimi, ekranlar arası bağlantıların, yazılımın modüllerinin, bilgi tabanının, eğitim ve test verilerinin nasıl oluşturulacağı işlemlerine karar verilmesi ve tasarlanması bu aşamada yapılmıştır. Kısaca yazılımın tüm ihtiyaçlarını karşılayacak detaylı bir çalışmanın yapılması tasarım basamağında gerçekleştirilmiştir.

3.4.1. Bilgi tabanı tasarımı

Çalışmanın bilgi tabanı tasarımında veri önışleme işlemi yapılmıştır. Veri tabanını tasarımı, verileri temizleme, eksik değer problemini çözme, verileri birleştirme, verileri dönüştürme ve verileri azaltma işlemleri için SQL komutları kullanılmıştır.

3.4.2. Verinin eğitim ve test kümesine ayrılması

Sınıflandırma algoritmalarının doğruluk oranları karşılaştırılır iken bilgi tabanındaki veriler eğitim verileri ve test verileri olmak üzere iki gruba ayrılmıştır. Eğitim veri seti ve test veri seti oluşturulurken holdout yöntemi kullanılmıştır.

Holdout yönteminde, belli sayıda örnek test veri seti için ayrılır, geriye kalan örnekler eğitim veri seti olarak kullanılır. Model eğitim veri seti kullanılarak oluşturulur ve test veri seti kullanılarak model değerlendirilir. Eğer veri dağılımı dengeli ise, veri setindeki örnek sayısı ve her sınıfa ait örnek sayısı fazla ise holdout yöntemi kullanılabilir [194]. Bu tez çalışmasında verilerin %80'i eğitim verisi ve %20'si test verisi olarak belirlenmiştir. Veri kümesinde bulunan 450 kayıttan 360 tanesi eğitim veri seti, 90 tanesi test veri seti olarak kullanılmıştır. Test veri seti rastsal olarak belirlenmiş, veri kümesi içerisinde her 5 kayıttan bir tanesi test verisi olarak kabul edilmiştir. Test verisindeki 90 adet kayıttan 50 tanesi “DEHB olmayan” sınıfına ait iken 40 tanesi “DEHB” sınıfına aittir. Veri kümesindeki veri dağılımı dengeli ve her sınıfa ait örnek sayısının fazla olması nedeni ile test verisindeki her sınıfa ait örnek sayısının yaklaşık olarak dengeli olduğu görülmektedir.

3. 5. Geliştirme

Geliştirme; yazılımın kodlanması aşamasıdır. Yazılım geliştirme ortamı, programlama dili, veri tabanı yönetim sistemi, yazılım geliştirme araçları seçimi kodlama aşamasında gerçekleştirilir [260]. Bu aşamada makine öğrenmesi algoritmaları kullanılarak DEHB'nin tahmin edilmesine yönelik C# programı kullanılarak bir uzman sistem geliştirilmiştir. Geliştirilen bu yazılım; bilgi tabanı oluşturma, verilerin görüntülenmesi, çıkarım mekanizması ve açıklama birimi olmak üzere dört alt bileşenden oluşmaktadır. Bu basamakta kullanılacak özellikler ve kodlanacak algoritmalar seçilmiştir.

3.5.1. Kullanılan sınıflandırma algoritmasının seçimi

Kullanılan sınıflandırma algoritmasının seçiminde, literatürde en çok kullanılan sınıflandırma algoritmaları model başarımları ölçütlerine göre karşılaştırılmıştır. Bu ölçütlere göre performansı en yüksek olan algoritma, %95,55 doğruluk oranı ile Naive Bayes algoritmasıdır. Bu nedenle model başarımları ölçütlerinin sonuçları ışığında uzman sistemin çıkarım mekanizmasında Naive Bayes algoritmasının kodlanmasına karar verilmiştir. Ayrıca Naive Bayes algoritması ile birlikte k-NN algoritması da kodlanarak sisteme eklenmiştir. Bu sayede geliştirilen sistem ile uzman yetki düzeyinde bulunan kullanıcıya isterse algoritmaları kullanarak sonuçlarını karşılaştırabilme fırsatı verilmektedir.

3. 6. Test ve Entegrasyon

Test; yazılımın kodlanması sürecinden sonra doğrulama ve sağlama yani test aşaması gerçekleştirilir. Geliştirilen yazılımın hem belirlenen gereksinimleri sağlayıp sağlamadığı hem de gerçekleştirimin planlanana uygun olup olmadığının kontrol etmek için yapılan çalışmadır [274]. Test, yazılımın gerçek hayata geçtiği aşamadır [275]. Bu aşamada, test verisi ile modelin değerlendirilmesi yapılmaktadır. Geliştirilen yazılımda test verileri listelenmekte, test veri setinde yer alan veriler girilerek algoritmaların başarısı kontrol edilebilmektedir.

3.6.1. Sistemin değerlendirilmesi

Geliştirilen modelin başarısı, doğru ve yanlış sınıfa atılan örnek sayıları ile alakalıdır. Test sonucunda ulaşılan sonuçların başarımları bilgileri karışıklık matrisi ile ifade edilmektedir. Sistemin performansı değerlendirilirken karışıklık matrisinden elde edilen bu sayılarla çeşitli ölçütler (model başarımları ölçütleri) hesaplanmaktadır. Kullanılan en temel model başarımları ölçütleri; doğruluk, duyarlılık, kesinlik ve f ölçütüdür [199, 213, 276].

$$\text{Doğruluk (Accuracy)} = (TP + TN) / (TP + FN + FP + TN) \quad (3.1)$$

$$\text{Duyarlılık (Recall)} = TP / (TP + FN) \quad (3.2)$$

$$\text{Kesinlik (Precision)} = TP / (TP + FP) \quad (3.3)$$

$$\text{F-ölçütü (F-measure)} = 2 * \text{Duyarlılık} * \text{Kesinlik} / (\text{Duyarlılık} + \text{Kesinlik}) \quad (3.4)$$

$$\text{TP oranı (TP rate)} = TP / (TP + FN) \quad (3.5)$$

$$\text{FP oranı (FP rate)} = FP / (TN + FP) \quad (3.6)$$

TP ve TN ile gösterilen sayılar sınıfları doğru tahmin edilen, FP ve FN ile gösterilen sayılar ise sınıfları yanlış tahmin edilen örneklerin sayılarını göstermektedir [200]. Geliştirilen modelin başarısı değerlendirilirken doğruluk, duyarlılık, kesinlik ve f ölçütlerinin dışında, ayrıca ROC area ve kappa istatistiği değerleri de ölçüt olarak

kullanılmaktadır. Roc area ve kappa istatistiği değerlerinin 1'e yakın olması sistemin başarısının yüksek olduğunu gösterir [167].

Bu tez çalışmasında bu ölçütler ışığında, sistemin performansının doğrulanması (onaylanması) ayrılan eğitim veri kümesi üzerinde (360 adet kayıt) k-kat çapraz geçerleme yöntemi ile yapılmaktadır. K-kat çapraz geçerleme tekniği; birkaç bin veya daha az satırdan meydana gelen veri tabanlarında, verilerin k gruba ayrıldığı k katlı çapraz geçerlilik yöntemi kullanılabilir. Veri seti rastgele k adet gruba ayrılır. K-kat çapraz geçerleme yönteminde, ilk aşamada birinci grup test, diğer gruplar öğrenim için kullanılır. Literatürü incelediğimizde, genellikle k değerinin 10 olarak seçildiği görülmektedir. Bu nedenle bu çalışmada da k-kat çapraz geçerleme tekniğindeki k değeri 10 olarak belirlenmiştir. Bu süreç her defasında bir grubun test, diğer grupların öğrenim amaçlı kullanılması ile sürdürülür. Sonuçta elde edilen on hata oranının ortalaması, kurulan modelin tahmini hata oranı olacaktır [167].

Tez çalışmasında sistemin performansı ilk önce 10-kat çapraz geçerleme yöntemi ile doğrulanmaktadır. Daha sonra geliştirilen sistem eğitim verileri (360 adet kayıt) ile eğitilirken bağımsız bir test verisi ile (90 adet kayıt) sistemin performansı test edilmektedir.

3. 7. İdame ve Bakım

Bu aşamada proje artık yaşayan bir yazılım haline gelir. Yazılım kullanılır ve problemler ortaya çıkar. Problemlere karşılık yeni fikirler ortaya çıkar, yeni ihtiyaçlar oraya çıkar ve bunlar değerlendirilmeye alınır. Bu değerlendirmeler sonrasında bakım aşamasına geçilir [275]. Bu kısımda ise geliştirilen uzman sistem kullanılarak ortaya çıkan problemler belirlenmiştir. Problemin çözümüne yönelik değerlendirmeler sonrasında bakım aşamasına geçilmiştir.

Bakım; yazılımın tesliminden sonra hata giderme ve yeni eklentiler yapma aşamasıdır. Yazılımın kullanıma başlanmasından sonra yazılımın desteklenmesi sürecini kapsar. Yazılımın eksiklerinin giderilmesi, iyileştirilmesi gibi alt aşamaları içeren aşamadır [260]. Çalışmada çocuk psikiyatristlerinin ve son kullanıcıların görüşleri doğrultusunda geliştirilen yazılım güncellenmiştir.




4. DEHB’NİN TAHMİN EDİLMESİNE YÖNELİK GELİŞTİRİLEN UZMAN SİSTEM BİLEŞENLERİ VE BULGULAR

DEHB’nin tahmin edilmesine yönelik geliştirilen sistemin çalışma süreci ve uzman sistem uygulama adımları aşağıda verilmiştir.

4.1. Sistemin Uygulama Süreci Adımları

DEHB’nin öngörülmesine yönelik geliştirilen dinamik uzman sistemin uygulama süreci adımları Şekil 4.1’de verilmiştir:





Şekil 4.1. Geliştirilen uzman sistemin genel yapısının akış şeması

4.2. Sistemin Bilgi Tabanının Oluşturulması

4.2.1. Veri kümelerinin oluşturulması

Geliştirilen uzman sistem DEHB öngörülmesine yönelik çocuk psikiyatristinin rolünü sanal olarak taklit etmektedir. Alan uzmanları;

- a. Çocuklarda görülen dikkat eksikliği, hiperaktivite ve davranım sorunlarını ölçen Conners Ebeveyn Derecelendirme Ölçeğinden (CADÖ-48),
- b. Conners Öğretmen Derecelendirme Ölçeğinden (CÖDÖ-28) ve
- c. Aile ve çocuk ile yapılan bireysel görüşmelerden elde edilen bilgileri analiz ederek DEHB tanısına karar vermektedir.

Çalışmada DEHB'nin öngörülmesine yönelik kullanılan nitelikler alan uzmanları tarafından APA'nın 2013 yılında yayımladığı DSM-V kılavuzundan elde edilen güncel bilgilerin analiz edilmesi sonucu belirlenmiştir. Alan uzmanının aile ve çocuk ile yaptığı bireysel görüşmede sorduğu sorular, izlem kriterleri ve ölçeklerden alınan puanlar kaydedilmiştir. Alan uzmanları tarafından toplamda DEHB'nin tahmin edilmesine yönelik; aile ve çocuk ile yapılan görüşmeler ve izlem kriterleri sonucunda 21 tane, ebeveyn tarafından doldurulan CADÖ-48 sonucunda elde edilen çocuğun dikkat eksikliği ve hiperaktivite puanları 2 tane ve öğretmen tarafından doldurulan CÖDÖ-28 ölçekleri sonucunda elde edilen çocuğun dikkat eksikliği ve hiperaktivite puanları 2 tane olmak üzere 25 nitelik oluşturulmuştur. Ayrıca bu niteliklere ait literatür incelemesi yapılmıştır.

Bu kapsamda bozukluğun tanısına yönelik alan uzmanlarının karmaşık ve deneyim gerektiren bu karar verme süreci geliştirilen uzman sisteme aktarılmıştır. Bu nitelikler, alabileceği değerler ve niteliklere ait referanslar Çizelge 4. 1'de verilmiştir:

Çizelge 4.1. Nitelikler, alabileceği değerler ve referanslar

Nitelikler	Nitelik Adı	Alabileceği Değerler
1. Cinsiyet [65, 75, 277-279]	<i>Gender</i>	Kız, Erkek
2. Ailenin kaçınıcı çocuğu [280-283]	<i>Birthsequence</i>	1,2,3...,- ...,10, 11 ve üzeri
3. Annenin doğum sırasındaki yaşı [284-287]	<i>Mage</i>	- 18 yaş ve altı, - 19 - 25 yaş arası, - 26 - 30 yaş arası, - 31 - 35 yaş arası, - 36 – 40 yaş arası, - 41 yaş ve üstü
4. Ailede hastalık öyküsü [9, 288-290]	<i>Fdisease</i>	Var, Yok
5. Ailede ruhsal bozukluk öyküsü [72, 291-292]	<i>Fmentaldisorder</i>	Var, Yok
6. Gebelikte sigara kullanımı [56, 293-295]	<i>Msmoking</i>	Var, Yok
7. Erken doğum öyküsü [72, 283, 296-297]	<i>Premature</i>	Var, Yok
8. Gebelikte alkol kullanımı [294, 298-300]	<i>Malcohol</i>	Var, Yok
9. Gebelikte ilaç kullanımı [291, 301-303]	<i>Mdrug</i>	Var, Yok
10.Zorlu doğum öyküsü [283, 285, 304-305]	<i>Thoughbirth</i>	Var, Yok
11.Annenin gebelik süreci [290, 292, 305, 306]	<i>Pregnancyprocess</i>	Normal, Sıkıntılı
12.Annenin gebelikte hastalık öyküsü [307-308]	<i>Mdisease</i>	Var, Yok
13.Annenin gebelikte ruhsal bozukluk öyküsü [291-292]	<i>Mmentaldisorder</i>	Var, Yok
14.Doğum ağırlığı [309-312]	<i>Birthweight</i>	- 2500 kg altı, - 2500 kg - 4500 kg arası, - 4500 kg üstü
15.Okuma yazmayı öğrenme zamanı [46, 56, 313-314]	<i>Readwrite</i>	- 1.sınıf 1.dönemden önce, - 1.sınıf 1.dönem, - 1.sınıf 1.dönemden sonra
16.Sınıf tekrarı yapıp yapmama durumu [46, 56, 313-314]	<i>Repetition</i>	Evet, Hayır
17.Şikâyetlerin birden fazla ortamda gözlenip gözlenmediği [1]	<i>Cenvironment</i>	Şikâyet yok, Evet, Hayır
18.Çocuktaki şikâyetler ne kadar zamandır var [1]	<i>Clong</i>	- Şikâyet yok, - 6 aydan daha kısa süre, - 6 ay ve daha uzun süre,

Çizelge 4.1. (devam) Nitelikler ve alabileceği değerler

Nitelikler	Nitelik Adı	Alabileceği Değerler
19.Ders başarı durumu [46, 56, 313-314]	<i>Success</i>	- Düşük (0-49), - Orta (50-69), - İyi (70-84), - Çok iyi (85-100)
20.Öğretmenden gelen olumsuz dönüt bilgisi [315-316]	<i>Pcomplait</i>	- Şikâyet yok, - Az, - Orta, - Fazla, - Çok Fazla
21.Ebeveynden gelen olumsuz dönüt bilgisi [315-316]	<i>Tcomplait</i>	- Şikâyet yok, - Az, - Orta, - Fazla, - Çok Fazla
22.Ebeveyn dikkat eksikliği puanı	<i>Pattentionscore</i>	Conners Ebeveyn Değerlendirme ölçeğine göre alınan puanlar
23.Ebeveyn hiperaktivite puanı	<i>Phyperactivityscore</i>	
24.Öğretmen dikkat eksikliği puanı	<i>Tattentionscore</i>	Conners Öğretmen Değerlendirme ölçeğine göre alınan puanlar
25.Öğretmen hiperaktivite puanı	<i>Thyperactivityscore</i>	
Sınıf Bilgisi	<i>Class</i>	DEHB, DEHB olmayan

Bilgi tabanında yer alan nitelikler; alan uzmanlarının kullandıkları DEHB tanı kriterlerini içermekte, kayıtlar ise DEHB tanısı alan ve almayan kliniksel hasta verilerinden oluşmaktadır. Hasta verilerinin tutulduğu standart bir veri tabanının olmaması nedeni ile gerçek uygulamalarda her zaman olduğu gibi DEHB bilgi tabanı içinde de eksik, gürültülü ve tutarsız kayıtların olduğu tespit edilmiştir. Bu nedenle alan uzmanlarının belirlediği niteliklere göre toplanan veriler üzerinde makine öğrenmesi uygulama süreci adımlarından veri ön işleme adımları çalıştırılmıştır.

4.2.2. Veri ön işleme basamakları

Geliştirilen yazılımın verimliliğini artırmak ve işlemleri kolaylaştırmak için eksik ve gürültülü veriler üzerinde veri ön işleme uygulanarak gerekli düzeltme işlemleri yapılmıştır. Veri temizleme ve veri dönüştürme işlemlerinde SQL Server Management Studio Express programı kullanılmıştır.

Çalışmada, veri ön işleme basamağında yapılan işlemler dört aşamadan oluşmaktadır:

1. Veri temizleme:

Veri temizleme aşamasında; DEHB veri kümesinde bazı hasta dosyalarının eksik bilgi içermesi nedeniyle ailenin kaçınıcı çocuğu olduğu bilgisi ve annenin doğum sırasındaki yaşı niteliklerine ait eksik değerlerin olduğu görülmüştür. Bu kategorik verilerdeki eksik verilerin sayısı çok fazla olmadığından, tüm kayıt silinmemiş ve aşağıdaki örnek komutlarda belirtildiği gibi “nullvalue” isimli genel bir değerle doldurulmuştur.

- ***Update adhdckbase set Birthsequence=' nullvalue' where Birthsequence is null;***
- ***Update adhdckbase set Mage =' nullvalue' where Mage is null;***

Bazı hasta kayıtlarında ise Conners DEHB Öğretmen Derecelendirme Ölçeği ve Conners DEHB Ebeveyn Derecelendirme Ölçeği doldurulmamıştır. Bu nedenle bu kayıtlarda bu ölçeklerden alınan dikkatsizlik ve hiperaktivite puanları bulunmamaktadır. *Thyperactivityscore* ve *Tattentionscore* niteliği boş olan 2 kayıt, *Phyperactivityscore* ve *Pattentionscore* niteliği boş olan 3 kayıt için, aşağıdaki komutlarda belirtildiği gibi bu alanların ortalaması alınarak düzeltme işlemi yapılmıştır.

- ***Update adhdckbase set Thyperactivityscore = (Select AVG (Thyperactivityscore) from adhdckbase where Thyperactivityscore is not null) where Thyperactivityscore is null;***
- ***Update adhdckbase set Phyperactivityscore = (Select AVG (Phyperactivityscore) from adhdckbase where Phyperactivityscore is not null) where Phyperactivityscore is null ;***
- ***Update adhdckbase set Tattentionscore = (Select AVG (Tattentionscore) from adhdckbase where Tattentionscore is not null) where Tattentionscore is null;***
- ***Update adhdckbase set Pattentionscore = (Select AVG (Pattentionscore) from adhdckbase where Pattentionscore is not null) where Pattentionscore is null;***

2. Veri birleştirme:

Veri birleştirme, birçok farklı kaynaktan gelen verilerin toplanması işlemidir. Birden fazla farklı formattaki veri kaynaklarının birleştirilmesi şema birleştirme hatasına neden olmaktadır. Bir veri kaynağında yer alan yaş bilgisi diğer veri tabanında doğum yılı olarak girilmiş olabilir. Aynı türde veriler birleştirilirken meta datalar dikkate alınmalıdır. Meta datalar özelliğin adını, barındırdığı verinin formatını, verinin kullanım alanıyla ilgili bilgiyi, veri girilmemesi durumunda uygulanacak olan kuralı ve veri giriş aralığını

açıklayan yapılardır [122, 269]. Bu nedenle, geliştirilen yazılım kullanılarak hasta dosyalarından, alan uzmanı izlem formundan, Conners ebeveyn ve öğretmen derecelendirme ölçeğinden alınan veriler tek bir veri tabanında birleştirilmiş ve artık veriler kaldırılmıştır.

3. Veri dönüştürme:

Naive Bayes algoritması genellikle kategorik veriler ile çalışırken KNN algoritması sayısal veriler ile çalışmaktadır. Veri dönüştürme aşamasında, algoritmaların çalışma prensibine göre tüm veriler üzerinde dönüştürme işlemi yapılmıştır. Bu aşamada elde edilen dönüştürmelerden örnekler aşağıda verilmiştir:

- ***Update adhdckbase set Success = '4' where Success <=100 and Success>=85***
- ***Update adhdckbase set Success = '3' where Success <=84 and Success>=70***
- ***Update adhdckbase set Success = '2' where Success <=69 and Success>=50***
- ***Update adhdckbase set Success = '1' where Success <=49 and Success>=0***

- ***Update adhdckbase set Gender = '1' where Gender = 'Kız'***
- ***Update adhdckbase set Gender = '2' where Gender = 'Erkek'***

- ***Update adhdckbase set Phyperactivityscore = '1' where Phyperactivityscore < 6***
- ***Update adhdckbase set Phyperactivityscore = '2' where Phyperactivityscore >= 6***

- ***Update adhdckbase set Birthsequence = '1' where Birthsequence = 1***
- ***Update adhdckbase set Birthsequence = '2' where Birthsequence >1***

- ***Update adhdckbase set Mage = '6' where Mage >=41***
- ***Update adhdckbase set Mage = '5' where Mage <=40 and Mage >=36***
- ***Update adhdckbase set Mage = '4' where Mage <=35 and Mage >=31***
- ***Update adhdckbase set Mage = '3' where Mage <=30 and Mage >=26***
- ***Update adhdckbase set Mage = '2' where Mage <=25 and Mage >=19***
- ***Update adhdckbase set Mage = '1' where Mage <=18***

- **Update** *adhdckbase* **set** *Birthweight* ='3' **where** *Birthweight* >4500
- **Update** *adhdckbase* **set** *Birthweight* ='2' **where** *Birthweight* <=4500 and *Birthweight*>2500
- **Update** *adhdckbase* **set** *Birthweight* ='1' **where** *Birthweight* <=2500

- **Update** *adhdckbase* **set** *Fdisease* ='1' **where** *Fdisease* ='Var'
- **Update** *adhdckbase* **set** *Fdisease* ='2' **where** *Fdisease* ='Yok'

- **Update** *adhdckbase* **set** *Msmoking* ='1' **where** *Msmoking* ='Var'
- **Update** *adhdckbase* **set** *Msmoking* ='2' **where** *Msmoking* ='Yok'

Yapılan veri dönüştürme işleminden sonra nitelikler ve aldığı değerler Çizelge 4.2’de verilmiştir. Veri dönüştürmede elde edilen bu yeni değerler; kodlama kısmında Naive Bayes algoritması için kategorik veri olarak kullanılırken KNN algoritması için sayısal veri olarak kullanılmıştır.

Çizelge 4.2. Veri dönüşümü sonrasında nitelikler ve aldığı yeni değerler

Nitelik Adı	Dönüşümler
<i>Gender</i>	- Kız = 1, - Erkek=2
<i>Birthsequence</i>	- 1 = 1, - 2,3...,- ...,10, 11 ve üzeri = 2
<i>Mage</i>	-18 yaş ve altı = 1, -19- 25 yaş arası = 2, -26- 30 yaş arası = 3, -31- 35 yaş arası = 4, -36 – 40 yaş arası = 5, -41 yaş ve üstü = 6
<i>Fdisease</i>	- Var = 1, - Yok = 2
<i>Fmentaldisorder</i>	- Var = 1, - Yok = 2
<i>Msmoking</i>	- Var = 1, - Yok = 2
<i>Premature</i>	- Var = 1, - Yok = 2
<i>Malcohol</i>	- Var = 1, - Yok = 2

Çizelge 4.2. (devam) Veri dönüşümü sonrasında nitelikler ve aldığı yeni değerler

Nitelik Adı	Dönüşümler
<i>Mdrug</i>	- Var = 1, - Yok = 2
<i>Thoughbirth</i>	- Var = 1, - Yok = 2
<i>Pregnancyprocess</i>	- Normal = 1, - Sıkıntılı = 2
<i>Mdisease</i>	- Var = 1, - Yok = 2
<i>Mmentaldisorder</i>	- Var = 1, - Yok = 2
<i>Birthweight</i>	- 2500 kg altı = 1, - 2500 kg- 4500 kg arası = 2, - 4500 kg üstü = 3
<i>Readwrite</i>	- 1.sınıf 1.dönemden önce = 1, - 1.sınıf 1.dönem = 2, - 1.sınıf 1.dönemden sonra = 3
<i>Repetition</i>	- Evet = 1, - Hayır = 2
<i>Cenvironment</i>	- Şikâyet yok = 1, - Evet = 2, - Hayır = 3
<i>Clong</i>	- Şikâyet yok = 1, - 6 aydan daha kısa süre = 2, - 6 ay ve daha uzun süre = 3
<i>Success</i>	- Düşük (0-49) = 1, - Orta (50-69) = 2, - İyi (70-84) = 3, - Çok iyi (85-100) = 4
<i>Pcomplait</i>	- Şikâyet yok = 1, - Az = 2, - Orta = 3, - Fazla = 4, - Çok Fazla = 5
<i>Tcomplait</i>	- Şikâyet yok = 1, - Az = 2, - Orta = 3, - Fazla = 4, - Çok Fazla = 5
<i>Pattentionscore</i>	Conners Ebeveyn Değerlendirme ölçeğine göre alınan puanların kesme puanının [317] altında olup olmadığı
<i>Phyperactivityscore</i>	
<i>Tattentionscore</i>	Conners Öğretmen Değerlendirme ölçeğine göre alınan puanların kesme puanının [317] altında olup olmadığı
<i>Thyperactivityscore</i>	
<i>Class</i>	DEHB, DEHB olmayan

4. Veri azaltma:

Veri azaltma aşamasında, sınıflandırma algoritmaları için anlam ifade etmeyen adı soyadı, boy, kilo ve sosyoekonomik düzey alanları veri kümesinden çıkartılmıştır.

- ***Alter Table adhdckbase Drop Column Pname;***
- ***Alter Table adhdckbase Drop Column Weight;***
- ***Alter Table adhdckbase Drop Column Height;***
- ***Alter Table adhdckbase Drop Column Income;***

4.2.3. Bilgi tabanında bulunan veri kümesinin sınıflara göre genel dağılımı

Bilgi tabanında yer alan niteliklere ait kayıtların sınıflara (DEHB ve DEHB olmayan) göre dağılımları veri kümesinin karakteristiğini göstermektedir. Bu nedenle Çizelge 4.3.'de tüm niteliklerin sınıflara göre dağılımları ve Şekil 4.2.'de niteliklere ait histogramlar verilmiştir. Veri önileme aşamasında kategorik verilerdeki eksik değerlerin bulunduğu kayıt silinmemiş ve "nullvalue" isimli genel bir değerle doldurulmuştur. Çizelge 4.3.'de görülen "nullvalue" isimli değer, veri önileme basamağında o kayıttaki bulunan eksik değerlerin genel bir değerle doldurulmuş olduğunu göstermektedir.

