

**ANKARA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

YÜKSEK LİSANS TEZİ

**AKCİĞER HASTALIKLARI TEŞHİSİNDE SINIFLANDIRMA VE BULANIK
MANTIK YÖNTEMLERİNİN UYGULANMASI**

Hilal KAYA

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

ANKARA

2018

Her hakkı saklıdır

TEZ ONAYI

Hilal KAYA tarafından hazırlanan “Akciğer Hastalıkları Teşhisinde Sınıflandırma ve Bulanık Mantık Yöntemlerinin Uygulanması” adlı tez çalışması 13/12/2018 tarihinde aşağıdaki jüri tarafından oy birliği / ~~oy çokluğu~~ ile Ankara Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı’nda **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Danışman : Prof. Dr. İman ASKERBEYLİ

Jüri Üyeleri:

Başkan: Doç. Dr. Süleyman TOSUN

Hacettepe Üniversitesi Bilgisayar Mühendisliği Anabilim Dalı

Üye : Doç. Dr. Mehmet/Serdar GÜZEL

Ankara Üniversitesi Bilgisayar Mühendisliği Anabilim Dalı

Üye : Prof. Dr. İman ASKERBEYLİ

Ankara Üniversitesi Bilgisayar Mühendisliği Anabilim Dalı

Yukarıdaki sonucu onaylarım.

Prof. Dr. Atila YETİŞEMİYEN

Enstitü Müdürü

ETİK

Ankara Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım bu tez içindeki bütün bilgilerin doğru ve tam olduğunu, bilgilerin üretilmesi aşamasında bilimsel etiğe uygun davrandığımı, yararlandığım bütün kaynakları atıf yaparak belirttiğimi beyan ederim.

13.12.2018



Hilal KAYA

ÖZET

Yüksek Lisans Tezi

AKCİĞER HASTALIKLARI TEŞHİSİNDE SINIFLANDIRMA VE BULANIK MANTIK YÖNTEMLERİNİN UYGULANMASI

Hilal KAYA

Ankara Üniversitesi
Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. İman ASKERBEYLİ

İnsanlar geçmişten günümüze yaşamlarını kolaylaştırmak amacıyla akıllı ve kontrol edilebilir, karar verebilme yeteneğine sahip yeni yöntemler aramaya ve geliştirmeye devam etmektedir. İnsanlara ait veriler ve tecrübelerin çeşitli yöntemler ile işlenerek programlar aracılığı ile makinelere çalışabilme yeteneğinin kazandırılması için bu ihtiyaçlardan doğan alanlar olan yapay zeka ve bulanık mantık yaklaşımları oldukça popüler hale gelmiştir. Yapay zeka ve bulanık mantık metodolojileri, birçok alanda aktif olarak kullanılmasının yanı sıra bu tez çalışmanın da alanı olan medikal alanda sınıflandırma, tanıma, tahmin, veri ilişkilendirme, teşhis, yorumlama ve karar verme gibi amaçlarla kullanılmakta, bu teknolojiler tıp alanında geniş çapta uygulama alanı bulmaktadır.

Çalışmada akciğer zarı kanseri olarak bilinen Mezotelyoma hastalığının teşhisi için bulanık mantık yöntemleri ve yapay sinir ağlarının entegrasyonundan oluşan bir yaklaşım olan ANFIS (Adaptif Ağ Tabanlı Bulanık Çıkarım Sistemi) ile bulanık bir çıkarım sisteminin tasarlanması amaçlanmıştır. Model oluşturulurken kullanılan kümeleme yöntemlerinin (Izgara Bölümleme, Alt Kümeleme, Bulanık-C Ortalamalar) genel performansları değerlendirilmiş, büyük veri setleri için kullanılacak boyut azaltım metodu olan Temel Bileşenler Analizi işlenmiştir. Model için gerçek veriler ile oluşturulan ve hastalığın teşhisinde kullanılacak faktörleri içeren bir veri seti kullanılmıştır. Elde edilen tahmin sonuçları, ortalama hata kareleri kökü ve doğruluk matrisine göre hesaplanan yüzde doğruluk oranları üzerinden değerlendirilmiştir.

Bulanık mantığın MATLAB programı üzerinde geliştirilen ANFIS tabanlı tahmin modeline adapte edilmesi için kullanılan kümeleme yöntemlerinden en iyi sonuçların Bulanık-C Ortalamalar (Fuzzy-C Means) ile alındığı deneyler sonucunda görülmüştür. Sonuç olarak ANFIS ile oluşturulan modelin başarılı ve tatmin edici bir tahmin performansı gösterdiği kanısına varılarak uygulanabilirliği gözlenmiştir. İnsan uzmanlığının maliyetini, zamanını ve verilen karar için hata oranını azaltmak amacıyla tasarlanan bu karar destek sistemi, sağlık alanında uzman kişiler tarafından Mezotelyoma teşhisinde kullanılabileceği gibi, medikal bağlamda bu yaklaşımlar ile yapılacak diğer çalışmalara ışık tutmaktadır.

Aralık 2018, 99 sayfa

Anahtar Kelimeler: Malign Mezotelyoma, Bulanık Mantık, ANFIS, Hastalık Teşhisi, Izgara Bölümleme, Alt Kümeleme, Bulanık-C Ortalamalar, Karar Destek Sistemi

ABSTRACT

Master Thesis

DIAGNOSIS OF LUNG DISEASES WITH IMPLEMENTING CLASSIFICATION AND FUZZY LOGIC METHODS

Hilal KAYA

University of Ankara
Graduate School of Natural and Applied Sciences
Department of Computer Engineering

Supervisor: Prof. Dr. İman ASKERBEYLİ

People continue to seek and develop new ways of intelligent and controllable, decision-making in order to facilitate their lives from past to present. Artificial intelligence and fuzzy logic approaches, which are the fields that arise from these needs, have become very popular in order to gain the ability of people to work with machines through various methods. In addition to the active use of artificial intelligence and fuzzy logic methodologies in many fields, this thesis is used in the medical field which is the field of this study, for classification, recognition, estimation, data association, diagnosis, interpretation and decision making, and these technologies are widely used in medicine.

In this study, it is aimed to design a fuzzy inference system with ANFIS (Adaptive Neuro Fuzzy Inference System) which is an approach integration of fuzzy logic methods artificial neural networks for the diagnosis of mesothelioma disease which is known as lung membrane cancer. Clustering methods (Grid Partitioning, Subtractive Clustering, Fuzzy-C Means Clustering) used in creating the model and its' general performances were evaluated and Principal Component Analysis dimension reduction method that can be used when working with large datasets were processed. For the proposed model in the study, firstly factors used in the diagnosis of the disease and a data set with real data were used and the estimation results were evaluated on the basis of mean error frames and the accuracy matrix.

Fuzzy logic was adapted to the ANFIS-based prediction model developed on the MATLAB program and as a result of the experiments, it was observed that the best results of the clustering methods were taken by the Fuzzy-C Means clustering method. Consequently, the applicability of the ANFIS-generated model was found to be successful and satisfactory. This decision support system, designed to reduce the cost, time and error rate of human expertise and it can be used by the experts in the field of health to diagnose mesothelioma. This study sheds light on the other studies to be carried out with these approaches in the medical context.

December 2018, 99 pages

Key Words: Malignant Mesothelioma, Fuzzy Logic, ANFIS, Disease Diagnosis, Grid Partitioning, Subtractive Clustering, Fuzzy-C Means Clustering, Decision Support System

TEŞEKKÜR

Tezimin hazırlanması sırasında bilgileri ve deneyimleri ışığında büyük özverileriyle beni yönlendiren, yardımlarını ve desteklerini esirgemeyen değerli danışman hocam Sayın Prof. Dr. İman ASKERBEYLİ (Ankara Üniversitesi Bilgisayar Mühendisliği Anabilim Dalı) ve değerli bölüm arkadaşım Vahid Babaei AJABSHIR'e sonsuz teşekkürlerimi sunarım.

Hilal KAYA

Ankara, Aralık 2018

İÇİNDEKİLER

TEZ ONAY SAYFASI

ETİK.....	i
ÖZET.....	ii
ABSTRACT	iii
TEŞEKKÜR	iv
SİMGELER DİZİNİ	viii
ŞEKİLLER DİZİNİ	x
ÇİZELGELER DİZİNİ	xi
1. GİRİŞ	1
1.1 Tezin Amacı	1
1.2 Tezin İçeriği	3
1.3 Bulanık Mantığın Tarihi Gelişimi	4
2. KAYNAK ÖZETLERİ	6
2.1 Bulanık Mantık Yöntemleri ile Gerçekleştirilen Tahmin Çalışmaları	6
2.2 Mezotelyoma için Yapılmış Çalışmalar	9
3. MATERYAL VE METOT	16
3.1 Malign Mezotelyoma ve Çeşitleri	16
3.1.1 Hastalığa yakalanmada etkili olan faktörler	18
3.1.2 Belirtileri, teşhisi ve tedavi yöntemleri.....	19
3.2 Yapay Sinir Ağları (ANN - Artificial Neural Network)	20
3.2.1 Biyolojik sinir hücreleri.....	21
3.2.2 Yapay sinir hücreleri	22
3.2.3 Yapay sinir ağının yapısı	26
3.2.4 Yapay sinir ağlarının sınıflandırılması	28
3.2.4.1 Yapıları ile yapay sinir ağları.....	28
3.2.4.2 Öğrenme algoritmaları ile yapay sinir ağları	28
3.2.4.3 Öğrenme zamanı ile yapay sinir ağları	29
3.2.5 YSA uygulama alanları	30
3.2.6 Yapay sinir ağlarının avantajları ve dezavantajları.....	30
3.3 Bulanık Mantık	31

3.3.1 Bulanık mantık ve bulanık sistemler kavramları	31
3.3.2 Bulanık kümeler	33
3.3.3 Dilsel değişkenler.....	37
3.3.4 Üyelik fonksiyonları.....	38
3.3.5 Bulanık çıkarım sistemi yapısı	41
3.3.5.1 Bulanıklaştırma	42
3.3.5.2 Kural tabanı.....	43
3.3.5.3 Bulanık çıkarım mekanizması ve modelleri	43
3.3.5.4 Durulaştırma	44
3.3.6 Bulanık mantığın avantajları ve dezavantajları	45
3.4 Sinir Ağları ve Bulanık Mantık Entegrasyonu	46
3.4.1 Sinirsel bulanık sistemler	46
3.4.2 Adaptif Ağ Tabanlı Bulanık Çıkarım Sistemi (ANFIS)	48
3.4.2.1 ANFIS mimarisi	48
3.5 Kümeleme Yöntemleri	52
3.5.1 Izgara Bölümleme Yöntemi (Grid Partitioning)	53
3.5.2 Alt Kümeleme Yöntemi (Subtractive Clustering).....	54
3.5.3 Bulanık-C Ortalamalar Yöntemi (Fuzzy-C Means Clustering)	57
3.6 Boyut Azaltımı	60
3.6.1 Temel Bileşenler Analizi (PCA - Principal Component Analysis).....	61
4. ARAŞTIRMA VE BULGULAR.....	65
4.1 Problemin Ortaya Koyulması ve Tezin Hedefi	65
4.2 Dataset ve Etki Eden Parametreler	66
4.3 Modelin Genel Yapısı ve Çalışma Aşamaları	68
4.4 Modelde Kullanılan Parametrelerin Hazırlanması	70
4.4.1 Veri ön işleme (Preprocessing).....	70
4.4.2 Boyut azaltma işlemi	70
4.5 Modelin Oluşturulma Süreci ve Performans Ölçütleri	71
4.5.1 Grid Partition yöntemi ile oluşturulan model ve sonuçları.....	73
4.5.2 Subtractive Clustering yöntemi ile oluşturulan model ve sonuçları	79
4.5.3 Fuzzy-C Means yöntemi ile oluşturulan model ve sonuçları	85

5. TARTIŞMA VE SONUÇ.....	90
KAYNAKLAR	93
ÖZGEÇMİŞ.....	99



SİMGELER DİZİNİ

Σ	Sigma
Π	Pi
μ	Mü
ϕ	Fi
ϵ	Kümenin elemanıdır
$\leq$	Küçük eşittir
$\geq$	Büyük eşittir
$\bar{x}$	x kümesinin tümleyeni
$\bar{y}$	y kümesinin tümleyeni
ϵ	Epsilon

Kısaltmalar

AIS	Yapay Bağışıklı Sistemi (Artificial Immune Systems)
ANFIS	Adaptif Ağ Tabanlı Bulanık Çıkarım Sistemi (Adaptive Neuro Fuzzy Inference Systems)
ANN	Yapay Sinir Ağları (Artificial Neural Network)
APC	Premature Atrial Kontraksiyon
CT	Computed Tomography
DN	Doğru Negatif
DP	Doğru Pozitif
DVM	Destek Vektör Makineleri
EKG	Elektrokardiyogram
FALCON	Fuzzy Adaptive Learning Control Network
FCM	Bulanık-C Ortalamalar (Fuzzy-C Means Clustering)
FINEST	Fuzzy Inference and Neural Network in Fuzzy Inference Software
FIS	Bulanık Çıkarım Sistemi (Fuzzy Inference System)
FOS	Factor of Safety
FuNe	Fuzzy Net
GARIC	Generalized Approximate Reasoning Based Intelligent Control
GP	Izgara Bölümleme (Grid Partitioning)
IMRT	Intensity Modulated Radiotherapy
KP	Karesel Programlama
LBBS	Left Bundle Branch Block
LIFE	Laboratory for International Fuzzy Engineering
LMT	Logistic Model Trees
MLR	Multiple Linear

MM	Malign Mezotelyoma (Malignant Mesothelioma)
NEFCLASS	Neuro Fuzzy Classification
NEFCON	Neuro Fuzzy Control
NEFPROX	Neuro Fuzzy Function Approximation
PART	Projective Adaptive Resonance Theory
PCA	Temel Bileşenler Analizi (Principal Component Analysis)
PVC	Prematür Ventriküler Kompleks
RBBB	Right Bundle Branch Block
RMSE	Ortalama Hata Kareleri Toplamı Kökü (Root Mean Square Error)
SCM	Alt Kümeleme (Subtractive Clustering)
SMO	Sıralı Minimal Optimizasyon
UCI	University Of California Irvine
WEKA	Waikato Environment for Knowledge Analysis
YN	Yanlış Negatif
YP	Yanlış Pozitif
YSA	Yapay Sinir Ağları

ŞEKİLLER DİZİNİ

Şekil 3.1 Akciğer yapısı ve mezotelyoma	16
Şekil 3.2 Plevra tümörleri.....	17
Şekil 3.3 Biyolojik sinir hücresi	21
Şekil 3.4 Yapay sinir hücresinin yapısı	23
Şekil 3.5 Çok katmanlı yapay sinir ağı modeli.....	27
Şekil 3.6 Bulanık küme teorisi	34
Şekil 3.7 Klasik küme örneği	35
Şekil 3.8 Bulanık küme örneği	35
Şekil 3.9 Isı kavramının bulanık küme yaklaşımı ile ifadesi	36
Şekil 3.10 Boy kavramının bulanık küme ile ifadesi.....	36
Şekil 3.11 Dilsel değişkenlerin bulanık küme ile ifadesi	38
Şekil 3.12 Bir üyelik fonksiyonunun bölümleri	40
Şekil 3.13 Bulanık çıkarım sistemi akış diyagramı	42
Şekil 3.14 Durulaştırma metotları	45
Şekil 3.15 Sugeno tipi bulanık çıkarım sistemi	47
Şekil 3.16 İki girişli ve iki kurallı Sugeno tipi bulanık çıkarım	49
Şekil 3.17 ANFIS mimarisi.....	49
Şekil 3.18 2 girişli değişkenli ızgara bölümlendirme modeli.....	53
Şekil 3.19 Temel bileşenler analizi yaklaşımı	62
Şekil 4.1 Tasarlanan model için gerçekleştirilen çalışma aşamaları	68
Şekil 4.2 Izgara Bölümlendirme yöntemi ile tahmin sonuçları	75
Şekil 4.3 Bulanık çıkarım sistemine verilen 1. ve 2. girdiler ile sonuç ilişkisinin 3 boyutlu simülasyonu.....	75
Şekil 4.4 Bulanık çıkarım sistemine verilen 1. ve 3. girdiler ile sonuç ilişkisinin 3 boyutlu simülasyonu.....	76
Şekil 4.5 Bulanık çıkarım sistemine verilen 2. ve 4. girdiler ile sonuç ilişkisinin 3 boyutlu simülasyonu.....	76
Şekil 4.6 ANFIS eğitim verisi sonucu.....	77
Şekil 4.7 ANFIS test verisi sonucu	77
Şekil 4.8 Modelde tanımlı kurallara göre sonuçların elde edilmesi	78
Şekil 4.9 Giriş - çıkış değerleri ve üyelik fonksiyonlarının bulanık kurallar ile ilişkilendirilmesi ve elden edilen çıkış değeri	79
Şekil 4.10 Alt kümeleme yöntemi ile tahmin sonuçları	83
Şekil 4.11 Bulanık çıkarım sistemine verilen 1. ve 2. girdiler ile sonuç ilişkisinin 3 boyutlu simülasyonu.....	83
Şekil 4.12 Bulanık çıkarım sistemine verilen 1. ve 3. girdiler ile sonuç ilişkisinin 3 boyutlu simülasyonu.....	84
Şekil 4.13 Bulanık çıkarım sistemine verilen 2. ve 3. girdiler ile sonuç ilişkisinin 3 boyutlu simülasyonu.....	84
Şekil 4.14 Bulanık-C Ortalamalar yöntemi ile tahmin sonuçları	86
Şekil 4.15 Bulanık çıkarım sistemine verilen 1. ve 2. girdiler ile sonuç ilişkisinin 3 boyutlu simülasyonu.....	86
Şekil 4.16 Bulanık çıkarım sistemine verilen 1. ve 3. girdiler ile sonuç ilişkisinin 3 boyutlu simülasyonu.....	87
Şekil 4.17 Bulanık çıkarım sistemine verilen 2. ve 3. girdiler ile sonuç ilişkisinin 3 boyutlu simülasyonu.....	87

ÇİZELGELER DİZİNİ

Çizelge 2.1 Mezotelyoma için gerçekleştirilen çalışmaların doğruluk sonuçları	11
Çizelge 2.2 Özellik seçimi gerçekleştirilmeden önce sonuçlar	15
Çizelge 2.3 Özellik seçimi gerçekleştirildikten sonra sonuçlar	15
Çizelge 3.1 Biyolojik sinir sistemi elemanlarının yapay sinir ağındaki karşılıkları	22
Çizelge 3.2 Bazı toplama fonksiyonları	24
Çizelge 3.3 Aktivasyon fonksiyonları	25
Çizelge 3.4 Dilsel değişkenlerin bulanık küme ile ifadesi	38
Çizelge 3.5 Yaygın olarak kullanılan üyelik fonksiyonları	39
Çizelge 4.1 Çalışmada kullanılan veri seti parametreleri	67
Çizelge 4.2 Doğruluk matrisi	72
Çizelge 4.3 Izgara bölümlene yöntemi ile elde edilen sonuçlar	74
Çizelge 4.4 Alt kümeleme yöntemi ile elde edilen sonuçlar	80
Çizelge 4.5 Bulanık-C Ortalamalar yöntemi ile elde edilen sonuçlar	85

1. GİRİŞ

1.1 Tezin Amacı

Günümüzde toplumsal yapının gelişmesi ve teknolojinin ilerlemesi ile beraber gerçek hayatta yaşanan sorunlar, problemler ve bu problemlerin çözümlerinde kişilerin sahip olduğu bakış açıları da farklı bir boyut kazanmaktadır. Karşılaşılan bazı problemler karşısında insanlar sözel ya da sayısal olarak elde ettikleri girdileri çeşitli yöntemler ile kullanarak probleme çözüm getirmektedirler. Bilinen matematiksel yaklaşımlar ve metotlar bu sayısal verileri kullanarak analizden geçirme ve problemi çözmeye konusunda en çok kullanılan yöntem iken, belirsizliğin olduğu durumlarda aynı şekilde tam anlamıyla yardımcı olamayıp yetersiz kalabilmektedirler. Son zamanlarda bazı teşhisi zor hastalıklarda olduğu gibi belirsizliğin olduğu durumlarda sıklıkla yapay zeka yöntemlerinden biri olan bulanık mantık kullanılarak farklı bir çözüm anlayışı uygulanmaktadır ve bu yönetime dayalı karar destek sistemleri geliştirilmektedir. Akıl ilkeleri temelinde oluşturulmuş kıyasa dayalı iki değerli (doğru/yanlış) mantık disiplini olan klasik mantığın aksine, bulanık mantık yaklaşımında olaylar nesnelere atanan “0” ve “1” arasındaki doğruluk dereceleri ile açıklanır ve böylelikle daha esnek bir şekilde duruma girdi oluşturan tüm sözel ve sayısal ifadeler arasında bir bağ kurar (Akıllı vd. 2014).

Günlük yaşantıda yaşanan karmaşıklık durumları genel olarak doğru bilgiye ulaşamama, belirsizlik ve karar verememe durumlarından kaynaklanır. Araştırılmak istenilen bazı konularda insan düşüncesinin net olmaması ve konu hakkında yeterli veriye ulaşamaması gibi durumlardan dolayı bu belirsizliklerle çoğu zaman karşılaşmaktadır. Bu gibi belirsiz ve kesin olmayan bilgiyi değerlendirmek için Zadeh’in önerdiği bulanık mantık temeline dayalı tahmin sistemleri kullanımına son zamanlarda birçok çalışmada rastlanılmaktadır (Zadeh 1965). Bu yaklaşımlar uzman sistemler olarak da adlandırılmaktadır. Bu uzman sistemler insan düşünce yapısı ve bilgisayar gücünden yola çıkarak karmaşık olan problemlere kolaylıkla çözüm getirebildiği için, bulanık mantık tabanlı uzman sistemler ele aldıkları problemlerde gerçeğe çok daha yakın ve daha doğru çözümler sunan dilsel veya matematiksel

sistemlerdir. Herhangi bir alan ile ilgili ortaya çıkan bir problemin çözümünde uzmanların bilgisini kullanarak ve bilgiye dayalı işlem yaparak çalışan bilgisayar programları olarak da ifade edilebilirler. Bu alanlar arasında bulanık mantık yaklaşımı ile modellenen karar sistemlerinin en çok kullanıldığı alanlardan biri, bu çalışmanın da konusu olan sağlık alanıdır (İçen ve Günay 2014).

Günümüzde teknolojinin sürekli gelişmesi ve yenilik halinde olması sebebiyle pek çok alanda olduğu gibi özellikle medikal alanda da bu gelişmelerin yardımıyla ilerlemeler yaşanmaktadır. Geçmiş zamanlarda tedavisi yapılamazken günümüzde kolay müdahalelerle tedavi edilebilen hastalıkların üstesinden genellikle teknoloji sayesinde gelinebilmektedir. Ancak teknolojinin ilerlemesini takiben her geçen gün değişen yaşam standartları, değişmekte olan çevre ve çeşitli faktörler sebebi ile yeni hastalıklar da ortaya çıkmaya devam edebilmektedir. Bunun sonucu olarak da medikal alanda gerçekleştirilmeye çalışılan teknolojik ilerleme için çalışmalar her geçen gün daha da artar şekilde devam etmektedir. Hastalık tespitinde kendi alanlarında uzmanlaşmış doktorların çalışmalarına katkı sağlayabilmek ve bazı belirlenmesi zor durumlarda teşhise kolaylık sağlayabilmek amacıyla teknolojik alanda çalışmalar yürütülmekte olup, bu alanda yapay zekanın çeşitli tekniklerinden faydalanıldığı görülmektedir. Pek çok hastalığın tedavisinde son derece önemli olan hastalığa doğru tanı koyabilme durumu, teşhisi zor olabilen Mezotelyoma (akciğer zarı kanseri) hastalığı için de büyük bir öneme sahiptir (Yılmaz 2012).

Medikal teşhis hastalığın derecesinin ileri seviyeye taşınmasını önleme ve hızlı müdahale edebilme açısından önemli ve kritik bir role sahiptir. Bu çalışmada, tıp literatüründe MM (Malignant Mesothelioma – Malignant Mezotelyoma) olarak geçen ve akciğer zarı kanseri olarak adlandırılan, teşhisinde zorluk yaşanabilen mezotelyoma hastalığı için bulanık mantık tabanlı tahmin modeli oluşturulmaya çalışılarak bir karar destek sistemi geliştirmek amaçlanmıştır.

1.2 Tezin İeriđi

Medikal alandaki alıřmalar iin modellenen bulanık mantık tabanlı uzman tahmin sistemlerinde, son gerekleřtirilen alıřmalar incelendiđinde ANFIS (Adaptif Ađ Tabanlı Bulanık ıkarım Sistemi - Adaptive Neuro Fuzzy Inference Systems)'in kullanıldıđı, sonu ve performans aısından tatmin edici sonular verdiđi grlmektedir. Bununla birlikte medikal alanın yanı sıra birok alanda veriler arasındaki iliřkinin modellenmesinde adaptif ađ yapısına dayalı bulanık ıkarım sisteminden faydalanılmaktadır. Girdilerden yararlanarak kural oluřturabilmesi ve kural oluřturulmasına olanak sađlaması, ANFIS'ın uzman grřlerinden faydalanması anlamına da gelmektedir. Bu nedenle karřılařılan birok tahmin problemini zme kavuřturabilmek adına yapay sinir ađlarına uzman grřlerinden yarar sađlama imkanı tanınmasından tr ortalama hata kareler kriterine gre daha iyi sonular elde edilmesine olanak sađlamaktadır (Berber ve Boru 2013).

Bu alıřmada da Mezotelyoma hastalıđının teřhisi iin hasta/sađlıklı ayırımını amalayan bulanık mantık tabanlı bir karar mekanizmasının geliřtirilmesi amalanmıřtır. Sistemin girdileri UCI (University Of California Irvine) Makine ğrenimi veritabanından elde edilen mezotelyoma veri setinden oluřmaktadır. Tasarlanan bulanık sistemin ıktısı ise eldeki verilerden ve bulanık modellemeyen elde edilen sonuca gre kiřinin sađlıklı ya da mezotelyoma řeklinde deđerlendirilmesi ve daha nce belirli olan sonular ile tahmini dođru yapıp yapamamasına dair bařarı oranının hesaplanmasıdır. Sistemin modellemesi Matlab (srm R2017b) programı kullanılarak yapılmıřtır. Tez beř ana bařlıktan meydana gelmektedir. Birinci blm, tezin amacı ve ieriđini ieren giriř blm oluřturmaktadır. İkinci blmde alıřmanın dayandıđı yntemin bir parası olan bulanık mantıđın tarihi geliřimi ve alıřmanın konusuyla iliřkilendirilebilecek alıřmaların yer aldıđı literatr taraması ana bařlıkları yer almaktadır. nc blmde alıřmada kullanılan materyal ve metotlar hakkında geniř kapsamlı bilgi verilmiř, bunu takiben kullanılan yntemlerin uygulama ařamalarının ve sonularının detaylı bir řekilde anlatıldıđı arařtırma ve bulgular drdnc blm olarak oluřturulmuřtur. Beřinci ve son blmde ise elde edilen

sonuçlar genel olarak değerlendirilmiş ve çalışmanın ilerleyen zamanlarda daha da geliştirilebilmesi açısından öneriler de eklenmiştir.

1.3 Bulanık Mantığın Tarihi Gelişimi

İnsanlara ait olan verilerin, tecrübelerin ve bir takım deneyimlerin bulanık mantık yaklaşımı ile ele alınması ve belirli algoritmalar ile işleminden geçirilmesi sonucu oluşturacağı kurallar vasıtasıyla sonuç değerleri üretilmekte ve makinelere çalışabilme yeteneği sağlanmaktadır. Bir bilgisayar ortamında sözel bir verinin ifade ediliş biçimi matematiksel biçimde olmaktadır. Bu ifadenin matematiksel boyuta geçişi bulanık kümeler ve bulanık mantık sayesinde sağlanabilmektedir. Mantık alanındaki çalışmaları sistematik hale getiren Aristoteles'in temelini attığı ve akıl ilkeleri temelinde oluşturulan, kıyaslamaya dayalı ve iki değerli (doğru/yanlış) olarak ifade edilen klasik mantığın bulanık mantıktan farkı, (0-1) olacak şekilde iki değere sahip olmasıdır. Ancak bulanık mantık ise klasiğin aksine [0-1] aralığında olacak şekilde ikiden fazla değere sahiptir. Bulanık mantık, klasik mantıktaki iki değişken arasındaki değerleri de ele alır ve çok değerli sonuçlar üretebilir ve yine klasik mantıkta yer alan 0-1 değerleri yerine bu iki sayı arasında yer alan ara değerlerle (0.5, 0.76 gibi) işlem gerçekleştirebilmeye imkan sağlamaktadır. 1900'lü yılların ilk zamanlarında Jan Lukasiewicz (1878-1956) klasik Aristo mantığına ek olarak (0,1) değerlerinin yanına bir değer daha ekleyerek [0,1,2] şeklinde ifade etmiştir. Donald E. Knuth (1938) ise bunun yerine [-1,0,1] değerlerini kullanmıştır. Daha sonrasında bulanık mantığın ilke ve yapısına ait birçok bilimsel yayın hazırlayan Zadeh bu alanın öncüsü olmuştur. Zadeh "kısa, mavi, sakın" gibi ifadelerin iki değerli üyelik fonksiyonu ile ifade edildiği klasik kümeler yerine, üyelik fonksiyonunun derece ile ifade edildiği bulanık kümeler tanımını ortaya çıkarmıştır. Zadeh'e göre bulanık mantık kavramı açıklanacak olursa, kesinlik, mutlak kesin diye bir durum yoktur ve her şeyin matematiksel olarak ifade edilmesi halinde bu 0 ve 1 arasındaki sınırdadır değişmektedir. Matematiksel olarak modellenmesi karmaşık ve zorlayıcı olan durumlar için bulanık mantık uygun bir yöntemdir (Kaftan vd. 2013).

Bulanık mantık kavramı ilk defa Assilian ve Mamdani tarafından bir buhar makinası kontrol sisteminde uygulamaya alınmıştır, çeşitli kurallar ile bu sistemi

gerçekleřtirmişlerdir. Sonrasında 1987 yılında Sendai metrosunda çalışmakta olan trenlerin denetiminde bulanık mantık kullanımı uygulanmış olup trenin istenilen konumda durması üç kat iyileştirilmiş, enerji bakımından %10'luk bir tasarruf sağlanmıştır. Elde edilen başarılar sayesinde bulanık denetim konusunda yapılan çalışmaların endüstriyel alandaki uygulamalarının daha da artması ile 1989 yılında Japonya'da LIFE (Laboratory for International Fuzzy Engineering) adlı bir laboratuvar ortamı kurulmuştur, burada yapılan araştırma çalışmalarına birçok firma katılmıştır (Anonim 2018a) (Keskenler ve Keskenler 2017).



2. KAYNAK ÖZETLERİ

2.1 Bulanık Mantık Yöntemleri ile Gerçekleştirilen Tahmin Çalışmaları

Bulanık mantık yöntemleri kullanılarak gerçekleştirilen tahmin çalışmaları incelendiğinde bu alanda birçok çalışma yapıldığı ve başarı ile sonuçlandığı görülmektedir. Bu çalışmanın konusu olan medikal alan dışında da farklı alanlar için ANFIS yaklaşımı ile çalışmaların gerçekleştirildiği tespit edilmiştir. ANFIS tabanlı hazırlanan bu modellerin test sonuçları incelendiğinde başarı oranlarının yüksek olduğu ve kullanım açısından faydalı olabileceği değerlendirilmiş; bu çalışmaya ışık tutan bahsedilen çalışmaların incelenmesiyle mezotelyoma hastalığı için de adaptif bulanık çıkarım sistemi yaklaşımından faydalanılarak hastalık tahminindeki başarı oranı değerlendirilmiştir. Literatürdeki bazı çalışmaların kapsamaları şu şekildedir:

Khalifa ve Komarizadeh (2012), çalışmalarında PCA (Principal Component Analysis - Temel Bileşen Analizi) ve Adaptif Ağ Tabanlı Bulanık Çıkarım Sistemi sınıflandırıcılarını birleştirerek cevizlerin boş ya da dolu şekilde olduğunu sınıflandıran bir ceviz tanıma sistemi geliştirmişlerdir. Çalışmada paslanmaz bir çelik blok darbe plakası olarak kullanılmış olup, bu darbe plakasına bir cihaz cevizleri bırakmaktadır ve bir mikrofon ile akustik yayımlar toplanmaktadır. Tespit edilen ses sinyalleri sonrasında bilgisayar tabanlı bir veri toplama sisteminde toplanmıştır. Sistem daha sonra test edilmiş ve cevizleri iki sınıfa ayırmıştır. Bu akıllı sistemin üç aşaması bulunmaktadır. Önişleme aşamasında sinyaller için bahsedildiği gibi veri toplama ve veri önişleme gerçekleştirilmiş ve sistemin performansını değerlendirmek için 281 örnek veri kullanılmıştır. Özellik belirleme aşamasında, bu sinyallerin bazı istatistiksel parametreleri sıralama için bir özellik kaynağı olarak seçilmiştir ve daha sonra PCA yöntemi kullanılarak özellikler azaltılmıştır. Sınıflandırma aşamasında ise ANFIS sınıflandırıcısının girdisi olarak seçilmiş istatistiksel özellikler kullanılmıştır. Önerilen PCA-ANFIS akıllı sisteminin sınıflandırma doğruluğu % 100 olarak hesaplanmıştır.

Ok (2010), tez çalışmasında yapay sinir ağları ve bulanık mantık yöntemlerinin birleşiminden oluşan adaptif sinirsel bulanık çıkarım sistemi ile Türkiye’de üçer aylık

periyotlara ait orta dönemli brüt elektrik enerjisi talep tahmini gerçekleştirmeye çalışmıştır. Veri seti eğitim, kontrol ve test olmak üzere üçe ayrılarak 22 yıllık 88 veri öbeğinden 60'ı oluşturulacak adaptif modelde ağın eğitimi için kullanılmıştır. Eğitim süreci boyunca kullanılacak bulanık çıkarım sisteminin oluşturulması için ANFIS içinde ızgara bölümlleme (grid-partition) ve alt kümeleme (sub-clustering) olmak üzere iki alternatif yöntem kullanılmıştır. Bu yöntemlerin her ikisi için de ayrı olacak şekilde tahmin modelleri oluşturulmuş ve elde edilen tahmin sonuçlarının başarıları kıyaslanmıştır. Ortaya çıkarılan model için performans karşılaştırması yapmak amacı ile ek olarak bir regresyon analizi modeli oluşturmuş ve elde edilen tahmin sonuçları ortalama mutlak yüzde hata kriteri üzerinden değerlendirilmiştir. Brüt elektrik talep tahmininde 20 test verisi üzerinde hesaplanan Ortalama Mutlak Hata (Mean Absolute Error) ile Grid Partitioning yöntemiyle oluşturulan tahmin modelinden % 3,95 hata alınırken, Sub-Clustering yöntemiyle oluşturulan model % 3,26 tahmin hatası vermiştir. Sonuç olarak ANFIS ile oluşturulan bu modelin başarılı ve tatmin edici bir tahmin performansı gösterdiği değerlendirilmiştir.

Kara (2008), tez çalışmasında diyabet hastalığının tanı ve tedavisi için ANFIS destekli bir uzman sistem geliştirmiş olup bu modelin internet ortamından da kullanılabilen faydalı bir sistem olması için web teknolojileri ve yazılım geliştirme gereçleri de kullanmıştır. Web teknoloji tabanlı uzman sistemin geliştirilmesinin ardından diyabet hastalarının sosyo-demografik verileri kullanılarak veri madenciliği teknikleri ile karşılaştırılması gerçekleştirilmiştir. Bu çalışmada da temel bileşen analizi ve ANFIS kombin edilerek teşhisin doğruluğu artırılmaya çalışılmıştır. Amaçlanan sistem iki aşamaya sahiptir. Öncelikle 8 olan özellik sayısı Principal Component Analysis ile 4'e indirilmiş, sonrasında adaptif tabanlı bulanık çıkarım sistemi ile sınıflandırma yapılmıştır. Amaçlanan sistemin sınıflandırma doğruluğu % 89.47 olarak hesaplanmıştır. Ek olarak ANFIS ile lojistik regresyon kıyaslanmış ve ANFIS yöntemi ile yapılan çalışmanın daha etkili olduğu tespit edilmiştir.

Fattahi (2017)'nin çalışmasında FOS (Factor Of Safety - Eğitim Güvenlik Faktörü)'un, doğru tahmininin, kararlılıklarının ve performanslarını değerlendirmenin kolay bir konu olmadığı savunularak uyarlamalı adaptif bulanık çıkarım sistemi eğitim güvenlik faktörü

için bir tahmin modeli oluşturmak amacıyla kullanılmıştır. Üç ANFIS modeli GP (Grid Partitioning), SCM (Subtractive Clustering) ve FCM (Fuzzy C-Means) metotları kullanılarak oluşturulmuştur. Giriş parametresi olarak kohezyon katsayısı, iç sürtünme açısı, eğim yüksekliği, eğim açısı ve birim ağırlığı gibi birçok önemli parametre kullanılırken, çıkış parametresi olarak FOS kullanılmıştır. Bu üç model arasında bir karşılaştırma yapılmış ve elde edilen sonuçlar ANFIS-SCM modelinin üstünlüğünü göstermiştir. Sonuç olarak ANFIS-SCM modelinin performansı MLR (Multiple Linear - Çoklu Doğrusal Regresyon) ile karşılaştırılmıştır ve elde edilen sonuçlar, ANFIS-SCM modelinin etkinliğini ispatlamıştır.

Abduljabar (2011), gazlı içecekler için uygulanacak olan bulanık mantık ve sinirsel bulanık mantık yaklaşımını kullanarak kural tabanı oluşturmayı ve oluşturulan bu kural tabanı ile gazlı içeceklerde karbondioksitin miktarını belirlemeyi amaçlamıştır. Karbondioksit miktarının sıcaklık, basınç ve yoğunluğa bağlı olduğu belirtilmiş olup giriş parametresi olarak bu değişkenler kullanılmışlardır. Çıkış parametresi olarak 5 dilsel değişken kullanılmış olup (çok kötü, kötü, orta, yüksek, çok yüksek) karbondioksit miktarı tespit edilmeye çalışılmıştır. Geleneksel bulanık mantık (mamdani-sugeno yöntemleri) ve ANFIS kullanılarak bu üç yöntemin sonuçları birbiriyle karşılaştırılmış ve karbondioksitin gerçek değerine en yakın olan yöntem belirlenmeye çalışılmış, sonuç olarak ANFIS ile daha başarılı sonucun elde edildiği görülmüştür.

Ziasabounchi ve Askerzade (2014), çalışmalarında adaptif tabanlı bulanık çıkarım sistemine dayanarak hastanın kalp hastalığı derecesini sınıflandırmayı amaçlamışlardır. Tahmin modeli için 7 adet değişken kullanılmıştır. Eğitilmiş ANFIS modelinin kalp hastalığı teşhisindeki tanıma becerisini test edebilmek için k-fold çapraz doğrulama yöntemi kullanılmıştır. Veri seti 303 girdiden oluşmaktadır. Önerilen modelde eğitim ve test işlemleri için hata oranları sırasıyla 0,01 ve 0.15 olarak hesaplanmış olup tatmin edici bir sonuç elde edilmiştir. Deney sonuçları, modelin, hastanın kalp hastalığı derecesini % 92.30 doğruluk oranıyla başarıyla tahmin ettiğini göstermektedir. Aynı zamanda bu sonuçlar, önerilen tekniğin, özellikle aynı kalp hastalığı veritabanını

kullanan diğer çalışmalar ile kıyaslandığında yüksek doğruluğa sahip olduğunu göstermektedir.

Bhuvaneswari (2013), kardiyovasküler hastalık riskini öngörmek için yüksek tahmin doğruluğu olan bir tıbbi tanı sistemi önermektedir. Sistem, Temel Bileşen Analizi ve Uyarlamalı Nöro Bulanık Çıkarım Sistemi'ne dayalı akıllı bir yaklaşım kullanılarak inşa edilmiştir. Bu sistemde de iki aşama kullanılmıştır. İlk aşamada, 13 değişkenli kalp hastalığı veri setinin boyutu PCA kullanılarak 7 değişkene indirgenmiştir. Sistemin performansını iyileştirmek için veri kümesinin boyutunun azaltılmasının faydası tespit edilmiştir. İkinci aşamada, ANFIS kullanılarak kalp hastalığı tanısı gerçekleştirilmektedir. Bu yaklaşım ile elde edilen sınıflandırma doğruluğu % 93,2'dir.

Bokde (2017), çalışmasında Normal sinüs ritmi, PVC (Prematür Ventriküler Kompleks-Prematür Ventriküler Kasılma), LBBB (Left Bundle Branch Block- Sol Bundle Branch Bloğu), RBBB (Right Bundle Branch Block- Sağ Bundle Branch Bloğu), APC (Premature Atrial Kontraksiyon- Atriyal Erken Kontraksiyon) ve tempolu atımlar olmak üzere altı tip kalp atışını sınıflandırmıştır. Araştırma, hastanın kalp atışının normal olup olmadığını belirlemek için EKG (Elektrokardiyogram) sinyalinin önemli özelliklerini tespit etmeyi amaçlamıştır. Üç farklı deneme ile elde edilen sonuçların ortalamaları sırasıyla doğruluk için % 98.43, duyarlılık için % 95.3 ve son olarak özgüllük için % 98.6 şeklindedir. Grid Partitioning ve Subtractive Clustering tabanlı ANFIS ile elde edilen bu sonuçlar, iki yapay sinir ağı gradient descent ve Levenberg Marquardt algoritması ile karşılaştırılmıştır. Bu çalışmada da ANFIS'in, EKG sınıflandırması için yapay sinir ağlarının ve bulanık sistemlerin en iyi özelliklerini entegre etme avantajına sahip olduğu kanıtlanmıştır. En iyi sonucun Subtractive Clustering tabanlı ANFIS ile elde edildiği görülmüştür.

2.2 Mezotelyoma için Yapılmış Çalışmalar

Bulanık mantık yaklaşımı ile gerçekleştirilen ve Bölüm 2.1'de bahsedilen çalışmaların yanı sıra, bu tezin konusu olan Malignant Mezotelyoma hastalığının teşhisi adına çeşitli çalışmalar gerçekleştirilmiştir.

Er vd. (2015), çalışmalarında Mezotelyoma hastalığı teşhisi için AIS (Artificial Immune Systems - yapay bağışıklık sistemi) geliştirerek bu sonuçları aynı veritabanını kullanan, yine Mezotelyoma teşhisine odaklanmış çok katmanlı yapay sinir ağları yaklaşımının sonuçları ile karşılaştırmışlardır. Bu amaçla kullanılan AIS modelinin algoritmik adımları şunlardır:

- Antikor popülasyonu oluşturularak supresyon eşiği belirlemek.
- Her antikor için klonlar (yeni antikor / antijen) üretmek.
- Antikor hücreleri arasındaki afiniteyi hesaplamak ve afiniteleri supresyon eşiğinden az olan antikorları öldürmek, supresyon sonrası antikor sayısını belirlemek.
- Bellek popülasyonunun sabit olduğundan emin olunamadığında adım 2'ye dönmek.
- Verilen değerleri sınıflandırmak.