Çizelge 4.3. Niteliklerin sınıflara göre dağılımı

Nitelikler	Niteliklerin Alabileceği Değerler	DEHB	DEHB olmayan	Toplam
1. Cinsiyet	Kız	50	134	184
	Erkek	150	116	266
2. Ailenin kaçınıcı çocuğu	İlk	99	101	200
	Diğer	85	125	210
	nullvalue	16	24	40
3. Annenin doğum sırasındaki yaşı	18 yaş ve altı	5	9	14
	19- 25 yaş arası	90	97	187
	26- 30 yaş arası	44	65	109
	31- 35 yaş arası	27	31	58
	36 – 40 yaş arası	11	14	25

Çizelge 4.3. (devam) Niteliklerin sınıflara göre dağılımı


Nitelikler	Niteliklerin Alabileceği Değerler	DEHB	DEHB olmayan	Toplam
3. Annenin doğum sırasındaki yaşı	41 yaş ve üstü	2	1	3
	nullvalue	21	33	54
4. Ailede hastalık öyküsü	Var	38	19	57
	Yok	162	231	393
5. Ailede ruhsal bozukluk öyküsü	Var	34	6	40
	Yok	166	244	410
6. Gebelikte sigara kullanımı	Var	38	17	55
	Yok	162	233	395
7. Erken doğum öyküsü	Var	32	23	55
	Yok	168	227	395
8. Gebelikte alkol kullanımı	Var	14	3	17
	Yok	186	247	433
9. Gebelikte ilaç kullanımı	Var	38	23	61
	Yok	162	227	389
10. Zorlu doğum öyküsü	Var	33	32	65
	Yok	167	218	385
11. Annenin gebelik süreci	Normal	166	216	382
	Sıkıntılı	34	34	68
12. Annenin gebelikte hastalık öyküsü	Var	33	22	55
	Yok	167	228	395
13. Annenin gebelikte ruhsal bozukluk öyküsü	Var	16	4	20
	Yok	184	246	430
14. Doğum ağırlığı	2500 kg altı	32	23	55
	2500 kg - 4500 kg arası	165	224	389
	4500 kg üstü	3	3	6

Çizelge 4.3. (devam) Niteliklerin sınıflara göre dağılımı

Nitelikler	Niteliklerin Alabileceği Değerler	DEHB	DEHB olmayan	Toplam
15. Okuma yazmayı öğrenme zamanı	1.sınıf 1.dönemden önce	49	71	120
	1.sınıf 1.dönem	114	178	292
	1.sınıf 1.dönemden sonra	37	1	38
16. Sınıf tekrarı yapıp yapmama durumu	Evet	13	2	15
	Hayır	187	248	435
17. Şikâyetlerin birden fazla ortamda gözlenip gözlenmediği	Şikâyet yok	22	225	247
	Evet	145	11	156
	Hayır	33	14	47
18. Çocuktaki şikâyetler ne kadar zamandır var	Şikâyet yok	22	225	247
	6 aydan daha kısa süre	114	2	116
	6 ay ve daha uzun süre	64	23	87
19. Ders başarı durumu	Düşük (0-49),	28	1	29
	Orta (50-69),	83	40	123
	İyi (70-84),	55	83	138
	Çok iyi (85-100)	34	126	160
20. Öğretmenden gelen olumsuz dönüt bilgisi	Şikâyet yok	42	239	281
	Az	36	9	45
	Orta	63	2	65
	Fazla	46	0	46
	Çok Fazla	13	0	13
21. Ebeveynden gelen olumsuz dönüt bilgisi	Şikâyet yok	27	229	256
	Az	24	15	39
	Orta	94	4	98
	Fazla	42	1	43
	Çok Fazla	13	1	14
22. Ebeveyn dikkat eksikliği puanı	Kesme puanının [317] altı	52	215	267
	Kesme puanı ve üstü	148	35	183

Çizelge 4.3. (devam) Niteliklerin sınıflara göre dağılımı				
Nitelikler	Niteliklerin Alabileceği Değerler	DEHB	DEHB olmayan	Toplam
23. Ebeveyn hiperaktivite puanı	Kesme puanının altı	60	165	225
	Kesme puanı ve üstü	140	85	225
24. Öğretmen dikkat eksikliği puanı	Kesme puanının altı	25	206	231
	Kesme puanı ve üstü	175	44	219
25. Öğretmen hiperaktivite puanı	Kesme puanının altı	29	199	228
	Kesme puanı ve üstü	171	51	222
Sınıf bilgisi	DEHB	200	250	450
	DEHB olmayan			

Şekil 4.2.' de tüm veri kümesinde her biri ayrı niteliğe ait olmak üzere 25 adet grafik ve 1 adet sınıf bilgisine ait grafik olmak üzere toplamda 26 adet grafik görülmektedir. Yatay ekseninde sınıf sınırları, dikey ekseninde sınıf frekansları işaretlenmiştir. Taban uzunluğu sınıf genişliğine, yüksekliği sınıf frekansına karşılık gelen ve üst üste bindirilmiş dikdörtgenler çizilmiştir. Burada mavi renk “DEHB olmayan” sınıfını (250), kırmızı renk ise “DEHB” sınıfını (200) temsil etmektedir.



Şekil 4.2. Tüm veri kümesine ait niteliklerin genel dağılımı

Şekil 4.3.' de DEHB sınıfı bilgisine ait 1 adet ve her biri ayrı niteliğe ait olmak üzere 25 adet toplamda 26 adet grafik görülmektedir.



Şekil 4.3. DEHB sınıfına ait veri kümesindeki niteliklerin genel dağılımı

Şekil 4.4.’ de “DEHB olmayan” sınıf bilgisine ait 1 adet ve her biri ayrı niteliğe ait olmak üzere 25 adet toplamda 26 adet grafik görülmektedir.




Şekil 4.4. DEHB olmayan sınıfına ait veri kümesindeki niteliklerin genel dağılımı

Sistemin bilgi tabanının oluşturulması sürecinde alan uzmanlarının rehberliği doğrultusunda nitelikler oluşturulmuş ve bu niteliklere ait kayıtlar toplanmış, bu kayıtlar üzerinde veri ön işleme adımları çalıştırılmıştır.

4.3. Sistemin kullanıcı yetki düzeyleri

Çocukta DEHB durumunun olup olmadığının öngörülmesi amacıyla çocuk psikiyatristlerinin alan uzmanlığı doğrultusunda geliştirilen uzman sistem; aileler, rehber veya sınıf öğretmenleri ve alan uzmanı olmak üzere ayrı yetki düzeylerine sahip üç kullanıcı tipi tarafından kullanılabilir. Şekil 4.5’de kullanıcı tipine göre yetki düzeyleri ve kullanım amaçları verilmiştir:



Şekil 4.5. Sistemde kullanıcı tipine göre yetki düzeyleri ve kullanım amaçları

Geliştirilen uzman sistemin kullanıcı yetki düzeyine göre bileşenleri aşağıda listelenmiştir;

Uzman yetki düzeyi:

- Bilgi tabanına kayıt girilmesi,
- Bilgi tabanında kayıt görüntüleme/silme/güncelleme,
- Bilgi tabanında yer alan niteliklerin ve kayıtların yazdırılması,
- Bilgi tabanında yer alan niteliklerin ve kayıtların Excel platformuna aktarılabilmesi,
- Çocukta DEHB durumunun olup olmadığına yönelik sistemin tahmin sonucu,
- Yardım

Ebeveyn yetki düzeyi:

- Çocukta DEHB durumunun olup olmadığına yönelik sistemin tahmin sonucu,
- Yardım

Öğretmen yetki düzeyi:

- Çocukta DEHB durumunun olup olmadığına yönelik sistemin tahmin sonucu,

- Yardım

Sistemde hem İngilizce hem de Türkçe dil desteği bulunmaktadır. Yetki düzeylerine göre giriş yapılan sistemin açılış ekranı Resim 4.1’de gösterilmiştir:

Resim 4.1. Giriş formu ekranı

4.4. Ebeveyn kullanıcı yetki düzeyi ve sistem başarımları testi

4.4.1. Bilgi tabanı

Ebeveyn kullanıcı yetki düzeyinde bilgi tabanı; alan uzmanları tarafından toplamda DEHB’nin tahmin edilmesine yönelik; aile ve çocuk ile yapılan görüşmeler ve izlem kriterleri sonucunda elde edilen 21 tane nitelik ve ebeveyn tarafından doldurulan CADÖ-48 sonucunda elde edilen çocuğun dikkat eksikliği ve hiperaktivite puanlarını içeren 2 tane nitelik olmak üzere 23 adet nitelik bilgisini içermektedir.

CÖDÖ-28 ölçeğini çocuğun öğretmeni doldurmaktadır. Bu nedenle “ebeveyn” yetki düzeyinde bulunan kullanıcının, bu ölçekten elde edilen çocuğun hiperaktivite ve dikkat eksikliğine ait niteliklere (24.nitelik Tattentionscore ve 25. nitelik Thyperactivityscore) erişim imkânının çok kısıtlı olduğu düşünülerek ebeveyn arayüzünde 23 nitelik ve 1 sınıf bilgisi kullanarak tahmin edebilecek şekilde sistem geliştirilmiştir. Sonuç olarak ebeveyn yetki düzeyinin bilgi tabanı; 450 kayıt, 23 nitelik ve 1 sınıf bilgisinden oluşmaktadır.

4.4.2. Çıkarım mekanizması

Kullanıcı “Ebeveyn” butonuna tıkladığında çocukta DEHB olup olmadığına yönelik sistemin tahmini sonucunu görebildiği çıkarım mekanizması formu gelmektedir. Bu formda alınan bilgiler çocuk psikiyatristlerinin DEHB tanısı koyarken izledikleri karar verme sürecinde aile ve çocuk ile bireysel görüşmeden alınan ve ailenin doldurduğu CADÖ-48 ölçeğinden elde edilen bilgileri içermektedir. Ebeveyn çıkarım mekanizması formu adım adım Resim 4.2, Resim 4.3 ve Resim 4.4’de verilmiştir:

Ebeveyn Alınan Bilgiler / 1- Aile Bilgileri, Annenin Hamilelik Süreci ve Çocuğun Gelişimsel Öyküsü			
1-Cinsiyet	ERKEK	9- Gebelikte ilaç kullanımı	VAR
2-Ailenin kaçına çocuğu	4	10- Zorlu doğum öyküsü	VAR
3- Annenin doğum sırasındaki yaşı	19 - 25 yaş arası	11- Annenin gebelik süresi	SIKINTILI
4- Ailede hastalık öyküsü	YOK	12- Annenin gebelikte hastalık öyküsü	VAR
5- Ailede ruhsal bozukluk öyküsü	YOK	13- Annenin gebelikte ruhsal bozukluk öyküsü	YOK
6- Gebelikte sigara kullanımı	YOK	14- Çocuğun doğum ağırlığı	2500 ve 4500 kg arası
7- Erken doğum öyküsü	YOK	15- Okuma yazmayı öğrenme zamanı	1. sınıf
8- Gebelikte alkol kullanımı	VAR	16- Sınıf tekrarı yaptı mı?	EVET
		17- Şikâyetler birden fazla ortamda gözleniyor mu? (ev ve okul)	EVET
		18- Çocuktaki şikâyetler ne kadar zamandır var?	6 ay ve daha uzun süre
		19- Ders başarı durumu	Düşük (0 - 49)
		20- Ebeveynlerden gelen olumsuz dönüt bilgisi	FAZLA
		21- Öğretmenden gelen olumsuz dönüt bilgisi	AZ

İleri

Resim 4.2. Ebeveyn kullanıcı yetki düzeyi çıkarım mekanizması (Adım 1)

Ebeveyn çıkarım mekanizması formunda ilk olarak çocuk psikiyatristlerinin aile ve çocuk ile birebir görüşme esnasında sorguladıkları bilgiler bulunmaktadır.

Naive Bayes Algoritması / Ebeveyn Arayüzü

Ebeveyn Alınan Bilgiler

2- Conner's Ebeveyn Değerlendirme Ölçeği

Hiçbir zaman | Nadiren | Sıklıkla | Her zaman

1. Eli boş durmaz sürekli bir şeylerle oynar.	☐	☐	☒	☐	6. Yerde duramaz, her an harekete hazırdır.	☐	☐	☒	☐
2. Çabuk heyecanlanır, ataktır.	☐	☐	☐	☒	7. Yağtlarından farklı konuşur (çocuksu, kekeleme, zor anlaşılma)	☐	☐	☒	☐
3. Her şeye kanır ve her şeyi yönetmek ister.	☐	☐	☐	☒	8. Başladığı bir işi sonunu getiremez.	☐	☐	☐	☒
4. Bir şeyler çöner veya emer (parmak, giysi, örtü vb.)	☐	☐	☒	☐	9. Dikkati kolay dağılır ya da uzun süre toplayamaz.	☐	☐	☐	☒
5. Kır kırır, tez canlıdır.	☐	☐	☐	☒					

İleri

Resim 4.3. Ebeveyn kullanıcı yetki düzeyi çıkarım mekanizması (Adım 2)

Bu formun ikinci adımında, CADÖ-48 ölçeğindeki DEHB'e yönelik belirtileri içeren maddelere aile tarafından verilen cevaplar alınmaktadır. Bu maddeler değerlendirilmektedir.

Naive Bayes Algoritması / Ebeveyn Arayüzü

1-Cinsiyet	ERKEK	9- Gebelikte ilaç kullanımı	VAR	17- Şikâyetler birden fazla ortamda gözleniyor mu? (ev ve okul)	EVET
2-Ailenin kaçını çocuğu	4	10- Zorlu doğum öyküsü	VAR	18- Çocuktaki şikâyetler ne kadar zamandır var?	6 ay ve daha uzun süre
3- Annenin doğum sırasındaki yaşı	19 - 25 yaş arası	11- Annenin gebelik süreci	SIKINTILI	19-Ders başan durumu	Düşük (0 - 49)
4- Ailede hastalık öyküsü	YOK	12- Annenin gebelikte hastalık öyküsü	VAR	20- Ebeveynlerden gelen olumsuz dönüt bilgisi	FAZLA
5- Ailede ruhsal bozukluk öyküsü	YOK	13-Annenin gebelikte ruhsal bozukluk öyküsü	YOK	21- Öğretmenden gelen olumsuz dönüt bilgisi	AZ
6- Gebelikte sigara kullanımı	YOK	14- Çocuğun doğum ağırlığı	2500 ve 4500 kg arası		
7- Erken doğum öyküsü	YOK	15- Okuma yazmayı öğrenme zamanı	1. sınıf		
8-Gebelikte alkol kullanımı	VAR	16- Sınıf tekrarı yaptı mı?	EVET		

22- Conners Ebeveyn Dikkat Eksikliği Puanı: 12

23- Conners Ebeveyn Hiperaktivite Puanı: 11

Analiz Et

Resim 4.4. Ebeveyn kullanıcı yetki düzeyi çıkarım mekanizması (Adım 3)

4.4.3. Sistemin başarımlı değerlendirilmesi


Sistemin başarımlı değerlendirmesinde, hem 10-kat çapraz geçerleme yöntemi ile sistemin performansı doğrulanmış, hem de bağımsız bir test veri seti ile sistemin performansı test edilmiştir. Literatürde en çok kullanılan; K-En yakın komşu (KNN), Karar Ağaçları (J48, CART), SVM, Naive Bayes, RBF Network ve Multilayer Perceptron sınıflandırma algoritmalarının [318-319] sonuçları model başarımlı ölçütlerine göre karşılaştırılmıştır. 10-kat çapraz geçerleme metodu kullanılarak doğrulanan modelin performans sonuçları Çizelge 4.4’de verilmiştir:

Çizelge 4.4. 10-kat çapraz geçerleme metodu kullanılarak doğrulanan modelin performans sonuçları (ebeveyn kullanıcı yetki düzeyi)

	Recall (Duyarlılık = TP Rate)	FP Rate	Precision (Kesinlik)	Specificity (Özgüllük)	F-Measure (F-Ölçütü)	ROC area	Kappa statistic	Accuracy Doğruluk
J48 (C4.5)	0,92	0,15	0,885	0,85	0,902	0,889	0,773	88,888
SVM	0,96	0,125	0,906	0,875	0,932	0,918	0,841	92,222
CART	0,935	0,156	0,882	0,844	0,908	0,896	0,784	89,444
ANN (Multilayer Perceptron)	0,92	0,119	0,906	0,881	0,913	0,933	0,802	90,277
KNN (k=3)	0,99	0,206	0,857	0,794	0,919	0,937	0,799	90,277
RBF Network	0,965	0,106	0,919	0,894	0,941	0,939	0,864	93,333
Naive Bayes (Geliştirilen sistemde kodlanan algoritma)	0,965	0,106	0,919	0,894	0,941	0,970	0,864	93,333

Sınıflandırma algoritmalarında başarı yüzdesinin genel olarak %80 ve üzerinde olması beklenir. Karşılaştırılan sınıflandırma algoritmalarının başarı yüzdelерinin %80’nin çok üzerinde olması sınıflandırma algoritmalarının çok büyük bir oranda doğru sonuç ürettiğini kanıtlamaktadır. Çizelge 4.4’de verilen sınıflandırma algoritmaları incelendiğinde, ebeveyn yetki düzeyinde bulunan nitelikler kullanıldığında Naive Bayes ve RBF Network algoritmalarının doğruluk yüzdelерinin eşit ve en yüksek doğruluk yüzdesi (%93,33) olduğu görülmektedir. Bu iki algoritmaya ait ROC değeri incelendiğinde Naive Bayes

algoritmasına ait bu değerin (0,97) daha yüksek olduğu görülmektedir. Naive Bayes algoritmasına ait ROC eğrisi Şekil 4.6.'da verilmiştir.



Şekil 4.6. 10-kat çapraz geçerleme metodu kullanılarak doğrulanan modelin Naive Bayes algoritmasına ait ROC eğrisi (ebeveyn kullanıcı yetki düzeyi)

10-kat çapraz geçerleme metodu kullanılarak doğrulanan modelin örnek sayılarına göre karşılaştırma sonuçları Çizelge 4.5’de verilmiştir:

Çizelge 4.5. 10-kat çapraz geçerleme metodu kullanılarak doğrulanan modelin örnek sayılarına göre karşılaştırma sonuçları (ebeveyn kullanıcı yetki düzeyi)

	J48 (C4.5)	SVM	CART	ANN (Multilayer Perceptron)	KNN (k=3)	RBF Network	Naive Bayes (Geliştirilen sistemde kodlanan algoritma)
Doğru Pozitif (TP)	184	192	187	184	198	193	193
Yanlış Negatif (FN)	16	8	13	16	2	7	7
Yanlış Pozitif (FP)	24	20	25	19	33	17	17
Doğru Negatif (TN)	136	140	135	141	127	143	143
Yanlış Olarak Sınıflandırılan Örnek Sayısı	40	28	38	35	35	24	24
Doğru Olarak Sınıflandırılan Örnek Sayısı	320	332	319	325	325	336	336


Çizelge 4.5 incelendiğinde doğru olarak sınıflandırılan örnek sayısının en yüksek olduğu sınıflandırma algoritmalarının Naive Bayes ve RBF algoritmaları olduğu görülmektedir. Naive Bayes algoritmasına ait karışıklık matrisi (TP, TN, FP ve FN değerleri) incelendiğinde TP sınıflandırılan örnek sayısı 193, FP sınıflandırılan örnek sayısı 17, TN sınıflandırılan örnek sayısı 143 ve FN sınıflandırılan örnek sayısı 7 olarak bulunmuştur. Toplamda doğru sınıflandırılan örnek sayısı 336 ve yanlış sınıflandırılan örnek sayısı 24 olarak tespit edilmiştir.

Sistem ayrıca bağımsız bir test veri seti ile test edilmiştir. Veri kümesinin %80'ni 360 tanesi eğitim kümesi olarak kullanılırken %20'si 90 tanesi bağımsız test verisi olarak kullanılmıştır. Bağımsız bir test seti ile test edilen modelin performans sonuçları Çizelge 4.6'da verilmiştir:

Çizelge 4.6. Bağımsız bir test seti ile test edilen modelin performans sonuçları (ebeveyn kullanıcı yetki düzeyi)

	Recall (Duyarlılık = TP Rate)	FP Rate	Precision (Kesinlik)	Specificity (Özgüllük)	F-Measure (F-Ölçütü)	ROC Area	Kappa statistic	Accuracy Doğruluk
J48 (C4.5)	0,94	0,125	0,904	0,875	0,922	0,937	0,819	91,11
SVM	0,94	0,1	0,922	0,9	0,931	0,92	0,842	92,22
CART	0,90	0,125	0,90	0,875	0,90	0,917	0,775	88,88
ANN (Multilayer Perceptron)	0,90	0,075	0,938	0,925	0,918	0,957	0,82	91,11
KNN (k=3)	0,98	0,2	0,86	0,8	0,916	0,95	0,793	90
RBF Network	0,96	0,1	0,923	0,9	0,941	0,952	0,864	93,33
Naive Bayes (Geliştirilen sistemde kodlanan algoritma)	0,96	0,1	0,923	0,9	0,941	0,967	0,864	93,33

Çizelge 4.6'da verilen sınıflandırma algoritmaları incelendiğinde, ebeveyn yetki düzeyinde bulunan nitelikler kullanıldığında Naive Bayes ve RBF Network algoritmalarının doğruluk yüzdelерinin eşit ve en yüksek doğruluk yüzdesi (%93,33) olduğu görülmektedir. Bu iki algoritmaya ait ROC değeri incelendiğinde Naive Bayes algoritmasına ait bu değerin (0,967) daha yüksek olduğu görülmektedir. Naive Bayes algoritmasına ait ROC eğrisi Şekil 4.7.'de verilmiştir.



Şekil 4.7. Bağımsız bir test seti ile test edilen modelin Naive Bayes algoritmasına ait ROC eğrisi (ebeveyn kullanıcı yetki düzeyi)

Bağımsız bir test seti ile test edilen modelin örnek sayılarına göre karşılaştırma sonuçları Çizelge 4.7’de verilmiştir:

Çizelge 4.7. Bağımsız bir test seti ile test edilen modelin örnek sayılarına göre karşılaştırma sonuçları (ebeveyn kullanıcı yetki düzeyi)

	J48 (C4.5)	SVM	CART	ANN (Multilayer Perceptron)	KNN (k=3)	RBF Network	Naive Bayes (Geliştirilen sistemde kodlanan algoritma)
Doğru Pozitif (TP)	47	47	45	45	49	48	48
Yanlış Negatif (FN)	3	3	5	5	1	2	2
Yanlış Pozitif (FP)	5	4	5	3	8	4	4
Doğru Negatif (TN)	35	36	35	37	32	36	36
Yanlış Olarak Sınıflandırılan Örnek Sayısı	8	7	10	8	9	6	6
Doğru Olarak Sınıflandırılan Örnek Sayısı	82	83	80	82	81	84	84

Çizelge 4.7 incelendiğinde doğru olarak sınıflandırılan örnek sayısının en yüksek olduğu sınıflandırma algoritmasının Naive Bayes algoritması olduğu görülmektedir. Naive Bayes algoritmasına ait karışıklık matrisi (TP, TN, FP ve FN değerleri) incelendiğinde TP sınıflandırılan örnek sayısı 48, FP sınıflandırılan örnek sayısı 4, TN sınıflandırılan örnek sayısı 36 ve FN sınıflandırılan örnek sayısı 2 olarak bulunmuştur. Toplamda doğru sınıflandırılan örnek sayısı 84 ve yanlış sınıflandırılan örnek sayısı 6 olarak tespit edilmiştir.

Sistemin performansı 10-kat çapraz geçерleme yöntemi ile doğrulanırken, ayrıca bağımsız bir test verisi ile de test edilmiştir. Elde edilen sonuçlar incelendiğinde ebeveyn kullanıcı yetki düzeyinde en yüksek performansı gösteren algoritmanın Naive Bayes algoritması olduğu görülmüştür. Elde edilen bulgulara göre 10-kat çapraz geçерleme yöntemine göre doğruluk yüzdesi ile bağımsız test verisi ile test edilen modelin bu algoritmaya ait doğruluk yüzdesinin eşit olduğu (%93,33) tespit edilmiştir.

4.4.4. Açıklama Birimi

Açıklama birimi bir uzman sistem yapısının zorunlu bir birimi olmasa da [85, 104], geliştirilen birçok uzman sistem yapısında var olan bir birimdir. DEHB belirtilerinin görülüp görülmediğine dair sistemin tahmini, analiz bulguları ve sistem önerisi kullanıcıya Resim 4.5’deki form ile gösterilmektedir.

AÇIKLAMA BİRİMİ (Ebeveyn Kullanıcı Yetki Düzeyi)

Sistemin Tahmini:

- Çocukta Dikkat Eksikliği ve Hiperaktivite Bozukluğuna işaret eden belirtiler bulunmamaktadır.
- Yine de eğer çocukta Dikkat eksikliği ve hiperaktivite bozukluğuna ait belirtilerolduğunu düşünüyorsanız mutlaka bir Çocuk Ruh Sağlığı uzmanına başvurunuz

Analiz Bulguları:

- DEHB Sınıfına ait olmama sonucu ($P(X Ci) * P(Ci)$)	11749156,7826655
- DEHB Sınıfına ait olma sonucu ($P(X Ci) * P(Ci)$)	2948871,71665051
- Sonuç Bulgusu:	NONADHD / Dikkat Eksikliği ve Hiperaktivite Sınıfına Ait Değil (11749156,7826655 > 2948871,71665051)

Resim 4.5. Ebeveyn kullanıcı yetki düzeyi açıklama birimi

4.5. Öğretmen kullanıcı yetki düzeyi

Kullanıcı Resim 4.1’de giriş formu ekranında “öğretmen” butonuna tıkladığında sistemin çocukta DEHB olup olmadığına yönelik tahmin sonucunu gösteren ve 25 nitelik bilgisinin kullanıldığı çıkarım mekanizması formu gelmektedir. Bu niteliklerin kullanıldığı çıkarım mekanizması formu uzman yetki düzeyinde detaylı bir şekilde verilmiştir.

4.6. Uzman kullanıcı yetki düzeyi ve sistemin başarımlı testi

Kullanıcı Resim 4.1’de giriş formu ekranında “uzman” butonuna tıkladığında sisteme kayıtlı “kullanıcı adı” ve “şifre bilgisi” ile giriş yapabilmektedir. Sistemde uzman yetki düzeyinde; yeni kayıt ekleme, kayıt listeleme, güncelleme, listeleme, silme, grafik ile görselleştirme, bilgi tabanını Excel programına aktarma, rapor alma gibi ek seçenekler mevcuttur.