Amaçlanan sistem ile sağlıklı olan ve Mezotelyoma hastalığına sahip olan kişiler için sınıflandırma sürecinde doğru teşhisin gerçekleştirilmesi amacıyla, doktorlara bir karar destek sistemi olarak fayda sağlanması hedeflenmiş ve C# ortamında geliştirme yapılmıştır. Veri seti, tıp fakültesi veri tabanından elde edilmiştir. Test edilen yapay bağışıklık sistemi ile % 97.74 oranında bir başarı elde edilmiştir. Yapay bağışıklık sistemi algoritmasının doğruluk sonuçlarının çok katmanlı yapay sinir ağı algoritmasından çok daha iyi olduğunu öne sürmüşlerdir.

Tutuncu ve Çataltaş, Malignant Mezotelyoma teşhisi çalışmalarında 9 farklı veri madenciliği algoritması kullanarak sınıflandırma yapmaya çalışmışlardır. Bu sınıflandırma algoritmaları sırası ile J48, Bayes Net, SMO (Sıralı Minimal Optimizasyon), LMT (Logistic Model Trees), Logistic, Multi Class Classifier, Random Committee, PART (Projective Adaptive Resonance Theory) ve ANN (Artificial Neural Network)'dir. İlk 8 algoritma WEKA (Waikato Environment for Knowledge Analysis) platformunda uygulanırken, ANN sınıflandırıcı Alyuda NeuroIntelligence 2.2. paket programı ortamında uygulanmıştır. Tüm algoritmalar kıyaslandığında en iyi sonuç ANN ile elde edilmiştir (Çizelge 2.1).

Çizelge 2.1 Mezotelyoma için gerçekleştirilen çalışmaların doğruluk sonuçları

Sınıflandırıcı Kuralları Yöntemi	Doğruluk Oranı
J48	%87.3457
Bayes Net	%88.2716
SMO	%88.8889
LMT	%89.1975
Logistic	%89.5062
Multi Class Classifier	%89.5062
Random Committee	%90.1235
PART	%90.7407
Artificial Neural Network	%99.0740

J48 bir karar ağacı algoritması olup C4.5 algoritmasının WEKA için adapte edilmiş halidir. Karar ağacı algoritmaları örnek veri kümesiyle başlayarak sınıflandırılmayı bekleyen durumlar için bir ağaç veri yapısı inşa eder ve bu ağaç oluşturulduğunda veritabanındaki her gruba uygulanması, o grubun sınıflandırılmasıyla sonuçlanır.

Bayes ağı, değişkenlerin temsilcisi olan düğümler ve bu değişkenler arası olasılıksal bağlantı ilişkilerinin temsilcisi olan oklar aracılığı ile grafiksel bölüm ve değişkenlere ait olan olasılık tabloları olmak üzere iki temel kuramdan oluşmaktadır (Çinicioğlu vd. 2013). Var olan problemin yapısı veya eldeki verilerin yetersizliği nedeniyle kesin bir sonuca varılamayan durumlarda bu yöntem oldukça kullanışlıdır ve bu sebepten en güzel kullanım alanlarının sağlık alanı olduğu (Charniak 1991, Lucas 2001) belirtilmektedir (Sorias 2015).

SMO algoritması, eğitim verileri arasındaki herhangi bir noktadan en uzak olan iki sınıf arasında bir karar sınırı bulan bir makine öğrenme yöntemi olarak adlandırılan DVM (Destek Vektör Makineleri) sınıflandırıcısını eğitmek amacıyla kullanılmak üzere

tasarlanmış bir optimizasyon yöntemidir. Kuadratik programlama problemi olarak çok terimli kernel (kabuk) fonksiyonları kullanmaktadır. Eğitilen DVM KP (Karesel Programlama) hesaplamaları gerektirdiğinden SMO, karesel hesaplamaları küçük problemlere dönüştürerek iç döngü üzerinden çözmeyi hedefler. SMO genel yapısı itibarı ile dış döngüde en iyi verilerin seçimini gerçekleştirir, iç döngüde ise seçilen bu verilere göre iki adet Langrage çarpanı hesaplamaktadır. İç ve dış döngüler tüm örnekler istenilen düzeye gelinceye dek çalıştırılır (Nizam ve Akın 2014) (Senel vd. 2017).

LMT, Lojistik Regresyon modellerini ve Karar Ağacı Öğrenmesi algoritmalarını birleştiren denetimli yapıda bir sınıflandırma modelidir. Bu algoritmanın çalışma prensibinde ağaç yapısı C4.5 algoritmasına benzer şekilde genişletilir, yapraklar üzerinde lojistik regresyon fonksiyonlarına sahip bir karar ağacı yapısıdır. Geleneksel karar ağaçlarında olduğu gibi, öznitelik testi her iç düğümle ilişkilendirilir. Her düğümün k çocuk düğümleri vardır ve örnekler öznitelik değerine bağlı olarak k dallarına ayrılır. Nümerik özellikler için, düğüm 2 çocuk düğüme sahiptir ve test, özellik değerini ve bir eşik değerini karşılaştırmaktan oluşur. Her bir ayrışmada, ebeveyn düğümün lojistik regresyonları alt düğümlere geçirilmektedir. Bunun sonucu olarak, yaprak düğümler tüm ebeveyn düğümlere ilişkin bilgi içerir ve her bir sınıf için olasılık tahminleri oluşturur. Algoritma işlendikten sonra oluşturulan ağaç yapısına budama işlemi uygulanarak model oluşturulur (Onan 2015) (Tutuncu ve Çataltaş 2017).

Logistic sınıflandırmada ise hedef, bağımlı değişkenin sonucunu tahmin edebilecek en sade modeli bulmaktır. Doğrusal regresyon analizinin temelinde bağımlı ve bağımsız değişkenler sayısal olarak belirtilir. Örnek olarak, yaş ile kan basıncı arasında bir ilişki aranması halinde bu durumda hem yaş değeri hem de kan basıncı değeri sayısal olarak tanımlanmalıdır, nitelik olarak belirtilemezler. Bağımlı değişkenlerin nitelik olarak belirtilmesi durumunda bağımsız değişkenlerle arasındaki ilişki lojistik regresyon yöntemiyle aranır. Doğrusal regresyon analizinde tahmin edilmesi amaçlanan bağımlı değişken sürekli iken, Lojistik Regresyon Analizinde bağımlı değişken sürekli değil kesikli bir değer almaktadır ve bu bağımlı değişkenin alabileceği değerlerden birinin gerçekleşme olasılığı tahmin edilir. Lojistik regresyon analizinde “model ki-kare” testi ile analiz sonucunda oluşturulan modelin uygun olup olmadığı, “Wald istatistiği” ile

her bir bağımsız değişkenin modelde varlığının anlamlı olup olmadığı test edilir (Anonim 2018b).

Multi Class Classifier (Çoklu sınıf sınıflandırma), destek vektör makineleri iki sınıfın ayrılmasında kullanılırken çok sınıflı destek vektör makineleri ile sınıflandırılacak grupların ikiden fazla olması durumu ele alınmaktadır. Destek vektör makineleri aslında iki katmanlı problemler için geliştirilmiş olsa da, iki türlü yaklaşımla çok sınıflı sınıflandırmaya dönüştürülebilir. Bu yaklaşımlardan biri, iki sınıflı bir sınıflandırma destek vektör makinesini çok sınıflı bir sınıflandırıcıya dönüştürmek için belirli bir şekilde birleştirirken, diğer yaklaşım ise eğitim numuneleriyle çok sınıflı bir sınıflandırma işlevini doğrudan çözmektir. İkinci yolun karar verme işlevlerini yerine getirmesi zordur, eğitim ve test süreçleri uzun süreçlerdir. Yani, ilk yöntem daha pratiktir ve bu yöntemden problemin ikili gruplara indirgenmesi (bire bir yaklaşımı), problemin tek gruptan bütün gruplara modellenmesi (bire çok yaklaşım) gibi çeşitli algoritmalar türetilmiştir.

Random Committee, rastgele bir temel sınıflandırıcılar grubu oluşturmak için kullanılan bir platformdur. Rastgele komite aynı zamanda meta sınıflandırıcı kategorisinde yer alan bir sınıflandırıcıdır, Weka'da uygulanmaktadır ve java sınıfları kullanılarak gerçekleştirilmektedir. Son tahmini, bireysel temel sınıflandırma algoritmaları tarafından üretilen tahminlerin ortalamasıdır.

PART (Projective Adaptive Resonance Theory), I. H. Witten ve E. Frank tarafından önerilen, böl ve yönet mantığı ile çalışan bir algoritma olup bu algoritma, kurallar kümesini sıralayan ve karar listeleri olarak adlandırılan kümeler üretmektedir. Bu algoritma her bir çalıştırmada kısmi bir C4.5 karar ağacı oluşturmaktadır ve en iyi kural bir yaprağın içinde olmaktadır. Böl ve yönet stratejisini, kurallı öğrenmenin ayrı ve başarılı stratejisiyle birleştirir (Akyol ve Alataş 2016).

ANN, yapay sinir ağları olarak bilinen, sınıflandırma, modelleme ve tahmin gibi birçok günlük hayat probleminin çözümünde başarılı sonuç veren bir yöntemdir. Yapay sinir ağları nöronlar arasındaki bağlantı ağırlıklarını ayarlayarak öğrenme gerçekleştirir.

Çalışmada kullanılan 9 farklı yöntemden biri olan ANN, bu tez çalışmasında da kullanılan ANFIS yaklaşımının tabanını oluşturmakta olup ANN ile detaylı bilgilerleyen bölümlerde verilmektedir.

Mezotelyoma için gerçekleştirilen çalışmalardan bir diğerini gerçekleştiren Devi ve Sasikala'ya göre, sadece CT (Computed Tomography) görüntüsünden mezotelyoma tanısı koymak zaman almakla beraber teşhis yanlışlığına da sebep olabilmektedir. Bu sebepten ince zarın sınırlarını daha iyi görselleştirebilmek için görüntü dönüşümleri kullanılmaktadır. Bu çalışmada da mezotelyoma görüntüleri üzerine Contourlet ve Curvelet dönüşümlerinin uygulanmasına yoğunlaşılmıştır. Contourlet dönüşümü, görüntülere yönsel filtre bankaları uygulamaktadır. Curvelet dönüşümü ise görüntüdeki bir referans elemanı üzerinde belirli işlemleri gerçekleştirerek elde edilir, etkili bir çoklu çözünürlük analizidir. Zayıf kenarların güçlendirilmesi ve gürültünün bastırılması amacıyla uygulanan bu algoritmalarından sonra geliştirilen bu görüntü bulanık mantık kullanılarak bölümlere ayrılır. Burada bulanık mantık, bir takım bulanık koşullar tarafından belirlenen kenarların sınıflandırılmasına dayanarak görüntüyü bölümler. Özetle çalışma, bulanık mantık uygulanarak mezotelyomaya sahip akciğer görüntülerinin bölümlenmesi ve Contourlet - Curvelet işlemleri de uygulanarak verimliliğin kıyaslanmasına dayanmaktadır. Çalışmanın sonucunda Contourlet dönüşümünün Curvelet dönüşümünden üstün olduğu görülmüştür (Yaşar 2015) (Devi ve Sasikala 2016).

Narayana vd. (2016), çalışmalarında WEKA ortamında SMO, J48, Random Forest ve Bayes Net algoritmalarını mezotelyoma teşhisi için uygulamış olup değişken sayısı fazla olduğunda Random Forest algoritmasının % 74'lük doğruluk oranı ile (Çizelge 2.2), değişken sayısı az olduğunda ise J48 algoritmasının % 71'lik doğruluk oranı ile (Çizelge 2.3) en iyi sonucu verdikleri tespit edilmiştir. Sonuçlar özellik seçimi yapılarak ve yapılmayarak iki şekilde değerlendirilmiştir.

Çizelge 2.2 Özellik seçimi gerçekleştirilmeden önce sonuçlar

Uygulanan Algoritma	Hesaplama Süresi (sn)	Doğru sınıflandırılmış veriler	Yanlış sınıflandırılmış veriler	Doğruluk Oranı (%)
<i>Bayes Net</i>	0.18	225	99	69.4444
<i>SMO</i>	0.28	231	93	71.2963
<i>J48</i>	0.04	225	99	69.4444
<i>Random Forest</i>	0.63	242	82	74.6914


Çizelge 2.3 Özellik seçimi gerçekleştirildikten sonra sonuçlar

Uygulanan Algoritma	Hesaplama Süresi (sn)	Doğru sınıflandırılmış veriler	Yanlış sınıflandırılmış veriler	Doğruluk Oranı (%)
<i>Bayes Net</i>	0.04	225	99	69.4444
<i>SMO</i>	0.01	230	94	70.9877
<i>J48</i>	0	233	91	71.9136
<i>Random Forest</i>	0.2	200	124	61.7284

3. MATERYAL VE METOT

3.1 Malign Mezotelyoma ve Çeşitleri


Mezotelyoma, karın boşluğunu saran zar olan periton, göğüs boşluğu ve akciğerleri saran zar olan plevra ve kalbi saran zar olan perikardı kaplayan bir tür epitel olan mezotelyumda başlayan kötü huylu bir tümördür. Akciğer zarı, kalp zarı, karın zarı ve testis zarından kaynaklanabilen sinsi başlangıçlı bir tümör olmasıyla birlikte yüzde yüksek oranlarda akciğer zarından (plevra) (Şekil 3.1) kaynaklanmaktadır (Anonim 2018c).



Şekil 3.1 Akciğer yapısı ve mezotelyoma (Anonim 2018d)

Mezotelyoma hastalığına, genellikle akciğerde ortaya çıkması sebebiyle “akciğer zarı kanseri” de denmektedir ve malign mezotelyoma plevra olarak da adlandırılmaktadır. Ancak nadir de olsa kalp, mide ve karındaki diğer dokularda da başlayıp yayılma gösterebilmektedir. Plevra, akciğer ve akciğerin etrafındaki göğüs kafesine ait yapıları

döşeyen zardır. Kökünü plevra isimli bu zardan alan ve buradan düffüz (yaygın) ve dağınık olarak başlayan, sonrasında gelişen ve yayılan malign (kötü huylu) tümörler mezotelyoma olarak adlandırılmaktadır. Bu nedenle de mezotelyoma daima kötü huylu (malign) olarak kabul edilmektedir. Ülkemizde de yaygın olan plevra kökenli, yani akciğer zarından doğan mezotelyomalardır. Plevra tümörleri şekil 3.2’de sınıflandırılmakta olup, bu çalışmada malign (yayılan nitelikteki kötü huylu tümörler) mezotelyoma üzerine çalışılmaktadır (Anonim 2018d).



Malign:	Yaygın nitelikli tümörleri tanıtmak için kullanılan genel ad
Benign:	İyi huylu tümörleri tanıtmak için kullanılan genel ad
Primer:	Plevradan kaynak alan
Sekonder:	Plevraya dışarıdan gelen

Şekil 3.2 Plevra tümörleri

3.1.1 Hastalığa yakalanmada etkili olan faktörler

Malign Mezotelyoma tümörünün zaman içinde ortaya çıkmasına sebep olarak bilinen başlıca etmenler asbest maruzu, Sv40 virüsü, uzun süreli radyasyona maruz kalınması ve genetik açıdan yatkınlıktır.

Asbest: Mezotelyoma, memleketimizde son zamanlarda yaygın görülen bir hastalık olmakla beraber dünyada görülme sıklığı 1 milyon kişide 1-2 iken ülkemizde yılda ortalama 500 kişiye hastalık tanısı konulmaktadır. Bu hastalık genellikle halk arasında çorak toprak, gök toprak, çelpek, höllük, ak toprak veya ceren olarak da bilinmekte olan asbest ve erionit denilen maddelere uzun yıllar maruz kalmış olan kişilerde ortaya çıkmaktadır. Asbest ya da diğer adıyla amyant, sıcaklığa, aşınmaya ve kimyasal maddelere karşı dirençli olan lifli yapıya sahip kanserojen bir silikat türü mineraldir. Asbest genellikle köy yerleşkelerinde evlerin badana yapılması, küçük çocuklarda pudra niyetine kullanılması ya da çeşitli meslek dalları gibi sebeplerle kalınan maruziyet sonucu mezotelyomaya sebep olabilmektedir, belirti ve bulgular genel olarak bu maruziyetten 20-40 yıl sonra ortaya çıkmaktadır (Anonim 2018e).

SV40 virüsü: Bazı çalışmaların incelenmesi ile çocukluk çağlarında mezotelyoma görülmesi ve ek olarak asbest teması olmayan olgu oranının %50'ye ulaşması sebebiyle, bu hastalığın gelişmesine etken olarak başka nedenlerin olabileceği de akıllara gelmiştir. Bu bağlamda yapılan değerlendirmelerde bazı mezotelyoma dokuları içinde çocuk felci aşısında kullanılan Simian 40 virüsü (SV 40) adı verilen bir virüsün bu vakalar ile ilişkilendirildiği görülmektedir. “Salk aşısı” olarak bilinen ve özellikle Amerika ve Avrupa ülkelerinde 1950 yıllarının sonlarında yaygın olarak kullanılan çocuk felci aşısının bu ülkelerde çok sayıda insana bu virüsün bulaşmasına sebep olduğu öğrenilmiştir. Ülkemizde ise bu aşı kullanılmadığından virüsün bulaşması ile alakalı delil elde edilememiştir (Akpınar 2010).

Radyasyona maruz kalmak: Yapılan bazı araştırmalarda ise başka bir kanser türü sebebiyle görülen tedavide radyasyon alınmasına bağlı olarak mezotelyoma riskinin de artabileceği değerlendirilmiştir.

Genetik yatkınlık: Çeşitli çalışmalarda ilk 2 madde ile kıyaslandığında daha düşük bir orana sahip olsa da ailesel yatkınlığın da sebep olabileceği görülmüştür.

3.1.2 Belirtileri, teşhisi ve tedavi yöntemleri

Bölüm 3.1.1’de bahsedilen ve bu hastalığı tetikleyebilecek olan bahse konu etkenlere maruz kalınması ile genellikle yıllar sonra ortaya çıkan malign mezotelyomanın başlıca belirtileri aşağıdaki şekildedir:

- Nefes darlığı, nefes alıp vermede güçlük yaşanması
- Göğüs kafesi altında ağrı, karın ağrısı ve şişkinlik
- Yutma güçlüğü (disfaji)
- Gece terlemeleri
- Yüksek ateş
- Sürekli öksürük hali
- Parmak uçlarında şişme
- İştah kaybı
- Sebebi belirlenemeyen kilo kaybı
- Omuz ağrısı

Mezotelyoma, bu semptomlara sahip birçok hastalığın var olması sebebi ile teşhisi zor bir vakadır. Ancak temel olarak muayene doktorun, şikayetçi kişinin hastalığa yakalanması ile alakalı şüphelendiği temel noktaları içeren geçmişini dinlemesi ve fiziki muayene yapması ile başlamaktadır. Tespit edilen tümörden doku örneğinin alınması ile patolojik inceleme sayesinde kesin teşhis konulabilir. Yapılan patolojik inceleme sonrasında hangi tip mezotelyoma olduğu da belirlenmelidir. Normal akciğer grafileri teşhis için yeterli olmayacağından, şikayetlerinde mezotelyoma belirtileri olan ve akciğer grafisinde plevrada anormallik tespit edilen durumlarda göğüs ve karın için X-ışınları, bilgisayarlı tomografi, MR ve PET-CT gibi yöntemlere başvurulabilir (Anonim 2018f).

Genellikle asbeste maruz kaldıktan sonra ortalama 20-40 yıl arasında ortaya çıkması sebebi ile uygulanan tedavi metotları da yaşlı insanların kaldırabileceği boyutlarda seçilmektedir. Tümörün lokasyonu, büyüklüğü ve yayılma durumu gibi etkenlere bakılarak bazı temel tedavi şekilleri uygulanabilir.

Ameliyat: Eğer tümörün yaygınlığı az ve erken bir evrede ise ameliyat gerçekleştirilebilir (Evre 1 ve evre 2 durumlarında).

Kemoterapi: Kemoterapi sırasında kanser tespit edilen hücrelerin yayılmasını ve büyümesini engelleyen ya da onları yok etmeye yarayan ilaçlar kullanılabilir.

Radyoterapi: Yaygın bir bölgeye uygulanması diğer organlar için zararlı olabileceğinden verilebilecek ışın miktarı sınırlıdır, bu durum da tedavinin başarı oranını düşürmektedir. Mezotelyomayı hafifletici bir tedavi olarak kullanılabilir.


Cyberknife veya IMRT (Intensity Modulated Radiotherapy): Bu yöntemler özellikle tespit edildiği bölgelere lokal şekilde uygulandığı durumunda hastanın şikayetlerini azaltma amaçlı uygulanabilir.

3.2 Yapay Sinir Ağları (ANN - Artificial Neural Network)

YSA (Yapay Sinir Ağları), insan beyninin gerçekleştirebildiği öğrenme, üretebilme, anlama, sınıflandırma, genelleme, analiz etme, hatırlama gibi çeşitli özellikleri modelleyerek bu işlemleri otomatik olarak gerçekleştirmeyi amaçlayan, birçok bilim dalında uygulanmakta olan ve çözülmesi zor olan karmaşık durumları çözebilme yeteneğine sahip olan mantıksal sistemlerdir. Donanım açısından elektronik devreler ile, yazılımsal bağlamda bilgisayarlarda modellenenirler. İnsanın biyolojik sinir ağı mimarisini matematiksel olarak taklit eden yapay sinir ağları ile karmaşık olayları işleyebilme yeteneğinin bilgisayar sistemlerine kazandırılması amaçlanmıştır.