4.6.1. Bilgi tabanına yeni kayıt ekleme/ listeleme/ silme/güncelleme

Sistemde uzman yetki düzeyinde giriş yapıldıktan sonra “Bilgi tabanı” seçeneği tıklanarak DEHB veri ambarı oluşturulmaktadır. Bu bölüm alan uzmanının, bilgi girişlerini daha rahat bir şekilde yapmasını ve kolaylıkla bilgi tabanını oluşturmasını sağlamaktadır. Alan uzmanları tarafından girilebilen ve üç aşamadan oluşan DEHB bilgi tabanı formu adım adım Resim 4.6, Resim 4.7 ve Resim 4.8’de gösterilmiştir:

Yeni Kayıt Oluşturma - DEHB'nin Öngörülmesine Yönelik Dinamik Uzman Sistem Tasarımı

Dosya Bilgi Tabanı Analiz Yardım

Kayıt Oluşturma Kayıt Düzenleme Veri Öngörme

1 2 3

Kayıt ID: 1 Çocukun Adı-Soyadı: Zeynep Tuana

1- Cinsiyet: KIZ
2- Ailenin kaçını çocuğu: 1
3- Annenin doğum sırasındaki yaşı: 26 - 30 yaş arası
4- Alidede hastalık öyküsü: YOK
5- Evet ise; Bireyin yalınlığı / Tanısı: YOK
6- Alidede ruhsal bozukluk öyküsü: YOK
7- Evet ise; Bireyin yalınlığı / Tanısı: YOK
8- Gebelikte sigara kullanımı: YOK
9- Erken doğum öyküsü: YOK
10- Gebelikte alkol kullanımı: YOK
11- Gebelikte ilaç kullanımı: YOK
12- Evet ise; İlaçın ismi: YOK
13- Zorlu doğum öyküsü: YOK
14- Annenin gebelik süresi: NORMAL
15- Annenin gebelikte hastalık öyküsü: YOK
16- Evet ise; Tanısı: YOK
17- Annenin gebelikte ruhsal bozukluk öyküsü: YOK
18- Evet ise; Tanısı: YOK
19- Çocuğun doğum ağırlığı: 2500 ve 4500 kg arası
20- Okuma yazmayı öğrenme zamanı: 1. sınıf 1. dönem bitiminden önce
21- Sınıf telafisi yaptı mı? HAYIR
22- Şikayetler birden fazla ortamda gözleniyor mu? (ev ve okul) SIKAYET YOK
23- Çocuktaki şikayetler ne kadar zamandır var? SIKAYET YOK
24- Ders başarı durumu: Çok İyi (85 - 100)
25- Ebeveynlerden gelen olumsuz dönüt bilgisi: ORTA
26- Öğretmenlerden gelen olumsuz dönüt bilgisi: 2

İleri

Resim 4.6. Bilgi tabanı oluşturma formu (Adım 1)

Bilgi tabanı oluşturma formunda 1. aşama doldurulduktan sonra 2. aşamaya geçmek için “İleri” butonuna tıklanır.

Yeni Kayıt Oluşturma - DEHB'nin Öngörülmesine Yönelik Dinamik Uzman Sistem Tasarımı

Dosya Bilgi Tabanı Analiz Yardım

Kayıt Oluşturma Kayıt Düzenleme Veri Öngörme

1 2 3

Kayıt ID: 1 Çocukun Adı-Soyadı: Zeynep Tuana

CONNER'S DİKKAT EKSİKLİĞİ VE HİPERAKTİVİTE BOZUKLUĞU EBEVEYN DEĞERLENDİRME ÖLÇEĞİ

Hiçbir zaman Nadiren Sıklıkla Her zaman				Hiçbir zaman Nadiren Sıklıkla Her zaman				
1. Eli boş durmaz sürekli bir şeylerle oynar. (parmak, giysi vb. ...)	☐	☐	☒	☐	26. Hassastır, kolay incinir.	☐	☐	☒
2. Büyüklere anksiyöz ve küstah davranır.	☐	☒	☐	☐	27. Kabadaylık taslar, başkalarını rahatsız eder.	☒	☐	☐
3. Arkadaşlık kumada ve sürdürmede zorlanır.	☐	☒	☐	☐	28. Tekrarlayıcı, durduramadığı hareketleri vardır.	☒	☐	☐
4. Çabuk heyecanlanır, ataktır.	☐	☐	☒	☐	29. Kaba ve acımasızdır.	☒	☐	☐
5. Herşeyi kargır ve yönetmek ister.	☐	☐	☒	☐	30. Yagna göre daha çocuksudur.	☒	☐	☐
6. Birşeyler Öğner veya emer. (parmak, giysi, örtü vb. ...)	☒	☐	☐	☐	31. Dikkati kolay dağılır yada dikkatini uzun süre toparlayamaz.	☐	☒	☐
7. Sık sık ve kolayca ağlar.	☐	☒	☐	☐	32. Baş ağrılan olur.	☒	☐	☐
8. Her an satılmaya hazırdr.	☐	☒	☐	☐	33. Ruh halinde ani ve gözle batan değışiklikler olur.	☐	☒	☐
9. Hayallere dalar.	☐	☒	☐	☐	34. Kurallar ve kstamlamalardan hoşlanmaz ve uymaz.	☐	☐	☒
10. Zor Öğrenir.	☒	☐	☐	☐	35. Sürekli kavga eder.	☒	☐	☐
11. Kıpr kıprdr, tez canlıdır.	☐	☐	☒	☐	36. Kardeşleri ile iyi geçinemez.	☐	☒	☐

Resim 4.7. Bilgi tabanı oluşturma formu (Adım 2)


2. aşamada CADÖ-48 ölçeğine ait veriler sisteme girilmektedir. 3. aşamaya geçmek için “İleri” butonuna tıklanmaktadır.

CONNER'S DİKKAT EKSİKLİĞİ VE HİPERAKTİVİTE BOZUKLUĞU ÖĞRETMEN DEĞERLENDİRME ÖLÇEĞİ				
	Hiçbir zaman	Nadiren	Sıklıkla	Her zaman
1. Kıpır kıpırdır, yerinde duramaz.	☐	☐	☒	☐
2. Zamansız ve uyumsuz sesler çıkarır.	☐	☒	☐	☐
3. İstekleri hemen yerine getirilmelidir.	☐	☐	☒	☐
4. Bilmiş tavırları vardır. Bilgiyi taslar.	☐	☐	☒	☐
5. Aniden parlar, ne yapacağı belli olmaz.	☐	☐	☒	☐
6. Eğlenciyi kaldırmaz.	☐	☒	☐	☐
7. Dikkati dağınıktır, uzun sürmez.	☐	☒	☐	☐
8. Diğer çocukları rahatsız eder.	☒	☐	☐	☐
9. Hayallere dalar.	☒	☐	☐	☐
10. Somurtur, surat asar.	☒	☐	☐	☐
15. Heyecana kapılıp, düşünmeden hareket eder.	☐	☒	☐	☐
16. Öğretmenin ilgisi hep üzerinde olsun ister.	☐	☐	☐	☒
17. Göründüğü kadıyla arkadaş grubuna alınmıyor.	☐	☒	☐	☐
18. Göründüğü kadıyla başka çocuklar tarafından kolaylıkla yönlendiriliyor.	☐	☒	☐	☐
19. Oyun kurallarına uymaz, muzıktır.	☐	☒	☐	☐
20. Göründüğü kadıyla liderlik özelliğinden yoksundur.	☐	☒	☐	☐
21. Bağladığı işin sonunu getiremez.	☐	☒	☐	☐
22. Olduğundan daha küçükmüş gibi davranır.	☐	☒	☐	☐
23. Hatalarını kabul etmez; suçu başkalarının üzerine atar.	☐	☒	☐	☐
24. Diğer çocuklarla iyi geçinemez.	☐	☒	☐	☐

Resim 4.8. Bilgi tabanı oluşturma formu (Adım 3)


Bilgi tabanı oluşturma formunun son aşamasında öğretmen tarafından doldurulan CÖDÖ-28 ölçeğine ait bilgiler sisteme girilerek “Kaydet” butonuna tıklanarak kayıt işlemi tamamlanır. Çalışmada bu form kullanılarak oluşturulan DEHB bilgi tabanı 450 kayıt, 25 nitelik ve 1 sınıf bilgisinden oluşmaktadır.

Uzman yetki düzeyinde bulunan kullanıcı Resim 4.9'daki form ile bilgi tabanında yer alan nitelikleri ve isteğe bağlı olarak tüm kayıtları veya sadece seçilen kayıtları Excel platformuna aktarılabilir.




Resim 4.9. Bilgi tabanının Excel platformuna aktarma formu

Ayrıca “uzman” yetki düzeyinde bulunan kullanıcı bilgi tabanını Resim 4.9’daki formu kullanarak çıktısını alabilir:



Resim 4.10. Bilgi tabanını yazdırma formu

DEHB bilgi tabanı oluşturulduktan sonra, Resim 4.11’de bilgi tabanının görüntülenmesi kısmında; bilgi tabanında bulunan kayıtlar silinebilir, yeni kayıtlar eklenebilir, mevcut kayıtlar güncellenebilir ve her bir niteliğe ait kayıtlar grafiksel olarak gösterilebilmektedir.



Resim 4.11. Bilgi tabanını görüntüleme/silme/güncelleme formu

4.6.2. Çıkarım mekanizması

Sınıflandırma algoritmaları karşılaştırıldığında, model başarımları ölçütleri ışığında performansı en yüksek olan algoritma Naive Bayes algoritmasıdır. Bu algoritmanın doğruluk oranının (%95,55) oldukça yüksek olduğu tespit edilmiştir. Bu nedenle geliştirilen dinamik uzman sistemin çıkarım mekanizmasında Naive Bayes sınıflandırma algoritması kullanılmıştır. Bu sayede veri kümesi kendini yenileyebilen dinamik bir yapı haline dönüşmüştür. Sisteme yeni bir kayıt girildiğinde; geliştirilen dinamik uzman sistem ile mevcut veri kümesinden sonucun öngörülmesi sağlanır. Sistemin uzman yetki düzeyi çıkarım mekanizması adım adım Resim 4.12, Resim 4.13, Resim 4.14 ve Resim 4.15’de verilmiştir:

Naive Bayes Algoritması - DEHB'nin Öngörülmesine Yönelik Dinamik Uzman Sistem Tasarımı

Dosya Bilgi Tabanı Analiz Yardım

Naive Bayes Algoritması KÖİN Algoritması

Ebeveynden Alınan Bilgiler / 1- Aile Bilgileri, Annenin Hamilelik Süreci ve Çocuğun Gelişimsel Öyküsü

1-Cinsiyet	KIZ	9- Gebelikte ilaç kullanımı	YOK	17- Şikâyetler birden fazla ortamda gözleniyor mu? (ev ve okul)	HAYIR
2-Allenin kaçını çocuğu	3	10- Zorlu doğum öyküsü	VAR	18- Çocukta şikâyetler ne kadar zamandır var?	6 aydan az süre
3- Annenin doğum sırasındaki yaşı	36 - 40 yaş arası	11- Annenin gebelik süresi	NORMAL	19-Ders başarı durumu	Orta (50 - 69)
4- Ailede hastalık öyküsü	VAR	12- Annenin gebelikte hastalık öyküsü	VAR	20- Ebeveynden gelen olumsuz dönüt bilgisi	ORTA
5- Ailede ruhsal bozukluk öyküsü	VAR	13-Annenin gebelikte ruhsal bozukluk öyküsü	YOK	21- Öğretmenden gelen olumsuz dönüt bilgisi	Y
6- Gebelikte sigara kullanımı	VAR	14- Çocuğun doğum ağırlığı	2500 kg altı		
7- Erken doğum öyküsü	YOK	15- Okuma yazmayı öğrenme zamanı	1. sınıf		
8-Gebelikte alkol kullanımı	YOK	16- Sınıf tekrarı yaptı mı?	HAYIR		

İleri

Resim 4.12. Uzman kullanıcı yetki düzeyi Naive Bayes çıkarım mekanizması formu (Adım 1)

Naive Bayes Algoritması - DEHB'nin Öngörülmesine Yönelik Dinamik Uzman Sistem Tasarımı

Dosya Bilgi Tabanı Analiz Yardım

Naive Bayes Algoritması KÖİN Algoritması

Ebeveynden Alınan Bilgiler

2- Conner's Ebeveyn Değerlendirme Ölçeği

	Hiçbir zaman	Nadiren	Sıklıkla	Her zaman
1. Elini boş durmaz sürekli bir şeylerle oynar.	☐	☐	☐	☒
2. Çabuk heyecanlanır, ataktır.	☐	☐	☐	☒
3. Her şeye karşı ve her şeyi yönetmek ister.	☐	☐	☒	☐
4. Bir şeyler çığır veya emir (parmak, giysi, örtü vb.)	☐	☐	☐	☒
5. Kıpır kıpırdır, tez canlıdır.	☐	☐	☒	☐
6. Yerinde duramaz, her an harekete hazırdır.	☐	☐	☒	☐
7. Yaşlılarından farklı konuşur. (çocuksu, kekeme, zor anlaşılabilir)	☐	☐	☒	☐
8. Bağladığı bir işin sonunu getiremez.	☐	☐	☐	☒
9. Dikkati kolay dağılır ya da uzun süre toplayamaz.	☐	☐	☐	☒

İleri

Resim 4.13. Uzman kullanıcı yetki düzeyi Naive Bayes çıkarım mekanizması formu (Adım 2)

Uzman yetki düzeyi Naive Bayes çıkarım mekanizmasında birinci ve ikinci adımda aileden gelen bilgiler kullanılmaktadır.

Naive Bayes Algoritması - DEHB'nin Öngörülmesine Yönelik Dinamik Uzman Sistem Tasarımı

Dosya Bilgi Tabanı Analiz Yardım

Naive Bayes Algoritması KNN Algoritması

Öğretmenden Alınan Bilgiler

3- Conner's Öğretmen Değerlendirme Ölçeği

	Hiçbir zaman	Nadiren	Sıklıkla	Her zaman
1. Kprı kapıdır, yerinde duramaz.	☐	☐	☒	☐
2. Zamansız ve uyumsuz sesler çıkarır.	☐	☐	☒	☐
3. Aniden patlar, ne yapacağı belli olmaz.	☐	☐	☒	☐
4. Dikkati dağınıktır, uzun sürmez.	☐	☐	☒	☐
5. Diğer çocukları rahatsız eder.	☐	☐	☒	☐
6. Hayallere dalar.	☐	☐	☐	☒
7. Bir anı bir anını tutmaz, duygulanı çabuk değişir.	☐	☐	☐	☒
8. Kavgacıdır.	☐	☐	☐	☒
9. Hareketlidir, durmak-oturmak bilmez.	☐	☐	☐	☒
10. Heyecana kapılıp, düşünmeden hareket eder.	☐	☐	☐	☒
11. Göründüğü kadanyla arkadaşlık grubuna alınmıyor.	☐	☐	☒	☐
12. Göründüğü kadanyla başka çocuklar tarafından kolaylıkla yönlendiriliyor.	☐	☐	☒	☐
13. Oyun kurallarına uymaz, mızıkçdır.	☐	☐	☒	☐
14. Göründüğü kadanyla liderlik özelliğinden yoksundur.	☐	☐	☒	☐
15. Başladığı işin sonunu getiremez.	☐	☐	☒	☐
16. Olduğundan daha küçükmüş gibi davranır.	☐	☐	☐	☒
17. Kprı kapıdır, yerinde duramaz. Hatalarını kabul etmez, suçu başkalarının üzerine atar.	☐	☐	☐	☒
18. Diğer çocuklarla iyi geçinemez.	☐	☐	☒	☐
19. Sınıf arkadaşlarıyla yardımlaşmaz.	☐	☐	☒	☐
20. Zorluklardan hemen yılar.	☐	☐	☒	☐
21. Öğretmenle iğbirliğine girmez.	☐	☒	☐	☐
22. Zor öğrenir.	☐	☒	☐	☐

İleri

Resim 4.14. Uzman kullanıcı yetki düzeyi Naive Bayes çıkarım mekanizması formu (Adım 3)

Formun üçüncü adımında CÖDÖ-28 ölçeğinde DEHB'e yönelik belirtileri içeren maddelere öğretmen tarafından verilen cevaplar alınmaktadır.

Naive Bayes Algoritması - DEHB'nin Öngörülmesine Yönelik Dinamik Uzman Sistem Tasarımı

Dosya Bilgi Tabanı Analiz Yardım

Naive Bayes Algoritması KNN Algoritması

1-Cinsiyet	KIZ	9- Gebelikte ilaç kullanımı	YOK	17- Şikâyetler birden fazla ortamda gözleniyor mu? (ev ve okul)	EVET
2-Allenin kaçını çocuğu	2	10- Zorlu doğum öyküsü	YOK	18- Çocukta şikâyetler ne kadar zamandır var?	6 aydan az süre
3- Annenin doğum sırasında yapı	19 - 25 yaş arası	11- Annenin gebelik süresi	NORMAL	19-Ders başarı durumu	Orta (50 - 69)
4- Alilde hastalık öyküsü	YOK	12- Annenin gebelikte hastalık öyküsü	VAR	20- Ebeveynin gelen olumsuz dönüt bilgisi	FAZLA
5- Alilde ruhsal bozukluk öyküsü	VAR	13- Annenin gebelikte ruhsal bozukluk öyküsü	YOK	21- Öğretmenden gelen olumsuz dönüt bilgisi	ORTA
6- Gebelikte sigara kullanımı	YOK	14- Çocuğun doğum ağırlığı	2500 ve 4500 kg arası		
7- Erken doğum öyküsü	YOK	15- Okuma yazmayı öğrenme zamanı	1. sınıf		
8- Gebelikte alkol kullanımı	YOK	16- Sınıf tekrarı yapı mı?	HAYIR		
22- Conners Ebeveyn Dikkat Eksikliği Puanı	13	24- Conners Öğretmen Dikkat Eksikliği Puanı	25		
23- Conners Ebeveyn Hiperaktivite Puanı	9	25- Conners Öğretmen Hiperaktivite Puanı	28		

Analiz Et

Resim 4.15. Uzman kullanıcı yetki düzeyi Naive Bayes çıkarım mekanizması formu (Adım 4)

Geliştirilen uzman sistem Naive Bayes algoritması kullanılarak ilk önce eğitim veri kümesi ile eğitilmektedir. Yeni bir durum ile karşılaşıldığında eğitim veri kümesinde bulunan kayıtlar çekilerek her bir sınıfa ait ihtimal durumu (DEHB, DEHB olmayan) için girilen nitelik değerlerinin frekans sayıları hesaplatılmaktadır. Her bir sınıfa ait sonucun çıkma olasılığı, o sonucu etkileyen tüm niteliklerin, o sınıfa ait sonucu sağlama olasılıklarının çarpımıdır. Naive Bayes algoritmasında her bir olasılığın sıfırdan büyük olması gerekir, aksi takdirde bütün olasılık sıfır olur, bu nedenle olasılık 0'a eşitse her nitelik değerine 0-1 arasında küçük bir değer eklenerek sorun çözülür. Yazılımda her bir olasılığın sıfırdan farklı olup olmaması kontrol edilmekte, eğer olasılık 0'a eşitse her bir nitelik değerine 1 eklenmektedir.

Sonuç olarak her bir sınıf bilgisine ait ihtimaller karşılaştırılarak yeni kaydı eğer “DEHB” sınıf bilgisine ait ihtimal daha yüksekse “DEHB” sınıfına, eğer “DEHB olmayan” sınıfına ait ihtimal daha yüksekse “DEHB olmayan” sınıfına atamaktadır. Her olasılık için sonuçlar hesaplanmakta ve en yüksek olasılığa sahip olan sınıfa yeni kayıt atanmaktadır. Hesaplanan belirti olasılığına göre sonuç kullanıcıya açıklama biriminde gösterilmektedir.

Geliştirilen dinamik uzman sistemdeki Naive Bayes çıkarım mekanizmasının pseudo (sözde) kodu aşağıda verilmiştir:

- Her bir sınıfa ait kayıt sayısının hesaplanması
- Hesaplanacak her bir nitelik için her bir sınıfa ait olma olasılığının hesaplanması
- Sonucun sıfır olma olasılığının ortadan kaldırılması
- DEHB belirtisinin olması (p) veya olmaması(q) oranlarının hesaplanması
- Eğer $p \text{ oranı} > q \text{ oranı}$ ise kuralın “DEHB” sınıfına değilse “DEHB olmayan” sınıfına atanması
- Sonuçların kullanıcıya açıklama biriminde gösterilmesi

Uzman yetki düzeyinde çıkarım mekanizmasında Naive Bayes algoritması ile birlikte KNN algoritması da kodlanarak sisteme eklenmiştir. KNN algoritması çıkarım mekanizması formu adım adım Resim 4.16, Resim 4.17, Resim 4.18 ve Resim 4.19’da gösterilmektedir:

KNN Algoritması - DEHB'nin Öngörülmesine Yönelik Dinamik Uzman Sistem Tasarımı

Dosya Bilgi Tabanı Analiz Yardım

Naive Bayes Algoritması KNN Algoritması

Ebeveyn Alınan Bilgiler / 1- Aile Bilgileri, Annenin Hamilelik Süreci ve Çocuğun Gelişimsel Öyküsü

1-Cinsiyet	KIZ	9- Gebelikte ilaç kullanımı	YOK	17- Şikayetler birden fazla ortamda gözleniyor mu? (ev ve okul)	EYET
2-Annin kaçını çocuğu	3	10- Zorlu doğum öyküsü	VAR	18- Çocukta şikayetler ne kadar zamandır var?	6 aydan az süre
3- Annenin doğum sırasındaki yaşı	19 - 25 yaş arası	11- Annenin gebelik süreci	SIKINTILI	19-Ders başarı durumu	Orta (50 - 69)
4- Ailede hastalık öyküsü	YOK	12- Annenin gebelikte hastalık öyküsü	YOK	20- Ebeveynin gelen olumsuz dönüt bilgisi	AZ
5- Ailede ruhsal bozukluk öyküsü	VAR	13-Annenin gebelikte ruhsal bozukluk öyküsü	YOK	21- Öğretmenden gelen olumsuz dönüt bilgisi	ORTA
6- Gebelikte sigara kullanımı	VAR	14- Çocuğun doğum ağırlığı	2500 kg altı		
7- Erken doğum öyküsü	VAR	15- Okuma yazmayı öğrenme zamanı	1. sınıf		
8- Gebelikte alkol kullanımı	YOK	16- Sınıf tekrarı yapı mı?	HAYIR		

İleri

Resim 4.16. KNN çıkarım mekanizması formu (Adım 1)

KNN Algoritması - DEHB'nin Öngörülmesine Yönelik Dinamik Uzman Sistem Tasarımı

Dosya Bilgi Tabanı Analiz Yardım

Naive Bayes Algoritması KNN Algoritması

Ebeveyn Alınan Bilgiler

2- Conner's Ebeveyn Değerlendirme Ölçeği

	Hiçbir zaman	Nadiren	Sıklıkla	Her zaman
1. Eli boş duması süresinde bir şeylerle oynar.	☐	☐	☒	☐
2. Çabuk heyecanlanır, ataktır.	☐	☐	☒	☐
3. Her şeye kanar ve her şeyi yönetmek ister.	☐	☐	☒	☐
4. Bir şeyler öğrenir veya emir (parmak, giysi, otu vb.)	☐	☐	☐	☒
5. Kırır kırpar, tez canlıdır.	☐	☐	☐	☒
6. Yerinde duramaz, her an harekete hazırdır.	☐	☐	☒	☐
7. Yağtlardan farklı konuşur (çocuksu, kekeleme, zor anlaşılma)	☐	☐	☒	☐
8. Başladığı bir işi sonunu getiremez.	☐	☐	☐	☐
9. Dikkati kolay dağılır ya da uzun süre toplayamaz.	☐	☐	☐	☒

İleri

Resim 4.17. KNN çıkarım mekanizması formu (Adım 2)

KNN Algoritması - DEHB'nin Öngörülmesine Yönelik Dinamik Uzman Sistem Tasarımı

Naive Bayes Algoritması KNN Algoritması

Öğretmenden Alınan Bilgiler

3- Conner's Öğretmen Değerlendirme Ölçeği

	Hiçbir zaman	Nadiren	Sıklıkla	Her zaman
1. Kırır koparır, yerinde duramaz.	☐	☐	☐	☒
2. Zamanı ve uyumsuz sesler çıkarır.	☐	☐	☐	☒
3. Aniden patlar, ne yapacağı belli olmaz.	☐	☐	☒	☐
4. Dikkati dağınıktır, uzun sürmez.	☐	☐	☒	☐
5. Diğer çocukları rahatsız eder.	☐	☐	☒	☐
6. Hayallere dalar.	☐	☐	☒	☐
7. Bir anı bir anı tutmaz, duyguları çabuk değişir.	☐	☐	☐	☒
8. Kavgacıdır.	☐	☐	☐	☒
9. Hareketlidir, durmak oturmamak bilmez.	☐	☐	☐	☒
10. Heyecana kapılır, düşünmeden hareket eder.	☐	☐	☒	☐
11. Göründüğü kadıyla arkadaşlık grubuna alınamıyor.	☐	☐	☒	☐
12. Göründüğü kadıyla başka çocuklar tarafından kolaylıkla yönlendiriliyor.	☐	☐	☐	☒
13. Oyun kurallarına uymaz, mızıkçadır.	☐	☐	☒	☐
14. Göründüğü kadıyla liderlik özelliğinden yoksundur.	☐	☐	☒	☐
15. Bağladığı işin sonunu getiremez.	☐	☐	☐	☒
16. Olduğundan daha küçükmüş gibi davranır.	☐	☐	☒	☐
17. Kırır koparır, yerinde duramaz. Hatalarını kabul etmez, suçlu başkalarının üzerine atar.	☐	☐	☐	☒
18. Diğer çocuklarla iyi geçinemez.	☐	☐	☒	☐
19. Sınıf arkadaşlarıyla yardımlaşmaz.	☐	☐	☒	☐
20. Zorluklardan hemen yılar.	☐	☐	☒	☐
21. Öğretmenle işbirliğine girmez.	☐	☒	☐	☐
22. Zor öğrenir.	☐	☒	☐	☐

İleri

Resim 4.18. KNN çıkarım mekanizması formu (Adım 3)

KNN Algoritması - DEHB'nin Öngörülmesine Yönelik Dinamik Uzman Sistem Tasarımı

Naive Bayes Algoritması KNN Algoritması

1-Cinsiyet KIZ

2-Allerin kaçını çocuğu 3

3- Annenin doğum sırasındaki yaşı 19 - 25 yaş arası

4- Ailede hastalık öyküsü YOK

5- Ailede ruhsal bozukluk öyküsü VAR

6- Gebelikte sigara kullanımı VAR

7- Erken doğum öyküsü VAR

8- Gebelikte alkol kullanımı YOK

9- Gebelikte ilaç kullanımı YOK

10- Zorlu doğum öyküsü VAR

11- Annenin gebelik süresi SIKINTILI

12- Annenin gebelikte hastalık öyküsü YOK

13- Annenin gebelikte ruhsal bozukluk öyküsü YOK

14- Çocuğun doğum ağırlığı 2500 kg altı

15- Okuma yazmayı öğrenme zamanı 1. sınıf

16- Sınıf teklifi yapı mı? HAYIR

17- Şikayetler birden fazla ortamda gösteriyor mu? (ev ve oku) EVET

18- Çocukta şikayetler ne kadar zamandır var? 6 aydan az süre

19- Ders başarı durumu Orta (50 - 69)

20- Ebeveynlerden gelen olumsuz dönüt bilgisi AZ

21- Öğretmenden gelen olumsuz dönüt bilgisi ORTA

22- Conner's Ebeveyn Dikkat Eksikliği Puanı 12

23- Conner's Ebeveyn Hiperaktivite Puanı 9

24- Conner's Öğretmen Dikkat Eksikliği Puanı 26

25- Conner's Öğretmen Hiperaktivite Puanı 26

Adhd şüphesi bulunmaktadır.