3.2.1 Biyolojik sinir hücreleri

Biyolojik sinir ağı insan beyinde yer alan sinir hücrelerinden oluşmaktadır. Biyolojik bir sinir hücresi temelde sinapslar, dentritler, hücre gövdesi ve aksonlardan oluşmaktadır. Sinir hücreleri nöronlar olarak da tanımlanmakta olup, geniş bir hücre gövdesi ve bu gövdeden dallanan uzun ve kısa uzantılardan meydana gelmektedir. Bu uzantıların kısa olanlarına dentrit, uzun olanlarına ise akson denilmektedir. Kısa uzantılar olan dentritler sinaptik sinyalleri girdi olarak almakta, hücre gövdesi bu sinyalleri analog bir yöntemle işlemektedir. Üretilen denetim sinyalleri, uzun olan uzantılar yani aksonlar aracılığı ile denetlenecek hedef hücelere veya hücre gruplarına iletilmektedir. Aksonlar, nöronların en uzun kısmıdır. Biyolojik sinir hücresinin temel yapısı şekil 3.3'te yer almaktadır.



Şekil 3.3 Biyolojik sinir hücresi (Anonim 2018g)

Hücre gövdesi, sinir hücrelerinin en kalın kısmı olup hücrenin yönetimi ve beslenmesinde rol oynarlar. Ayrıca dentritler aracılığı ile getirilen uyarıları aksonlara aktarırlar. İçeriğinde sitoplazma ve çekirdek bulunmaktadır. Sinapslar sinirler arası boşluk ve akson uçları olarak geçmektedir. Sinir hücrelerinin (nöronların) diğer sinir hücrelerine ya da sinir hücresi olmayan kas ve salgı bezi hücrelerine mesaj iletilmesinde görev alan özel bağlantı noktası görevini sinapslar görmektedir. Sinir hücrelerinde uyarılar dentritten aksona doğru iletilmektedir.


3.2.2 Yapay sinir hücreleri

Yapay sinir ağı da bir nevi biyolojik sinir ağındaki yapıyı taklit etmektedir ve biyolojik sinir ağlarının matematiksel modelidir. Aynı biyolojik sinir ağlarında yer alan sinir hücreleri gibi yapay sinir ağlarında da yapay sinir hücreleri, nöronlar, sinaptik bağlantılar ve bağlantılar arasındaki transfer işlemleri için fonksiyonlar bulunmaktadır. Yapay sinir hücreleri, elde olan geçmiş verilerde tanımlı bu girdi ve çıktılar arasında kurulan ilişkiyi öğrenerek eğitilirler. Bu yapay sinir hücrelerinin çeşitli şekillerde bağlanması ile katman katman bir yapı şeklinde yapay sinir ağını oluşturmaktadır. Biyolojik sinir sistemi yapıtaşlarının, yapay sinir ağı modelindeki karşılığı çizelge 3.1’de yer almaktadır (Ayana 2016).

Çizelge 3.1 Biyolojik sinir sistemi elemanlarının yapay sinir ağındaki karşılıkları

İnsan Sinir Sistemi - Yapay Sinir Ağı Sistemi	
<i>Yapay Sinir Ağı Sistemi</i>	<i>İnsan Sinir Sistemi</i>
İşlem yapan eleman	Nöron
Toplama işlemini gerçekleştiren fonksiyon	Ağaç (dendrit)
Transfer fonksiyonu	Hücre gövdesi
Elemanın çıkışı	Sinir lifi (akson)
Ağırlıklar	Bağlantı noktası (sinaps)

Yapay bir sinir hücresi girişi ve çıkışı belli olan, ağırlıklar, birleştirme fonksiyonu ve aktivasyon fonksiyonundan oluşan beş temel bileşenli bir yapıdır (Şekil 3.4).



Şekil 3.4 Yapay sinir hücresinin yapısı (Anonim 2018h)

Yapay Sinir ağlarının genel özellikleri;

Girdiler: Yapay sinir hücrelerine gelen veriler olup gelen, girdi olarak adlandırılan bileşenler yapay sinir hücresine bir başka hücreden ya da direkt olarak dış dünyadan da gelebilirler. Girdilerden gelen bu veriler aynı biyolojik sinir hücrelerinde de olduğu gibi nöron çekirdeğine iletilerek toplanır, ağırlık öğrenmesi istenen örnekler tarafından belirlenir.

Ağırlıklar: Yapay sinir hücresine gelen bilgiler girdiler üzerinden çekirdeğe ulaşmadan önce geldikleri bağlantıların ağırlığıyla çarpılarak çekirdeğe iletilir. Bu sayede girdilerin üretilen çıktı üzerindeki etkisi ayarlanabilmektedir, burada yapay hücreye gelen bilginin önemi ve hücre üzerindeki etkisi ortaya çıkmaktadır. Bu ağırlıkların değerleri sıfır, negatif ya da pozitif olabilir. Ağırlıkların büyük ya da küçük olması önemli ya da önemsiz olarak sınıflandırılmaz. Girdilerden sıfır ağırlığına sahip olanlar çıktı üzerinde herhangi bir etki göstermemektedir.

Birleştirme Fonksiyonu: Birleştirme (toplama) fonksiyonu, bir yapay sinir hücresine ağırlıklarla çarpılarak gelen girdileri toplayarak o hücrenin net girdisinin hesaplanması

görevini üstlenmektedir. Bu işlem için çeşitli fonksiyonlar kullanılmaktadır. En çok kullanılan ağırlıklı toplamı bulmaktır. Her girdi değeri sahip olduğu ağırlığı ile çarpılarak toplanır ve böylelikle ağa gelen girdinin net hali belirlenmiş olur.

$$NET = \sum_{i=1}^N x_i * w_i \quad (3.1)$$

Eşitlik 3.1’de şekilde formülize edilen hücre net girdisi için, burada x girdileri, w ağırlıkları, N ise bir hücreye gelen girdi sayısının toplamı olarak tanımlanmaktadır. Genellikle kullanılan bu formülün yanı sıra, yapay sinir ağlarında yapılması planlanan çalışmaya göre verilecek karar ile farklı fonksiyonlar da kullanılabilir, en uygun toplama fonksiyonunun seçilmesi için geliştirilmiş bir yöntem bulunmamaktadır. Farklı toplama fonksiyonu örnekleri çizelge 3.2’de sıralanmıştır (Öztemel 2012).

Çizelge 3.2 Bazı toplama fonksiyonları

Çarpım $Net = \prod_{i=1}^N X_i * W_i$	Girdi değişkenleri ağırlık değerleri ile çarpılır ve sonrasında bulunan değerler birbirleriyle çarpılarak Net Girdi değeri hesaplanır.
Maksimum $Net = Max (X_i * W_i)$	n adet girdi içinden ağırlıklar girdilerle çarpıldıktan sonra değerlerden en büyüğü Net girdi olarak belirlenir.
Minimum $Net = Min (X_i * W_i)$	n adet girdi içinden ağırlıklar girdilerle çarpıldıktan sonra değerlerden en küçüğü Net girdi olarak belirlenir.
Çoğunluk $Net = \sum_{i=1}^N Sgn (X_i * W_i)$	n adet girdi içinden ağırlıklar ile girdiler çarpıldıktan sonra pozitif ile negatif olan değerlerin sayısı bulunur. Büyük olan sayı hücrenin net girdisi olarak belirlenir.
Kimülatif Toplam $Net = Net (eski) + \sum_{i=1}^N X_i * W_i$	Hücreye gelen bilgiler ağırlıklı olarak toplanır. Daha önce hücreye gelen bilgilere yeni hesaplanan girdi değerleri eklenerek hücrenin net girdisi hesaplanır.

Aktivasyon Fonksiyonu: Aktivasyon (transfer) fonksiyonu ile yapay sinir hücresine gelen ve daha önce toplama fonksiyonu ile hesaplanan net girdi işlenerek hücrenin bu girdiye karşılık üreteceği çıktı belirlenmektedir. Bu fonksiyon genellikle doğrusal olmayan bir fonksiyon seçilir. Yapay sinir ağlarının özelliklerinden olan doğrusal olmama durumu, aktivasyon fonksiyonlarının seçilen bu özelliğinden gelmektedir. Aktivasyon fonksiyonu seçilirken dikkat edilmesi gereken bir diğer nokta ise fonksiyonun türevinin kolay hesaplanabilir olmasıdır. Geri beslemeli ağlarda aktivasyon fonksiyonunun türevi de kullanıldığı için hesaplamaların yavaşlamaması için türevi kolay hesaplanır bir fonksiyon seçilir. Toplama fonksiyonunda olduğu gibi aktivasyon fonksiyonu için de çeşitli formüller kullanılabilmektedir (Çizelge 3.3). Genellikle en yaygın olarak kullanılan “Sigmoid fonksiyonu” kullanılmaktadır.

Çizelge 3.3 Aktivasyon fonksiyonları

Doğrusal (Lineer) Aktivasyon Fonksiyonu	$F(Net) = A * Net$ (A sabit bir sayı)	Doğrusal problemlere çözüm getirmek için aktivasyon fonksiyonu doğrusal bir fonksiyon olarak seçilebilir. Toplama fonksiyonundan elde edilen sonuç, belirli bir katsayı ile çarpılarak hücrenin çıktısı olarak hesaplanır.
Adım (step) Aktivasyon Fonksiyonu	$F(Net) = \begin{cases} 1 & \text{if } Net > \text{Eşik Değer} \\ 0 & \text{if } Net \leq \text{Eşik Değer} \end{cases}$	Gelen Net girdinin belirli bir eşik değer üstünde veya altında olmasına göre hücre çıktısı 0 veya 1 değerini alır.
Sigmoid Aktivasyon Fonksiyonu	$F(Net) = \frac{1}{1 + e^{-Net}}$	Türevi alınabilen ve sürekli bir fonksiyondur. Doğrusal olmaması ile YSA uygulamalarında sık kullanılır. Girdilerin her biri için 0 ile 1 arasında bir değer üretir.


Çizelge 3.3 Aktivasyon fonksiyonları (devam)

Tanjant Hiperbolik Aktivasyon Fonksiyonu	$F(Net) = \frac{e^{Net} + e^{-Net}}{e^{Net} - e^{-Net}}$	Tanjant hiperbolik fonksiyonu, yapı itibarı ile sigmoid fonksiyonuna benzemektedir. Sigmoid fonksiyonunda çıkış değerleri 0 ile 1 arasında değişirken tanjant hiperbolik fonksiyonunun çıkış değeri -1 ile 1 arasında değişmektedir.
Eşik Değer Fonksiyonu	$F(Net) = \begin{cases} 0 & \text{if } Net \leq 0 \\ Net & \text{if } 0 < Net < 1 \\ 1 & \text{if } Net \geq 1 \end{cases}$	Gelen bilgiler 0'dan küçük-eşit olduğunda 0 çıktısı, 1'den büyük-eşit olduğunda 1 çıktısı, 0 ile 1 arasında olduğunda ise yine kendisini veren çıktılar üretilebilir.
Sinüs Aktivasyon Fonksiyonu	$F(Net) = \sin(Net)$	Öğrenilmesi düşünülen olayların sinüs fonksiyonuna uygun dağılım gösterdiği hallerde kullanılabilir.

Çıktılar: Aktivasyon fonksiyonundan çıkan değer yapay sinir hücresinin çıktı değeridir. Bu değer yapay sinir ağının çıktısı olarak dış dünyaya verilebildiği gibi tekrar ağın içinde de kullanılabilir. Her yapay sinir hücresinin birden fazla girdisi olabilirken çıktısı tek olmaktadır. Bu çıktı ise istenilen sayıda hücreye girdi olarak gidebilir.

3.2.3 Yapay sinir ağının yapısı

Yapay sinir hücrelerinin birbirine bağlanmasıyla oluşan yapılara yapay sinir ağları denilmektedir. Yapay sinir ağları giriş katmanı, ara (gizli) katmanlar ve çıkış katmanı olmak üzere 3 ana bölümde incelenmektedir (Şekil 3.5). Hücreler 3 katman halinde ve her katman içinde paralel olarak bir araya gelerek ağı oluştururlar.



Şekil 3.5 Çok katmanlı yapay sinir ağı modeli (Anonim 2018i)

Giriş Katmanı: Dış çevreden yapay sinir ağına gelen verileri alarak ara katmana iletir. Giriş katmanında bilgi işleme alınmaz, gelen her bir bilgi işlenmeden bir sonraki katmana gönderilmektedir. Her işlem elemanı sadece bir tane girdi ve bir tane çıktıya sahiptir. Giriş katmanında yer alan her bir girdi elemanı bir sonraki katmanda bulunan girdi elemanlarının tümüne iletilmektedir.

Ara (Gizli) Katman: Giriş katmanından alınan bilgiler bu katmana gelmekte ve işlem görerek bir sonraki katmana iletilmektedir. Çok katmanlı bir yapıda bulunan bir ağda, birden fazla ara katman ve her bir katmanda birden fazla işlem elemanı bulunabileceği gibi ara katmanın hiç yer almadığı ağ yapıları da mevcuttur. Bir ağda birden fazla ara katman mevcut ise ara katmanların kendi aralarında yer alan hücre sayıları da farklılık gösterebilmektedir. Ara katman sayısının artması, bu katmanlarda yer alan hücre sayılarının artması gibi durumlar hesaplamada yaşanacak karmaşıklığı ve hesaplama sürelerini arttıracaktır ancak bu durumlar çözülmesi zor olan karmaşık problemlerin giderilmesinde de avantaj olarak kullanılmaktadır.

Çıkış katmanı: Ara (gizli) katmandan gelen bilgiler işleme alınarak ağa girdi katmanından verilen bilgilere karşılık ağıın ürettiği çıkış değerlerini belirler ve dış çevreye iletir. Çıktı katmanında da birden fazla işlem elemanı yer alabilir. Her işlem elemanı bir önceki katmanda yer alan bütün işlem elemanları ile ilişkilidir ve her işlem elemanının bir çıktısı mevcuttur. Yapısı geri beslemeli olarak kurgulanan ağlarda bu katmanda üretilen çıktı kullanılarak ağıın yeni ağırlık değerleri için hesaplama gerçekleştirilebilmektedir.

3.2.4 Yapay sinir ağlarının sınıflandırılması

Yapay sinir ağları çalışma prensibi olarak benzer olmalarına rağmen bir standart kapsamında model oluşturmamaktadır. Yapay sinir ağlarının sınıflandırılması, sinir hücrelerinin dizilimleri, ağırlıklarını düzenlemek adına yapılan hesaplamaların türleri ve zamana göre 3 başlık altında sınıflandırılabilirler (Güney 2009).

3.2.4.1 Yapıları ile yapay sinir ağları

Yapay sinir hücreleri birbirlerine bağlanma şekillerine göre ileri beslemeli ve geri beslemeli olarak ikiye ayrılmaktadır. İleri beslemeli ağlarda nöronlar ağıın girişinden çıkışına doğru sıralı katmanlar şeklinde olup bu katmanlarda sadece kendinden sonra yer alan katmanlara bir bağlantı bulunmaktadır. Yapay sinir ağına gelen bilgi öncelikle giriş katmanına, sonrasında ara katmana ve son olarak çıkış katmanında sırasıyla işlenir, sonuç olarak dış dünyaya çıkar. Geri beslemeli yapay sinir ağlarında ise ileri beslemeli ağlarda yer alan yapının aksine bir yapay sinir hücresinin çıktısı sadece kendinden sonra gelen nöron katmanına girdi olarak verilmez. Kendinden önceki katmanda ya da kendi katmanında bulunan herhangi bir nörona girdi olarak bağlantı sağlayabilmektedir.

3.2.4.2 Öğrenme algoritmaları ile yapay sinir ağları

Yapay sinir ağları öğrenebilme yeteneği sayesinde ağa giren girdilere göre çıktılar üretebilmektedir. Öğrenme işleminin gerçekleştirilmesinde izlenen 3 yol bulunmaktadır.

Danışmanlı öğrenme algoritmasında ağa verilen girdilere ek olarak çıktılar da verilmektedir, verilen bu girdiler için istenilen çıkış değerlerini oluşturmak adına ağırlıkların güncellenmesi yapılır. Sonrasında çıktının beklenen değeri ile ağın hesapladığı çıktı değeri arasındaki hata hesaplanarak, yeni ağırlıklar hesaplanan bu hata değerine göre güncellenir. Bu işlem geri yayılım algoritması olarak tanımlanmaktadır.

Danışmansız öğrenme algoritmasında ağa öğrenebilmesi için örnek girdiler verilmektedir, danışmanlı öğrenmede olduğu gibi ağa beklenen çıktı değeri verilmez. En başta verilen girdi değerleri için ağ kendi kurallarını oluşturarak her bir örneği birbirine yakın olma durumlarına göre sınıflandırmaktadır. Burada sınıflandırma işlemi verilen ağırlık katsayılarına göre yapılmaktadır.

Takviyeli (destekleyici) öğrenme algoritmasında ağa çok detay verilmemekle beraber girilen bilgilere karşılık çıktılarına bakılarak, yapay sinir ağına çıkan bu sonuçların doğru, yanlış, iyi ya da kötü olduğu belirtilir ve bunun sonucunda ağın bu bilgiyi kullanarak tekrar öğrenme aşamasına geçmesi amaçlanmaktadır.

3.2.4.3 Öğrenme zamanı ile yapay sinir ağları

Öğrenme zamanına göre yapay sinir ağları dinamik ve statik olmak üzere ikiye ayrılmaktadır.

Statik öğrenmede yapay sinir ağına verilen eğitim girdileri ile ağ eğitilir ve ağın yapısı kaydedilir. Yani ağ kullanılmadan önce eğitilmektedir. Bu aşamadan sonra ağ aynı yapıyla çalışır ve kullanımı esnasında ağırlıklar bir değişikliğe uğramamaktadır.

Dinamik öğrenmede ise yapay sinir ağı eğitim verileriyle eğitildikten sonra kullanımı sırasında da öğrenme işlemine devam etmektedir. Eğitim aşaması tamamlandıktan sonra ağırlıklar değiştirilerek çalışmaya devam eder ve bu sayede sürekli öğrenen bir ağ elde edilebilir.

3.2.5 YSA uygulama alanları

Yapay sinir ağıları, temelde bu çalışmanın da amacını oluşturan aşağıdaki fonksiyonları gerçekleştirmek için kullanılmaktadır.

- Sınıflandırma, tanıma ve eşleştirme
- Tahmin
- Veri ilişkilendirme ve filtreleme
- Teşhis ve yorumlama

Bunlar dışında otomotiv sektörü, bankacılık, uzay sanayisi, elektrik, finans ve iş, sağlık ve ilaç sanayi, askeri, haberleşme, endüstri, sigortacılık, eğlence ve üretim alanlarında da gittikçe artan bir potansiyelle kullanılmaktadır (Ağyar 2015).

YSA yöntemleri bulanık mantık yöntemleri ile beraber çok başarılı bir temel teşkil etmektedir. Yapay sinir ağıları uygulamalara kısa zamanda uygulanabilen sadeliğe ve fonksiyona sahiptir. Bu çalışmada da YSA yöntemlerinin bulanık mantık ile birleştirilmesi sonucu ortaya çıkan ANFIS tabanlı yaklaşım ile tahmin modeli üzerine çalışılmıştır.

3.2.6 Yapay sinir ağlarının avantajları ve dezavantajları

Yapısı gereği çok sayıda sinir hücresinden meydana gelen yapay sinir ağıları, bu sinir hücreleri zarar görse bile oluşturulan sistem çalışma bakımından güvenilirdir. Yapay sinir ağının eğitimi aşamasında oluşturulan model için genel özellikler öğrenildiğinden eğitim esnasında verilmeyen yeni sağlanacak girdiler için de sistem tahmin gerçekleştirerek sonuç elde edebilir. Eğitim aşamasında ağa verilen girdiler sonraki aşamalarda ortaya çıkacak sorunlar için doğru ve net sonuç alınması açısından önem arz etmektedir. Algılama ile ilgili işlemlerde kullanılabilir olup örüntü işleme ve bu çalışmada olduğu gibi sınıflandırma işlemlerinde de kullanılabilirler. Yapay sinir ağıları kendi kendilerine öğrenip kendilerini güncellemeleri durumunda sürekli olarak öğrenebilme yeteneğine sahiptir. Yapısını oluşturan hücreler doğrusal olmadığı için

oluşturulan sistem doğrusal olmayan problemler için de çözüm getirebilir. Yine yapısını oluşturan hücrelerin basit işlemleri çözebilen hücrelerden oluşması sayesinde yapay sinir ağı modelinin gerçekleşmesini kolay bir hale getirmektedir. Hücrelerin çözüm getirilecek problemlerin tümüne değil de problemin bir kısmına odaklanması, karmaşık haldeki problemlerin çözümünde görev paylaşımı sayesinde kolaylık sağlamaktadır.

Birbirlerine paralel halde çalışan işlemciler olmadan gerçekleştirilemediği için donanım ile bağımlı haldedir. Bir problem karşısında yapay sinir ağı ile modelleme gerçekleştirileceğinde, probleme uygun olan ağ yapısı sadece deneme yöntemi ile bulunabilmektedir ve kurgulanan yapının doğru olup olmadığını kontrol edebilecek bir mekanizma da bulunmamaktadır. Yapay sinir ağına girecek giriş parametrelerinin belirlenmesi aşamasında bir kural işletilmemektedir. Modelin oluşturulması temelinde gerçekleştirilen eğitim işlemi gerçekleştirilirken bu eğitimin ne zaman bitirileceğine dair kesin bir durum bulunmamaktadır. Eğitim sonrası hata oranının belli bir eşik değeri altına düşmesi eğitim aşamasının sonu olarak belirlenebilir ancak bu değerin en optimize eşik değeri olması gerekmektedir. Belirlenecek olan ağın şekli sistem performansını direkt etkileyecektir. Yapay sinir ağının davranışları için kesin bir yargıdan bahsedilemez ve sonuçta elde edilen tahmin değerinin her zaman doğru bir karar olduğunun kesinliği bulunmamaktadır.

3.3 Bulanık Mantık

3.3.1 Bulanık mantık ve bulanık sistemler kavramları

Literatürde matematiğin reel dünyaya uyarlanması olarak geçen bulanık Mantık kavramını ilk ortaya atan Zadeh, 1964 yılı başlarında ortaya çıkan düşüncelerini 1965 yılında Bulanık Mantık ve Bulanık Kümeler adıyla sunmuştur. L. Zadeh'e göre ortaya sunduğu kuramda geçen bulanık ifadesi matematiksel bir ifade olup düşünmenin sayısal verilerle gerçekleşmesi günümüzde insan zihni için alışlagelmiş bir durum değildir. Klasik mantık yaklaşımında bir önermenin doğru ya da yanlış olarak sınıflandırılması ilkesi mevcutken, bulanık mantık tanımının temelinde kesin sınırlamalar yerine kümelerle çeşitli derecelerle üye olma ilkesi bulunmaktadır. $\{0,1\}$ olacak şekilde iki değerli kümeden oluşan klasik mantık yaklaşımı Aristoteles Mantığı, Klasik Mantık gibi

adlarla da anılabilmektedir. Burada 0 ifadesi önerilen durumun yanlışlığına, 1 ise doğruluğuna karşılık gelmektedir. Bulanık mantık ilkesine göre ise önerme, 0-1, doğru-yanlış, evet-hayır gibi ifadeler arasında ara bir değere karşılık gelmektedir (Doğan 2016).

Gerçek hayatta yaşanan olaylar üyelik derecesi yaklaşımıyla ele alınarak bu olayların hangi miktarda gerçekleştiğini belirlemeye yarayan çoklu mantık sistemi olan bulanık mantık ilkesine göre nesneler bir kümeye belirli bir derecede ait olabilirler ve bu aitlik durumu üyelik derecesi ile ifade edilebilir. Üyelik fonksiyonları yardımıyla hesaplanan üyelik dereceleri, eşitlik 3.2’de gösterilmekte olup x elemanın A kümesindeki üyelik derecesi aşağıdaki şekilde ifade edilebilir (Şahinler vd. 2006) (İncekara 2010).

$$\mu_A(x) : x \rightarrow [0,1] \text{ yani } 0 \leq \mu_A \leq 1 \quad (3.2)$$

Önermelerin doğruluk dereceleri ile ilgilenen bulanık mantık, bu anlamda olasılık kavramına benzese de birbirinden farklı kavramlardır. Önermelerin doğruluğu, doğru olarak sınıflandırılan bir önerme hakkındaki netliğin derecesine bağlı olmakta olup bulanıklık kavramı, bir durumdaki belirsiz veya net olmayan tanımlama iken olasılık kavramı bir olayın meydana gelişindeki belirsizlik ifadesine karşılık gelmektedir (Aytaç 2011).

Bulanık mantık temelde 4 ana kavrama dayanmakta olup, bunlar aşağıdaki şekilde sıralanabilir (Mahmood 2010).

- * Bulanık Kümeler
- * Dilsel değişkenler
- * Olasılık dağılımları
- * Bulanık “eğer-ise” kuralları

Ortaya çıkan herhangi bir konudaki problem için net ve kesin olmayan bilgilerin var olduğu durumlarda, insanlara yanlış olmayan ve net bilgiler vermek adına çeşitli karar destek sistemlerinin sağlanması bulanık mantığın temel amaçlarındanıdır. Bulanık

mantık sınırları keskin olmayacak biçimde ve kolayca anlaşılabilir olup, belirsiz durumları, kesin olmayan verileri, karmaşık fonksiyonları uzman kişilerin görüş ve tecrübelerine dayanarak modelleyebilir ve modellenen uzman sistemler üzerinde kullanılarak performanslarına üstün katkı sağlamaktadır.

Bulanık mantık yaklaşımı temelli bulanık sistemler ise, bulanık mantık çalışma prensibini kullanarak çalışma adımlarının oluşturulması, performansların irdelenmesi, sonuçların gözlenmesi ve değerlendirilmesi amacıyla geliştirilen sistemlerdir ve “eğer-ise” biçimindeki birtakım bulanık kurallardan oluşan kural ya da bilgiye dayanan sistemler olarak tanımlanabilmektedirler. Bulanık sistemlerin kullanılış amacı karmaşık sistemlerin modellenmesi ve çözümüne odaklanılan problemlerden hızlı ve doğruluk payı yüksek sonuçlar alınmak istenmesidir. Anlaşılmasının kolay olması, dayandığı matematiksel teorilerin sade ve basit olması, esnekliği, eksik ya da yeterli olmayan verilerle işlem gerçekleştirebilmesi sayesinde bulanık mantık ile model oluşturmak çalışmalarda tercih edilmektedir. Bu çalışmada da kullanılan ve ilerleyen bölümlerde anlatılan ANFIS gibi uyarlanabilir teknikler yardımı ile rastgele bir girdi ve çıktı veri kümelerini eşleştirerek bulanık modeller de oluşturabilir. En büyük avantajı ise insanların sıradan günlük yaşantılarında kullandıkları dili kullanabilmesidir (Alı 2011).

3.3.2 Bulanık kümeler

Klasik (geleneksel, keskin) kümelerde geçen küme kavramında, bir verinin bir kümenin elemanı olması, ait olduğu durumda “1”, ait olmadığı durumda “0” olarak ifade edilmekte olup ikili (binary) mantık temellidir. Bu iki değer arasında bir değer söz konusu olmadığından belirsizlik içeren durumlarda problemin çözümü güç bir hal almaktadır. Bulanık kümelerde ise bir verinin bir kümeye ait olma durumu üyelik dereceleri ile ifade edilir ve bulanık kümeler üyelik fonksiyonları (belirleyici fonksiyon, karakteristik fonksiyon ya da ayırım fonksiyonu) ile gösterilirler.


X evrensel kümesinde tanımlı olan ve elemanları x olan bulanık A kümesi için μ_A karakteristik fonksiyonu aşağıdaki şekilde ifade edilir. Üyelik fonksiyonu A 'nın elemanlarını $[0,1]$ kümesine dönüştürürken bu dönüşüm A 'nın her elemanı için bir sıralı

ikili kümesiyle ifade edilebilmektedir. $\{1\}$ değeri ait olmaya karşılık gelirken $\{0\}$ değeri ait olmamaya karşılık gelir.

$$A : X \rightarrow [0,1]$$

(3.3)

$$\mu_A(x) = \begin{cases} 1, & \text{eğer } x \in A \text{ ise,} \\ 0, & \text{diğer durumlarda,} \end{cases}$$



“ x , A kümesinin içindedir” şeklindeki bir önermenin doğruluk derecesi $(x, \mu_A(x))$ sıralı ikisiyle belirlenir. Eğer bu sıralı ikilinin ikinci elemanı 1 ise önerme doğru, eğer bu değer 0 ise önerme yanlış olarak tanımlanır. A kümesi ise;

$$A = \{(x, \mu_A(x)) | x \in A, \mu_A(x) \in [0,1]\}$$

(3.4)

olarak ifade edilebilir. Burada;


X : Evrensel küme

x : Evrensel kümenin elemanı

A : Bulanık küme


$\mu_A(x)$: küme elemanı olarak tanımlanan x kesin sayılarının A bulanık kümesindeki üyelik derecelerine karşılık gelmektedir.

A klasik kümesi bu kümeye tam üye olan elemanlardan oluşan bir küme olarak tanımlanabilir. U evrensel kümesi içindeki her bir elemanın kümenin içinde olup olmaması durumu grafikte şekil 3.7'deki gibi ifade edilebilir.



Şekil 3.7 Klasik küme örneği (Anonim 2018j)



Bulanık kümeler ise sahip olduğu elemanlarının üyelik derecelerini belirlerken üyelik fonksiyonlarının çeşitlerinden (üçgen, yamuk, çan eğrisi vb.) yararlanırlar, bu durum bir F bulanık kümesi için aşağıdaki şekilde ifade edilebilir.



Şekil 3.8 Bulanık küme örneği (Anonim 2018j)


Bulanık küme yaklaşımının üye olma durumundan üye olmama durumuna dereceli geçişi ifade etmesindeki kabiliyeti, bize belirsizlik durumunun ölçülmesinde güçlü ve anlamlı araçlar sunmakta ve dilsel olarak ifade edilen belirsiz kavramların anlamlı bir şekilde gösterilmesini sağlamaktadır. Şekil 3.9'da yer alan örnekte belirli ifadelerle

tanımlanabilen veya tanımlanamayan sıcak ve soğuk ifadelerinin bulanık küme yaklaşımı ile ele alınması yer almaktadır.



Şekil 3.9 Isı kavramının bulanık küme yaklaşımı ile ifadesi (Anonim 2018k)

Başka bir örnek ile insanların boyları ile bulanık küme ilişkisi aşağıdaki şekilde temsil edilebilir.



Şekil 3.10 Boy kavramının bulanık küme ile ifadesi (Anonim 2018j)

3.3.3 Dilsel deęişkenler


Deęişkenler genel olarak sayısal deęerler alırken bir deęişkenin sözel bir ifade alması halinde tanımı dilsel deęişken olarak geçmektedir. Sözel deęişkenler deęer karşılığı olarak kelime veya cümleleri alan deęişkenlerdir. Bulanık küme teorisini klasik kümelerden ayıran en önemli özellik, sayısal deęişkenler yerine sözel deęişkenleri kullanabilmesidir. Sözel ifadeler aracılığıyla klasik metotlar ile tam olarak tanımlanamamış karmaşık problemlerin çözümü bulanık kümeler ile gerçekleştirilebilir. Baykal ve Beyan sözel deęişkenleri eşitlik 3.5'te yer alan şekilde ifade etmektedir (Baykal ve Beyan 2004).

$$\text{Dilsel Deęişken} = (X, T(X), U, G, M) \quad (3.5)$$

Burada X deęişken adı, $T(X)$ deęeri deęişkenin içerdığı sözel ifadeler kümesidir. U , deęişken özelliklerini tanımlayan evrensel küme; $G, T(X)$ 'te terim üreten dizimsel gramerdir. M deęeri ise, U evrensel kümesindeki bulanık kümelere karşılık gelen $T(X)$ terimlerinin semantik kurallarıdır.

Örnek ile açıklanacak olursa A , bir hareket halindeki nesneler kümesi olsun. Oluşturulacak küme için, "hareket edebilen bir x nesnesinin yakınlık derecesi nasıl bulunur" sorusuna çözüm bulunmaya çalışıldığında çözüm evresinde bir "YAKIN" bulanık kümesi tanımlanacak olursa; bu bulanık küme için "mesafe" kavramı dilsel bir deęişken olarak tanımlanır.

"YAKIN" kavramı ise uzaklık-yakınlık terimlerini ifade eden bir sözel kavram olarak tanımlanır. Uzaklığı tanımlanacak nesnenin, yakınlık-uzaklık ölçütüne baęlı bir üyelik fonksiyonu tanımlanarak "YAKIN" adında bir bulanık küme oluşturulabilir.



Şekil 3.11 Dilsel değişkenlerin bulanık küme ile ifadesi

Çizelge 3.4 Dilsel değişkenlerin bulanık küme ile ifadesi

Nesne	Mesafe	Yakınlık derecesi, μ (mesafe)
1	800	0
2	150	1
3	350	0.5
4	260	0.8

Tanımlanan üyelik fonksiyonuna göre birtakım örnek nesneler ve yakınlık dereceleri ise çizelge 3.4'deki şekilde sıralanabilir.

Bu işlemde durum veya sonuçların dilsel yorumları dilsel terimler olarak tanımlanmaktadır ve örnekte ölçülebilen mesafe kavramı, dilsel yorumlar açısından çok uzak, uzak, normal, yakın, çok yakın vb. şeklinde ifade edilebilir.

3.3.4 Üyelik fonksiyonları

Üyelik fonksiyonları kümeye üye olan elemanların süreklilik ya da ayrıklık durumuna bakmaksızın var olan bulanık durumu somut olarak ifade etmeye ve bu elemanların kümeye ait olma derecelerini göstermeye yarayan fonksiyonlardır. Fonksiyonlar vasıtası ile üyelik dereceleri arasındaki geçişler kesintisiz ve keskin bir şekilde olmadan, sakin bir yapıda gerçekleştirilmektedir.

Literatürde bazı üyelik fonksiyonları; üçgen üyelik fonksiyonu, yamuk üyelik fonksiyonu, gaussian üyelik fonksiyonu, çan eğrisi üyelik fonksiyonu, sigmoidal üyelik fonksiyonu, s üyelik fonksiyonu, π üyelik fonksiyonu olarak sıralanabilir. Bu fonksiyonlar arasından üçgen, yamuksal, gaussian ve çan eğrisi üyelik fonksiyonları hesaplamalarının kolay olması sebebi ile sıklıkla çalışmalarda kullanılmaktadır. Hangi fonksiyonun kullanımının daha uygun olup olmayacağına üzerinde çalışılan konunun alanından elde edilen verilere göre karar verilmektedir.

Yaygın olarak kullanılan fonksiyonlar aşağıdaki gibi olup grafiksel gösterimleri ve fonksiyon tanımları çizelge 3.5’de yer almaktadır.


Çizelge 3.5 Yaygın olarak kullanılan üyelik fonksiyonları

Yaygın olarak kullanılan üyelik fonksiyonları		
Fonksiyon Çeşidi	Fonksiyonel İfade	Fonksiyonel Grafik
Üçgen Üyelik Fonksiyonu	$\mu_A(x) = \begin{cases} 0, & x < a_1 \\ \frac{x - a_1}{a_2 - a_1}, & a_1 \leq x \leq a_2 \\ \frac{a_3 - x}{a_3 - a_2}, & a_2 \leq x \leq a_3 \\ 0, & x > a_3 \end{cases}$	
Yamuk Üyelik Fonksiyonu	$\mu_A(x) = \begin{cases} 0, & x < a_1 \\ \frac{x - a_1}{a_2 - a_1}, & a_1 \leq x \leq a_2 \\ 1, & a_2 \leq x \leq a_3 \\ \frac{a_4 - x}{a_4 - a_3}, & a_3 \leq x \leq a_4 \\ 0, & x > a_4 \end{cases}$	

Çizelge 3.5 Yaygın olarak kullanılan üyelik fonksiyonları (devam)

Gaussian Üyelik Fonksiyonu	$\mu(x; m, s) = \exp\left\{-\frac{(x - m)^2}{2s^2}\right\}$	
Çan Şekli Üyelik Fonksiyonu	$\mu(x; a_1, a_2, a_3) = \left\{ \frac{1}{1 + \left \frac{x - a_3}{a_1} \right ^2} \right\}$	
S Üyelik Fonksiyonu	$\mu(x; a, b, c) = \begin{cases} 0 & x < a \\ 2\left(\frac{x-a}{b-a}\right)^2 & a \leq x \leq b \\ 1 - 2\left(\frac{x-c}{c-a}\right)^2 & b \leq x \leq c \\ 1 & x > c \end{cases}$	

Bir üyelik fonksiyonunun temel yapısal bileşenleri ise çekirdek (core), destek (support), yükseklik (height) ve sınır kümesi (boundary) ve geçiş noktası olarak tanımlanmaktadır (Yaman 2014).



Şekil 3.12 Bir üyelik fonksiyonunun bölümleri (Eravcı 2016)

Çekirdek bölümü, üyelik fonksiyonunun 1'e eşit olduğu alan olup, bulanık kümenin tam üyeliğe sahip elemanlarına üyelik fonksiyonunun çekirdeği denmektedir. $\mu_A(x) = 1$ olarak ifade edilir.

Destek bölümü, bulanık kümenin 0'dan büyük olan elemanları olarak tanımlanan kısmından oluşur ve $\mu_A(x) > 0$ şeklinde tanımlanır.

Fonksiyonun iki tarafında yer alan sınır bölgeleri ise, $[0,1]$ arasında üyelik değeri alan ve $0 < \mu_A(x) < 1$ olarak tanımlı tam üyeliğe erişememiş (kısmen üye) kısımlardır.

Geçiş noktası ise üyelik fonksiyonun geçiş noktası $\mu_A(x) = 0.5$ üyelik derecesine sahip elemanı ifade eder.


A bulanık kümesinin en büyük üyelik derecesi, bu bulanık kümenin yüksekliğini ifade etmektedir ve $\max(\mu_A(x))$ olarak tanımlanmaktadır.

3.3.5 Bulanık çıkarım sistemi yapısı

Bulanık çıkarım sistemi, bulanık kural tabanı olarak adlandırılan iş süreci ve giriş çıkış bulanık kümeleri arasında kurulmuş olan ilişkilerin sonuçlarını bir araya getirerek sistemin bir çıkışlı davranmasını sağlayan işlemler topluluğundan meydana gelen bir mekanizmadır.

Modelin oluşturulması için ilk etapta, çözümlenmesi gereken problem tanımlanır, uygun parametreler seçilerek giriş değerlerinin hangi oranda hangi üyelik kümesine ait olduğu saptanır ve bu giriş değerleri bulanıklaştırılır. Daha sonrasında oluşturulan kurallar dizisi ile bu kurallardan geliştirilen çeşitli çıkarım yöntemlerinden seçim yapılır. Bu kurallar kural içerisindeki birleştiricilerin anlamlarının irdelenmesi ile hesaplanmaktadır. Son işlem adımlarında ise bulanık çıkan bu değerlerin durulaştırılması işlemi ya da klasik sayılara dönüştürülmesi işlemi gerçekleştirilir.

Bulanık bir sistemin akış diyagramı şekil 3.13'de yer almaktadır.



Şekil 3.13 Bulanık çıkarım sistemi akış diyagramı

Bulanık girişlerden çeşitli sonuçların üretilmesi için çeşitli çıkarım modelleri oluşturulmuş olup Mamdani Yöntemi, Takagi-Sugeno Yöntemi, Tsukamoto Yöntemi, Larsen Yöntemi bunların başında gelenlerdir. Sugeno Tipi bulanık çıkarım sistemi, girdi ve çıktı veri girdilerine göre bulanık kuralların oluşturulması için sistematik bir bakış açısı sağlamaktadır. Parametrelerin optimize edilebilmesi avantajı açısından diğer sistemlerden daha faydalı olan bu metotta, bulanık çıkarım sisteminde son kısımda yer alan çıktı değişkeni, girdi değişkenlerinin lineer bir fonksiyonu ya da sabit bir fonksiyon şeklindeki üyelik fonksiyonuna sahiptir. Parametreleri optimize edilebilen Sugeno tipi çıkarım sistemler, bu çalışmada da kullanılan “Adaptif Ağ Tabanlı Bulanık Çıkarım Sistemi” olarak tanımlanmaktadır (Köse vd. 2011).

3.3.5.1 Bulanıklaştırma

Dış dünyadan sisteme girdi olarak verilen nümerik (sayısal) değişkenlerin dilsel değerlere dönüştürülmesi işlemi bulanıklaştırma olarak adlandırılmaktadır. Bu işlem,

Bölüm 4.3'te ele alınan ve oluşturulacak model için önceden tanımlanan üyelik fonksiyonlarından yararlanılarak bu giriş değerleri üyesi oldukları bulanık kümeler ile eşleştirilir ve işlem sonunda üyelik dereceleri belirlenerek bulanık değerlere dönüştürülür (Tiryaki ve Kazan 2007).

3.3.5.2 Kural tabanı

Giriş değerlerinin bulanıklaştırılmasını takiben elde edilen sözel ifadeler, tıpkı insanların karar verme sürecinde olduğu gibi kural tabanında yer alan önermelerle karşılaştırılır ve yine dilsel olarak yargı sonuçları elde edilmektedir. Elde edilen bu sonuçların hangi oranda geçerli olduğu yine girişteki üyelik dereceleri tarafından belirlenir. Bu işlem sürecine bulanık karar verme süreci adı verilir (Nauck vd. 1992).

Bir bulanık kural, 'eğer... o halde... olsun' şeklinde sözel girdi ve çıktı değerlerine sahip olmalıdır. Örneğin (A değeri B ise, o halde C değeri D'dir) şeklinde tanımlanan bir bulanık kuralda, 'eğer...' olarak başlayan ilk bölümü öncül, '... o halde' olarak devam eden kısma ise sonuç ya da karar adı verilmektedir. Bir kuralın öncül kısmı birden fazla durum içermekte ise bu yapıya karma kural adı verilmektedir ve bu kuraldan tek bir sonuç elde edebilmek için bulanık operatörlerden yararlanılır.

Kural tabanı yapısına bakıldığında birden fazla kuralın etkilenmesi ya da tetiklenmesi çıkış sayısının da birden fazla olması ile sonuçlanması beklenir ancak çıkış değeri sadece bir adettir. Tetiklenen bu kurallar ve onların oluşturduğu çıkış değerleri arasında seçim yapmak için çeşitli yollar vardır. Gerçekleştirilen bu seçim işlemine çıkarım denmekte olup bu işlem adımı çıkarım mekanizması tarafından sağlanır (İncekara 2010).

3.3.5.3 Bulanık çıkarım mekanizması ve modelleri

Bu kısım karar verme işleminin gerçekleştirildiği bölüm olup, bulanıklaştırma safhasından elde edilen bilgileri, kural tabanı ile bağlantı sağlayarak işleme alır. Girdiler


ile çıktıların eşleştirildiği bu işlemde elden edilen sonuç durulaştırma bölümüne girdi olarak sağlanır.