Sonuç

K değerini giriniz 3

Uzaklık: 10

Uzaklık: 5,65685424949238

Uzaklık: 5,8309518946453

Uzaklık: 5,3851648071245

Uzaklık: 5,65685424949238

Uzaklık: 5,91607978309962

Uzaklık: 6,2449979982984

Uzaklık: 5,74456294653883

Uzaklık: 5,616770787109647

Öklid Uzaklık Noktaları

Series1

Analiz Et

Yeni Sorgu

Sonucu Kural Tabanına Ekle

Resim 4.19. KNN çıkarım mekanizması formu (Adım 4)

KNN algoritması nesneler arasındaki yakınlık ilişkisine göre çalışır. Mesafe hesaplamada öklid uzaklığı, minkowski uzaklığı, manhattan uzaklığı gibi mesafe hesaplama yöntemleri kullanılır.

Bu tez çalışması kapsamında nesneler arasındaki yakınlık ilişkisi belirlenirken Öklid uzaklığı kullanılmıştır. Geliştirilen dinamik uzman sistemdeki KNN algoritmasının pseudo kodu aşağıda verilmiştir:

- K değerinin belirlenmesi
- Diğer nesneler ile hedef nesne arasındaki öklit uzaklıklarının hesaplanması
- Belirlenen uzaklıkların sıralanması
- En küçük uzaklığa bağlı olarak komşuların bulunması
- En yakın komşu kategorilerinin girilen k değerine göre toplanması.
- En uygun komşunun seçilmesi

Geliştirilen sistemde, “uzman” yetki düzeyinde bulunan kullanıcıya isterse algoritmaları kullanarak sonuçlarını karşılaştırabilme fırsatı verilmektedir.

4.6.3. Sistemin başarımlı değerlendirilmesi


10-kat çapraz geçerleme metodu kullanılarak doğrulanan modelin performans sonuçları (uzman yetki düzeyi) Çizelge 4.8’de verilmiştir:

Çizelge 4.8. 10-kat çapraz geçerleme metodu kullanılarak doğrulanan modelin performans sonuçları (uzman kullanıcı yetki düzeyi)

	Recall (Duyarlılık = TP Rate)	FP Rate	Precision (Kesinlik)	Specificity (Özgüllük)	F-Measure (F-Ölçütü)	ROC Area	Kappa statistic	Accuracy (Doğruluk)
J48 (C4.5)	0,955	0,119	0,91	0,881	0,932	0,943	0,841	92,222
SVM	0,98	0,106	0,92	0,894	0,949	0,937	0,880	94,166
CART	0,95	0,125	0,905	0,875	0,927	0,932	0,830	91,666
ANN (Multilayer Perceptron)	0,945	0,1	0,922	0,9	0,933	0,966	0,847	92,5
KNN (k=3)	0,995	0,119	0,913	0,881	0,952	0,972	0,886	94,444
RBF Network	0,97	0,088	0,933	0,912	0,951	0,959	0,886	94,444
Naive Bayes (Geliştirilen sistemde kodlanan algoritma)	0,985	0,094	0,929	0,906	0,956	0,987	0,898	95

Model başarımlar ölçütlerinden specificity, recall, precision ve F ölçüt değerlerinin, ROC area değeri gibi 1'e yakın olması istenir [167, 215, 320-321]. Karşılaştırma tablosu incelendiğinde tüm algoritmaların Roc area, TP rate, recall, precision, specificity ve f ölçüt değerlerinin 1'e yakın olduğu görülmektedir. Ayrıca kappa istatistik değerinin 0,81 ile 1,00 arasında olması “neredeyse mükemmel” derecede bir uyum olduğunu gösterir [210].

Çizelge 4.8’de verilen sınıflandırma algoritmaları incelendiğinde, doğruluk yüzdesi en yüksek olan algoritmanın Naive Bayes algoritması olduğu (%95) görülmektedir. Doğruluk yüzdesi en yüksek olan Naive Bayes algoritmasına ait ROC eğrisi Şekil 4.8.’de verilmiştir. Naive Bayes algoritmasına ait ROC değeri incelendiğine bu değerin 0,987 olduğu görülmektedir. Bu değerin 1’e yakın olması sistemin tesadüfi bir tahminde bulunmadığını, neredeyse mükemmel derecede bir sonuç ürettiğini göstermektedir.



Şekil 4.8. 10-kat çapraz geçerleme metodu kullanılarak doğrulanan modelin Naive Bayes algoritmasına ait ROC eğrisi (uzman kullanıcı yetki düzeyi)

10-kat çapraz geçerleme metodu kullanılarak doğrulanan modelin örnek sayılarına göre karşılaştırma sonuçları (uzman kullanıcı düzeyinde kullanılan 25 nitelik bilgisini içeren) Çizelge 4.9’da verilmiştir:

Çizelge 4.9. 10-kat çapraz geçерleme metodu kullanılarak doğrulan modelin örnek sayılarına göre karşılaştırma sonuçları (uzman kullanıcı yetki düzeyi)


	J48 (C4.5)	SVM	CART	ANN (Multilayer Perceptron)	KNN (k=3)	RBF Network	Naive Bayes (Geliştirilen sistemde kodlanan algoritma)
Doğru Pozitif (TP)	191	196	190	189	199	194	197
Yanlış Negatif (FN)	9	4	10	11	1	6	3
Yanlış Pozitif (FP)	19	17	20	16	19	14	15
Doğru Negatif (TN)	141	143	140	144	141	146	145
Yanlış Olarak Sınıflandırılan Örnek Sayısı	28	21	30	27	20	20	18
Doğru Olarak Sınıflandırılan Örnek Sayısı	332	339	330	333	340	340	342

Çizelge 4.9 incelendiğinde doğru olarak sınıflandırılan örnek sayısının en yüksek olduğu sınıflandırma algoritmasının Naive Bayes algoritması olduğu görülmektedir. Naive Bayes algoritmasına ait karışıklık matrisi (TP, TN, FP ve FN değerleri) incelendiğinde TP sınıflandırılan örnek sayısı 197, FP sınıflandırılan örnek sayısı 15, TN sınıflandırılan örnek sayısı 145 ve FN sınıflandırılan örnek sayısı 3 olarak bulunmuştur. Toplamda doğru sınıflandırılan örnek sayısı 342 ve yanlış sınıflandırılan örnek sayısı 18 olarak tespit edilmiştir. Uzman yetki düzeyi için bağımsız bir test seti ile test edilen modelin performans sonuçları Çizelge 4.10’da verilmiştir:

Çizelge 4.10. Bağımsız bir test seti ile test edilen modelin performans sonuçları (uzman kullanıcı yetki düzeyi)

	Recall (Duyarlılık) =TP Rate	FP Rate	Precision (Kesinlik)	Specificity (Özgüllük)	F-Measure (F-Ölçütü)	ROC Area	Kappa statistic	Accuracy (Doğruluk)
J48 (C4.5)	0,98	0,075	0,942	0,925	0,961	0,967	0,909	95,555
SVM	0,96	0,075	0,941	0,925	0,95	0,943	0,887	94,44
CART	0,98	0,075	0,942	0,925	0,961	0,982	0,909	95,555
ANN (Multilayer Perceptron)	0,92	0,1	0,92	0,9	0,92	0,969	0,82	91,111
KNN (k=3)	0,98	0,075	0,942	0,925	0,961	0,983	0,909	95,55
RBF Network	0,96	0,075	0,941	0,925	0,95	0,981	0,887	94,44
Naive Bayes (Geliştirilen sistemde kodlanan algoritma)	0,98	0,075	0,942	0,925	0,961	0,9915	0,909	95,55

Çizelge 4.10’da verilen sınıflandırma algoritmaları incelendiğinde, uzman yetki düzeyinde bulunan nitelikler kullanıldığında Naive Bayes, J48, CART ve KNN (k=3) algoritmalarının doğruluk yüzdelerinin eşit ve en yüksek doğruluk yüzdesi (%95,55) olduğu görülmektedir. Diğer algoritmaların doğruluk yüzdeleri incelendiğinde yaklaşık olarak tüm algoritmaların birbirine yakın doğruluk yüzdelerine sahip olduğu tespit edilmiştir. En yüksek doğruluk yüzdelerine sahip bu dört algoritmaya ait ROC değerleri incelendiğinde Naive Bayes algoritmasına ait bu değerin (0,9915) daha yüksek olduğu görülmektedir. Naive Bayes algoritmasına ait ROC eğrisi Şekil 4.9.’da verilmiştir.



Şekil 4.9. Bağımsız bir test seti ile test edilen modelin Naive Bayes algoritmasına ait ROC eğrisi (uzman kullanıcı yetki düzeyi)

Bağımsız bir test seti ile test edilen modelin örnek sayılarına göre karşılaştırma sonuçları Çizelge 4.11’de verilmiştir:


Çizelge 4.11. Bağımsız bir test seti ile test edilen modelin örnek sayılarına göre karşılaştırma sonuçları (uzman kullanıcı yetki düzeyi)

	J48 (C4.5)	SVM	CART	ANN (Multilayer Perceptron)	KNN (k=3)	RBF Network	Naive Bayes (Geliştirilen sistemde kodlanan algoritma)
Doğru Pozitif (TP)	49	48	49	46	49	48	49
Yanlış Negatif (FN)	1	2	1	4	1	2	1
Yanlış Pozitif (FP)	3	3	3	4	3	3	3
Doğru Negatif (TN)	37	37	37	36	37	37	37
Yanlış Olarak Sınıflandırılan Örnek Sayısı	4	5	4	8	4	5	4
Doğru Olarak Sınıflandırılan Örnek Sayısı	86	85	86	82	86	85	86

Çizelge 4.11 incelendiğinde doğru olarak sınıflandırılan örnek sayısının en yüksek olduğu sınıflandırma algoritmasının Naive Bayes algoritması olduğu görülmektedir. Naive Bayes algoritmasına ait karışıklık matrisi (TP, TN, FP ve FN değerleri) incelendiğinde TP sınıflandırılan örnek sayısı 49, FP sınıflandırılan örnek sayısı 3, TN sınıflandırılan örnek sayısı 37 ve FN sınıflandırılan örnek sayısı 1 olarak bulunmuştur. Toplamda doğru sınıflandırılan örnek sayısı 86 ve yanlış sınıflandırılan örnek sayısı 4 olarak tespit edilmiştir. Elde edilen bulgular incelendiğinde en yüksek performansı gösteren algoritmanın Naive Bayes algoritması olduğu (10-kat çapraz geçerleme yöntemine göre doğruluk yüzdesi=%95, bağımsız test verisi ile test edilen modelin doğruluk yüzdesi=%95,55) görülmüştür.

4.1.3. Açıklama Birimi

Bir uzman sistemin bilgi tabanını kullanarak elde ettiği çıkarımı açıklayabilme özelliğine sahip olması istenir [322]. DEHB'nin tahmin edilmesine yönelik geliştirilen sistemin öngörüsü kullanıcıya Resim 4.20'deki form ile gösterilmektedir:



Resim 4.20. Uzman kullanıcı yetki düzeyi açıklama birimi

Açıklama birimi kısmında DEHB'nin öngörülmesine yönelik elde edilen tahmin sonucu ve analiz bulguları kullanıcılara iletilmektedir.

5. TARTIŞMA VE SONUÇLAR

Bu çalışmada; çocuk psikiyatristlerinin alan uzmanlığı doğrultusunda, çocukta DEHB durumunun olup olmadığını tahmin edebilen bir erken uyarı sistemi geliştirilmiş ve oluşturulan DEHB bilgi tabanı kullanılarak sınıflandırma algoritmalarının performansları karşılaştırılmıştır.

Literatürde konu ile ilgili benzer çalışmalar incelendiğinde, hastalık ön tanı çıkarımında uzman sistemlerin yaygın olarak kullanıldığı görülmektedir. Alan uzmanlarının hastalık tanısında izledikleri karmaşık ve deneyim gerektiren karar verme süreçleri uzman sistemlere aktarılmaktadır. Yapılan psikiyatri alanındaki çalışmalarda uzman sistemlerin kullanılarak etkili sonuçlar elde edildiği ve mental bozuklukların taramasında uzman sistemlerin kullanıldığı görülmüştür [323-324]. Şizofreni tespitinde kullanılmak üzere çeşitli uzman sistemler tasarlanmışlardır [224, 325-326]. Geliştirilen sistemlerden bazıları şizofreni hastalarının EEG sinyallerinden yola çıkarak ön tanı koyarken [327], bazıları da f-MRI fonksiyonel manyetik rezonans resimlerini kullanarak beyindeki örüntülerin anormalliklerinin analizini yaparak ön tanı koymaktadır [328]. Yapılan çalışmalar incelendiğinde; Alzheimer hastalığı [246], uyku bozukluğu [329-330] ve bipolar bozukluk [331] gibi daha birçok mental bozuklukların erken tanısında uzman sistemlerin benzer bir şekilde kullanıldığı ve etkili sonuçlar elde edildiği rapor edilmiştir. Diğer tıbbi alanlardaki, tüberküloz [332], akciğer kanseri [333], meme kanseri [334] ve tiroit hastalığı [335] gibi birçok hastalığın değerlendirilmesinde de paralel bir şekilde uzman sistemlerin kullanıldığı görülmektedir.

Çalışmada ilk olarak, alan uzmanlarının DEHB tanısı koyarken kullandıkları cinsiyet, çocuğun akademik başarısı, öğretmen ve ebeveyn olumsuz dönüt bilgisi, erken doğum öyküsü, annenin gebelik süreci gibi tanı kriterlerini ve 450 adet kliniksel hasta verisini içeren bir “DEHB bilgi tabanı” oluşturulmuştur. Geliştirilen uzman sistemin bilgi tabanına yeni kayıtlar eklenebilmekte, mevcut kayıtlar silinip, düzenlenebilmekte ve grafiksel olarak görüntülenebilmektedir yani sistemin performansının iyileştirilebilmesi için sistemin eğitilebilmesine fırsat verilmektedir. DEHB bilgi tabanının oluşturulması sistematik bir kayıt sisteminin geliştirilmesi, yeni kayıtların standardize edilmesi ve hazırlanan bu bilgi tabanının sonraki araştırmalara zemin oluşturması açısından önemlidir. Uzman sistemlerde bilgi tabanı; alan uzmanlarından alınan bilgilerin kullanılması, geçmiş

verilerin kullanılması, mevcut kuralların kullanılması ve algoritmalar ile kuralların rastgele oluşturulması gibi farklı yollar ile oluşturulabilir [261-263]. Uzman sistemler incelendiğinde bilgi tabanı oluşturulması sürecinde yaygın olarak alan uzmanlarının bilgisinin, geçmiş verilerin ve hem alan uzmanlarının bilgisinin hem de geçmiş verilerin birlikte kullanıldığı görülmektedir [151, 264, 267]. Bu çalışmada da bilgi tabanı oluşturulurken benzer şekilde hem çocuk psikiyatristlerin alan bilgisi hem de geçmişteki veriler kullanılmıştır. Fernando, Henskens ve Cohen (2011) psikiyatri alanında geliştirilen uzman sistemlerin alan uzmanlarından bağımsız bir şekilde geliştirildiği ve istenilen hedefe henüz ulaşmadığını belirtmişlerdir [32]. Alan uzmanlarından bağımsız geliştirilen çalışmaların ne kadar güvenilir olduğu tartışmalıdır.

Geliştirilen yazılımın yeteneği ve performansı öğrenme sürecinde kullanılan sınıflandırıcının performansı ile doğru orantılıdır. Bu nedenle sınıflandırıcıların performans analizi ve bu analizde kullanılacak metotlar önemlidir [143]. Bu tez çalışmasında geliştirilen sistemde herhangi bir sınıflandırıcı kodlanmadan önce sınıflandırıcıların performans analizleri karşılaştırılarak en yüksek performansı gösteren sınıflandırma algoritması seçilmiştir. Sınıflandırma algoritmalarının performans analizleri kontrol edilirken model başarımlarından doğruluk, duyarlılık, özgüllük, kesinlik, f-ölçütü, roc area ve kappa istatistiği değerleri kullanılmıştır. Uzman sistemlerin performanslarının ölçümü ile ilgili, literatürdeki çalışmalar incelendiğinde çalışmaların bir kısmında geliştirilen sistemlerin performanslarının ölçülmediği [22, 222-223], performansları ölçülen çalışmalar incelendiğinde ise model başarımlarından en çok roc eğrisi, doğruluk, duyarlılık ve özgüllük değerlerine göre performanslarının ölçüldüğü [151, 207, 336] görülmüştür. Polat ve Güneş (2007) sistemlerinin performansını ölçerken doğruluk (% 89,47), özgüllük (%92) ve duyarlılık (85,71) değerlerini kullanmışlardır [207]. Aishwarya ve Anto (2014) benzer şekilde çalışmalarının performanslarını doğruluk (%89,54), özgüllük (% 85.67) ve duyarlılık (%87.96) değerlerine göre ölçmüşlerdir [336]. David ve Jayachandran (2018) çalışmalarının performanslarını ölçerken aynı model başarımlarını (doğruluk =%97,55, duyarlılık =% 89,18 ve özgüllük = 97,074) kullanmışlardır. Ayrıca David ve Jayachandran (2018) çalışmalarında TP, TN, FP ve FN sayılarını da belirtmişlerdir [337]. Hossain, Rahaman, Mustafa ve Andersson (2017) çalışmalarında tanı sistemlerinin etkinliğini analiz etmek için roc eğrisinin yaygın olarak kullanıldığını ifade ederek çalışmalarının performanslarını ölçmede roc eğrisini ve roc area değerini sunmuşlardır [151]. Bu çalışmada da benzer şekilde sınıflandırma algoritmalarının

performans analizinde model başarımlar ölçütlerinden roc eğrisi, doğruluk, özgüllük ve duyarlılık ölçütleri kullanılmıştır. Ayrıca kesinlik, FP rate, kappa istatistik değerleri ve TP, FN, FP, TN sayıları da çalışmada verilmiştir.

DEHB'nin erken tanısına yönelik çalışmalarda kullanılan giriş parametreleri incelendiğinde genellikle EEG, MRI, fNIRS gibi nörogörüntüleme belirteçlerinin kullanıldığı tespit edilmiştir [40-42, 44]. Uzman sistemlerde; alan uzmanlarının düşünme biçimleri ve izledikleri süreçler geliştirilen sisteme aktarılır. Geliştirilen uzman sistem, DEHB öngörülmesine yönelik çocuk psikiyatristinin rolünü sanal olarak taklit etmektedir. Bu nedenle bu çalışmada nörogörüntüleme belirteçleri yerine, çocuk psikiyatristlerinin DEHB tanısına karar verirken kullandıkları parametreler sisteme aktarılmıştır. Kullanıcı yetki düzeyine göre geliştirilen sistemde kullanılan nitelikler farklılık göstermektedir. Uzman yetki düzeyinde 25 nitelik kullanılırken ebeveyn yetki düzeyinde 23 nitelik bilgisi kullanılmıştır. Ebeveyn kullanıcı düzeyinde bulunan kullanıcının, öğretmenin dolduracağı formdan gelen puanlara erişemeyeceği dikkate alınarak, iki nitelik bilgisinin (24.nitelik *Tattentionscore* ve 25. nitelik *Thyperactivityscore*) aldığı değerler kullanılmamıştır.

Çalışmada oluşturulan DEHB bilgi tabanı üzerinde SVM, J48, ANN, KNN, RBF Network ve Naive Bayes sınıflandırma algoritmalarının model başarımlar ölçütlerine göre karşılaştırmalı analizi yapılmıştır. Bu sınıflandırma algoritmaları literatürde en çok kullanılan algoritmalar arasındadır [318-319]. DEHB'nin sınıflandırılmasına ilişkin yapılan çalışmalarda kullanılan algoritmalar incelendiğinde en çok SVM algoritmasının kullanıldığı görülmüştür [42, 338-340]. SVM algoritmasının yanı sıra Diskriminant Fonksiyon Analizi [341-342], Sinir Ağları [343-344] ve RBF [345-346] algoritmalarının da sıklıkla kullanıldığı tespit edilmiştir. Bu tez çalışmasında da performansı karşılaştırılan algoritmalar arasında benzer şekilde SVM, ANN (Multilayer Perception algoritması) ve RBF algoritmaları bulunmaktadır. Performansları karşılaştırılan sınıflandırma algoritmaları arasında en yüksek başarımlar gösteren Naive Bayes algoritması kodlanarak geliştirilen uzman sistemin çıkarım mekanizmasında kullanılmıştır.

Sınıflandırma algoritmalarının doğruluk oranları karşılaştırılır iken bilgi tabanındaki veriler eğitim verileri ve test verileri olmak üzere iki gruba ayrılmıştır. Eğitim veri seti ve test veri seti oluşturulurken holdout yöntemi kullanılmıştır. Bu yöntemde, belli sayıda örnek sistemin performansının test edilmesi için ayrılır, geriye kalan örnekler ise sistemin

eğitilmesinde kullanılır. Model eğitim veri seti kullanılarak oluşturulur ve test veri seti kullanılarak model değerlendirilir. Bu tez çalışmasında 360 adet kayıt eğitim veri kümesi ve 90 adet kayıt test veri kümesi olarak ayrılmıştır. Sistemin başarımlarını değerlendirmesinde, a) ayrılan bu eğitim veri kümesi üzerinde 10-kat çapraz geçerleme yöntemi kullanılarak sistemin performansı doğrulanmış ve b) hold out yöntemi kullanılarak ayrılan bağımsız bir test verisi ile (90 adet kayıt) sistemin performansı test edilmiştir. Basit geçerleme yöntemi, çapraz geçerlilik yöntemi, k-kat çapraz geçerleme yöntemi, bootstrap örnekleme yöntemi ve hold out gibi çeşitli model performans değerlendirme yöntemleri bulunmaktadır [167, 194]. Uzman sistemlerin performans değerlendirme yöntemleri ile ilgili, literatürdeki çalışmalar incelendiğinde benzer şekilde 10-kat çapraz geçerleme yöntemi ile sistem performansının doğrulandığı [207, 336] veya bağımsız bir test verisi ile test edildiği [27, 337] görülmektedir. Bu tez çalışmasında hem 10-kat çapraz geçerleme yöntemi kullanılarak geliştirilen sistemin performansı onaylanmış hem de bağımsız bir test veri kümesi ile sistemin performansı test edilmiştir.

Çalışmada kullanılan veri kümesi 450 adet (200 DEHB tanısı alan ve 250 adet DEHB tanısı almayan) kliniksel hasta verilerinden oluşmaktadır. Çalışmalarda veri kümesinin büyüklüğü ile birlikte veri kümesinin temsil edebilirliği ve giriş parametresi sayısı da önemlidir [269]. DEHB'nin sınıflandırılmasına yönelik farklı yöntemler kullanılarak yapılan çalışmaların örneklem sayısı incelendiğinde, erişilebilen örnek sayısına göre farklılık gösterdiği görülmektedir. Tenev ve diğerleri (2014) çalışmalarında, 117 yetişkin (67 DEHB, 50 kontrol) hasta verisi kullanırken [43], Mueller, Candrian, Kropotov, Ponomarev ve Bascherave (2010) tarafından yapılan çalışmada 148 adet örneklem kullanılmıştır [338]. DEHB'nin sınıflandırılmasına yönelik bir içerik analizi çalışmasında örneklem sayısının 10 [347-348] ile 1177 [344] arasında geniş bir oranda değiştiği belirtilmektedir [349]. Her ne kadar 10 örneklem sayısını kullanan çalışmalar mevcutsa da, genel bir kural olarak, alınacak örneklem büyüklüğünün değişken sayısının en az 5 katı, hatta 10 katı civarında olması gerektiği vurgulanmaktadır. Ayrıca örneklem büyüklüğü olarak 50 çok zayıf, 100 zayıf, 200 orta, 300 iyi, 500 çok iyi, 1000 mükemmel olduğu söylenmektedir [350].

Model başarımlarını ölçütlerine göre performansları karşılaştırılan sınıflandırma algoritmaları arasında en yüksek başarımları gösteren Naive Bayes algoritması geliştirilen uzman sistemin çıkarım mekanizmasında kullanılmıştır. Geliştirilen sistemde; uzman, öğretmen ve

ebeveyn kullanıcı yetki düzeylerinde bağımsız bir test seti ile test edilen modelin Naive Bayes algoritmasına ait elde edilen a) doğruluk oranı b) duyarlılık değeri c) özgüllük değeri ve d) roc area değeri bulguları, literatürde DEHB'nin erken tanısına yönelik farklı yöntemler kullanılarak yapılan diğer çalışmaların bulguları ile aşağıda karşılaştırmalı olarak verilmiştir.

Uzman ve öğretmen yetki düzeylerinde; bağımsız bir test seti ile test edilen modelde karşılaştırılan sınıflandırma algoritmalarının tümünün başarı yüzdelерinin 0,90'dan büyük olduğu tespit edilmiştir. En yüksek performansı gösteren Naive Bayes algoritmasının doğruluk oranı %95,55'dir. Model başarıml ölçütlerinden roc-area, recall, specificity, precision ve f ölçüt değeri lerinin 1'e yakın olması durumu geliştirilen sistemin tesadüfi bir tahminde bulunmadığına işaret eder [320]. Çizelge 4.10 incelendiğinde söz konusu tüm değeri lerin (roc-area=0,991, recall=0,98, specificity = 0,925, precision=0,942, f-measure=0,961) 1'e yakın olduğu görülmektedir. Bu bulgu önemli derecede bir uyum olduğunu, geliştirilen uzman sistemin tesadüfi bir tahminde bulunmadığını göstermektedir.

Çizelge 4.6 incelendiğinde, ebeveyn yetki düzeyinde bağımsız bir test seti ile test edilen modelde karşılaştırılan algoritmalar dan en yüksek performansı gösteren Naive Bayes algoritmasının doğruluk oranı %93,33 olduğu görülmektedir. Naive Bayes algoritmasına ait roc-area değeri nin 0,967, recall değeri nin 0,96, specificity değeri nin 0,9, precision değeri nin 0,923 ve f ölçütünün 0,941 olduğu tespit edilmiştir. Yapılan çalışma ile DEHB bilgi tabanında bulunan nitelikler ile büyük bir kısmının açıklanabildiği sonucuna varılmıştır. Sistem 290 adet veri kümesi ile çalıştırılıp test edildiğinde %88,62 doğruluk oranı ile çalışırken [351] 450 adet veri kümesi ile çalıştırılıp test edildiğinde %95,55 doğruluk oranı ile çalıştığı tespit edilmiştir. Yani geliştirilen sistemin, ne kadar çok eğitilirse o kadar iyi sonuç verdiği gözlemlenmiştir.

DEHB'nin erken tanısına yönelik farklı yöntemler kullanılarak yapılan çalışmaların doğruluk oranı bulguları incelendiğinde; bazı çalışmaların doğruluk oranının bu tez çalışmasında bulunan doğruluk oranından (%95,55) daha düşük olduğu [340, 352-353], bazı çalışmaların doğruluk oranlarının ise bu tez çalışmasında bulunan doğruluk oranı ile paralellik gösterdiği [44, 338, 345] görülmüştür. Mohammadi ve diğerlerinin (2016) nörogörüntüleme belirteçlerinin kullanıldığı çalışmada doğruluk oranı %92,28, bulunmuş, özgüllük ve duyarlılık değeri verilmemiştir [44]. Johnston ve diğerleri (2014) yaptıkları

çalışmalarının %93 doğruluk oranına sahip olduğunu belirtmişlerdir [345]. Yine benzer şekilde Mueller, Candrian, Kropotov, Ponomarev ve Bascherave (2010) tarafından DEHB'nin sınıflandırılmasına ilişkin yapılan çalışma, %92 doğruluk oranına, %90 duyarlılık ve %94 özgüllük değerlerine sahiptir [338]. Bu çalışmalarda verilen doğruluk oranı bulguları, bu tez çalışmasında bulunan doğruluk oranı ile paralellik göstermektedir. Doğruluk oranı bulgusu daha düşük olan çalışmalar incelendiğinde; Igual ve diğerleri (2012) tarafından yapılan çalışma %72 doğruluk oranına, %60 duyarlılık ve %86 özgüllük değerlerine sahiptir [340]. Tan, Guo, Ren, Epstein ve Lu (2017) tarafından yapılan çalışmada, doğruluk oranı %69, duyarlılık oranı %78 ve özgüllük oranı % 57 bulunmuştur [352]. Yine benzer şekilde Dai, Wang, Hua ve He (2012) yaptıkları çalışmanın doğruluk oranını %59, duyarlılık değerini % 44 ve özgüllük değerini % 71 olarak bulmuşlardır [353]. Verilen doğruluk oranları arasındaki bu farklılıkların, çalışmalarda kullanılan giriş parametrelerinin, örneklem sayılarının ve kullanılan yöntemlerin farklılıklarından kaynaklandığı söylenebilir.

Sonuç olarak, geliştirilen dinamik uzman sistem ile çocukta DEHB durumunun olup olmadığını tahmin eden bir erken uyarı sistemi geliştirilmiştir. Sistem DEHB ile ilgili alan uzmanlarına yardımcı olmak, şikâyet ve tanı bilgileriyle ilgili bir DEHB bilgi tabanı oluşturmak ve DEHB'nin erken tanısına destek olmak amacıyla kullanılabilir. Geliştirilen uzman sistem, bilgi tabanındaki kayıtlar değiştirilerek farklı problemlerin çözümüne de uyarlanabilir.

Toplanan kayıtlar, Gazi Üniversitesi Çocuk Ruh Sağlığı ve Hastalıkları Polikliniğine başvuru yapan çocukların kliniksel verilerinden oluşmaktadır. Bu bağlamda kliniksel değerlendirme sonucunda, "DEHB olmayan" sınıfına ait çocukların, DEHB tanısı veya herhangi bir psikiyatrik bozukluk tanısı almasa bile okulla ilgili uyum sorunları, ergenlik sorunları, ders başarı durumunun düşük olması gibi bir problem sonucunda kliniğe başvurdıkları bilinmektedir. Bu nedenle, ileride yapılacak çalışmalarda hastalık tanısı bulunmayan grubun toplum popülasyonundan tesadüfi seçilmesi önerilebilir. Fakat tesadüfi seçilen grubun içinde hasta olan çocukların da bulunabileceği riski unutulmamalı ve bu riski ortadan kaldıracak tedbirlerin alınması gerekmektedir.

Bu çalışmada DEHB'nin öngörülmesine yönelik kullanılan nitelikler, Gazi Üniversitesi Çocuk Ruh Sağlığı ve Hastalıkları Anabilim Dalında, çalışılan alan uzmanları tarafından

belirlenmiş ve belirlenen bu niteliklere yönelik ayrıca literatür taraması yapılmıştır. İleride yapılacak uzman sistem çalışmalarında, hastalığın değerlendirilmesine yönelik daha çok sayıda alan uzmanı ile çalışılması önerilebilir. Bu sayede, alan uzman bilgisi çeşitliliğine fırsat vereceği ve alan uzmanları arasında bulunan fikir ayrılıklarının minimize edileceği düşünülmektedir.

Ayrıca geliştirilen uzman sistemin web üzerinden ulaşılabilir hale getirilmesiyle alan uzmanlarının kullanımına açılmasının, sistemde hali hazırda var olan kayıtların en ideal biçimini almasına katkı sağlayacağı ve en ideale yaklaşan kayıtlar sayesinde tüm ihtimallerin sürece katılmasıyla söz konusu uzman sistemin daha hızlı ve daha kesin DEHB ön tanısının konulmasına önemli oranda yardımcı olacağı öngörülmektedir.



KAYNAKLAR

1. Amerikan Psikiyatri Birliđi (APA). (2014). *Ruhsal Bozuklukların Tanısal ve Sayımsal El Kitabı, Beşinci Baskı (DSM-5), Tanı Ölçütleri Başvuru El Kitabı* (çev. Körođlu, E.). Ankara: Hekimler Yayın Birliđi. (Eserin orijinali 2013’de yayımlandı). 29-33.
2. Whalen, C. K., Henker, B., Jamner, L. D., Ishikawa, S. S., Floro, J. N., Swindle, R., Perwien, A. R., and Johnston, J. A. (2006). Toward mapping daily challenges of living with ADHD: Maternal and child perspectives using electronic diaries. *Journal of Abnormal Child Psychology*, 34(1), 111-126.
3. Weiss, M., and Murray, C. (2003). Assessment and management of attention-deficit hyperactivity disorder in adults. *Canadian Medical Association Journal (CMAJ)*, 168(6), 715-722.
4. Barkley, R. A. (2015). *Attention-Deficit Hyperactivity Disorder* (Fourth edition). Newyork, London: The Guilford Press.
5. Larsson, J. O., Larsson, H., and Lichtenstein, P. (2004). Genetic and environmental contributions to stability and change of ADHD symptoms between 8 and 13 years of age: a longitudinal twin study. *Journal of the American Academy of Child and Adolescent Psychiatry*, 43(10), 1267-1275.
6. Pliszka, S., and AACAP Work Group on Quality Issues. (2007). Practice parameter for the assessment and treatment of children and adolescents with attention-deficit/hyperactivity disorder. *Journal of the American Academy of Child and Adolescent Psychiatry*, 46(7), 894-921.
7. Erdoğan, E. (2002). Dikkat eksikliđi hiperaktivite bozukluđunda frontal ve parietal bölge disfonksiyonları. *Klinik Psikiyatri*, 5, 145-150.
8. Tuđlu, C., ve Şahin, Ö. Ö. (2010). Erişkin dikkat eksikliđi hiperaktivite bozukluđu: Nörobiyoloji, tanı sorunları ve klinik özellikler. *Psikiyatride Güncel Yaklaşımlar*, 2(1). 75-116.
9. Öncü, B., ve Şenol, S. (2002). Dikkat eksikliđi hiperaktivite bozukluđunun etiyojisi: Bütüncül yaklaşım. *Klinik Psikiyatri Dergisi*, 5(2), 111-119.
10. Insel, T. R. (2014). The NIMH research domain criteria (RDoC) project: Precision medicine for psychiatry. *American Journal of Psychiatry*, 171(4), 395-397.
11. Seixas, F., Zadrozny, B., Laks, J., Conci, A., and Saadea, D. C. M. (2014). A Bayesian network decision model for supporting the diagnosis of dementia, Alzheimer’s disease and mild cognitive impairment. *Computers in Biology and Medicine*, 51, 140–158.

12. Zarinbal, M., Zarandi, M. F., Turksen, I. B., and Izadi, M. (2015). A type-2 fuzzy image processing expert system for diagnosing brain tumors. *Journal of Medical Systems*, 39(110), 1-20.
13. Zhang, X., Hu, B., Ma, X., Moore, P., and Chen, J. (2014). Ontology driven decision support for the diagnosis of mild cognitive impairment. *Computers in Biology and Medicine*, 113, 781–791.
14. Allahverdi, N. (2002). *Uzman Sistemler: Bir Yapay Zeka Uygulaması*. İstanbul: Atlas Yayıncılık, 16-20.
15. Ünsal, Ö. (2011). *Mesleki Alan Seçimlerinin Makine Öğrenmesi Algoritması Kullanılarak Belirlenmesi*, Yüksek Lisans Tezi, Gazi Üniversitesi Bilişim Enstitüsü, Ankara, 3-30.
16. Kai, W., Vijayashree, J., and Jayashree, J. (2017). Fuzzy logic-based diagnosis system for mental illness. *Journal of Computer and Mathematical Sciences*, 8, 210-217.
17. Hossain, M. S., Monrat, A. A., Hasan, M., Karim, R., Bhuiyan, T. A., and Khalid, M. S. (2016, May). *A belief rule-based expert system to assess mental disorder under uncertainty*. In Informatics, Electronics and Vision (ICIEV), 2016 5th International Conference on IEEE, 1089-1094.
18. Kan, L. V., Kuznetsova, Y. M., and Miraculous, N. V. (2010). Expert systems in the field of psycho-diagnostics. *Artificial Intelligence and Decision Making*, 2, 26-35.
19. De Bruin, H., Hasey, G., Khodayari-Rostamabad, A., Maccrimmon, D., and Reilly, J. (2016). *Expert system for determining patient treatment response*. U.S. Patent No. 9460400. Washington, DC: U.S. Patent and Trademark Office.
20. Coulson, J. S. (2000). SHHHH: An expert system for the management of clients with vocally disruptive behaviors in dementia. *Educational Gerontology*, 26(4), 401-408.
21. Brasil, L. M., De Azevedo, F. M., and Barreto, J. M. (2001). A hybrid expert system for the diagnosis of epileptic crisis. *Artificial intelligence in medicine*, 21(1-3), 227-233.
22. Goel, P., and Sharma, D. (2014). Implementation of expert system for medical assistance in disruptive mood disorders (ESDMD). *International Journal of Computer Applications*, 106(2), 32-37.
23. Hole, K. R., and Gulhane, V. S. (2014). Rule-based expert system for the diagnosis of memory loss diseases. *International Journal of Innovative Science, Engineering & Technology*, 1(3), 80-83.
24. Roca-Bennasar, M., Garcia-Mas, A., Llaneras, N., and Blat, J. (1991). Kraepelin: An expert system for the diagnosis of obsessive-compulsive disorders. *European psychiatry*, 6(4), 171-175.

25. Herrero, B., Laita, L. M., Roanes-Lozano, E., Maojo, V., de Ledesma, L., Crespo, J., and Laita, L. (2002). *A Symbolic Computation-Based Expert System for Alzheimer's Disease Diagnosis*. In: Calmet J., Benhamou B., Caprotti O., Henocque L., Sorge V. (editor) *Artificial Intelligence, Automated Reasoning, and Symbolic Computation*, Springer, Berlin, Heidelberg, 38-50.
26. Zekri, F., and Bouaziz, R. (2016, October). *Rule management in clinical decision support expert system for the alzheimer disease*. In *International Conference on Knowledge Science, Engineering and Management*, Springer, Cham. 465-477.
27. Riza, L. S., Pradini, M., and Rahman, E. F. (2017, March). *An expert system for diagnosis of sleep disorder using fuzzy rule-based classification systems*. In *IOP Conference Series: Materials Science and Engineering*, IOP Publishing, 185(1), 1-6.
28. Hassan, A. R., and Haque, M. A. (2017). An expert system for automated identification of obstructive sleep apnea from single-lead ECG using random under sampling boosting. *Neurocomputing*, 235, 122-130.
29. Yong, S. P., Awang Rambli, D. R., and Anh, N. T. M. (2007, October). *Depression consultant expert system*. 6th Annual Seminar on Science and Technology, Tawau, Sabah, Malaysia.
30. Randa, C. P. B., and Permanasari, A. E. (2014, November). *Development of diagnosis expert system for personality disorders*. In *Electrical Engineering and Informatics (MICEEI), 2014 Makassar International Conference on IEEE*, 180-183.
31. Chittooran, M. M. (1995), *Adhdexpert: The Development of a Prototype Expert System for Identification of Attention Deficit Hyperactivity Disorder*, Doctoral Dissertation, Mississippi State University, Mississippi State, USA.
32. Fernando, I., Henskens, F., and Cohen, M. (2011, July). *A domain specific expert system model for diagnostic consultation in psychiatry*. In *Software Engineering, Artificial Intelligence, Networking and Parallel/Distributed Computing (SNPD), 2011 12th ACIS International Conference on IEEE*, 3-6.
33. Amrit, C., Paauw, T., Aly, R., and Lavric, M. (2017). Identifying child abuse through text mining and machine learning. *Expert Systems with Applications*, 88(1), 402-418.
34. Garcia-Perez, E., Violante, A., and Cervantes-Perez, F. (1998). Using neural networks for differential diagnosis of Alzheimer disease and vascular dementia. *Expert Systems with Applications*, 14(1-2), 219-225.
35. Dias, R., Salvini, R., Nierenberg, A., and Lafer, B. (2016). Machine learning approach with baseline clinical data forecasting depression relapse in bipolar disorder. *Bipolar Disorders*, 18, 103-103.
36. Sun, Y., Tang, Y., Ding, S., Lv, S., and Cui, Y. (2011). Diagnose the mild cognitive impairment by constructing Bayesian network with missing data. *Expert Systems with Applications*, 38(1), 442-449.

37. Zhang, D., Wang, Y., Zhou, L., Yuan, H., Shen, D., and The Alzheimer's Disease Neuroimaging Initiative. (2011). Multimodal classification of Alzheimer's disease and mild cognitive impairment. *Neuroimage*, 55(3), 856-867.
38. Ramoni, R. B., Saccone, N. L., Hatsukami, D. K., Bierut, L. J., and Ramoni, M. F.. (2009). A testable prognostic model of nicotine dependence. *Journal of Neurogenet*, 23(3), 283-292.
39. Williams, J. A., Weakley, A., Cook, D. J., and Schmitter-Edgecombe, M. (2013, June). *Machine learning techniques for diagnostic differentiation of mild cognitive impairment and dementia*. In Workshops at the Twenty-Seventh AAAI Conference on Artificial Intelligence, 71-76.
40. Ghassemi, F., Hassan_Moradi, M., Tehrani-Doost, M., and Abootalebi, V. (2012). Using non-linear features of EEG for ADHD/normal participants' classification. *Procedia-Social and Behavioral Sciences*, 32, 148-152.
41. Qureshi, M. N. I., Oh, J., Min, B., Jo, H. J., and Lee, B. (2017). Multi-modal, multi-measure, and multi-class discrimination of ADHD with hierarchical feature extraction and extreme learning machine using structural and functional brain MRI. *Frontiers in Human Neuroscience*, 11, 1-16.
42. Sidhu, G. S., Asgarian, N., Greiner, R., and Brown, M. R. (2012). Kernel Principal Component Analysis for dimensionality reduction in fMRI-based diagnosis of ADHD. *Frontiers in Systems Neuroscience*, 6, 1-16.
43. Tenev, A., Markovska-Simoska, S., Kocarev, L., Pop-Jordanov, J., Müller, A., and Candrian, G. (2014). Machine learning approach for classification of ADHD adults. *International Journal of Psychophysiology*, 93(1), 162-166.
44. Mohammadi, M. R., Khaleghi, A., Nasrabadi, A. M., Rafieivand, S., Begol, M., and Zarafshan, H. (2016). EEG classification of ADHD and normal children using non-linear features and neural network. *Biomedical Engineering Letters*, 6(2), 66-73.
45. Peng, X., Lin, P., Zhang, T., and Wang, J. (2013). Extreme learning machine-based classification of ADHD using brain structural MRI data. *PLOS One*, 8(11), 1-12.
46. Ercan, S. E., Mukaddes, N. M., Yazgan Y., Akay, A., ve Yıldız, Ö. (2013). *Türkiye Dikkat Eksikliği Hiperaktivite Bozukluğu Uzman Görüşü Raporu*. Türkiye, 3-12.
47. MEGEP. (2016). *DEHB ve Kaynaştırma. Çocuk Gelişimi ve Eğitimi Modülü*. Ankara: Millî Eğitim Bakanlığı, 7-11.
48. Esmailpoor, Z., Nasrabadi, A. M., and Malayeri, S. (2015, May). *An auditory brainstem response-based expert system for ADHD diagnosis using recurrence qualification analysis and wavelet support vector machine*. In Electrical Engineering (ICEE) 23rd Iranian Conference on IEEE, 6-10.

49. Fakhrahmad, S. M., Sadreddini, M. H., and Zolghadri Jahromi, M. (2015). A proposed expert system for word sense disambiguation: deductive ambiguity resolution based on data mining and forward chaining. *Expert Systems*, 32(2), 178-191.
50. Oktoria, Yang, C. H. and Chuang, L. Y. (2016). An Application of expert system for diagnosing fever caused by viral infection. *Journal of Life Sciences and Technologies*, 4(1), 17-21.
51. Kamley, S., Jaloree, S., and Thakur, R. S. (2016). Performance comparison between forward and backward chaining rule based expert system approaches over global stock exchanges. *International Journal of Computer Science and Information Security*, 14(3), 74.
52. Matthew, O., Buckley, K., Garvey, M., and Moreton, R. (2016). Multi-tenant database framework validation and implementation into an expert system. *International Journal of Advanced Studies in Computers, Science and Engineering*, 5(8), 13-21.
53. Bussing, R., Lebninger F., and Eyberg S. (2006). Difficult child temperament and attentiondeficit/hyperactivity disorder in preschool children. *Infants and Young Children*, 19, 123-131.
54. Egger, H. L., Kondo, D., and Angold, A. (2006). The epidemiology and diagnostic issues in preschool attention deficit/hyperactivity disorder: A review. *Infants and Young Children*, 19(2), 109-122.
55. Barkley, R. A., Fischer, M., Smallish, L., and Fletcher, K. (2006). Young adult outcome of hyperactive children: Adaptive functioning in major life activities. *Journal of the American Academy of Child & Adolescent Psychiatry*, 45(2), 192-202.
56. Akay, A. P., Ercan E. S., Perçinel İ., Ardiç Ü. A., Güney S. A., Demirkaya S. K., Öztürk Y., Güler A. S. ve Yazıcı H. U. (2016), *Çocuk ve Ergen Ruh Sağlığı ve Hastalıkları*, Türkiye Çocuk ve Genç Psikiyatri Derneği Yayınları, 33-55.
57. Biederman, J., Faraone, S. V., Mick, E., Williamson, S., Wilens, T. E., Spencer, T. J., Weber, W., Jetton, J., Kraus, I., Pert, J., and Zallen, B. (1999). Clinical correlates of ADHD in females: findings from a large group of girls ascertained from pediatric and psychiatric referral sources. *Journal of the American Academy of Child & Adolescent Psychiatry*, 38(8), 966-975.
58. Doğangün, B., ve Yavuz, M. (2011). Dikkat eksikliği hiperaktivite bozukluğu. *Türk Pediatri Arşivi*, 46(11), 25-28.
59. Merrell, C., and Tymms, P. B. (2001). Inattention, hyperactivity and impulsiveness: Their impact on academic achievement and progress. *British Journal of Educational Psychology*, 71(1), 43-56.

60. Ercan, E. S., ve Aydın, C. (2000). *Dikkat Eksikliği Hiperaktivite Bozukluğu Özellikleri, Tedavisi Çocuklarda ve Erişkinlerde Belirtileri*. Ercan, E.S. (Editör). Dikkat Eksikliği Hiperaktivite Bozukluğu (Üçüncü baskı). İstanbul: Gendaş.
61. Özmen, S. K. (2010). Okulda dikkat eksikliği ve hiperaktivite bozukluğu (DEHB). *Mersin Üniversitesi Eğitim Fakültesi Dergisi*, 6(2), 1-10.
62. Rowland, A. S., Lesesne, C. A., and Abramowitz, A. J. (2002). The epidemiology of attention-deficit/hyperactivity disorder (ADHD): A public health view. *Developmental Disabilities Research Reviews*, 8(3), 162-170.
63. Semerci, Z. B., ve Turgay, A. (2011). *Bebeklikten Erişkinliğe Dikkat Eksikliği-Hiperaktivite Bozukluğu* (Beşinci baskı). İstanbul: Alfa Basım Yayım Dağıtım, 52-67.
64. Abalı, O. (2012). *Hiperaktivite ve Dikkat Eksikliği* (Üçüncü baskı). İstanbul: Adeda Yayıncılık, 39-40.
65. Kayaalp, L. (2008). *Dikkat Eksikliği Hiperaktivite Bozukluğu*. Sürekli Tıp Eğitimi Etkinlikleri Sempozyum Dizisi, 62, 147-152.
66. Biederman, J. (2005). Attention-deficit/hyperactivity disorder: A selective overview. *Biological psychiatry*, 57(11), 1215-1220.
67. Lewis, M., and Rudolph, K. D. (Eds.). (2014). *Handbook of Developmental Psychopathology*. New York and London: Springer Science and Business Media, 427-442.
68. Cortese, S. (2012). The neurobiology and genetics of attention-deficit/hyperactivity disorder (ADHD): What every clinician should know. *European Journal of Paediatric Neurology*, 16(5), 422-433.
69. Sürücü, Ö. (2003). *Anababa-Öğretmen El Kitabı, Dikkat Eksikliği Hiperaktivite Bozukluğu*. İstanbul: YA-PA Yayınları, Turan Ofset.
70. Barkley, R. A., Edwards, G., Laneri, M., Fletcher, K., and Metevia, L. (2001). Executive functioning, temporal discounting, and sense of time in adolescents with attention deficit hyperactivity disorder (ADHD) and oppositional defiant disorder (ODD). *Journal of Abnormal Child Psychology*, 29(6), 541-556.
71. Rutter, M., Cox, A., Tupling, C., Berger, M., and Yule, W. (1975) Attainment and adjustment in two geographical areas: The prevalence of psychiatric disorders. *The British Journal of Psychiatry*, 126, 493-509.
72. Şenol, S. (2008). *Dikkat Eksikliği Hiperaktivite Bozukluğu, Çocuk ve Ergen Psikiyatrisi Temel Kitabı*, Çuhadaroglu, Ç. (Editör). Ankara: Çocuk ve Gençlik Ruh Sağlığı Derneği Yayınları, 293-311.

73. Biederman, J., Milberger, S., Faraone, S. V., Kiely, K., Guite, J., Mick, E., Ablon S, Warburton R, and Reed, E. (1995). Family environment risk factors for attention-deficit hyperactivity disorder: A test of Rutter's indicators of adversity. *Archives of General Psychiatry*, 52(6), 464-470.
74. Turgay, A. (2001). *Dikkat Eksikliği ve Hiperaktivite Bozukluğunda Yaşam Boyu Değişim, Dikkat Eksikliği Hiperaktivite Bozukluğu ve Özgül Öğrenme Güçlüğü*. Ankara: Ankara Üniversitesi Basımevi, 111-132.
75. Willcutt, E. G. (2012). The prevalence of DSM-IV attention-deficit/hyperactivity disorder: A meta-analytic review. *Neurotherapeutics*, 9(3), 490-499.
76. Turgay, A. (1997). *Gençlerde Dikkat Eksikliği ve Hiperaktivite Bozukluğu (DEHB): Sınıflandırma, Tanı ve Tedavide Yenilikler, Ergenlikte Ruhsal Sorunlara Yaklaşım*. Türkiye: Ege Psikiyatri Sürekli Yayınları, 2(3), 413-452.
77. Kandemir, H. (2009). *Dikkat Eksikliği Hiperaktivite Bozukluğu Olan Çocuklar ve Ailelerinde Yaşam Kalitesinin Değerlendirilmesi*, Tıpta Uzmanlık Tezi, Ankara Üniversitesi, Tıp Fakültesi, Ankara, 1-2.
78. Elhadeif, S. (2017). *Zihin Kuramı Çerçevesinde Dikkat Eksikliği ve Hiperaktivite Bozukluğu Olan Çocukların Duygu Tanıma ve Diğer Kişilerin Zihinsel Durumlarını Temsil Performansları*, Yüksek Lisans Tezi, Beykent Üniversitesi Sosyal Bilimler Enstitüsü, İstanbul, 3-25.
79. Kelly, D. P., and Aylward, G. P. (1992). Attention deficits in school-aged children and adolescents: current issues and practice. *Pediatric Clinics of North America*, 39(3), 487-512.
80. Börekçi, B. (2017). *Okul Öncesi Çocuklarda Dikkat Eksikliği Hiperaktivite Bozukluğu Belirtilerinin, Davranışsal, Sosyal Problemler, Aile İşlevselliği ve Ebeveyn Tutumları ile İlişkilerinin Değerlendirilmesi*, Yüksek Lisans Tezi, Işık Üniversitesi Sosyal Bilimler Enstitüsü, İstanbul, 15-16.
81. Erman, Ö. (2001). Dikkat eksikliği hiperaktivite bozukluğunda anne baba öğretmen eğitimi: Gözden geçirme. *Çocuk ve Gençlik Ruh Sağlığı Dergisi*, 8(1), 39-47.
82. Sharda, R., Delen, D., Turban, E., Aronson, J., Liang, T., and King, D. (2014). *Business Intelligence and Analytics: Systems for Decision Support* (Tenth edition). USA: Pearson, 477-480.
83. Nabiyev, V. V. (2012), *Yapay Zeka*. Ankara: Seçkin Yayıncılık.
84. Tetik, İ. (2009). *Uzman Sistem Tasarlayabilen Bir Bilgisayar Programının Geliştirilmesi*, Yüksek Lisans Tezi, Afyon Kocatepe Üniversitesi Fen Bilimleri Enstitüsü, Afyon, 5-35.
85. Çınar, M. (2007). *Prostat Kanseri Riskinin Tespitinde Sınıflandırıcı Tabanlı Uzman Sistem Kullanımı*, Yüksek Lisans Tezi, Ege Üniversitesi Fen Bilimleri Enstitüsü, İzmir, 9-45.

86. Koçyiğit, N. (2008). *Merkezi Klima Sistemlerinde Arıza Giderme ve İşletim İçin Bilgi Tabanlı Uzman Sistem Geliştirilmesi*, Doktora Tezi, Marmara Üniversitesi Fen Bilimleri Enstitüsü, 10-30.
87. Çayıroğlu, İ., ve Dizdar, E. N. (2006), Uzman sistem destekli online ders yerleştirme programı, *Teknoloji*, 9 (4), 283-293.
88. Çetinkaya, S. (2003). *Kara Kuvvetleri Personel Seçimi İçin Bir Uzman Sistem Tasarımı*, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul. 5-25.
89. Oruç, K., Anagün, A. S., ve Burnak, N. (1998). Kontrol grafiği seçiminde uzman sistem kullanımı, *Endüstri Mühendisliği*, 9 (4), 3-8.
90. Çöllü, O. (2009). *Uzman Sistem Yaklaşımı İle Web Tabanlı Personel Seçim Sisteminin Geliştirilmesi*, Yüksek Lisans Tezi, Celal Bayar Üniversitesi Sosyal Bilimler Enstitüsü, Manisa, 41-42.
91. Kethudaoğlu, A. (2012). *Uzman Sistem Kullanarak Tanıtılan Figürlerin Öğretimini Sağlayan Yazılım Tasarımı*, Yüksek Lisans Tezi, Karabük Üniversitesi Fen Bilimleri Enstitüsü, Karabük, 3-20.
92. Buchanan, B. G. and Smith, R. G. (1988). Fundamentals of expert systems. *Annual Review of Computer Science*, 3, 23-58.
93. Altuntaş, B. M. (2005). *Etkin Bir Tedarikçi Değerlendirme ve Seçme Süreci İçin Uzman Sistem Yaklaşımı*, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, 7-21.
94. Avcı, D. (2009). *Görülen Parazit Yumurtalarının Otomatik Sınıflandırılması İçin Bir Uzman Sistem Tasarımı*, Yüksek Lisans Tezi, Fırat Üniversitesi Fen Bilimleri Enstitüsü, Elâzığ, 8-9.
95. Kurbanoglu, S. (1992). Uzman sistemler. *Türk Kütüphaneciliği*, 6(4), 189-193.
96. Charniak, E., and McDermott, D. (1985), *Introduction to Artificial Intelligence*. Boston: Adisson-Wesley Longman Publishing.
97. İçen, D., ve Günay, S. (2014). Uzman sistemler ve istatistik. *İstatistikçiler Dergisi: İstatistik & Aktüerya*, 7, 37-45.
98. Harmon, P. and King, D. (1985). *Expert Systems*. New York: John Wiley.
99. Çakır, Ş. (2003). *Kara Kuvvetleri Mesaj İşleme ve Sınıflandırma Uzman Sistemi*, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul. 7-26.
100. Kar, F. (2012). *Bir İmalat İşletmesinde Süreçlerle Yönetim ve Uzman Sistem Uygulaması*, Yüksek Lisans Tezi, Sakarya Üniversitesi Fen Bilimleri Enstitüsü, Sakarya, 33-34.