Bu blok, çıkarım motoru (fuzzy engine), bulanık kural tabanlı sistem, bulanık denetleyici, ilişkisel hafıza gibi terimlerle de anılmakta olup en önemli işlem “eğer-o halde” kurallarıdır. Bulanık çıkarım mekanizmasında uzman görüşler, bulanık kurallardan oluşan kural tabanı ile gösterilir. Çıkarım mekanizmasında kuralların varsayım kısmındaki terimler arasında gerçekleştirilen işlemler mevcuttur ve terimler genellikle *AND*, *OR* veya *NOT* işlemleriyle bağlanmışlardır ancak kontrol uygulamalarında genellikle sadece *AND* işlemi kullanılır.

Bazı bulanık çıkarım metotları Mamdani, Max Prod, Zadeh, Lukasiewics, Gödel, Kleene-Dienes, Sharp ve ANFIS yaklaşımının da temelini oluşturan Takagi-Sugeno olarak sıralanabilir (Sinecen 2002).

3.3.5.4 Durulaştırma

Çıkarım biriminden alınan bulanık denetim değerlerinin reel dünyada kullanılabilecek gerçek ve sayısal değerlere dönüştürülmesi işlemine durulaştırma adı verilir. Bulanık çıkarım sisteminin son adımı olan durulaştırma işlemi için çeşitli yöntemler kullanılmaktadır. En çok kullanılan ağırlık merkezi metodu ile durulaştırma olup diğerleri şekil 3.9’da sıralanmaktadır (Altaş 1999).



- Maksimumların ilki [FOM] (veya küçüğü [SOM])
- Maksimumların sonuncusu [LOM]
- Ağırlık Ortalama
- Yükseklik Metodu
- Maksimumların Ortası [MOM]

Ağırlık Merkezi Metodu

- Toplamların Merkezi [COS]
- En Büyük Alanın Merkezi [COLA]
- Ağırlık Merkezi [COG] (veya Alanın Merkezi [COA])

Şekil 3.14 Durulaştırma metotları

Uygun durulaştırma yöntemleri seçilirken elde edilecek sonucun belirsiz olmaması, makul olması (belli bir bölgenin yaklaşık olarak orta değerinde bulunması), seçilen yöntemin hesaplama açısından basit olması gibi kriterlere dikkat edilmelidir.

3.3.6 Bulanık mantığın avantajları ve dezavantajları

Bulanık mantık, detaylı bir matematiksel model gerektirmezken birden çok giriş-çıkış değişkeni aynı zamanda irdelenebilir. Bulanık denetimdeki tüm kurallar aynı zamanda uygulanıp sonuçlandırılabilir ve giriş-çıkış değişkenlerinin tüm birleşimleri için çıkış belirleme zorunluluğu yoktur. Girdilerin dikkatli bir şekilde seçimi oluşturulan kuralların sayısını önemli ölçüde indirgenmesini sağlar. Bulanık çıkarım sistemi içerisine yerleştirilen denetim kuralları sistem girişlerinin belirli birleşimlerinde istenilen çıkış elde edilmezse diğer girişlere dokunulmadan denetim işlemini gerçekleştiren aktif kurallar yeniden düzenlenebilir. Bulanık çıkarım sistemine kurallar rahatlıkla eklenebilir veya istenen belirli bir özellikteki denetim kurallarının özelliği rahatlıkla sistem davranışını bozmayacak şekilde eklenebilir. Karmaşık sistemlerde istenen kalite, nitelik ve hıza göre birden fazla bulanık çıkarım sistemi kullanılabilir. Karmaşık sistemlerde bulanık mantık adaptasyonu genellikle kolay bir şekilde gerçekleştirilebilmektedir.

Uygulamada kullanılan kuralların oluşturulması uzmana bağlıdır. Kullanılan kural tabanının karar mekanizmasının temelinde yer alması nedeniyle uzman tecrübelerine dayanması gerekmektedir. Kullanılacak üyelik fonksiyonlarının bulunması için

kullanılabilecek genel bir kural bulunmamaktadır. Belirleme işlemi deneme yanılma yolu ile bulunmasından dolayı uzun zaman alabilmektedir. Bulanık Mantık Sistemleri kendi başlarına öğrenme yeteneğine sahip değildirler. Bu özelliği sağlamak için sinir ağları kullanımı, endüktif öğrenme gibi yöntemler kullanılmaktadır. Bu şartlara uymayan durumlar için mevcut kuralların kullanılması mümkün değildir (Bahadır 2017).

3.4 Sinir Ağları ve Bulanık Mantık Entegrasyonu


3.4.1 Sinirsel bulanık sistemler

Önceki bölümlerde yapıları hakkında detaylı bilgi sunulan sinir ağları ve bulanık mantık metotları yeteneklerini birbirleri ile entegre edebilen iki teknolojidir. Yapay sinir ağları ile bulanık mantığa öğrenme yeteneği kazandırılabilir. Sinir ağları ile ortaya çıkan verilerdeki anlamlılaştırma sorunu, bulanık mantığın dilsel ifadeleri ve eğer-o halde kuralları sayesinde ortadan kaldırılarak daha anlaşılır çıktılar ortaya çıkarılabilir. Sinirsel-bulanık sistemler oluşturulurken temel amaç bu iki metodun da avantajlı yanlarını kullanmak ve bir araya getirmektir.

Bulanık mantık yaklaşımı ile yapay sinir ağlarının birleşimi Bulanık Sinir Ağları ve Sinirsel Bulanık Sistemler olmak üzere 2'ye ayrılmaktadır. Bulanık Sinir Ağları ile bulanık girdileri işleyebilen bir yapay sinir ağı oluşturmak amaçlanırken sinirsel bulanık sistemler ile bulanık çıkarım sistemleri yapar sinir ağları yetenekleri ile zenginleştirilebilmektedir. Sinir ağları veriden öğrenme işlemini gerçekleştirebilir ancak öğrenilen bu bilgiyi anlamak güçtür. Bulanık sistemlerde ise dilsel terimler ve bulanık kurallar sayesinde kolaylıkla anlaşılabilir ancak öğrenme için yöntemlere sahip değildir. Bu iki teknik bu sebeplerden birbirlerini tamamlarlar. Oluşturulan bu karma sistemlerin çoğu sinir ağı başlığında bulanıklık yaklaşımını kullanmak ve sinir hücrelerindeki temel özellikleri değiştirmek düşüncesiyle gerçekleştirilmektedir.

Literatürde bulunan çeşitli sinirsel bulanık sistemler ANFIS, FALCON (Fuzzy Adaptive Learning Control Network), FINEST (Fuzzy Inference and Neural Network in Fuzzy

Inference Software), FuNe (Fuzzy Net), GARIC (Generalized Approximate Reasoning based Intelligent Control), NEFCLASS (Neuro Fuzzy Classification), NEFCON (Neuro Fuzzy Control), NEFPROX (Neuro Fuzzy Function Approximation) şeklinde sıralanabilir.



Şekil 3.15 Sugeno tipi bulanık çıkarım sistemi (Varol 2016)

Bu çalışmada ise ANFIS yaklaşımı kullanılarak mezotelyoma hastalık teşhisi için bir sinirsel bulanık sistem modeli oluşturulmuştur. En iyi bilinen sinirsel bulanık sistemlerden biri olan ANFIS, bulanık kural tabanlı sistemlerde uygulanabilen farklı çözüm yöntemlerinden biri olan Takagi-Sugeno bulanık modelini kullanmaktadır. Sugeno tipi bulanık modeldeki bulanık bir kural eşitlik 3.6'daki şekilde ifade edilebilir:

$$\text{EĞER } x = A \text{ ve } y = B \text{ ise } z = f(x, y) \quad (3.6)$$

Burada A ve B giriş bulanık kümeleridir, $z = f(x, y)$ fonksiyonu ise x ve y değerlerine bağlı olarak çıkışı belirler. Bulanık kurallar aracılığı ile elde edilen çıkışların, yine bulanık kurallardan kazanılan üyelik değerleri üzerinden ağırlıklı ortalaması alınarak, sonuç değeri hesaplanmaktadır.

3.4.2 Adaptif Ağ Tabanlı Bulanık Çıkarım Sistemi (ANFIS)

ANFIS temelde Sugeno tipi bulanık çıkarım sistemlerinin sinirsel ağlara uyarlanmış hali olup melez öğrenme algoritması sayesinde bulanık eğer-o halde kuralları ile uzman görüşünü yansıtan girdi-çıkı yaklaşımını ortaya koyar. Kolay uygulanabilir eğitim algoritmalarını içeren yapısıyla yapay sinir ağları ve uzman bilgi sistemi ile bulanık mantığı bünyesinde birleştirilerek son yıllarda çok çeşitli konu alanlarında kullanılan bir yapay zeka tekniğidir. Bu ağ yapısı katmanlar halinde yer alarak her biri için ayrı ayrı fonksiyonların tanımlandığı düğümlerden oluşur (Tür ve Balas 2010).

ANFIS modelin kullanılmasında en büyük avantaj, parametreleri optimize edebilmektir. Çözümlenecek problem için modellenecek yapıya göre muhtemel tüm kuralları atayabilmekte ya da kuralların veriler yardımıyla uzman görüş ile atanmasına olanak sağlamaktadır. Bulanık çıkarım modeli oluşturulurken üyelik fonksiyonları seçimi sistemi modelleyecek kullanıcıya bağlı olup burada tercih söz konusudur. Ancak modellere bakılarak üyelik fonksiyonunun şeklinin ve adedinin ne olması gerektiğine kolayca karar verilememektedir.


3.4.2.1 ANFIS mimarisi

Yapısı incelendiğinde ANFIS'in bulanık çıkarım sistemindeki kurallar ve giriş-çıkış bilgilerinden oluştuğu görülür. ANFIS'in yapısındaki bulanık çıkarım sisteminin yapısının ifade edilebilmesi için girişler x ve y , çıkış f olarak kabul edilirse "eğer-ise-o halde" kuralı oluşumu aşağıdaki eşitlikteki gibi olacaktır. Burada A ve B bulanık kümeler, p, q, r değerleri ise sonuç değişkenleridir (Doğan 2016).


$$\text{Kural 1: } E\check{G}ER \ x = A_1 \text{ ve } y = B_1 \text{ ise } O \text{ HALDE } f_1 = p_1x + q_1y + r_1$$

$$\text{Kural 2: } E\check{G}ER \ x = A_2 \text{ ve } y = B_2 \text{ ise } O \text{ HALDE } f_2 = p_2x + q_2y + r_2$$

Sugeno bulanık çıkarım mekanizması (Şekil 3.16) ve ANFIS mimarisi (Şekil 3.17) aşağıda yer almaktadır.



Şekil 3.16 İki girişli ve iki kurallı Sugeno tipi bulanık çıkarım



Şekil 3.17 ANFIS mimarisi

ANFIS mimarisi 5 katmanlı ileri beslemeli bir yapay sinir ağı yapısına sahip olup bu katmanların fonksiyonları aşağıdaki şekilde sıralanabilir (Haznedar ve Kalınlı 2015) (Yücel ve Güneri 2010).

1.Katman:

Bulanıklaştırma katmanı olarak da adlandırılır. Bu katmanda yer alan her bir i düğümü için üyelik fonksiyonları yardımı ile bulanık kümelerle aitlik derecesini belirleyecek şekilde üyelik dereceleri hesaplanır.

$$O_{1,i} = \mu_{Ai}(x), i = 1,2 \text{ ya da} \quad (3.7)$$

$$O_{1,i} = \mu_{Bi-2}(y), i = 3,4 \quad (3.8)$$

x ve y değerleri düğüm girişlerini, Ai ve Bi herhangi bir bulanık küme parametresi, μ_{Ai} ve μ_{Bi} ise üyelik fonksiyonlarını ifade etmektedir. Üyelik fonksiyonları için Bölüm 3.4.4'te bahsedilen üyelik fonksiyonlarından biri seçilebilir. Bu katmanda yer alan her düğümden alınan giriş sinyalleri diğer katmanlara iletilmektedir.

2. Katman:

Kural katmanı olarak da tanımlanabilir. Bu katmanda yer alan düğümler Π olarak etiketlenmiştir ve kendisine gelen sinyallerin “ve” mantıksal işlemi gerçekleştirilerek çarpımlarını çıkış olarak üreten sabit bir düğümdür. Çarpım işlemi matematiksel olarak aşağıdaki şekilde ifade edilmektedir:

$$O_{2,i} = w_i = \mu_{Ai}(x) * \mu_{Bi}(y), i=1,2 \quad (3.9)$$

Her bir kural düğümünün μ_i 1. katmandan gelen üyelik derecelerinin çarpımı olmaktadır. Her düğüm çıktısı, her bir kuralın ateşleme seviyesini (firing strength) gösterir.

3. Katman:

Normalizasyon katmanı olarak da adlandırılır. Bu katmanda yer alan her bir düğüm sabit bir düğümdür ve kural katmanından (2. katman) gelen tüm düğümleri giriş olarak kabul etmektedir. Her bir kuralın normalleştirilmiş ateşleme seviyesi hesaplanmaktadır, yani kuralların ağırlıkları normalize edilir.

$$O_{3,i} = w_i / (w_1 + w_2), i=1,2 \quad (3.10)$$

i . düğüm, i . kuralın gerçekleşme derecesinin, tüm kuralların gerçekleşme derecelerine oranı hesaplanır.

4.Katman:

Arındırma katmanı olarak da tanımlanabilir. Bu katmanda yer alan her bir düğümde verilen bir kuralın ağırlıklandırılmış sonuç değerleri hesaplanmaktadır. Bu tabakadaki nodlar adaptif olup nod fonksiyonu, sugeno sisteminde herhangi bir mertebeden bir fonksiyondur.

$$O_{4,i} = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i) \quad (3.11)$$

Burada w_i ortalaması, katman 3'ün çıkışı olup, $\{p_i, q_i, r_i\}$ ise bu katmanda bulunan düğümlerin parametrelerinden oluşan parametre kümesidir. Bu katmanın parametreleri, sonuç ya da çıkış parametreleri olarak ifade edilmektedir.

5.Katman:

Toplam katmanı olarak da adlandırılabilir. Bu katmanda sadece bir düğüm yer almaktadır ve o da Σ ile etiketlenmiştir. Bu katmanda, arındırma katmanındaki her bir düğümün çıkış değeri toplanır ve sonuç olarak ANFIS bulanık çıkarım sisteminin gerçek değeri ortaya çıkar. Sistemin çıkış değerinin hesaplandığı eşitlik 3.12'ye göre gerçekleştirilmektedir.

$$O_{5,i} = \text{toplam çıkış} \quad (3.12)$$

$$= \sum_i \bar{w}_i f_i = \sum_i w_i f_i / \sum_i w_i$$

Böylelikle ANFIS yapısı tamamlanmış olup Bölüm 4.3'te mezotelyoma hastalığı teşhisi probleminde ANFIS'in nasıl uygulanabileceği konusuna değinilecektir.

3.5 Kümeleme Yöntemleri

Veri analizi gerçekleştirmek amacıyla en çok kullanılan yöntemlerden biri kümeleme analizidir. Nesnelerin sınıflandırılma işleminin nasıl bir şekilde yapılacağını ele alan istatistiksel bir yöntem olan kümeleme analizi, özellikle son yıllarda fen alanında gerçekleştirilen ya da iş kollarını destekleyen çalışmalarda sıklıkla kullanılmaktadır. Bir çalışma gerçekleştirilirken, verilerin ortak özellikleri ortaya konularak aralarındaki benzerlik durumlarına göre belirlenen gruplar içerisine toplanması ve sınıflandırılmasını sağlayan bir yöntemdir. Böylelikle girdiler arasındaki benzerlikler baz alınarak ilişkili veriler aynı grup veya kümede toplanır ve çalışmayı sağlayan kişi için sade ve net bir şekilde işe yarar bilgiler elde edilir.


Bulanık kümeleme ise elde olan verilerin doğrudan bulanıklaştırılmasını sağlayan bir yöntemdir. Bulanık kümelemede, veriler kümelenirken bulanık yöntemler kullanılır ve bir veriye birden fazla küme içinde sınıflandırılabilme avantajı sağlanır. Bu yaklaşım, kümelerin birbirlerinden belirgin bir şekilde ayrılamadığı durumlarda ve bazı verilerin küme üyeliğinde kararsız kaldığı durumlarda kullanılabilir. Bulanık Kümeleme Yöntemleri, diğer kümeleme yöntemlerinin tersine veri topluluğundaki her bir verinin elde bulunan bütün kümelere belirli ölçüde girmesine imkan tanıyan üyelik fonksiyonlarını kullanırlar. Veriler bir araya toplanarak işlem hızı daha iyi seviyelere getirilir ve sistem genel bir yapı içinde ele alınır. Birbirlerine benzeyen veriler aynı küme içinde yüksek üyelik ilişkisi ile yer alırlar, bu sebepten verilerin kümeye ya da kümelere ait olabilme durumları hesaplanır.

Diğer kümeleme yöntemlerinde olduğu gibi bulanık kümeleme de temelde uzaklık ölçüm yaklaşımına dayanır. Bu uzaklık yöntemlerinden hangisinin seçileceği ise kümenin yapısına ve hangi algoritmanın kullanıldığına bağlıdır. Bu çalışmada da bulanık kümeleme metotları içinde kullanılabilen Grid Partitioning (Izgara Bölümleme), Subtractive Clustering (Alt Kümeleme) ve Fuzzy-C Means Clustering (Bulanık-C Ortalamalar) yöntemleri kullanılmıştır (Bayrakçı ve Barışçı 2008) (Erilli ve Karaköy 2015).

3.5.1 Izgara Bölümleme yöntemi (Grid Partitioning)

Bir bulanık çıkarım sistemi oluşturulmak istenildiğinde oluşturulacak modelin öğrenimi temel olarak ızgara bölümleme (Grid Partitioning), ağaç bölümleme (Tree Partitioning) ve dağılım bölümleme (Scatter Partitioning) olmak üzere kullanılabilecek 3 tür giriş alanı bölümleme yöntemine dayanmaktadır. Bu çalışmada, bu yöntemler arasında ızgara bölümleme yöntemi kullanılmış olup diğer kümeleme yöntemlerine göre performansı değerlendirilmiştir. ANFIS-Grid olarak geçen bu bölümleme yöntemi, ızgara bölümleme ile kümeleme ve ANFIS yapısının birleşiminden oluşmaktadır.

Geliştirilmesi amaçlanan modelin bir öğrenme süreci olan eğitim (training) aşamasının en başlarında, grid partition metodu elde olan veri setini daha önceden belirlenmiş olan kullanılacak üyelik fonksiyonlarının sayısı ve türlerine göre ızgara olarak adlandırılan dikdörtgen alt alanlara bölmektedir. Şekil 3.12’de örnek olarak 2 giriş değişkeni ve her giriş değişkeni için 2 üyelik fonksiyonunun tanımlandığı durumda alt alanlara bölümleme gösterilmektedir.



Şekil 3.18 2 giriş değişkenli ızgara bölümleme modeli (Sadouki ve Haddad 2016)

Izgara bölümleme modelinin temel mantığı, oluşturulacak modelde kullanılacak veri setinde, girdi değişkenleri için üyelik fonksiyonlarının tüm olası kombinasyonlarını hesaplayarak kurallar oluşturmaktır. Bu durum, girdi değişkenlerinin sayısı ne kadar artar ise bulanık kuralların sayısının da buna bağlı olarak hızla artış göstermesi ile

sonuçlanmaktadır. Izgara bölümlleme metodunun ana sınırlaması, girdi sayısı (sensörler) arttıkça kuralların sayısının hızla artmasıdır. Izgara bölümlleme kullanıldığında, bulanık kuralların sayısının girdi değişkenlerinin sayısının artışı ile birlikte katlanarak artması ile oluşan bu durum "**curse of dimensionality**" olarak tanımlanmaktadır ve bu durum adaptif bulanık çıkarım sistemi performansını olumsuz etkilemektedir. Çalışmada da model oluşturulurken her denemede üyelik fonksiyonu sayısı artırılarak ve farklı üyelik fonksiyonu tipleri denenerek bu değişimin ANFIS performansı üzerindeki etkisi değerlendirilmiştir.

“Curse of dimensionality” durumu ile başa çıkmak ve yapısını bozmadan veriyi daha az değişken ile temsil edebilmek için eldeki verinin konu alanı da göz önünde bulundurularak sahip olunan bazı niteliklerden önemli olanları özellik olarak çıkarılabilir ve veriyi temsilen bu özellikler (feature) kullanılabilir. Bu amaçla kullanılacak özellik seçme (feature selection) ya da özellik çıkarma (feature extraction) yöntemleri bulunmaktadır. Bu çalışmada ise Bölüm 3.7.1’de detayları anlatılan özellik çıkarma ve boyut azaltma yöntemlerinden biri olan “Dimensionality Reduction” tekniği olarak PCA kullanılmaktadır.

Örneğin her giriş değişkeni için m sayıda üyelik fonksiyonu ve toplam girdi değişkeni sayısı n olarak ifade edilecek olursa, ızgara bölümlleme sonucunda elde edilecek toplam bulanık kural sayısı m^n olarak ifade edilmektedir. Bu nedenle bu metot genellikle az sayıda giriş değişkenine (çoğunlukla 6’dan az olacak şekilde) sahip uygulamalar için uygun olarak değerlendirilmektedir. Izgara bölümlleme yöntemi daha çok birkaç üyelik fonksiyonu ile daha doğru şekilde çalışabilmekte olup bu da daha az simülasyon zamanı gerektirmektedir. Düşük hata değerlerine ulaşmak için az sayıda üyelik fonksiyonu ile bu metodu kullanmak daha uygundur (Vaidhehi 2014).