101. Ata, U. (2010). *Uak Arıza Tespit Amalı Web Tabanlı Bulanık Uzman Sistem Tasarımı*, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, 12-13.
102. Anagün, A. S. (1997). Selecting inventory models using an expert system. *Computers and Industrial Engineering*, 33 (1-2), 299-302.
103. Yıldız, M. (2005). Bilişim teknolojilerinin uzman sistem boyutu ile analizi. *Seluk Üniversitesi Sosyal Bilimler MYO Dergisi*, 8(1-2), 189-212.
104. Negnevitsky, M. (2005). *Artificial intelligence: A Guide to Intelligent Systems* (Second edition). England: Pearson Education, 1-18.
105. Öztürk, V., ve Sönmez, A. C. (2006). Değerlendirme sistemleri için melez uzman sistem yaklaşımı. *İTÜ Dergisi/d Mühendislik*, 5(5), 3-14.
106. Akgöbek, Ö. ve akır, F. (2009, 11-13 Şubat). *Veri madenciliğinde bir uzman sistem tasarımı*. Akademik Bilişim'09- XI. Akademik Bilişim Konferansı Bildirileri, Şanlıurfa, 801-806.
107. Tagın, E., ve Taşaltın, R. (2000). Mekanizmaların tasarımında uzman sistemler, *Marmara Üniversitesi Fen Bilimleri Dergisi*, 16, 253-254.
108. Şahin, İ., ve Börklü, H. R. (2008). 2B görünüşlerden otomatik katı modeller oluşturmada uzman bir yaklaşım. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 14(2), 111-123.
109. Yeşiltepe, M. B. (2015). *Hitit Çivi Yazılı Metinlerin Okunmasında Uzman Sistem Uygulama Örnekleri*, Yüksek Lisans Tezi, Başkent Üniversitesi Fen Bilimleri Enstitüsü, Ankara, 13-14.
110. Özkan, M. T. ve Gülesin, M. (2001). Uzman sistem yaklaşımı ile civata ve dişli ark seçimi, *Türk Mühendislik ve Çevre Bilimleri Dergisi*, 25 (3), 169-177.
111. Dikgitmez, M. (2002). *MRP Sisteminde Bilgi Tabanlı Uzman Sistem Uygulaması*, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen bilimleri Fakültesi, İstanbul, 3-17.
112. Göztepe, K., Boran, S. ve Yazgan, H. R. (2012, 20-22 Haziran). *Siber saldırıların tespiti ve engellenmesi için uzman sistem tasarımı: Siber savunma uzman sistemi (SİSU)*. YAEM2012 (Yöneylem Araştırması ve Endüstri Mühendisliği 32.Ulusal Kongresi), İstanbul, 1-8.
113. Şahin, İ., Calp, M. H., ve Aka, Ö. (2011). Kredibilite notu değerlendirmeye yönelik bir uzman sistem yaklaşımı. *Politeknik Dergisi*, 14(1), 79-83.
114. Parsaye, K., and Chignell, M. (1988). *Expert Systems for Experts*. New York: John Wiley & Sons.

115. Vural, İ. (1998). *Kalite Kontrolünde Uzman Sistemler*, Yüksek Lisans Tezi, İstanbul Üniversitesi Sosyal Bilimler Enstitüsü, İstanbul, 6-20.
116. Öztemel, E. (2003). *Yapay Sinir Ağları*. İstanbul: Papatya Yayıncılık, 1-24.
117. Alpaydın, E. (2009). *Introduction to Machine Learning*. (Second edition). London: MIT Press, 1-19.
118. Amasyalı, M. F. (2008). *Yeni Makine Öğrenmesi Metotları ve İlaç Tasarımına Uygulamaları*, Doktora Tezi, Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, 93-95.
119. Berry, M. J., and Linoff, G. (2000). *Mastering Data Mining*. Newyork: John Wiley & Sons, 407-494.
120. Baykal, A. (2006). Veri madenciliği uygulama alanları. *DÜ Ziya Gökalp Eğitim Fakültesi Dergisi*, 7, 95-107.
121. Dalyan, T. (2006). *Makine Öğrenmesinde 1R Algoritması ve İkinci Kuralın(2R) Oluşturulması*, Yüksek Lisans Tezi, Kocaeli Üniversitesi Fen Bilimleri Enstitüsü, Kocaeli, 14-15.
122. Han, J., Kamber, M. and Pei, J. (2011). *Data Mining: Concepts and Techniques*. USA: Morgan Kaufmann Publishers, 1-14.
123. Liao, S. (2003). Knowledge management technologies and applications: Literature review from 1995 to 2002, *Expert Systems with Applications*, 2(25), 155–164.
124. Lantz, B. (2013). *Machine Learning with R*. Birmingham: Packt Publishing Ltd.
125. Baykasoğlu, A. (2005, 2-4 Şubat). *Veri madenciliği ve çimento sektöründe bir uygulama*. Akademik Bilişim Konferansı, Gaziantep Üniversitesi, Gaziantep, 1-14.
126. Kumar, K., and Thakur, G. S. M. (2012). Advanced applications of neural networks and artificial intelligence: A review. *IJ Information Technology and Computer Science*, 6, 57-68.
127. Rybina, G., and Rybin, V. (2005). Static and dynamic integrated expert systems: State of the art, problems and trends. *International Journal "Information Theories & Applications*, 12, 203-211.
128. Setyaputri, K. E., Fadlil, A., and Sunardi, S. (2018). Comparative analysis of certainty factor method and bayes probability method on ENT disease expert system. *Scientific Journal of Informatics*, 5(2), 205-212.
129. Bashir, S., Qamar, U., and Khan, F. H. (2016). WebMAC: A web based clinical expert system. *Information Systems Frontiers*, 20(5) 1135–1151.

130. Prasaddl, B., Prasad, P., and Sagar, Y. (2011). An approach to develop expert systems in medical diagnosis using machine learning algorithms (asthma) and a performance study. *International Journal on Soft Computing (IJSC)*, 2(1), 26-33.
131. Kaya, Y., and Tekin, R. (2012). An expert system for epileptic seizure detection based on extreme learning machine. *International Journal of Informatics Technologies*, 5(2), 33-40.
132. Vila-Frances, J., Sanchis, J., Soria-Olivas, E., Serrano, A. J., Martinez-Sober, M., Bonanad, C., and Ventura, S. (2013). Expert system for predicting unstable angina based on Bayesian networks. *Expert Systems with Applications*, 40(12), 5004-5010.
133. Castillo, E., Gutierrez, J. M., and Hadi, A. S. (2012). Expert systems and probabilistic network models. Springer Science & Business Media. 8-10.
134. Yavaş, A., and Civalek, Ö. (2005) Yapı hasarlarının belirlenmesinde uzman sistemlerin kullanımı. *Türkiye Mühendislik Haberleri, Türkiye İnşaat Mühendisleri Odası*, (439-440), 5-6.
135. Ojeme, B., Mbogho, A., and Meyer, T. (2016, December). *Probabilistic expert systems for reasoning in clinical depressive disorders*. In Machine Learning and Applications (ICMLA), 15th IEEE International Conference on IEEE, 599-604.
136. Mottalib, M. M., Rahman, M. M., Habib, M. T., and Ahmed, F. (2016). Detection of the onset of diabetes mellitus by Bayesian classifier based medical expert system. *Transactions on Machine Learning and Artificial Intelligence*, 4(4), 1-8.
137. Hassan, N., Arbaity, N., Shah, N. A. A., and Afizah, Z. (2017). Fuzzy expert system for heart attack diagnosis. In *Materials Science and Engineering Conference Series*, 226(1), 1-7.
138. Motlagh, H. A. M., Bidgoli, B. M., and Fard, A. A. P. (2017). Design and implementation of a web-based fuzzy expert system for diagnosing depressive disorder. *Applied Intelligence*, 1-12.
139. Nguyen, D. D. (2017). Designing optimal knowledge base for neural expert systems. *International Business Research*, 10(6), 137-144.
140. Cowell, R. G., Lauritzen, S. L., and Mortera, J. (2011). Probabilistic expert systems for handling artifacts in complex DNA mixtures. *Forensic Science International: Genetics*, 5(3), 202-209.
141. Ballin, M., Scanu, M. and Vicard, P. (2010). Estimation of contingency tables in complex survey sampling using probabilistic expert systems. *Journal of Statistical Planning and Inference*, 140 (6), 1501-1512.
142. Nagori, V., and Trivedi, B. (2014). Types of expert system: Comparative study. *Asian Journal of Computer and Information Systems*, 2(2), 20-33.

143. Kocamaz, A. F. (2012). *Makine Öğrenmesi Tabanlı Bir Uzman Sistem Tasarımı*, Doktora Tezi, Trakya Üniversitesi Fen Bilimleri Enstitüsü, Edirne, 4-5.
144. Akgöbek, Ö., ve Kaya, S. (2011). Veri madenciliği teknikleri ile veri kümelerinden bilgi keşfi: Medikal veri madenciliği uygulaması. *E-Journal of New World Sciences Academy*, 6(1), 238-245.
145. Akgöbek, Ö., ve Öztemel, E. (2006). Endüktif öğrenme algoritmalarının kural üretme yöntemleri ve performanslarının karşılaştırılması. *Sakarya Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 10(1), 1-9.
146. Öz, E., ve Baykoç, Ö. F. (2004). Tedarikçi seçimi problemine karar teorisi destekli uzman sistem yaklaşımı. *Gazi Üniversitesi. Mühendislik ve Mimarlık Fakültesi Dergisi*, 19(3), 275-286.
147. Chu, C. M., Chien, W. C., Lai, C. H., Bludau, H. B., Tschai, H. J., Pai, L., Hsieh, S. M., Chu, N. F., Klar, A., Haux, R., and Wetter, T. (2009). A Bayesian expert system for clinical detecting coronary artery disease. *Journal of Medical Sciences*, 29(4), 187-194.
148. Tekerek, A. (2011). Veri madenciliği süreçleri ve açık kaynak kodlu veri madenciliği araçları. *Akademik Bilişim*, 11, 2-4.
149. Kaya, M., ve Özel, S. A. (2014, 5-7 Şubat). *Açık kaynak kodlu veri madenciliği yazılımlarının karşılaştırılması*. Akademik Bilişim Konferansı Bildirileri, Mersin Üniversitesi, Mersin, 47-53.
150. Liang, N. Y., Saratchandran, P., Huang, G. B., and Sundararajan, N. (2006). Classification of mental tasks from EEG signals using extreme learning machine. *International Journal of Neural Systems*, 16(01), 29-38.
151. Hossain, M. S., Rahaman, S., Mustafa, R., and Andersson, K. (2017). A belief rule-based expert system to assess suspicion of acute coronary syndrome (ACS) under uncertainty. *Soft Computing*, 1-16.
152. Singla, J., and Grover, D. (2017). The diagnosis of diabetic nephropathy using neuro-fuzzy expert system. *Indian Journal of Science and Technology*, 10(28), 1-8.
153. Insani, M. I., Alamsyah, A., and Putra, A. T. (2018). Implementation of expert system for diabetes diseases using naïve bayes and certainty factor methods. *Scientific Journal of Informatics*, 5(2), 185-193.
154. Alonzo, A. L. D., Campos, J. J. M., Layco, L. L. M., Maratas, C. A., and Sagum, R. A. (2014). ENTDEx: ENT diagnosis expert system using bayesian networks. *Journal of Advances in Computer Networks*, 2(3), 182-187.
155. Fallahi, A., and Jafari, S. (2011). An expert system for detection of breast cancer using data preprocessing and bayesian network. *International Journal of Advanced Science and Technology*, 34, 65-70.

156. Zhang, C., and Zhang, S. (2002). *Association Rule Mining, Models and Algorithms*. Berlin: Springer.
157. Özkan, Y. (2008). *Veri Madenciliği Yöntemleri*. İstanbul: Papatya Yayıncılık Eğitim, 45-46.
158. Göker, H. (2012). *Üniversite Giriş Sınavında Öğrencilerin Başarılarının Veri Madenciliği Yöntemleri İle Tahmin Edilmesi*, Yüksek Lisans Tezi, Gazi Üniversitesi Bilişim Enstitüsü, Ankara, 29-30.
159. Soria, D., Garibaldi, J. M., Ambrogi, F., Biganzoli, E. M., and Ellis, I. O. (2011). A ‘non-parametric’ version of the naive Bayes classifier. *Knowledge-Based Systems*, 24(6), 775-784.
160. Daş, B. ve Türkoğlu, İ. (2014, 25-27 Eylül). *DNA dizilimlerindeki nükleotit çiftlerinin frekans değerlerine göre farklı sınıflandırma yöntemleri ile karşılaştırılması*, Tıp Teknolojileri Ulusal Kongresi, Kapadokya, 191-194.
161. Çalışkan, S. K. ve Soğukpınar, İ. (2008). K× KNN: K-means ve k en yakın komşu yöntemleri ile ağlarda nüfuz tespiti. *EMO Yayınları*, 120-124.
162. Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5-32.
163. Bounsaythip, C. and Esa, R. R. (2001). Overview of data mining for customer behavior modeling, *VTT Information Technology*, 18, 1-53.
164. Yang, D. P., Li, J., Ran, L., and Zhou, C. (2008). *Applications of Data Mining Methods in the Evaluation of Client Credibility*, Applications of Data Mining in E-Business and Finance C. Soares et al. (Editors.). Amsterdam: IOS Press, 35-43.
165. Pal, M., and Mather, P.M. (2003), An assessment of the effectiveness of decision tree methods for land cover classification, *Remote Sensing of Environment*, 86, 554-565.
166. Argüden, Y., Erşahin, B. (2008). *Veri Madenciliği: Veriden Bilgiye, Masraftan Değere*. İstanbul: ARGE Danışmanlık Yayınları, 38-40.
167. Akpınar, H. (2000). Veri tabanlarında bilgi keşfi ve veri madenciliği, *İstanbul Üniversitesi İşletme Fakültesi Dergisi*, 29(1), 1-22.
168. Wu, R. C., Chen, R. S., and Chian, S. S. (2006). Design of a product quality control system based on the use of data mining techniques. *IIE Transactions*, 38(1), 39-51.
169. Uğur, A., ve Kınacı, A. C. (2006). *Yapay zekâ teknikleri ve yapay sinir ağları kullanılarak web sayfalarının sınıflandırılması*. XI. Türkiye’de İnternet Konferansı (inet-tr’06), Ankara, 1-4.
170. Marakas, G. M. (2003). *Modern Data Warehousing, Mining, and Visualization: Core Concepts*. New Jersey: Prentice Hall, Upper Saddle River, 130-131.

171. Tekin, R., Kaya, Y. ve Tağluk, M. E. (2011, 5-7 Ekim). *K-means ve YSA temelli hibrit bir model ile epileptik EEG işaretlerinin sınıflandırılması*. Elektrik Elektronik Bilgisayar Semp. Fırat Üniversitesi, Elâzığ, 279-280.
172. Tosun, T. (2006). *Veri Madenciliği Teknikleriyle Kredi Kartlarında Müşteri Kaybetme Analizi*, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, 7-9.
173. Haykin, S. (1999). *Neural Networks: A Comprehensive Foundation*. New Jersey: Prentice Hall Inc, 318-319.
174. Mammadova, N. (2012). *Süt Sığırlarında Mastitisin Bazı Yapay Zekâ Yöntemleri Kullanılarak Erken Dönemde Tespiti*, Doktora tezi, Selçuk Üniversitesi Fen Bilimleri Enstitüsü, Konya, 9-15.
175. Ramkumar, G.D. and Swami, A. (1998). Clustering data without distance functions. *Bulletin of the IEEE Computer Society Technical Committee on Data Engineering*, 21(1), 9-14.
176. Çiçek, E. (2005). Müşteri ilişkileri yönetimini uygulama sürecinde başarıyı etkileyen faktörler. *Selçuk Üniversitesi Karaman İktisadi ve İdari Bilimler Dergisi*, 2(5), 60-72.
177. Tapkan, P., Özbakır, L. ve Baykasoğlu, A. (2011, 30 Eylül- 2 Ekim). *Weka ile veri madenciliği süreci ve örnek uygulama*. Endüstri Mühendisliği Yazılımları ve Uygulamaları Kongresi, 242-267.
178. Arslan, H. (2008). *Sakarya Üniversitesi Web Sitesi Erişim Kayıtlarının Web Madenciliği İle Analizi*, Yüksek Lisans Tezi, Sakarya Üniversitesi Fen Bilimleri Enstitüsü, Sakarya, 80-81.
179. Sarıman, G. (2011). Veri madenciliğinde kümeleme teknikleri üzerine bir çalışma: K-means ve K-medoids kümeleme algoritmalarının karşılaştırılması. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 15(3), 192-202.
180. Özdamar, K. (2004). *Çok Değişkenli Analizler*. Eskişehir: Kaan Kitabevi.
181. Koyuncugil, A. S. ve Özgülbaş, N. (2009). Veri madenciliği: Tıp ve sağlık hizmetlerinde kullanımı ve uygulamaları. *Gazi Üniversitesi Bilişim Teknolojileri Dergisi*, 2(2), 21-32.
182. Tunç, A. ve Ülger, İ. (2016, 30 Ocak- 5 Şubat). *Veri madenciliği uygulamalarında özellik seçimi için finansal değerlere binning ve five number summary metotları ile normalizasyon işleminin uygulanması*. XVIII. Akademik bilişim konferansı, Adnan Menderes Üniversitesi, Aydın, 1-8.
183. Almuallim, H. and Dietterich, T. (1991). *Learning with Many Irrelevant Features*. Menlo Park, CA: AAAI Press, 547-552.

184. Saeys, Y., Inza, I., and Larranaga, P. (2007). A review of feature selection techniques in bioinformatics, *Bioinformatics*, 23(19), 2507-2517.
185. Gümüşçü, A., Aydılek, İ. B., ve Taşaltın, R. (2016). Mikro-dizilim veri sınıflandırmasında öznitelik seçme algoritmalarının karşılaştırılması. *Harran Üniversitesi Mühendislik Dergisi*, 1(1), 1-7.
186. Gülgezen, G. (2009). *Kararlı ve Başarımı Yüksek Öznitelik Seçimi*, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, 1-10.
187. Quinlan, J. R. (1993). *C4.5: Programs for Machine Learning*, San Francisco: Morgan Kaufmann, 235-240.
188. Silahtaroglu, G. (2008). *Veri madenciliği kavram ve algoritmaları*, İstanbul: Papatya Yayıncılık, 15-83.
189. Ay, D. ve Çil, İ. (2008). Migros Türk A.Ş.' de birliktelik kurallarının yerleşim düzeni planlamada kullanılması, *Endüstri Mühendisliği Dergisi*, 21(2), 14-29.
190. İnternet: Hu, J. *About Data Mining: Basic Steps of Applying Machine Learning Methods*, URL: <http://www.aboutdm.com/2013/03/basic-steps-of-applying-machine.html>, Son Erişim Tarihi: 01.11.2017.
191. Topuz, M. D. (2014). *Makine Öğrenmesi Algoritmaları ve Anomali Tespiti*, Yüksek Lisans Tezi, Bahçeşehir Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, 2-11.
192. Esfandiari, N., Babavalian, M.R., Moghadam, A.M.E., and Tabar, V. K. (2014). Knowledge discovery in medicine: Current issue and future trend, *Expert System with Applications*, 41, 4434-4463.
193. Gökmen, Ş. (2015). *Müşteri İlişkileri Yönetiminde Bir Araç Olarak Veri Madenciliği ve Parekende Sektöründe Bir Uygulama*, Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi Sosyal Bilimler Enstitüsü, İstanbul, 45-46.
194. İnternet: Öğütücü, Ş. *İstanbul Teknik Üniversitesi Veri Madenciliği Şule Öğütücü Ders Notları*, URL: <http://ninova.itu.edu.tr/tr/dersler/bilisim-enstitusu/195/bbl-606/ekkaynaklar?g8396>, Son Erişim Tarihi: 01.11.2017.
195. İnternet: Chapman, P., Clinton, J., Kerber, R., Khabaza, T., Reinartz, T., Shearer, C., Wirth, R. *Crisp-dm 1.0: Step-by-step data mining guide*, SPSS Inc, URL: <https://www.the-modeling-agency.com/crisp-dm.pdf>, Son Erişim Tarihi: 02.11.2018.
196. Ordu, B. (2013). *Veri Madenciliğinde Sınıflayıcı Teknikler İle Demir Çelik Sektöründe Bir Uygulama*, Yüksek Lisans Tezi, Karabük Üniversitesi Sosyal Bilimler Enstitüsü, Karabük, 39-40.
197. Acar Şaylan, Ç. (2013). *Böbrek Nakli Geçirmiş Hastalarda Akıllı Yöntem Tabanlı Yeni Öznitelik Seçme Algoritması Geliştirilmesi*, Yüksek Lisans Tezi, Kadir Has Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, 17-18.

198. Yaralıoğlu, K. (2004). Uygulamada Karar Destek Yöntemleri, İzmir: İlkem Ofset.
199. Coşkun, C., ve Baykal, A. (2011). *Veri madenciliğinde sınıflandırma algoritmalarının bir örnek üzerinde karşılaştırılması*. Akademik Bilişim, Malatya, 1-8.
200. Güner, E.S. (2008). *Türkçe İçin Derlem Tabanlı Bir Anafor Çözümleme Çalışması*, Yüksek Lisans Tezi, Trakya Üniversitesi Fen Bilimleri Enstitüsü, Edirne, 36-38.
201. Akbulut, A. (2015, 15-18 Ekim). *Bilgisayar destekli otizm terapi sistemi tasarımı*, Tıp Teknolojileri Ulusal Kongresi, Muğla, 1-4.
202. Bunkhumpornpat, C., Sinapiromsaran K., Lursinsap C. (2009) *Safe-Level-SMOTE: Safe-Level-Synthetic Minority Over-Sampling TEchnique for Handling the Class Imbalanced Problem*. In: Theeramunkong T., Kijssirikul B., Cercone N., Ho TB. (eds) *Advances in Knowledge Discovery and Data Mining. PAKDD 2009. Lecture Notes in Computer Science*, vol 5476. Berlin: Springer. 475-482.
203. Raschka, S. (2015). *Python Machine Learning*. Birmingham: Packt Publishing Ltd. 191-196.
204. Metz, C. E. (1978). Basic principles of ROC analysis. *Seminars in nuclear medicine*, 8(4), 283-298.
205. Nizam, H., ve Akın, S. S. (2014, 27-29 Kasım). *Sosyal medyada makine öğrenmesi ile duygu analizinde dengeli ve dengesiz veri setlerinin performanslarının karşılaştırılması*. Türkiye'de İnternet Konferansı, Yaşar Üniversitesi, İzmir, 1-6.
206. Talan, M. İ. (2016). *Veri Madenciliği ile Karpal Tünel Sendromuna Yönelik Ön Tanı Destek ve Hasta Takip Sisteminin Geliştirilmesi*, Yüksek Lisans Tezi, Gazi Üniversitesi Bilişim Enstitüsü, Ankara, 29-30.
207. Polat, K., and Güneş, S. (2007). An expert system approach based on principal component analysis and adaptive neuro-fuzzy inference system to diagnosis of diabetes disease. *Digital Signal Processing*, 17(4), 702-710.
208. Cantor, A. B. (1996). Sample-size calculations for Cohen's kappa. *Psychological Methods*, 1(2), 150-151.
209. Ben-David, A. (2008). Comparison of classification accuracy using Cohen's Weighted Kappa. *Expert Systems with Applications*, 34(2), 825-832.
210. Landis, J. R., and Koch, G. G. (1977). The measurement of observer agreement for categorical data. *Biometrics*, 33, 159-174.
211. Krzanowski, W. J., and Hand, D. J. (2009). *ROC Curves for Continuous Data*. London: Chapman and Hall/CRC. 18-21.
212. Kılıç, S. (2013). ROC analysis in clinical decision making. *Journal of Mood Disorders*, 3(3), 135-136.

213. Fawcett, T. (2006). An introduction to ROC analysis. *Pattern Recognition Letters*, 27(8) 861-874.
214. Hanley, J. A., and McNeil, B. J. (1982). The meaning and use of the area under a receiver operating characteristic (ROC) curve. *Radiology*, 143(1), 29-36.
215. Hosmer, D. W., Lemeshow, S., and Sturdivant, R. (2013). *Applied Logistic Regression* (3 rd edition). New York: John Wiley & Sons.
216. Tsiptsis, K., and Chorianopoulos, A. (2010). *Data Mining Techniques in CRM: Inside Customer Segmentation*, Londra: John Wiley & Sons. Ltd., 19-20.
217. Sethi, H. (2016). Diabetes diagnoser: Expert system for diagnosis of diabetes type-II. *International Journal of Computer Applications*, 148(11), 19-25.
218. Babalık, A., ve Güler, İ. (2007). Boğaz enfeksiyonlarının teşhis ve tedavisinde uzman sistem kullanımı. *Selçuk-Teknik Dergisi*, 6 (2), 109-119.
219. Yılmaz, A. (2012). *Demir Eksikliği Anemisi Teşhisi İçin Bir Bulanık Uzman Sistem Tasarlanması*, Yüksek Lisans Tezi, Selçuk Üniversitesi Fen bilimleri Enstitüsü, Konya, 55-56.
220. Keleş, A., and Keleş, A. (2008). ESTDD: Expert system for thyroid diseases diagnosis, *Expert Systems with Applications*, 34(1), 242-246.
221. Başçiftçi, F. ve İncekara, H. (2011). İnternet tabanlı bulanık girişli uzman sistem tasarımıyla mikrobiyoloji tahlil sonuçlarının yorumlanması, *Selçuk Üniversitesi Teknik – Online Dergisi*, 10(1), 53-55.
222. Nunes, L. C., Pinheiro, P. R., and Pequeno, T. C. (2009, November). *An expert system applied to the diagnosis of psychological disorders*. In *Intelligent Computing and Intelligent Systems*, IEEE International Conference on IEEE, 363-367.
223. Cha, A. P., and Romli, A. (2010). Human-computer interaction of design rules and usability elements in expert system for personality-based stress management. *International Journal of Intelligent Computing Research*, 1(1/2), 33-42.
224. Manalu, S. R., Abbas, B. S., Gaol, F. L., and Trawiński, B. (2017). *An expert system to assist with early detection of schizophrenia*. In *Asian Conference on Intelligent Information and Database Systems*, Springer, Cham., 802-812.
225. Windriyani, P., Kom, S., Wiharto, S. T., Kom, M., and Sihwi, S. W. (2013, June). *Expert system for detecting mental disorder with forward chaining method*. In *ICT for Smart Society (ICISS)*, 2013 International Conference on IEEE, 1-7.
226. Al-Wahaibi, A., Al-Hajry, M., Al-Bahrani, Z., and Al-Busaidi, K. A. (2016). The development and acceptance of autism advisory expert system. *International Journal of Computing & Information Sciences*, 12(2), 179-188.

227. Marakakis, E., Vassilakis, K., Kalivianakis, E., and Micheloyiannis, S. (2005, December). *An expert system for epilepsy with uncertainty*. In AIML 05 Conference, 72-78.
228. Aydın, F. (2011). *Kalp Ritim Bozukluğu Olan Hastaların Tedavi Süreçlerini Desteklemek Amaçlı Makine Öğrenmesine Dayalı Bir Sistemin Geliştirilmesi*, Yüksek Lisans Tezi, Trakya Üniversitesi Fen Bilimleri Enstitüsü, Edirne, 3-5.
229. Dreiseitl, S., Ohno-Machado, L., Kittler, H., Vinterbo, S., Billhardt, H., and Binder, M. (2001). A comparison of machine learning methods for the diagnosis of pigmented skin lesions. *Journal of Biomedical Informatics*, 34(1), 28-36.
230. Çentik, G. (2013). *Makine Öğrenmesi Yöntemlerinin Polisomnografik Verilere Uygulanması*. Doktora Tezi, Trakya Üniversitesi Fen Bilimleri Enstitüsü, Edirne, 76-79.
231. Soliman, A. B., Fares, M., Elhefnawi, M. M., and Al-Hefnawy, M. (2016, September). *Features selection for building an early diagnosis machine learning model for Parkinson's disease*. In Artificial Intelligence and Pattern Recognition (AIPR), International Conference on IEEE, 1-4.
232. Demircioğlu, H. Z., ve Bilge, H. Ş. (2015). Yumurtalık kanseri veri kümesindeki gen ifadelerinin veri madenciliği ile analizi. *Marmara Fen Bilimleri Dergisi*, 27(4), 125-134.
233. Sorias, S. (2014). Psikiyatrik tanıda betimsel ve kategorik yaklaşımların kısıtlılıklarını aşmak: Bayes ağlarına dayalı bir öneri. *Türk Psikiyatri Dergisi*, 25, 1-12.
234. Suhasini, A., Palanivel, S., and Ramalingam, V. (2010). Multi decision support model for psychiatry problem. *International Journal of Computer Applications*, 1(25), 61-69.
235. Sumathi, M. R., and Poorna, B. (2016). Prediction of mental health problems among children using machine learning techniques. *International Journal of Advanced Computer Science and Applications*, 7(1), 552-557.
236. De la Fuente, J. M., Bengoetxea, E., Navarro, F., Bobes, J., and Alarcón, R. D. (2011). Interconnection between biological abnormalities in borderline personality disorder: use of the bayesian networks model. *Psychiatry Research*, 186(2), 315-319.
237. Chang, Y. S., Fan, C. T., Lo, W. T., Hung, W. C., and Yuan, S. M. (2015). Mobile cloud-based depression diagnosis using an ontology and a Bayesian network. *Future Generation Computer Systems*, 43, 87-98.
238. Anugraha, A., Vinotha, E., Anusha, R., Giridhar, S., and Narasimhan, K. (2017, June). *A machine learning application for epileptic seizure detection*. In Computational Intelligence in Data Science (ICCIDS) International Conference, 1-4.

239. Shoeb, A. H., and Guttag, J. V. (2010). *Application of machine learning to epileptic seizure detection*. In Proceedings of the 27th International Conference on Machine Learning, 975-982.
240. Guo, L., Rivero, D., Dorado, J., Rabunal, J. R., and Pazos, A. (2010). Automatic epileptic seizure detection in EEGs based on line length feature and artificial neural networks. *Journal of Neuroscience Methods*, 191(1), 101-109.
241. Hoexter, M. Q., Miguel, E. C., Diniz, J. B., Shavitt, R. G., Busatto, G. F., and Sato, J. R. (2013). Predicting obsessive-compulsive disorder severity combining neuroimaging and machine learning methods. *Journal of Affective Disorders*, 150(3), 1213-1216.
242. Askland, K. D., Garnaat, S., Sibrava, N. J., Boisseau, C. L., Strong, D., Mancebo, M., Greenberg, B., Rasmussen, S., and Eisen, J. (2015). Prediction of remission in obsessive compulsive disorder using a novel machine learning strategy. *International Journal of Methods in Psychiatric Research*, 24(2), 156-169.
243. Gath, S. J., and Kulkarni, R. V. (2012). A review: Expert system for diagnosis of myocardial infarction. *International Journal of Computer Science and Information Technologie*, 3(6), 5315-5321.
244. Doğantekin, E., Doğantekin, A., and Avcı, D. (2011). An expert system based on generalized discriminant analysis and wavelet support vector machine for diagnosis of thyroid diseases. *Expert Systems with Applications*, 38(1), 146-150.
245. Karabatak, M., and Ince, M. C. (2009). An expert system for detection of breast cancer based on association rules and neural network. *Expert Systems with Applications*, 36(2), 3465-3469.
246. Sigut, J., Piñeiro, J., Gonzalez, E., and Torres, J. (2007). An expert system for supervised classifier design: Application to alzheimer diagnosis. *Expert Systems with Applications*, 32(3), 927-938.
247. Swami, P., Godiyal, A. K., Santhosh, J., Panigrahi, B. K., Bhatia, M., and Anand, S. (2014, December). *Robust expert system design for automated detection of epileptic seizures using SVM classifier*, In Parallel, Distributed and Grid Computing (PDGC) International Conference IEEE, 219-222.
248. Masri, R. Y., and Jani, H. M. (2012, June). *Employing artificial intelligence techniques in mental health diagnostic expert system*. In Computer & Information Science (ICCIS), 2012 International Conference on IEEE, 495-499.
249. Leau, Y. B., Loo, W. K., Tham, W. Y., and Tan, S. F. (2012). Software development life cycle AGILE vs traditional approaches. In *International Conference on Information and Network Technology*, 37(1), 162-167.
250. Jalote, P. (2008). *A Concise Introduction to Software Engineering*, London: Springer, 13-28.

251. İnternet: Yılmaz a, G. (2007). Yazılım Mühendisliği Ders Notları, *Bölüm 2-Yazılım Geliştirme Yaşam Döngüsü*, Kültür Üniversitesi, İstanbul, 2, URL: <http://web.iku.edu.tr/~gyilmaz/>, Son Erişim Tarihi: 11.06.2018.
252. Macit, Y., ve Tüzün, E. (2015, 9-11 Eylül). *Uygulama yaşam döngüsü yönetimi karşılaştırmalı süreç incelemesi*. Ulusal Yazılım Mühendisliği Sempozyumu (UYMS), Yaşar Üniversitesi, İzmir, 122-133.
253. İnternet: Baykara, M. Yazılım Tasarım ve Mimarisi Ders Notları, *Bölüm 2-Yazılım Yaşam Döngüsü ve Süreç Modelleri*, Fırat Üniversitesi, Elâzığ, 4-16, URL: <http://web.firat.edu.tr/mbaykara/ytm2.pdf>, Son Erişim Tarihi: 11.06.2018.
254. Hewlett Packard (HP) Enterprise. (2017). *Brief: Agile is the New Normal: Adopting Agile Project Management*.1-4.
255. Agile Turkey. (2013) Software Productivity Report, Turkey, 1-30.
256. İnternet: Hashimi, J. *Agile (Çevik) Modelleme ve Çevik Yazılım Geliştirme*, 1-2, URL:<https://jamshidhashimi.com/agilecevik-modelleme-ve-cevik-yazilim-gelistirme>, Son Erişim Tarihi: 12.06.2018.
257. Highsmith, J. (2002, October). *What is Agile Software Development*. CrossTalk The Journal of Defense Software Engineering, 4-9.
258. Gencer, C., ve Kayacan, A. (2017). Yazılım proje yönetimi: Şelale modeli ve çevik yöntemlerin karşılaştırılması. *Bilişim Teknolojileri Dergisi*, 10(3), 335-352.
259. Alpaslan, G. ve Kalıpsız, O. (2014, 27-29 Kasım). *Çevik süreç ile model tabanlı yazılım geliştirme*. Elektrik – Elektronik – Bilgisayar ve Biyomedikal Mühendisliği Sempozyumu, 704-707.
260. Özbilgin, İ. G., ve Özlü, M. (2010, 10 – 12 Şubat). *Yazılım geliştirme süreçleri ve ISO 27001 bilgi güvenliği yönetim sistemi*. Akademik Bilişim Konferansı Bildirileri, Muğla Üniversitesi, Muğla, 1-14.
261. Xu, D. L., Liu, J., Yang J. B., Liu G. P., Wang, J., Jenkinson, I., and Ren, J. (2007). Inference and learning methodology of belief-rule-based expert system for pipeline leak detection. *Expert Systems with Applications*, 32(1), 103–113.
262. Yang, J. B., Liu, J., Xu, D. L., Wang, J., and Wang, H. W. (2007). Optimal learning method for training belief rule-based systems. *IEEE Transactions on Systems, Man, and Cybernetics (Part A)*, 37, 569-585.
263. Hossain, M. S., Habib, I. B., and Andersson, K. (2017). *A belief rule based expert system to diagnose dengue fever under uncertainty*. In Computing Conference 2017, 179-186.
264. Mahmood, N. T. (2016). Estimation medicine for diseases system to support medical diagnosis by expert system. *International Journal of Advanced Computer Science and Applications*, 7(9), 140-144.

265. Caballero-Ruiz, E., Garcia-Saez, G., Rigla, M., Villaplana, M., Pons, B., and Hernando, M. E. (2016). Automatic classification of glycaemia measurements to enhance data interpretation in an expert system for gestational diabetes. *Expert Systems with Applications*, 63, 386-396.
266. Alic, B., Gurbeta, L., Badnjevic, A., Badnjevic-Cengic, A., Malenica, M., Dujic, T., Causevic, A., and Bego, T. (2017). *Classification of metabolic syndrome patients using implemented expert system*. Proceedings of the International Conference on Medical and Biological Engineering, Springer, Singapore, 601-607.
267. Hossain, M. S., Ahmed, F., Johora, F. T. and Andersson, K. (2017). A belief rule based expert system to assess tuberculosis under uncertainty. *Journal of Medical Systems*, 41(43), 1-11.
268. Shao, Y., Liu, B., Li, G., and Yan, R. (2017, July). *A fault diagnosis expert system for flight control software based on SFMEA and SFTA*. In Software Quality, Reliability and Security Companion (QRS-C), 2017 IEEE International Conference on IEEE, 626-627.
269. Oğuzlar, A. (2003). Veri ön işleme. *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 21, 67-76.
270. Khozeimeh, F., Alizadehsani, R., Roshanzamir, M., Khosravi, A., Layegh, P., and Nahavandi, S. (2017). An expert system for selecting wart treatment method. *Computers in Biology and Medicine*, 81, 167-175.
271. Akhoondi, R., and Hosseini, R. (2016). A fuzzy expert system for prognosis of the risk of development of heart disease. *Journal of Advances in Computer Research*, 7(2), 101-114.
272. Wang, X., Qu, H., Liu, P., and Cheng, Y. (2004). A self-learning expert system for diagnosis in traditional Chinese medicine. *Expert Systems with Applications*, 26(4), 557-566.
273. Şeker, S. E. (2014). Yazılım deliştirme hayat döngüsü. *Yönetim Bilişim Sistemleri Ansiklopedisi*, 1(2), 1-5.
274. İnternet: Yılmaz b, G. *Yazılım Mühendisliği Ders Notları, Bölüm 7-Yazılım Doğrulama ve Geçerleme*, Kültür Üniversitesi, İstanbul, 3, URL: <http://web.iku.edu.tr/~gyilmaz/>, Son Erişim Tarihi: 11.06.2018.
275. Şeker, S. E. (2015). Yazılım geliştirme modelleri ve sistem/yazılım yaşam döngüsü. *Yönetim Bilişim Sistemleri Ansiklopedisi*, 2(3), 18-29.
276. Davis, J., and Goadrich, M. (2006, June). *The relationship between precision-recall and ROC curves*. In Proceedings of the 23rd International Conference on Machine Learning, 233-240.

277. Gül, N., Tiryaki, A., Kültür, S. E. C., Topbaş, M., and Ak, I. (2010). Prevalence of attention deficit hyperactivity disorder and comorbid disruptive behavior disorders among school age children in Trabzon. *Bulletin of Clinical Psychopharmacology*, 20(1), 50-56.
278. Polanczyk, G., and Rohde, L. A. (2007). Epidemiology of attention-deficit/hyperactivity disorder across the lifespan. *Current opinion in psychiatry*, 20(4), 386-392.
279. Staller, J., and Faraone, S. V. (2006). Attention-deficit hyperactivity disorder in girls. *CNS Drugs*, 20(2), 107-123.
280. Şenol, S., ve Şener Ş (1998). *Dikkat Eksikliği Hiperaktivite Bozukluğu*. (Güleç C, Köroğlu E, ed.). Temel Psikiyatri Kitabı. 1. Baskı, Ankara: Mediographics Basım Servisi, 1119-1131.
281. Aktepe, E. (2011). Dikkat Eksikliği Hiperaktivite Bozukluğu Tanısı Konan Çocuk ve Ergenlerde Eş Tanılar ve Sosyodemografik Özellikler. In *Yeni Symposium*, 49(4), 201-208.
282. Carballo, J. J., Garcia-Nieto, R., Alvarez-Garcia, R., Caro-Canizares, I., Lopez-Castroman, J., Munoz-Lorenzo, L., Leon-Martinez, V., and Baca-Garcia, E. (2013). Sibship size, birth order, family structure and childhood mental disorders. *Social Psychiatry and Psychiatric Epidemiology*, 48(8), 1327-1333.
283. Halmoy, A., Klungsoyr, K., Skjærven, R., and Haavik, J. (2012). Pre-and perinatal risk factors in adults with attention-deficit/hyperactivity disorder. *Biological Psychiatry*, 71(5), 474-481.
284. Gustafsson, P., and Kallen, K. (2011). Perinatal, maternal, and fetal characteristics of children diagnosed with attention-deficit-hyperactivity disorder: results from a population-based study utilizing the Swedish Medical Birth Register. *Developmental medicine & child neurology*, 53(3), 263-268.
285. Amso, D., and Scerif, G. (2015). The attentive brain: insights from developmental cognitive neuroscience. *Nature Reviews Neuroscience*, 16(10), 606-619
286. Yulaf, Y. (2011). *Dikkat Eksikliği Hiperaktivite Bozukluğu Tanısı Alan Çocuk ve Ergenlerde Yürütücü İşlevler'in Davranışsal ve Nörokognitif Yöntemlerle Değerlendirilmesi*, Uzmanlık Tezi, Marmara Üniversitesi Tıp Fakültesi,, Çocuk Ruh Sağlığı ve Hastalıkları Anabilim Dalı, 19-20.
287. Chiodo, L. M., Da Costa, D. E., Hannigan, J. H., Covington, C. Y., Sokol, R. J., Janisse, J., Greenwald, M., Ager, J., and Delaney-Black, V. (2010). The impact of maternal age on the effects of prenatal alcohol exposure on attention. *Alcoholism: Clinical and Experimental Research*, 34(10), 1813-1821.
288. McIntosh, D. E., Mulkins, R. S., and Dean, R. S. (1995). Utilization of maternal perinatal risk indicators in the differential diagnosis of ADHD and UADD children. *International Journal of Neuroscience*, 81(3-4), 35-46.

289. Guney, E., Cetin, F. H., and Iseri, E. (2015). The role of environmental factors in etiology of attention-deficit hyperactivity disorder. In Norvilitis, J. M. (Ed.). (2015). *ADHD-New Directions in Diagnosis and Treatment*. IntechOpen, 15-34.
290. Faraone, S., and Biederman, J. (1998) Neurobiology of attention deficit hyperactivity disorder. *Biological Psychiatry*, 44, 951-958.
291. Clements, C. C., Castro, V. M., Blumenthal, S. R., Rosenfield, H. R., Murphy, S. N., Fava, M., Erb, J.L., Churchill, S. E., Kaimal, A. J., Doyle, A. E., Robinson, E. B., Smoller, J. W., Kohane, I. S., and Perlis R. H. (2015). Prenatal antidepressant exposure is associated with risk for attention-deficit hyperactivity disorder but not autism spectrum disorder in a large health system. *Molecular Psychiatry*, 20(6), 727-734.
292. Park, S., Cho, S. C., Kim, J. W., Shin, M. S., Yoo, H. J., Oh, S. M., Han, H., Cheong, J. H., and Kim, B. N. (2014). Differential perinatal risk factors in children with attention-deficit/hyperactivity disorder by subtype. *Psychiatry Research*, 219(3), 609-616.
293. Max, W., Sung H. Y., and Shi, Y. (2013) Attention deficit hyperactivity disorder among children exposed to secondhand smoke: A logistic regression analysis of secondary data. *International Journal of Nursing Studies*, 50, 797-806.
294. Mick, E., Biederman, J., Faraone, S. V., Sayer, J., and Kleinman, S. (2002). Case-control study of attention-deficit hyperactivity disorder and maternal smoking, alcohol use, and drug use during pregnancy. *Journal of the American Academy of Child & Adolescent Psychiatry*, 41(4), 378-385.
295. Zhu, J. L., Olsen, J., Liew, Z., Li, J., Niclasen, J., and Obel, C. (2014). Parental smoking during pregnancy and ADHD in children: the Danish national birth cohort. *Pediatrics*, 134(2), e382-e388.
296. Henriksen, L., Wu, C. S., Secher, N. J., Obel, C., and Juhl, M. (2015). Medical augmentation of labor and the risk of ADHD in offspring: a population-based study. *Pediatrics*, 135(3), e672-e677.
297. Silva D, Colvin L, Hagemann E, Bower C (2014) Environmental risk factors by gender associated with attention-deficit/hyperactivity disorder. *Pediatrics*, 133, e14-e22.
298. Froehlich, T. E., Anixt, J. S., Loe, I. M., Chirdkiatgumchai, V., Kuan, L., and Gilman, R. C. (2011). Update on environmental risk factors for attention-deficit/hyperactivity disorder. *Current psychiatry reports*, 13(5), 333-344.
299. Deniz, E., Öztop, D. B., ve Mısıktık, S. (2008). Dikkat eksikliği hiperaktivite bozukluğu. *Türkiye Aile Hekimliği Dergisi*, 12(4), 207-212.

300. Brookes, K. J., Mill, J., Guindalini, C., Curran, S., Xu, X., Knight, J., Chen, C. K., Huang, Y. S., Sethna, V., Taylor, E., Chen, W., Breen, G., and Asherson, P. (2006) A common haplotype of the dopamine transporter gene associated with attention-deficit/hyperactivity disorder and interacting with maternal use of alcohol during pregnancy. *Archives of General Psychiatry*, 63, 74-81.
301. Laugesen, K., Olsen, M. S., Andersen, A. B. T., Froslev, T., and Sorensen, H. T. (2013). In utero exposure to antidepressant drugs and risk of attention deficit hyperactivity disorder: a nationwide Danish cohort study. *British Medical Journal Open*, 3(9), 1-7.
302. Liew, Z., Ritz, B., Rebordosa, C., Lee, P. C., and Olsen J. (2014) Acetaminophen use during pregnancy, behavioral problems, and hyperkinetic disorders. *JAMA Pediatrics*, 168, 313-320.
303. Thompson, J. M., Waldie, K. E., Wall, C. R., Murphy, R., Mitchell, E. A., and Group, A. S. (2014) Associations between acetaminophen use during pregnancy and ADHD symptoms measured at ages 7 and 11 years. *PLoS One*, 9(9), 1-6.
304. Firestone, P., and Prabhu, A. N. (1983). Minor physical anomalies and obstetrical complications: their relationship to hyperactive, psychoneurotic, and normal children and their families. *Journal of Abnormal Child Psychology*, 11(2), 207-216.
305. Minder, B., Das-Smaal, E. A., JM Brand, E. F., and Orlebeke, J. F. (1994). Exposure to lead and specific attentional problems in schoolchildren. *Journal of Learning Disabilities*, 27(6), 393-399.
306. Viltart, O., Mairesse, J., Darnaudery, M., Louvart, H., Vanbesien-Mailliot, C., Catalani, A., and Maccari, S. (2006). Prenatal stress alters Fos protein expression in hippocampus and locus coeruleus stress-related brain structures. *Psychoneuroendocrinology*, 31(6), 769-780.
307. Chen, Q., Sjölander, A., Langström, N., Rodriguez, A., Serlachius, E., D'onofrio, B. M., Lichenstein, P., and Larsson, H. (2013). Maternal pre-pregnancy body mass index and offspring attention deficit hyperactivity disorder: a population-based cohort study using a sibling-comparison design. *International Journal of Epidemiology*, 43(1), 83-90.
308. Andersen, S. L., Laurberg, P., Wu, C. S., and Olsen, J. (2014). Attention deficit hyperactivity disorder and autism spectrum disorder in children born to mothers with thyroid dysfunction: a Danish nationwide cohort study. *BJOG: An International Journal of Obstetrics & Gynaecology*, 121(11), 1365-1374.
309. Mick, E., Biederman, J., Prince, J., Fischer, M. J., and Faraone, S. V. (2002). Impact of low birth weight on attention-deficit hyperactivity disorder. *Journal of Developmental & Behavioral Pediatrics*, 23(1), 16-22.

310. Brinksma, D. M., Hoekstra, P. J., van den Hoofdakker, B., De Bildt, A., Buitelaar, J. K., Hartman, C. A., and Dietrich, A. (2017). Age-dependent role of pre-and perinatal factors in interaction with genes on ADHD symptoms across adolescence. *Journal of psychiatric research*, 90, 110-117.
311. Indredavik, M. S., Vik, T., Evensen, K. A. I., Skranes, J., Taraldsen, G., and Brubakk, A. M. (2010). Perinatal risk and psychiatric outcome in adolescents born preterm with very low birth weight or term small for gestational age. *Journal of Developmental & Behavioral Pediatrics*, 31(4), 286-294.
312. Deutscher, B., and Fewell, R. R. (2005). Early predictors of attention-deficit/hyperactivity disorder and school difficulties in low-birthweight, premature children. *Topics in Early Childhood Special Education*, 25(2), 71-79.
313. Ayaz, A. B., Ayaz, M., ve Yazgan, Y. (2013). Dikkat eksikliği ve hiperaktivite bozukluğunda sosyal cevaplılıkta görülen değişiklikler. *Türk Psikiyatri Dergisi*, 24(2), 101-110.
314. Kanay, A. ve Girli, A. (2008). Dikkat eksikliği hiperaktivite bozukluğu olan 9-13 yaş grubu ilköğretim öğrencilerinin uyumsal davranışları, benlik kavramı ve akademik başarıları arasındaki ilişkiler. *Dokuz Eylül Üniversitesi Buca Eğitim Fakültesi Dergisi*, 23, 184-191.
315. Loeber, R., Green, S. M., Lahey, B. B., and Stouthamer-Loeber, M. (1991). Differences and similarities between children, mothers, and teachers as informants on disruptive child behavior. *Journal of Abnormal Child Psychology*, 19(1), 75-95.
316. Mitsis, E. M., McKAY, K. E., Schulz, K. P., Newcorn, J. H., and Halperin, J. M. (2000). Parent-teacher concordance for DSM-IV attention-deficit/hyperactivity disorder in a clinic-referred sample. *Journal of the American Academy of Child & Adolescent Psychiatry*, 39(3), 308-313.
317. Dereboy, Ç., Şenol, S., Şener, Ş., ve Dereboy, F. (2007). Conners kısa form öğretmen ve ana baba değerlendirme ölçeklerinin geçerliliği. *Türk Psikiyatri Dergisi*, 18, 48-58.
318. Wu, X., Kumar, V., Quinlan, J. R., Ghosh, J., Yang, Q. , Motoda, H., McLachlan, G. J., Ng, A., Liu, B., Yu, P. S., Zhou, Z., Steinbach, M., Hand, D. J., and Steinberg, D. (2008) . Top 10 algorithms in data mining, *Knowledge and Information Systems*, 14(1), 1-37.
319. Wu, X., and Kumar V., (2009). *The Top Ten Algorithms in Data Mining* (First edition), USA: Chapman & Hall/CRC.
320. Tantıuş, A. C. (2012). Metin sınıflandırma. *Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi*, 5(2), 1-12.
321. Göker, H., Bülbül, H. I., and Irmak, E. (2013, December). *The estimation of students' academic success by data mining methods*. In Machine Learning and Applications (ICMLA), 2013 12th International Conference on IEEE, 535-539.

322. Şahin, İ., Calp, M. H., and Özkan, A. (2014). An expert system design and application for hydroponics greenhouse systems, *Gazi University Journal of Science*, 27(2), 809-822.
323. Yap, R.H., and Clarke, D.M. (1996). *An expert system for psychiatric diagnosis using the DSM-III-R, DSM-IV and ICD-10 classifications*. In: Proceedings of the AMIA Annual Fall Symposium, 229-233.
324. Singh, S. (2015). A fuzzy rule based expert system to diagnostic the mental illness (MIDExS). *International Journal of Intelligent Systems Technologies and Applications*, 3(9), 8759-8764.
325. Razzouk, D., Mari, J. D. J., Shirakawa, I., Wainer, J., and Sigulem, D. (2006). Decision support system for the diagnosis of schizophrenia disorders. *Brazilian Journal of Medical and Biological Research*, 39(1), 119-128.
326. Singh, P. K., and Sarkar, R. (2015). A simple and effective expert system for schizophrenia detection. *International Journal of Intelligent Systems Technologies and Applications*, 14(1), 27-49.
327. Sabeti, M., Katebi, S. D., Boostani, R., and Price, G. W. (2011). A new approach for EEG signal classification of schizophrenic and control participants. *Expert Systems with Applications*, 38(3), 2063-2071.
328. Rashid, B., Damaraju, E., Pearlson, G. D., and Calhoun, V. D. (2014). Dynamic connectivity states estimated from resting fMRI Identify differences among Schizophrenia, bipolar disorder, and healthy control subjects. *Frontiers in Human Neuroscience*, 8, 1-13.
329. Fred, A., Filipe, J., Partinen, M., and Paiva, T. (2000). European Neurological Network. In T., Paiva, and T. Penzel (Eds.), *An expert system for the diagnosis of sleep disorders*. IOS Press, Amsterdam, 127-147.
330. Yıldız, A., Akın, M., and Poyraz, M. (2011). An expert system for automated recognition of patients with obstructive sleep apnea using electrocardiogram recordings. *Expert Systems with Applications*, 38(10), 12880-12890.
331. Elgohary, M.I., Alzohairy, T.A., Eissa, A.M., Eldegahidy, S., and Hussein, M. (2016). An intelligent system for diagnosing schizophrenia and bipolar disorder based on MLNN and RBF. *International Journal of Scientific Research in Science, Engineering and Technology*. 2(4), 117–123.
332. Osamor, V. C., Azeta, A. A., and Ajulo, O. O. (2014). Tuberculosis–diagnostic expert system: An architecture for translating patient’s information from the web for use in tuberculosis diagnosis. *Health Informatics Journal*, 20(4), 275-287.
333. Avcı, E. (2012). A new expert system for diagnosis of lung cancer: GDA-LS_SVM. *Journal of Medical Systems*, 36(3), 2005-2009.