3.5.2 Alt Kümeleme yöntemi (Subtractive Clustering)

Alt kümeleme algoritması, küme sayısını ve küme lokasyonunu otomatik olarak tahmin edebilen ANFIS ağırları ile sentez halinde olan bir yaklaşımdır. Bu kümeleme algoritmasında her veri potansiyel bir küme merkezi olarak görülmektedir. Bu metodun

kullanımında veri setinin boyutuyla belirlenmesi sürecinde geçen hesaplama zamanı doğru orantılıdır.

Alt kümeleme algoritması, “mountain clustering” metodunun gelişmiş halidir. Eldeki verilerden küme merkezlerinin oluşturulması esasına dayanmaktadır. Bu algoritma hızlı bir algoritmadır çünkü buradaki karmaşıklık hesabı var olan boyutların sayısına göre değil “mountain clustering” algoritmasının tersine modelin oluşturulmasında kullanılacak olan verilerin sayısına dayanmaktadır. Algoritmanın çalışma adımları sırasıyla şu şekilde tanımlanmaktadır (Bey vd. 2013):

Normalize edilmiş veri kümesinden ilk merkez (center) seçilir. Burada önemli nokta eldeki veri setinde yer alan her bir verinin aday birer merkez olmasıdır. Her bir veri Gauss fonksiyonu ile işlenir.

$$D_i = \sum_{j=1}^n \exp\left(\frac{x_i - x_j^2}{\left(\frac{r_a}{2}\right)^2}\right) \quad (3.13)$$

Burada x_i değeri aday merkez noktası, x_j değeri ise j . data noktası olup, r_a değeri ise komşu noktaların merkezinin yarıçapına denk gelmektedir. Burada birçok komşu veri noktasına sahip olan bir veri noktasının sahip olacağı D değerinin çok büyük olması beklenmektedir. Her bir veri noktası için D_i noktası hesaplamaları tamamlandıktan sonra, maksimum D değerine sahip olan nokta başlangıç merkezi olarak seçilecektir. Maksimum D değerinin eşit çıktığı durumlarda ise bu noktalardan birisi rastgele bir şekilde seçilmektedir.

Bu adımdan sonra, kümenin merkezinin yakınlarında bulunan diğer veri noktalarının gücü, bir değer çıkartılarak azaltılır.

$$D_i \cdot \exp \left(\frac{-x_i - x_{c_1}^2}{(r_b/2)^2} \right) \quad (3.14)$$

Yarıçap r_b içinde olan i . komşu noktanın gauss fonksiyonu aşağıdaki formül ile dönüştürülür:

$$D_i = D_i - D_{c_1} \exp \left(\frac{-x_i - x_{c_1}^2}{(r_b/2)^2} \right) \quad (3.15)$$

Sonraki aşamada, bir sonraki küme merkezinin bulunması gerekmektedir ve bu sebepten önceki merkezin Gauss fonksiyonu yenisinin belirlenmesi amacıyla aşağıdaki formül ile hesaplanır. Buradaki azaltmalar bir önceki merkeze olan mesafeye dayanmaktadır.

$$D_i = D_i - D_{c_1} \exp \left(\frac{-x_i - x_{c_i}^2}{(r_b/2)^2} \right) \quad (3.16)$$

Burada r_b değeri, aşağıdaki formül ile hesaplanmaktadır:

$$r_b = \eta * r_a \quad (3.17)$$

η squash faktörü, r_b ise bir komşu veri noktasından ilk küme merkezine olan yarıçaptır. Burada, r_b değeri r_a değerinden büyük olacağı için squash faktörü *overfitting* durumunu tanımlamaktadır. η değerinin default değeri 1.5'dur.

Gerçekleştirilen bu işlemler tüm kümeler için maksimum D değerine ulaşılan kadar tekrarlanır. Algoritma küme sayısını, yarıçap, squash faktörü, kabul oranı (accept ratio), red oranı (reject ratio) gibi özel parametrelere dayanarak döndürmektedir. Bu parametreler, algoritmada geçen “options” seçeneği ile yönetilebilmektedir. Buradaki r_a parametresi, oluşturulacak kümelerin sayısını güçlükle etkileyen parametre olmaktadır. Bu parametrenin büyük bir değere sahip olması genellikle az sayıda küme oluşturulması

ve yüksek kalitede bir model oluşturulamaması ile sonuçlanırken, küçük bir değere sahip olması da aşırı sayıda kural oluşturulabilmesine ve bunun sonucunda “over-defined” bir sistemin ortaya çıkmasına sebebiyet vermektedir. Kabul oranı ise birinci küme merkezinin potansiyelinin bir kesiti olarak tanımlanır ve bunun üzerinde bir başka veri noktası bir küme merkezi olarak kabul edilir. Red oranı ise belirlenen potansiyel değer in aşağısında yer alan bir veri noktasının küme merkezi olarak kabul edilmemesi durumunu belirlemektedir (Lafta 2010).

3.5.3 Bulanık-C Ortalamalar yöntemi (Fuzzy-C Means Clustering)

Bulanık-C Ortalamalar algoritması bulanık tabanlı kümeleme yöntemlerinin en iyi yöntemlerinden biri olup sıklıkla kullanılmaktadır. Algoritma, klasik kümeleme yöntemi ifadesinde kullanılan “Hard” terimine dayanan Sert C-Ortalama lı Kümeleme yöntemine dayanır. Sert C-Ortalama lı Kümeleme yönteminde her veri noktası belirli bir kümeye aittir ya da değildir.

Bu algoritma 1973 yılında Dunn tarafından öne sürülmüş olup geliştirilmesi 1981 yılında Jim Bezdek tarafından gerçekleştirilmiştir. Genellikle örüntü tanıma çalışmalarında sıklıkla kullanılan bu algoritmanın klasik kümelerden farkı, her bir veri parçasının iki veya daha fazla sayıda alt kümeye ait olabilmesini sağlamasıdır; bunun yanı sıra her bir veri noktasının değişik derecelere sahip olabilmesine olanak sağlamaktadır. Bulanık mantık tabanlı bir algoritma olduğu için her veri, kümelerin her birine $[0,1]$ arasında değişen birer üyelik derecesi ile aittir. Ancak aynı veri noktasının değişik kümelerdeki üyelik derecelerinin toplamı 1’e denk gelmelidir. Veri noktası, hangi küme merkezine yakın ise o kümeye ait olma üyelik derecesi, diğer kümelere ait olma üyelik derecelerinden daha büyük olur. Eşitlik 3.18’de formülize edilecek olursa; i veri, j küme, üyelik derecesi $ü_{i,j}$, m ise küme sayısı olarak ifade edilebilir.

$$\sum_{j=1}^m ü_{i,j} = 1 \quad (3.18)$$

Bu duruma ek olarak aynı veri kümesi içinde yer alan verilerin üyelik dereceleri toplamı veri sayısı olan n 'den daha küçük bir değerde olmalıdır. Ancak tüm veriler bir kümede toplanırlarsa üyelik dereceleri toplamı veri sayısına eşit olabilir, bu karşılaşılması zor bir durum olarak tanımlanmaktadır. Bu ifade de eşitlik 3.19'daki şekilde formülize edilmektedir:

$$\sum_{j=1}^m \ddot{u}_{i,j} \leq n \quad (3.19)$$

Bezdec'in sunduğu Bulanık-C Ortalamalar kümeleme yönteminde, her bir verinin her kümeye belirli bir üyelik derecesi ile katılmasının yanında, verilerin değişik kümelere atanması için veri noktaları ile üyesi oldukları küme merkezleri arasındaki uzaklığın ağırlık ortalamasının alınması esas alınmaktadır. En başta belirlenen küme merkezleri rastgele seçilmektedir. Bu ağırlığı hesaplayan fonksiyon ise eşitlik 3.20'de görüldüğü şekilde tanımlanmaktadır. En küçük kareler yöntemi temelli olan amaç fonksiyonu ötelenerek minimize edilmeye çalışılır. Belirli bir eşik değerin altında ise işlem durdurulur.

$$f(\ddot{u}, v) = \sum_{k=1}^n \sum_{i=1}^c (\ddot{u}_{ik})^m \|x_k - v_i\|^2 \quad (3.20)$$

Denklem 3.20'deki v vektörü küme merkezlerinin koordinatlarını temsil etmektedir. Kümelemeler için bu fonksiyonun değişim uzayında en küçüklenmesi gerekir. Bu en küçükleme işlemi için türev alınarak işlem yapılır ve üyelik dereceleri için aşağıdaki gibi formülize edilerek sonucunda üyelik matrisi hesaplanır. Bu denklemde $(x_k - v_i)$ olarak ifade edilen işlem, k : küme ve i : veri noktası arasındaki Öklid mesafesidir. m olarak ifade edilen değer ise bulanıklık indeksidir. $\ddot{u}_{ik}$ olarak tanımlanan ifade, x_i : veri noktasının j . kümedeki üyelik derecesidir (Fattahi ve Bayatzadehfard 2017).

$$\ddot{u}_{ik} = \frac{1}{\sum_{j=1}^c \left(\left\| \frac{x_k - v_i}{x_k - v_j} \right\| \right)^{\frac{2}{m-1}}} \quad (3.21)$$

$$(1 \leq i \leq c; \quad 1 \leq k \leq n)$$

Bu işleme eş zamanlı olarak küme merkezlerinin de ağırlıklı ortalama formülüne göre değişmesi gerekmektedir. Bu formül eşitlik 3.22'deki şekilde ifade edilmektedir. v_i olarak tanımlanan ifade, kümenin p –boyutlu merkezidir.

$$v_i = \frac{\sum_{k=1}^n (\ddot{u}_{ik})^m x_k}{\sum_{k=1}^n (\ddot{u}_{ik})} \quad (1 \leq i \leq c) \quad (3.22)$$

Bu yöntem ile verilerin kümelerle ayırma işleminin tamamlanması için sırasıyla takip eden işlemlerin gerçekleştirilmesi gerekmektedir:

1) $X = \{x_1, x_2, x_3, \dots, x_n\}$ olarak ifade edilen bir veri noktası dizisi için, genel olarak 2'den büyük ve veri sayısının bir eksiğine kadar olacak şekilde kümeleme sayısı olan c değeri seçilir ($2 < c < n - 1$).

2) U üyelik matrisi rastgele alınarak c ortalama vektör bileşenleri aşağıdaki formül ile hesaplanır.

$$v^{(l)} = \frac{\sum_{k=1}^n [\ddot{u}_{ki}^{(l)}]^m x_k}{\sum_{k=1}^n [\ddot{u}_{ki}^{(l)}]^m} \quad (1 \leq i \leq c) \quad (3.23)$$

3) Hesaplanan küme merkezlerine göre üyelik dereceleri ilk adımda aşağıdaki formüle göre yenilenir:

$$\ddot{u}_{ik}^{(1+1)} = \frac{1}{\sum_{j=1}^c \left(\left\| \frac{x_k - v_i}{x_k - v_j} \right\| \right)^{\frac{2}{m-1}}} \quad (3.24)$$

$$(1 \leq i \leq c; \quad 1 \leq k \leq n)$$

4) Bu adımda gerçekleştirilen hesaplamaların ardışık olarak birbirine yakınlık durumları kontrol edilir, tekrara gidilir ya da işlem durdurulur. Bu işlem için var olan son iki yineleme hesapları karşılaştırılır. Eski U matrisi ile yeni U matrisi karşılaştırılır ve fark ε 'dan küçük olana kadar işlemler devam eder.

$$\max_{i,j} \{|u_{ij}^{(k+1)} - u_{ij}^{(k)}|\} < \varepsilon \quad (3.25)$$

(3.25) denkleminde göre gerçekleştirilen bu işlemde, ε değeri 0 ile 1 arasında yer alan sonlandırma değeri, k değeri ise iterasyon adımıdır (Abbasimehr vd. 2011).

Kümeleme işlemi tamamlandıktan sonra oluşturulan U üyelik matrisi kümelemenin sonucunda ortaya çıkan bulanık değerleri içermektedir. Berraklaştırma işlemi gerçekleştirilerek, bu değerler 0 ya da 1 değerlerine dönüştürülebilir (Yıldız vd. 2010) (Atalay ve Tortum 2010).

Literatürdeki diğer kümeleme yöntemleri ile Bulanık-C Ortalamalar kümeleme yönteminde karşılaşılan büyük sorunlardan biri, işleme başlamadan önce küme sayısının seçilmesidir. Küme sayısının gerçekte ne olması gerektiği bilinmeyen bir değer olup algoritmanın çalışmasında kullanılacak veri setinin yapısına göre değişiklik gösterebilmektedir. Bu nedenle, küme sayısının değerini belirlemek için çeşitli indeksleme çözümleri geliştirilmiş ve kümeleme sayılarına bu yaklaşımlara göre karar verilmiştir.

3.6 Boyut Azaltımı

Makine öğrenmesi, veri madenciliği ve istatistiki çalışmalarda sahip olunan veri kümesinin boyutu arttıkça, genellikle bu boyutlar arasından çok az sayıda kısım kümelerle ilgili olmaktadır. Çalışma esnasında kümeler ile ilgisi olmayan boyutlardaki veriler fazla gürültüye sebep olabilir ve ortaya çıkarılabilecek kümelerin gizli kalmasına sebep olabilir. Verinin boyut sayısı arttıkça kümeleme çalışmasının karmaşık bir hale gelmesi, kümeleme işlem süresinin uzaması, doğruluk oranı yüksek kümeleme çalışmasının gerçekleştirilememesi gibi sebeplerden boyut azaltma işlemine başvurulmaktadır (Yıldız vd. 2010). Verinin hangi konu ile ilgili olduğu göz önüne alınarak bazı niteliklerden önemli olanları özellik olarak belirlenebilir ve veriyi temsilen o özellikler (feature) kullanılır. Amaç, verinin yapısını bozmadan verinin daha az değişkenle temsil edilebilmesi, eldeki verinin gereksiz olan niteliklerinin belirlenerek

veriden çıkarılmasıdır. Boyut azaltma işlemi öznelik çıkarma (feature extraction) ve özellik seçimi (feature selection) olacak şekilde bölümlere ayrılabilir.

Özellik seçme orijinal veri setini temsil edebilecek en iyi alt kümenin ve verinin sınıfını en iyi tahmin edebilecek özelliklerin seçimi olarak tanımlanmaktadır. Verinin dağılımı bozulmadan veri setindeki n adet özellik arasından en iyi k adet özellik seçilerek gereksiz nitelikler atılır ve istatistiksel yöntemler kullanılır (Budak 2018).


Öznelik çıkarma (özellik çıkarma) ise tamamen yeni bir özellik kümesi oluşturulmasıdır. Yüksek boyutlu boşluktaki verileri daha az boyutta alana dönüştürme işlemidir. Yüksek boyutlu veri kümeleri için boyut azaltma yöntemi genellikle boyutsallık laneti (curse of dimensionality) dezavantajlarından kaçınmak için uygulanan bir işlemdir. Bu çalışmada ise özellik çıkarma tekniklerinden olan Temel Bileşenler Analizi kullanılarak boyut azaltma işlemi gerçekleştirilecek, oluşturulan modelin performansı arttırılmaya çalışılacaktır.

Boyut azaltma işleminin avantajları için; kümenin boyutunun düşürülerek algoritmanın hızının arttırılması, ilgili olmayan ve gürültüye sahip olan verilerin elenmesi, veri kalitesinin daha da geliştirilmesi, veri kümesinin sade bir şekilde 2D veya 3D gibi düşük boyutlara indirgenerek görselleştirilebilmesi, ifade edilebilmesi ve anlaşılabilir hale gelmesi, verinin depolanması için gerekli olan bellek miktarının ve gerekli zamanın azaltılması, geliştirilen modelin yüksek performansta çalışması sıralanabilir (Budak 2018).

3.6.1 Temel Bileşenler Analizi (PCA - Principal Component Analysis)

Temel Bileşenler Analizi, bir boyut azaltma işlemidir. Veri setine dahil olan tüm değişkenler ve bu değişkenlerden bazılarının sayıca fazla olması ve aynı model içerisinde birbirleri ile ilişkileri olan değişkenler olduğunun da belirli olması halinde, veri seti boyutun daha küçük sayılara azaltılması amacıyla bu işlem gerçekleştirilebilir. Temel bileşenler analizindeki temel amaç, boyut azaltarak veri kümesini sadeleştirmek ve kullanılacak veri setinde yer alan girdileri doğru açıdan irdelleyerek birbirleri ile olan ilişkilerini daha net bir biçimde ortaya çıkarmaktır (Şengöz ve Özdemir 2016).

Yüz tanıma, verileri sınıflandırma, örüntü tanıma, görüntü sıkıştırma gibi alanlarda yaygın olarak kullanılan bu yöntem, veri setinde yer alan parametrelerin varyans-kovaryans yapısını, bu parametrelerin doğrusal bileşimleri vasıtasıyla açıklanması ile boyut indirgenmesi ve yorumlanmasını sağlayan çok değişken içeren istatistiki bir metottur. Girdiler arasındaki benzerlik ve farkları irdeleyerek, boyut azaltma işlemi gerçekleştirir, buna ek olarak mümkün olduğunca orijinal veri seti yapısını koruyarak yeni veri setini meydana getirir. Temel bileşenler analizi yapı itibarı ile doğru açı tespiti (uygun koordinatın seçilmesi) ve çok boyutlu bir yapıda olan veri setini, tespit edilen doğru açıdan irdeleyerek veri setinde yer alan parametreler arası ilişkilerin kestirilmesi şeklinde (Şekil 3.13) problemi 2 temel adımda ele almaktadır.



Şekil 3.19 Temel bileşenler analizi yaklaşımı (Cömert 2015)

Çok boyutlu veri setinde veriler arası ilişkiler karmaşık haldedir. Ancak doğru açının tespiti ile çok boyuttan oluşan bu veri setindeki ilişkilerin lineer bir şekilde olduğu ortaya çıkarılabilir. Bu evrede de uygun koordinat sistemini belirlemek için sırasıyla aşağıdaki işlemler gerçekleştirilir:

1. eksen için verilerin en büyük değişiminde olan yön tespit edilir.
2. eksen için önceki eksen olan 1. eksene dikey olan ve verilerin en büyük değişiminde olan yön tespit edilir.
3. eksen için, önceki 1. ve 2. eksene dikey olan ve kalan verilerin en büyük değişiminde olan yön tespit edilir.

Bu işlemler sonucunda bu dikey olan en büyük değişime sahip yönler “**temel bileşenler**” olarak ifade edilmektedir. PCA yönleri, verilerin değişimi ile ilgili en büyük

katkısı olan yönü en başta belirtir, sonrasında ise daha az katkıda olan yönleri ortaya çıkarmaktadır. Temel bileşenlerin yeterli sayısını tanımlamak amacıyla ise “**tutulan varyans**” ifadesi kullanılmaktadır. Kullanılacak ilk temel bileşenlerin toplam varyansı veri setinde yer alan orijinal verilerin toplam varyansının %90-%95’ine denk gelmelidir. Temel bileşenler analizinin aşamaları sırasıyla aşağıdaki şekildedir:

1) Veri setinin hazırlanması

İlk etapta temel bileşen analizinin uygulanacağı veri seti işleme hazır hale getirilir.

2) Ortalama çıkarma

Veri setinin her bir boyutunu kendi ortalamasından çıkarmak gereklidir. Veri setinde yer alan x ve y değerleri için $(x - \bar{x})$ ve $(y - \bar{y})$ değerleri elde edilecektir.

3) Özdeğerler ve özvektörlerin elde edilmesi için kovaryans matris oluşturulması

Kovaryans iki rastgele değişkenin birlikte ne kadar değiştiklerinin ölçüsüdür. İki den fazla değişkene bakıldığında ise kovaryans matris kullanılır. X ve Y olarak belirlenen iki değişken arasındaki ilişki eşitlik 3.26 ile hesaplanabilir.

$$cov(X, Y) = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{n-1} \quad (3.26)$$

Kovaryans matrisin en büyük değerlerine **eigenvalues**, bu değerlere uygun gelen kovaryans matrisin özvektörlerine **eigenvectors** denilmektedir.

4) Karesel bir matris olan kovaryans matrsten özvektörler ve özdeğerler elde edilmesi

Özdeğerler ve özvektörler bir matrisin özellikleridir ve matris hakkında önemli bilgiler taşırlar. Bir vektör üzerine uygulanan matris o vektörün hem büyüklüğünü hem de yönünü değiştirebilir. Ancak, bir matris bazı belirli vektörler üzerinde etkideğinde onun büyüklüğünü bir çarpan kadar katlar, yani sadece büyüklüğünü değiştirir, doğrultularını

değiştirmez. Doğrultusu değiştirilmeyen bu vektörler matrisin özvektörleri olarak tanımlanır.