334. Keleş, A., Keleş, A., and Yavuz, U. (2011). Expert system based on neuro-fuzzy rules for diagnosis breast cancer. *Expert Systems with Applications*, 38(5), 5719-5726.
335. Azar, A. T., Hassanien, A. E., and Kim, T. H. (2012). *Expert system based on neural-fuzzy rules for thyroid diseases diagnosis*. In *Computer Applications for Biotechnology, Multimedia, and Ubiquitous City*, Springer, Berlin, Heidelberg, 94-105.
336. Aishwarya, S., and Anto, S. (2014). A medical expert system based on genetic algorithm and extreme learning machine for diabetes disease diagnosis. *International Journal of Science, Engineering and Technology Research (IJSETR)*, 3(5).75-80.
337. David, D. S., and Jayachandran, A. (2018). A new expert system based on hybrid colour and structure descriptor and machine learning algorithms for early glaucoma diagnosis. *Multimedia Tools and Applications*, 1-12.
338. Mueller, A., Candrian, G., Kropotov, J. D., Ponomarev, V. A., and Baschera, G. M. (2010). Classification of ADHD patients on the basis of independent ERP components using a machine learning system. *Nonlinear Biomedical Physics*, 4(1), 1-12.
339. Helgadottir, H., Gudmundsson, O. O., Baldursson, G., Magnusson, P., Blin, N., Brynjolfsdottir, B., Emilsdottir, A., Gudmundsdottir, G. B., Lorange, M., Newman, P. K., Johannesson, G. H. and Johnsen, K. (2015). Electroencephalography as a clinical tool for diagnosing and monitoring attention deficit hyperactivity disorder: a cross-sectional study. *British Medical Journal Open*, 5(1), 1-9.
340. Igual, L., Soliva, J. C., Escalera, S., Gimeno, R., Vilarroya, O., and Radeva, P. (2012). Automatic brain caudate nuclei segmentation and classification in diagnostic of attention-deficit/hyperactivity disorder. *Computerized Medical Imaging and Graphics*, 36(8), 591-600.
341. Duffy, F. H., Shankardass, A., McAnulty, G. B., and Als, H. (2017). A unique pattern of cortical connectivity characterizes patients with attention deficit disorders: a large electroencephalographic coherence study. *BioMed Central (BMC) Medicine*, 15(51), 1-19.
342. Smith, J. L., Johnstone, S. J., and Barry, R. J. (2003). Aiding diagnosis of attention-deficit/hyperactivity disorder and its subtypes: discriminant function analysis of event-related potential data. *Journal of Child Psychology and Psychiatry*, 44(7), 1067-1075.
343. Allahverdy, A., Nasrabadi, A. M., and Mohammadi, M. R. (2011, May). *Detecting ADHD children using symbolic dynamic of nonlinear features of EEG*. In *Electrical Engineering (ICEE) 19th Iranian Conference on IEEE*, 1-4.
344. Deshpande, G., Wang, P., Rangaprakash, D., and Wilamowski, B. (2015). Fully connected cascade artificial neural network architecture for attention deficit hyperactivity disorder classification from functional magnetic resonance imaging data. *IEEE Transactions on Cybernetics*, 45(12), 2668-2679.

345. Johnston, B. A., Mwangi, B., Matthews, K., Coghill, D., Konrad, K., and Steele, J. D. (2014). Brainstem abnormalities in attention deficit hyperactivity disorder support high accuracy individual diagnostic classification. *Human Brain Mapping*, 35(10), 5179-5189.
346. Cheng, W., Ji, X., Zhang, J., and Feng, J. (2012). Individual classification of ADHD patients by integrating multiscale neuroimaging markers and advanced pattern recognition techniques. *Frontiers in Systems Neuroscience*, 6, 1-11.
347. Abibullaev, B., and An, J. (2012). Decision support algorithm for diagnosis of ADHD using electroencephalograms. *Journal of Medical Systems*, 36(4), 2675-2688.
348. Zhu, C. Z., Zang, Y. F., Liang, M., Tian, L. X., He, Y., Li, X. B., Sui, M. Q., Wang, Y. F., and Jiang, T. Z. (2005, October). *Discriminative analysis of brain function at resting-state for attention-deficit/hyperactivity disorder*. In International Conference on Medical Image Computing and Computer-Assisted Intervention, 468-475.
349. Pulini, A. A., Kerr, W. T., Loo, S. K., and Lenartowicz, A. (2018). Classification accuracy of neuroimaging biomarkers in Attention-Deficit/Hyperactivity Disorder: Effects of sample size and circular analysis. *Biological Psychiatry: Cognitive Neuroscience and Neuroimaging*, 1-13.
350. Tavşancıl, E. (2002). *Tutumların Ölçülmesi ve SPSS ile Veri Analizi*. Ankara: Nobel Yayıncılık. 51-52.
351. Göker, H., and Tekedere, H. (2019), Dynamic expert system design for the prediction of attention deficit and hyperactivity disorder in childhood, *International Journal of Informatics Technologies*, 12(1), 33-41.
352. Tan, L., Guo, X., Ren, S., Epstein, J. N., and Lu, L. J. (2017). A computational model for the automatic diagnosis of attention deficit hyperactivity disorder based on functional brain volume. *Frontiers in Computational Neuroscience*, 11, 1-14.
353. Dai, D., Wang, J., Hua, J., and He, H. (2012). Classification of ADHD children through multimodal magnetic resonance imaging. *Frontiers in Systems Neuroscience*, 6, 1-8.



EK-1. Naive Bayes algoritmasının C#.NET dili kodları

```

void naivebayes()
{
VeriDoldur();
double pcsinif1, pcsinif2, sonucsinif1, sonucsinif2, sinif1 = 0, sinif2 = 0;
double pxsinif1=1, pxsinif2=1;
double[,] pxsayi = new double[2, 25];
double[,] pxoran = new double[2, 25];
double kayitsayisi = verikumesi.Rows.Count;
DataRow[] kayit = verikumesi.Select();
    foreach(DataRow eleman in kayit)
    {
        if (eleman[26].ToString() == "NonAdhd")
            sinif1++;
        if (eleman[26].ToString() == "Adhd")
            sinif2++;
    }

    pcsinif1 = sinif1 / kayitsayisi;
    pcsinif2 = sinif2 / kayitsayisi;
    for (int j = 0; j < 25; j++)
    {
        foreach (DataRow eleman in kayit)
        {
            string degerler =
            (((System.Windows.Forms.ComboBox)this.Controls["comboBox" + (j +
1).ToString()]).Text).ToString();
            if (eleman[26].ToString() == "NonAdhd" &&
            eleman[j + 1].ToString() == degerler)
            {
                pxsayi[0, j]++;
            }
            if (eleman[26].ToString() == "Adhd" &&
            eleman[j + 1].ToString() == degerler)
            {
                pxsayi[1, j]++;
            }
        }
    }
    for (int j = 0; j < 25; j++)
    {
        pxoran[0, j] = ((pxsayi[0, j]) / (sinif1)) + 1;
        pxoran[1, j] = ((pxsayi[1, j]) / (sinif2)) + 1;
    }
    for (int j = 0; j < 25; j++)
    {
        pxsinif1 = pxsinif1 * pxoran[0, j];
        pxsinif2 = pxsinif2 * pxoran[1, j];
    }
    sonucsinif1 = pcsinif1 * pxsinif1;
    sonucsinif2 = pcsinif2 * pxsinif2;

    Form37 frm = new Form37();

    if (sonucsinif1 > sonucsinif2)
    {
        frm.MESAJ1 = sonucsinif1.ToString();
        frm.MESAJ2 = sonucsinif2.ToString();
        frm.MESAJ3 = "NONADHD / Dikkat Eksikliği ve Hiperaktivite Sınıfına
Ait Değil\n" + "( "+ sonucsinif1.ToString() + " > " + sonucsinif2.ToString()+ " )";
    }
}

```

EK-1. (devam) Naive Bayes algoritmasının C#.NET dili kodları

```

        frm.MESAJ4 = " - Çocukta Dikkat Eksikliği ve Hiperaktivite Bozukluğuna işaret eden belirtiler bulunmamaktadır.\n\n - Yine de eğer çocukta Dikkat eksikliği ve hiperaktivite bozukluğuna ait belirtilerolduğunu düşünüyorsanız\n mutlaka bir Çocuk Ruh Sağlığı uzmanına başvurunuz";
        frm.ShowDialog();
    }
    else if (sonucsinif1<sonucsinif2) {
        frm.MESAJ1 = sonucsinif1.ToString();
        frm.MESAJ2 = sonucsinif2.ToString();
        frm.MESAJ3 = "ADHD / Dikkat Eksikliği ve Hiperaktivite Sınıfına Ait\n" + "( " + sonucsinif1.ToString() + " < " + sonucsinif2.ToString()+ " )";
        frm.MESAJ4 = " - Çocukta Dikkat Eksikliği ve Hiperaktivite Bozukluğuna işaret eden belirtiler bulunmaktadır.\n\n - Vakit kaybetmeden mutlaka bir Çocuk Ruh Sağlığı uzmanına başvurunuz. \n\n - Tüm hastalıklarda olduğu gibi kesin tanı ancak uzman tarafından klinik değerlendirmeye konulabilir.";
        frm.ShowDialog();
    }
}

```

EK-2. KNN algoritmasının C#.NET dili kodları

```

private void kEnYakinAlgoritmasiUygula(string[] girilenDegerler)
{
    string[] kuralDegerleri;
    IList<string> kuralSeti = KuralTabaniGetir(girilenDegerler[0]);

    foreach (var series in chart1.Series)
    {
        series.Points.Clear();
    }

    uzaklikSonuclariMap.Clear();

    minKdegerleri.Clear();
    listBox1.Items.Clear();
    for (int i = 0; i < kuralSeti.Count; i++)
    {
        kuralDegerleri = kuralDegerleriniGetir(kuralSeti.ElementAt(i));
        if (kuralDegerleri.Length > 25)
        {
            double uzaklikKareliToplami =
Math.Pow((Convert.ToInt32(kuralDegerleri[2]) - Convert.ToInt32(girilenDegerler[1])),
2) + Math.Pow((Convert.ToInt32(kuralDegerleri[3]) -
Convert.ToInt32(girilenDegerler[2])), 2) +
Math.Pow((Convert.ToInt32(kuralDegerleri[4]) - Convert.ToInt32(girilenDegerler[3])),
2) + Math.Pow((Convert.ToInt32(kuralDegerleri[5]) -
Convert.ToInt32(girilenDegerler[4])), 2) +
Math.Pow((Convert.ToInt32(kuralDegerleri[6]) - Convert.ToInt32(girilenDegerler[5])),
2) + Math.Pow((Convert.ToInt32(kuralDegerleri[7]) -
Convert.ToInt32(girilenDegerler[6])), 2) +
Math.Pow((Convert.ToInt32(kuralDegerleri[8]) - Convert.ToInt32(girilenDegerler[7])),
2) + Math.Pow((Convert.ToInt32(kuralDegerleri[9]) -
Convert.ToInt32(girilenDegerler[8])), 2) +
Math.Pow((Convert.ToInt32(kuralDegerleri[10]) -
Convert.ToInt32(girilenDegerler[9])), 2) +
Math.Pow((Convert.ToInt32(kuralDegerleri[11]) -
Convert.ToInt32(girilenDegerler[10])), 2) +
Math.Pow((Convert.ToInt32(kuralDegerleri[12]) -
Convert.ToInt32(girilenDegerler[11])), 2) +
Math.Pow((Convert.ToInt32(kuralDegerleri[13]) -
Convert.ToInt32(girilenDegerler[12])), 2) +
Math.Pow((Convert.ToInt32(kuralDegerleri[14]) -
Convert.ToInt32(girilenDegerler[13])), 2) +
Math.Pow((Convert.ToInt32(kuralDegerleri[15]) -
Convert.ToInt32(girilenDegerler[14])), 2) +
Math.Pow((Convert.ToInt32(kuralDegerleri[16]) -
Convert.ToInt32(girilenDegerler[15])), 2) +
Math.Pow((Convert.ToInt32(kuralDegerleri[17]) -
Convert.ToInt32(girilenDegerler[16])), 2) +
Math.Pow((Convert.ToInt32(kuralDegerleri[18]) -
Convert.ToInt32(girilenDegerler[17])), 2) +
Math.Pow((Convert.ToInt32(kuralDegerleri[19]) -
Convert.ToInt32(girilenDegerler[18])), 2) +
Math.Pow((Convert.ToInt32(kuralDegerleri[20]) -
Convert.ToInt32(girilenDegerler[19])), 2) +
Math.Pow((Convert.ToInt32(kuralDegerleri[21]) -
Convert.ToInt32(girilenDegerler[20])), 2) +
Math.Pow((Convert.ToInt32(kuralDegerleri[22]) -
Convert.ToInt32(girilenDegerler[21])), 2) +
Math.Pow((Convert.ToInt32(kuralDegerleri[23]) -

```

EK-2. (devam) KNN algoritmasının C#.NET dili kodları

```

Convert.ToInt32(girilenDegerler[22])), 2) +
Math.Pow((Convert.ToInt32(kuralDegerleri[24]) -
Convert.ToInt32(girilenDegerler[23])), 2) +
Math.Pow((Convert.ToInt32(kuralDegerleri[25]) -
Convert.ToInt32(girilenDegerler[24])), 2);
        double uzaklikSonuc = Math.Sqrt(uzaklikKareliToplami);
        uzaklikSonuclariMap.Add(i, uzaklikSonuc);

        listBox1.Items.Add(" Uzaklık: " + uzaklikSonuc.ToString());
        chart1.Series["Series1"].Points.Add(uzaklikSonuc);
    }

}

List<KeyValuePair<int, double>> tempList = new List<KeyValuePair<int,
double>>(uzaklikSonuclariMap);

tempList.Sort(delegate(KeyValuePair<int, double> firstPair,
KeyValuePair<int, double> secondPair)
{
    return firstPair.Value.CompareTo(secondPair.Value);
});

foreach (KeyValuePair<int, double> pair in tempList)
{
    if (minKdegerleri.Count >= k)
    {
        break;
    }

    minKdegerleri.Add(kuralSeti.ElementAt(pair.Key));

    listBox1.Visible = true;
    listBox1.Items.Add(kuralSeti.ElementAt(pair.Key) + " Uzaklık: " +
Convert.ToString(pair.Value));
}

}

private bool kuralTabaniIcindeAra(string[] aranilanKural)
{
    string[] kuralDegerleri;
    IList<string> kuralSeti = KuralTabaniGetir(aranilanKural[0]);
    for (int i = 0; i < kuralSeti.Count; i++)
    {
        kuralDegerleri = kuralDegerleriniGetir(kuralSeti.ElementAt(i));
        if (kuralDegerleri.Length > 25)
        {
            if (kuralDegerleri[2].Equals(aranilanKural[1]) &&
kuralDegerleri[3].Equals(aranilanKural[2]) &&
kuralDegerleri[4].Equals(aranilanKural[3]) &&
kuralDegerleri[5].Equals(aranilanKural[4]) &&
kuralDegerleri[6].Equals(aranilanKural[5]) &&
kuralDegerleri[7].Equals(aranilanKural[6]) &&
kuralDegerleri[8].Equals(aranilanKural[7]) &&
kuralDegerleri[9].Equals(aranilanKural[8]) &&
kuralDegerleri[10].Equals(aranilanKural[9]) &&
kuralDegerleri[11].Equals(aranilanKural[10]) &&

```

EK-2. (devam) KNN algoritmasının C#.NET dili kodları

```

kuralDegerleri[12].Equals(aranilanKural[11]) &&
kuralDegerleri[13].Equals(aranilanKural[12]) &&
kuralDegerleri[14].Equals(aranilanKural[13]) &&
kuralDegerleri[15].Equals(aranilanKural[14]) &&
kuralDegerleri[16].Equals(aranilanKural[15]) &&
kuralDegerleri[17].Equals(aranilanKural[16]) &&
kuralDegerleri[18].Equals(aranilanKural[17]) &&
kuralDegerleri[19].Equals(aranilanKural[18]) &&
kuralDegerleri[20].Equals(aranilanKural[19]) &&
kuralDegerleri[21].Equals(aranilanKural[20]) &&
kuralDegerleri[22].Equals(aranilanKural[21]) &&
kuralDegerleri[23].Equals(aranilanKural[22]) &&
kuralDegerleri[24].Equals(aranilanKural[23]) &&
kuralDegerleri[25].Equals(aranilanKural[24]))
    {
        kuralTabanindaBulunanSonuc = kuralDegerleri;
        return true;
    }
}
return false;
}
private string[] kuralDegerleriniGetir(string kural)
{
    return kural.Split(stringAyraci, StringSplitOptions.None);
}

```

EK-3. Gazi Üniversitesi Etik Komisyon izin belgesi

Gazi Ü. Evrak Tarih ve Sayısı: 21/12/2017-E.181641



T.C.
GAZİ ÜNİVERSİTESİ
Etik Komisyonu



Sayı : 77082166-302.08.01-
Konu : Bilimsel ve Eğitim Amaçlı

BİLİŞİM ENSTİTÜSÜ MÜDÜRLÜĞÜNE

İlgi : 16/08/2017 tarihli ve 73247369-302.08.01- 116711 sayılı yazı.

İlgi yazınız ile göndermiş olduğunuz, Bilişim Sistemleri Anabilim Dalı Doktora Öğrencisi **Hanife GÖKER'in**, **Yrd.Doç.Dr.Hakan TEKEDERE'nin** danışmanlığında yürüttüğü "*Makine Öğrenmesi Teknikleri Kullanılarak Çocukluk Çağı Dikkat Eksikliği ve Hiperaktivite Bozukluğunun Tahmin Edilmesine Yönelik Uzman Sistem Tasarımı*" adlı tez çalışması ile ilgili konu Komisyonumuzun **19.12.2017** tarih ve **10** sayılı toplantısında görüşülmüş olup,

İlgilinin çalışmasının, yapılması planlanan yerlerden izin alınması koşuluyla yapılmasında etik açıdan bir sakınca bulunmadığına oybirliği ile karar verilmiş ve karara ilişkin imza listesi ekte gönderilmiştir.

Bilgilerinizi ve gereğini rica ederim.

e-imzalıdır
Prof. Dr. Alper CEYLAN
Komisyon Başkanı

Araştırma Kod No: 2017-471

Ek:1 Liste

EK-4. Gazi Üniversitesi Sağlık Araştırma ve Uygulama Merkezi yasal izin belgesi

Evrak Tarih ve Sayısı: 14/05/2018-E.21119



T.C.
GAZİ ÜNİVERSİTESİ
Sağlık Araştırma ve Uygulama Merkezi
Gazi Hastanesi Başhekimliği



Sayı : 90005124-605.99-
Konu : Dr.Öğr.Üyesi Hakan
TEKEDERE/Proje Kabulü

Sayın Dr.Öğr.Üyesi Hakan TEKEDERE
(Gazi Üniversitesi Sağlık Hizmetleri Meslek Yüksekokulu Gölbaşı/ANKARA)

İlgi : 27/04/2018 tarihli ve . sayılı yazı.

İlgi kayıtlı dilekçeniz incelenmiş olup, "Makine Öğrenmesi Teknikleri Kullanılarak Çocukluk Çağı Dikkat Eksikliği ve Hiperaktivite Bozukluğunun Tahmin Edilmesine Yönelik Uzman Sistem Tasarımı" başlıklı projeniz için, Çocuk ve Ergen Ruh Sağlığı ve Hastalıkları Anabilim Dalının klinik verilerini kullanma talebiniz ilgili bölüme uygun görülmüştür. Bilgilerinizi rica ederim.

e-imzalıdır
Prof. Dr. Ahmet DEMİRCAN
Başhekim

Güvenli Elektronik İmza ile
Aşıl ile Aynadır
15.05.2018



Errata Düzeltmek İçin: <http://belgedogrulama.gaz.edu.tr>
Gazi Üniversitesi Sağlık Araştırma ve Uygulama Merkezi
06030 Beşevler/ANKARA
Tel:0 (312) 202 34 90/2024651 Faks:0 (312) 223 65 28
teke@gaui.edu.tr teke@gaui.edu.tr

Pin: 23122
Bilgi için: Nilhal Dayan
Bilginin Evrak Sorumlusu

Bu belge, 5070 Sayılı Elektronik İmza Kanununa göre Güvenli Elektronik İmza ile imzalanmıştır. (PIN:23122)

EK-5. Gazi Üniversitesi Çocuk Ruh Sağlığı ve Hastalıkları Anabilim Dalı kurum yetkilisi izin belgesi



**T.C:
GAZİ ÜNİVERSİTESİ
ETİK KOMİSYONU**

**İLGİLİ BÖLÜM / ANABİLİM DALI / BİLİM DALI BAŞKANI VEYA
KURUM SORUMLUSUNUN BİLGİLENDİRİLDİĞİNE DAİR BELGE**

GAZİ ÜNİVERSİTESİ ETİK KOMİSYONU BAŞKANLIĞINA

Yrd. Doç. Dr. Hakan TEKEDERE' nin sorumlu araştırmacısı olduğu "Makine Öğrenmesi Teknikleri Kullanılarak Çocukluk Çağı Dikkat Eksikliği ve Hiperaktivite Bozukluğunun Tahmin Edilmesine Yönelik Uzman Sistem Tasarımı" isimli araştırma projesi hakkında bilgilendirildim.

Bilgilerinize arz ederim.

Tarih:

Kurum: Gazi Üniversitesi Sağlık Araştırma ve Uygulama Merkezi (Gazi Üniversitesi Hastanesi) / Çocuk Ruh Sağlığı ve Hastalıkları

Ad ve Soyadı: Prof. Dr. Yasemen Işık TANER (Anabilim Dalı Başkanı)

İmza:

Prof. Dr. Yasemen Işık TANER
T.C. G.Ü. T. T. Fakültesi
Çocuk ve Ergen Psikiyatrisi
Diploma Kurulu
Dip. Tercihli Öğretim Üyesi

ÖZGEÇMİŞ

Kişisel Bilgiler

Soyadı, adı : GÖKER, Hanife
 Uyuğu : T.C:
 Doğum tarihi ve yeri : 1982, Bala
 Medeni hali : Evli, iki çocuk annesi
 Telefon : 0 (312) 484 24 21
 E-mail : hanifegoker@gmail.com
hanife.goker1@gazi.edu.tr

Eğitim Derecesi

Okul/Program

Mezuniyet Yılı

Doktora	Gazi Üniversitesi Bilişim Sistemleri	2014-Devam ediyor
Yüksek Lisans	Gazi Üniversitesi Bilgisayar Eğitimi	2010-2012
Lisans	Atatürk Üniversitesi Bilgisayar ve Öğretim Teknolojileri Öğretmenliği	2000-2004

İş Deneyimi, Yıl

Çalıştığı Yer

Görev

2011-Devam	Ahmet – Alper Dinçer Anadolu Lisesi	Bilişim Teknolojileri Öğretmeni
2009-2011	Ahmet – Alper Dinçer Anadolu Lisesi	Müdür Yardımcısı
2007-2009	Ahmet – Alper Dinçer Anadolu Lisesi	Bilişim Teknolojileri Öğretmeni
2006-2007	Akyurt Çok Programlı Lisesi	Bölüm Şefi
2004-2006	Akyurt Çok Programlı Lisesi	Bilişim Teknolojileri Öğretmeni

Yabancı Dil

İngilizce

YAYINLAR

Yüksek Lisans Tezi

1. **Göker, H.** (2012). *Üniversite Giriş Sınavında Öğrencilerin Başarılarının Veri Madenciliği Yöntemleri İle Tahmin Edilmesi*, Yüksek Lisans Tezi, Gazi Üniversitesi Bilişim Enstitüsü Bilgisayar Eğitimi, Ankara, 2012

SCI, SCI-EXP., SSCI, AHCI Tarafından Taranan Makaleler:

2. **Göker, H.**, Özyayın, L., & Tekedere, H. (2016). The Effectiveness and Usability of the Educational Software on Concept Education for Young Children with Impaired Hearing. *EURASIA Journal of Mathematics, Science & Technology Education*, 12(1), 109–124.

Diğer İndeksler Tarafından Taranan Makaleler:

3. **Göker, H.**, and Tekedere, H. (2019), Dynamic expert system design for the prediction of attention deficit and hyperactivity disorder in childhood, *International Journal of Informatics Technologies*, 12(1), 33-41.
4. **Göker, H.**, Tekedere, H. (2017). Fatih Projesine Yönelik Görüşlerin Metin Madenciliği Yöntemleri İle Otomatik Değerlendirilmesi. *Bilişim Teknolojileri Dergisi*, 10 (3), 291-299.
5. Tekedere, H., & **Göker, H.** (2016). Examining the Effectiveness of Augmented Reality Applications in Education A Meta Analysis. *International Journal of Environmental & Science Education*, 11(16), 9469–9481.
6. **Göker, H.**, & Tekedere, H. (2016). Engellilere Yönelik E-Öğrenme Ortamları Konusunda Yapılan Lisansüstü Tez Çalışmalarının İçerik Analizi. *Adıyaman Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, (24), 945–970.
7. **Göker, H.**, Şahin, İ., & Tekedere, H. (2015). Erken Çocukluk Döneminde Otizm Teşhisine Yönelik Dinamik Uzman Sistem Tasarımı. *Bilişim Teknolojileri Dergisi*, 8(8), 167–172.
8. Çakır, H., & **Göker, H.** (2014). Gençlerin Bilişim Suçlarına İlişkin Farkındalık Düzeylerinin İncelenmesi. *Terazi Hukuk Dergisi*. ISSN: 1306-9802.

Bilimsel Toplantı-Kongre ve Görevler:

9. Tekedere, H., & **Göker, H.** (2019). Üniversite Öğrencilerinin Bilgi Kirliliğine Yönelik Aldıkları Bireysel Önlemler, 13. Uluslararası Bilgisayar ve Öğretim Teknolojileri Sempozyumu (ICITS 2019), Kırşehir.

10. **Göker, H.**, & Tekedere, H. Engellilere Yönelik E-Öğrenme Ortamları Konusunda Yapılmış Çalışmaların Lisansüstü Tezlere Dayalı Analizi YÖK Veri Tabanı Örnekleme, 10. Uluslararası Bilgisayar ve Öğretim Teknolojileri Sempozyumu (ICITS 2016), Rize.
11. **Göker, H.**, and Bulbul. H.I (2014) "Improving an Early Warning System to Prediction of Student Examination Achievement." Machine Learning and Applications (ICMLA), 2014 13th International Conference on. IEEE.
12. **Göker, H.**, Bulbul. H.I, and Irmak, E. (2013). "The Estimation of Students' Academic Success by Data Mining Methods." Machine Learning and Applications (ICMLA), 2013 12th International Conference on. Vol. 2. IEEE.

Hobiler

Model uçak, doğa yürüyüşü, rafting, bilgisayar, tiyatro



GAZİLİ OLMAK AYRICALIKTIR.