5) Bileşenlerin seçilmesi ve özellik vektörünün oluşturulması

Elde edilen özvektör ve özdeğerler sayesinde eksenler ve özellik vektörü elde edilir. Veri setinin temel bileşenleri en yüksek özdeğerler ile özvektörlerden oluşmaktadır. Genellikle, özvektörler öncelikli olarak kovaryans matristen elde edilir ve daha sonra yüksek değerden düşük değere doğru sıralanır. Amaç bileşenleri veriyi temsil etme oranına göre sıralamaktır. Böylelikle en önemli bileşenden en az önemli bileşene doğru bir sıralama yapılır. Eğer bazı bileşenler atılırsa sonuçta elde edilecek veri seti orijinal veri setinden daha az boyuta sahip olabilir. Örneğin n boyutlu bir veri setinden n özvektör ve özdeğer elde edildikten sonra p kadar özvektör seçilirse sonuçta elde edilecek veri seti sadece p boyutlu olacaktır.

$$\text{ÖzellikVektörü} = (\text{özvektör}_1, \text{özvektör}_2, \dots, \text{özvektör}_n) \quad (3.27)$$

6) Yeni veri setinin türetilmesi

Veri setini en iyi temsil edecek, önem derecesi en yüksek olarak seçilen bileşenler ile normalize edilmiş verinin transpozu alınarak çarpılması sonucu yeni veri seti üretilir (Cömert 2015).

$$\text{YeniVeriSeti} = \text{ÖzellikVektörü} * \text{NormalizeEdilmiş Veri} \quad (3.28)$$

4. ARAŞTIRMA VE BULGULAR

Bulanık mantık yaklaşımı ile oluşturulan karar destek ya da tahmin sistemleri, herhangi bir problem karşısında meydana gelecek karar verme sürecinin karmaşık ve hassas olduğu durumlarda ve adeta insan gibi karar verebilecek bir kontrol mekanizmasına ihtiyaç duyulduğunda kullanılabilecek faydada sistemlerdir. Bu nedenle mezotelyoma hastalığının teşhisinde kullanılabilecek ve hasta kişilerden elde edilen parametreler her ne kadar uzman görüşler tarafından kullanılabilecek olsa da daha doğru ve kesin kararın alınabilmesi uzman görüşlere ek olarak kendi kendine karar verebilen bir karar destek sisteminin olması ile mümkün olacaktır. Girdi ve çıktı değerlerinin davranış durumlarının sisteme öğretilmesi ile geliştirilecek olan model, değişkenlik gösteren girdiler ile nasıl bir şekilde tepki vereceğini sezgisel bir biçimde doğru tahmin edebilir ve bu girdiler geliştirilen bu yaklaşımla hata almadan kontrol edilebilir.

Mezotelyoma hastalık teşhisi de bulanık sistem yaklaşımı ile ilişkilendirilecek olursa hastalığın teşhisi için alınan bazı tıbbi değerler ve çıktı değerleri sistemin giriş ve çıkış parametrelerini oluşturacaktır.

Tanı ve teşhis sürecini hızlandırma, bunun sonucunda da tedavi sürecini hızlı başlatabilme amacı ile bu parametrelerin bulanık mantık ve yapay sinir ağları entegresi olan ANFIS tabanlı yaklaşım vasıtasıyla sisteme öğretim işlemi gerçekleştirilecek ve ileri aşamalarda sisteme verilen yeni girdiler ile çıktıyı doğru tahmin edebilecek şekilde otomatize edilebilecektir.

4.1 Problemin Ortaya Koyulması ve Tezin Hedefi

Tıbbi tanı, sağlık açısından önemli ve kritik bir role sahiptir. Doğru ve zamanında gerçekleştirilen tanı neticesinde tedaviye geçiş süreci hızlanarak hastalık düzeyinin ileri seviyelere taşınması engellenebilir ya da çeşitli tedavi metotları ile hasta bir nebze rahatlatılabilir. Tıbbi konuların derinliği ve bu konuların keskin ve net olmayabilen yapıları nedeni ile uzman tahmin sistemleri ile bu alanlar üzerinde çalışmak son yıllarda önemli hale gelmiş ve gittikçe de önemi artmaktadır.

Birçok araştırmacı klinik semptomlara bağlı olarak medikal hastalıklara tanı koymak amacıyla yapay sinir ağları, kural tabanlı sistemler, uzman sistemler ve bulanık uzman sistemler tabanlı çeşitli uygulamalar geliştirmektedir. Bu noktada güncel çalışmalar incelendiğinde uyarlamalı sinirsel bulanık çıkarım sistemi temelli geliştirilen uygulamaların, hastalıkların tahmininde ve diğer çalışma alanlarında da olumlu sonuçlar ve çözümler getirdiği gözlemlenmiştir. ANFIS, son yıllarda yapılan çalışmalarda özellikle fonksiyon yaklaşımlı çözümlerde, örüntü tanıma tabanlı problemlerde kullanıldığı görülmekte olan yararlı ve güçlü sinir ağı yaklaşımlarından biridir. Bu özelliklerine ek olarak bilgisayar sistemleri üzerinde hızlı, maddi yanı çok olmayan, ekstra müdahale gerektirmeyecek tıbbi tanımlar gerçekleştirebilmek amacıyla tıbbi alanda destekleyici araçlar olarak kullanılmaktadır. Bahsedilen avantajlarından dolayı bu çalışmanın amacı, mezotelyoma hastalarını kümeleme metotlarını da kullanarak ANFIS ile normal (sağlıklı) ve anormal (hasta/mezotelyoma) şeklinde gruplara doğru sınıflandırabilecek akıllı bir tanı modeli geliştirmek olarak şekillendirilmiştir.

Teşhislerde hastalara ait hasta geçmiş bilgileri ve hasta şikayetleri (semptomlar) önemli rol oynamaktadır. Uzman görüşler, hastalara ait klinik semptomları değerlendirerek teşhiste bulunmaktadır. Bulanık mantık kullanılarak oluşturulan karar destek sistemleri tecrübeli doktorların, hastalığın teşhisini yaparken kullandığı tüm bilgileri girdi olarak alarak IF-THEN kural tabanına dönüştürür ve doktorlar gibi teşhiste bulunabilir. Bu çalışmada da kişilerin bilgilerinden oluşan gerçek bir veri seti kullanılmıştır.

4.2 Dataset ve etki eden parametreler

Bu çalışmada bilgi kaynağı olarak UCI Makine Öğrenimi veritabanından elde edilen mezotelyoma veri seti kullanılmıştır. UCI makine öğrenmesi veri havuzu, makine öğrenimi algoritmalarının analizleri, veri madenciliği, yapay zeka ile ilgili alanlarda çeşitli çalışmalarda kullanılmak üzere oluşturulan veri tabanları, veri üreteçleri topluluğudur. Arşiv 1987 yılında David Aha ve Kaliforniya Üniversitesi'ndeki (UC Irvine) yüksek lisans öğrencileri tarafından bir ftp arşivi olarak oluşturulmuş olup o zamandan bu yana dünyanın her yerinden eğitimciler, öğrenciler ve araştırmacılar

tarafından yaygın bir makine öğrenme veri seti kaynağı olarak kullanılan oldukça etkili ve faydalı bir arşivdir.

Çalışmada kullanılan veri seti, Dicle Üniversitesi Tıp Fakültesi tarafından hazırlanmış olup UCI veritabanı üzerinde sunulmuştur (Anonim 2018l). Veri tabanı 324 mezotelyoma hasta veri numunesinden oluşmakta olup her bir örnek 34 özellik içermektedir (Çizelge 4.1), bu bağlamda büyük ve kapsamlı bir veri setidir. Veriler 228 sağlıklı bireyden ve mezotelyoma hastalığına sahip 96 vakadan oluşmaktadır, veri setine düzensiz olarak işlenmiştir ve tüm veriler hasta raporlarından alınan gerçek verilerdir.

34 özellik ve aldıkları değerler sırası ile aşağıdaki şekilde olup son satırda yer alan “tanı sınıfı” da sonuç değeridir, 1:sağlıklı, 2: mezotelyoma (hasta) olarak sınıflandırılmıştır. “-“ olarak yer alan ifade değerler aralığını, “/” olarak yer alan ifade ise belirli olan değişkenleri ifade etmek için kullanılmıştır. Örneğin; Yaş:19-85 yaşların 19 ile 85 arasında değiştiği, solunum güclüğü: 0/1 solunum gücüğünün olup olmadığı anlamına gelir.

Çizelge 4.1 Çalışmada kullanılan veri seti parametreleri


Yaş	19-85
Cinsiyet	0/1
Şehir	0-8
Asbest maruziyeti	0/1
MM tipi	0/1/2
Asbeste maruz kalma süresi	0-70
Tanı yöntemi	0/1
Keep side	0/1/2
Sitoloji	0/1
Semptom süresi	0.5-52
Solunum güclüğü	0/1
Göğüs ağrısı	0/1
Zayıflık	0/1
Sigara alışkanlığı	0/1/2/3
Performans durumu	0/1
Beyaz kan	1700-21500
Hücre sayımı (WBC)	4-22
Hemoglobin (HGB)	0/1

Çizelge 4.1 Çalışmada kullanılan veri seti parametreleri (devam)

Trombosit sayısı (PLT)	111-904
Sedimentasyon	11-129
Kan laktik dehidrogenaz (LDH)	101-1128
Alkalen fosfataz (ALP)	41-489
Toplam protein	3.1-8.5
Albumin	1.5-6.9
Glikoz	60-421
Plevral laktik dehidrojenaz	110-7541
Plevral protein	0-6.7
Plevral albumin	0-4.4
Plevral glikoz	2-151
Ölü-canlı	0/1
Plevral efüzyon	0/1
Tomografide plevral kalınlık	0/1
Plevral asit düzeyi (pH)	0/1
C-reaktif protein (CRP)	11-103
Tanı sınıfı	1/2

4.3 Modelin Genel Yapısı ve Çalışma Aşamaları

Çalışma esnasında şekil 4.1’de yer alan blok diyagramdaki başlıklar sırası ile takip edilerek işlemler gerçekleştirilmiş ve bulanık mantık tabanlı model oluşturulmuştur.



Şekil 4.1 Tasarlanan model için gerçekleştirilen çalışma aşamaları

Model oluşturulurken öncelikle giriş ve çıkış değerleri tayin edilmiş, veri seti üzerinde bulanık mantık yöntemleri uygulanmaya başlanmadan önce modelin eğitimi ve bütün işlem aşamaları tamamlandıktan sonra modelin test edilmesi için verinin %80'i eğitim, %20'si test amacıyla rastgele şekilde ayrılmıştır.

Rastgele seçilme amacı sonuçların daha doğru ve güvenilir olmasıdır. Gerçekleştirilen bu ilk adımdan sonra veri setindeki parametrelere ait değerlerin çeşitli aralıklarda olması sebebiyle normalizasyon uygulanarak veri ön işleme gerçekleştirilmiştir. Önişleme gerçekleştirilip veriler standartize edildikten sonra parametre sayısının fazla olması sebebiyle temel bileşenler analizi metodu ile boyut azaltımı gerçekleştirilmiş ve yeni veri seti hazır hale getirilmiştir.

Bu aşamadan sonra oluşturulan yeni veri seti üzerinde sırasıyla Izgara Bölümleme, Alt Kümeleme ve Bulanık-C Ortalamalar kümeleme yöntemleri ile temel bulanık kuralların geliştirilmesi hususunda boyut azaltımı sonucu seçilen parametrelerin hangi durumlarda hangi neticeleri verebileceği belirlenmiş ve bununla ilgili çeşitli kombinasyonlar kurularak bulanık kurallar oluşturulmuştur. Sistem bunun sonucu olarak hasta/hasta değil bilgisini içeren bir çıktı üretmiştir.

Geliştirilen bulanık mantık modelinin belirli giriş değerleri karşısında oluşturduğu çıktılar göz önünde bulundurularak daha önceden elde var olan gerçek değerler (tanı sınıfı) ile sonuçlar karşılaştırılmış ve tutarlılık durumu değerlendirilmiştir. Son aşamada ise ortalama hata kareleri toplamı kökü ile doğruluklar hesaplanmış ve kümeleme yöntemlerinin hangi parametre sayısı ile hangi oranlarda başarılı oldukları kıyaslanmıştır. Bulanık mantık ile uzman sistem oluşturmak için gerekli olan model, MATLAB R2017b ortamında geliştirilmiştir.

4.4 Modelde Kullanılan Parametrelerin Hazırlanması

4.4.1 Veri ön işleme (Preprocessing)

Veri setinde yer alan değerlerin Bölüm 4.2’de de gösterildiği gibi farklı aralıklarda olması sebebiyle öncelikle normalleştirme işlemi uygulanmıştır. Veri dönüştürme işlemi; düzeltme, birleştirme, genelleştirme ve normalleştirme gibi değişik şekillerde adlandırılabilir. Veri normalleştirme işlemi sıklıkla kullanılan veri dönüştürme işlemlerinden birisi olup bu çalışmada da normalleştirme işlemi için teknik olarak ortalama normalleştirme (mean normalization) metodu kullanılmıştır.

Ortalama normalleştirme, ele alınan bir girdi değişkeni için hesaplanan ortalama değerin, bu değerlerden çıkarılmasıdır. Girdi değişkeni sıfırdan yeni bir ortalama değer ile sonuçlanan değişkendir. Yani her bir değişken değerinden ortalamanın farkı alınarak, elde edilen bu fark, eşitlik 4.1’de yer alan s_i değer aralığı (max-min) değerine bölünmektedir. $\bar{x}$ değeri ise tüm değerlerin ortalamasıdır. Kullanılan bu yöntemin amacı veri setini standart bir hale getirmek olup böylelikle ham veriler standart verilere dönüştürülerek veriler arasındaki ölçü birimi farklılığı ortadan kaldırılmış olur.

$$x_{normal} = \frac{x - \bar{x}}{s_i} \quad (4.1)$$

4.4.2 Boyut azaltma işlemi

Kullanılan veri setinde yer alan parametre sayısının 34 adet olması ve bu kadar fazla sayıda değerin bir arada doğru kurallar içerisinde bulanık mantık modelini oluşturmasının tecrübe, uzman bilgisi ile çok fazla sayıda test gerektirmesi, sistemin beklenen performansta çalışmamasına sebep olması yaklaşımıyla boyut azaltımı uygulanmış ve boyut azaltımı yöntemi olarak da temel bileşenler analizi metodu kullanılmıştır. Boyut azaltımı için hazırlanan kaba kod aşağıdaki şekildedir.

```

[coeff,score,latent] = pca(train_input); %eğitim datası için PCA uygulanması%
test_input = bsxfun(@minus,test_input,mean(train_input)); %test datası için de
                                                    aynı PCA'nın kullanımı%
test_input = test_input * coeff;

train_input = score(:,1:k); %PCA score hesaplandıktan sonra eğitim datasının boyut
                            azaltımı%

test_input = test_input(:,1:k); %eğitim datası için PCA score hesaplandıktan sonra test
                                datasının boyut azaltımı%

```

Eğitim seti için oluşturulan boyut azaltım modeli test verisi için de kullanılmıştır. k değeri ile seçilen özellik sayısı, yani azalmış olan değişken sayısı belirlenmektedir. Kümeleme metotları uygulanırken bu k değeri için çeşitli denemeler yapılarak sonuçlar kıyaslanmıştır.

4.5 Modelin Oluşturulma Süreci ve Performans Ölçütleri

PCA uygulandıktan sonra giriş parametreleri ve çıkış parametreleri sisteme verilerek sırasıyla kümeleme algoritmalarına uygulanmıştır. Seçilen üyelik fonksiyonu tipleri, değişken sayıları ile bulanık mantık kuralları oluşturulmuş ve doğruluklar hesaplanmıştır.

Tahmin değerleri sonuçları bulanık mantık yaklaşımı gereği 0 ile 1 arasındaki ondalıklı sayılardan oluştuğundan gerçek değerler ile kıyaslanabilmesi için belirli bir eşik değer ile 0 ve 1 olacak şekilde güncellenmiştir. Eşik değer belirlenmesinde sistem performansını en iyi şekilde etkileyecek değer için çeşitli denemeler yapılmış ve 0.4 değeri eşik değer (threshold) olarak belirlenmiştir. Bu aşamadan önce literatürdeki diğer çalışmalar için de bu evrenin nasıl gerçekleştirildiği incelenmiştir ve örnek çalışmalar baz alınmıştır. “0.4” üzerindeki değerler 1’e (hastalıklı), “0.4” altında kalan değerler 0’a (sağlıklı) çekilmiştir (Mandal 2018).

Yapılan çalışmalar MATLAB üzerinde yazılan kodlar ile gerçekleştirilmiş olup oluşturulan bulanık mantık modelinin anlaşılabilirliği adına örnek olması açısından Grid

Partitioning metodu için arayüz üzerinden de denemeler yapılmış ve çıktılar sonuçlara eklenmiştir.

Oluşturulan modelin güvenilirliğini, performansını değerlendirmek amacıyla ayrılan test verisi ile RMSE (Root Mean Square Error - Ortalama Hata Kareler Kökü) ve doğruluk oranı yüzdeleri hesaplanmıştır. RMSE, önerilen modelin doğruluğunu nicel olarak almak için istatistiksel bir performans göstergesidir. Tahmin edilen her bir değer ile buna karşılık gelen gerçek değer arasındaki fark alınarak bu farkın karesinin ortalamasının karekökü hesaplanmaktadır. RMSE ile hata ortalama büyüklüğü ölçülmektedir, yani ölçülen değerler ile model tahminleri arasındaki hata oranları belirlenir.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (t_p - o_p)^2} \quad (4.2)$$

Eşitlik 4.2’de yer alan N değeri veri miktarını, t_p değeri gözlenen gerçek değeri, o_p değeri ise tahmin edilen değeri temsil etmektedir. Ayrılan test verisi ile sistemin tahmin ettiği sonuçlar ve gerçek sonuçlar arasında karşılaştırma yapılarak doğruluk (accuracy) hesaplanmasında kullanılan doğruluk matrisi (Çizelge 4.2) ve formülü eşitlik 4.3’teki şekildedir.

$$Doğruluk = \frac{DN + DP}{DN + DP + YN + YP} \quad (4.3)$$

Çizelge 4.2 Doğruluk matrisi

Kullanılan doğruluk matrisi		Tahmin edilen sınıf	
		Mezotelyoma	Sağlıklı
Gerçek sınıf	Mezotelyoma	Doğru pozitif	Yanlış pozitif
	Sağlıklı	Yanlış negatif	Doğru negatif

Tanı testi için doğruluk (accuracy) değeri ise doğru şekilde sınıflandırılan örneklerin, toplam doğru ve yanlış sınıflandırılmış örnek sayısına bölünmesiyle elde edilir. Tahmin edilen durumda hastalık bulunuyorsa ve gerçek değerde o kişi hasta ise bu durum DP (doğru pozitif) tir . Gerçekte hasta olmayan bir kişinin tahmin edilen değerlere göre de hasta olmadığı belirlenirse bu durum DN (doğru negatif) tir. *DP* ve *DN* değerlerinin her ikisi de doğru sınıflandırmayı göstermektedir. *YP* (Yanlış pozitif) değeri, gerçekte hasta olan bir kişinin tahmin edilen sınıfta sağlıklı olarak bulunması, *YN* (yanlış negatif) değeri ise gerçekte sağlıklı olan bir bireyin sistem tarafından mezotelyoma olarak sınıflandırılması anlamına gelmektedir. *YP* ve *YN* değerleri ise yanlış olan sınıflandırmaları göstermektedir.

4.5.1 Grid Partition yöntemi ile oluşturulan model ve sonuçları

Grid partitioning yönteminde üyelik fonksiyonu olarak üçgen üyelik fonksiyonu ve gauss üyelik fonksiyonu ile çalışma gerçekleştirilmiştir. Grid partitioning metodunda maksimum 256 adet bulanık kural oluşturulabilmesi sebebiyle üyelik fonksiyonu sayısı yüksek tutulamamıştır. PCA ile parametre sayısı en fazla 5'e kadar seçilmiştir. Model için yazılan örnek bir sözde kod aşağıdaki şekildedir.

```
opt = genfisOptions('GridPartition');
opt.NumMembershipFunctions = [5 5];
opt.InputMembershipFunctionType = ["trimf" "trimf"];
fis = genfis(trnd(:,1:2),trnd(:,3),opt);
tsto = tstd(:,5);
output = evalfis(tstd(:,1:4),fis);
r=sqrt(sum((tsto(:)-output(:)).^2)/numel(tsto))
```


RMSE değeri ve doğruluklar denenen üyelik fonksiyon tipleri ve üyelik fonksiyonu sayılarına göre aşağıdaki tablodaki gibidir. PCA_s olarak adlandırılan değer k için seçilen değerdir.

Çizelge 4.3 Izgara bölümlleme yöntemi ile elde edilen sonuçlar

[PCA_s] & MFT [MembershipFuctionType]	MFN [Membership Function Number]	RMSE [testing]	Accuracy [%]
k=2 [trimf trimf]	[3 3]	0.446	73
	[4 4]	2.930	64
	[5 5]	0.676	55
k=2 [gaussmf gaussmf]	[3 3]	0.408	75
	[4 4]	0.526	75
	[5 5]	0.461	72
k=3 [trimf trimf trimf]	[3 3 3]	0.677	56
	[4 4 4]	1.720	65
	[5 5 5]	4.007	69
k=3 [gaussmf gaussmf gaussmf]	[3 3 3]	1.355	69
	[4 4 4]	3.012	53
	[5 5 5]	1.447	52
k=4 [trimf trimf trimf trimf]	[3 3 3 3]	1.490	63
	[4 4 4 3]	1.506	52
	[5 5 5 2]	0.784	69
k=4 [gaussmf gaussmf gaussmf gaussmf]	[3 3 3 3]	0.933	61
	[4 4 4 3]	0.720	81
	[5 5 5 2]	0.537	81
k=5 [trimf trimf trimf trimf trimf]	[3 3 3 3 3]	0.381	93


Çizelge 4.3’den de görüleceği üzere, en iyi sonuç değeri k=5 ve üçgen üyelik fonksiyonu seçilerek gerçekleştirilen 243 (3^5) bulanık kurallı deneme ile elde edilmiştir ancak doğruluk oranı yüksek olmasına rağmen işlem süresi fazla bulanık kural olması sebebi ile oldukça uzun sürmüştür. Grid partitioning metodu, bu kısıtlamaları sebebi ile performans açısından çok etkili bulunmamıştır. Grid partitioning için gerçekleştirilen çalışmaların Matlab arayüzü ile oluşturulan aşamaları aşağıdaki şekillerde sıralanmıştır.

Test verisinde yer alan gerçek sonuçlar ve bulanık uzman sistemin sonuç çıktısı olan tahmin sonuçlarının dağılımı örnek olarak şekil 4.2’deki gibidir.




Şekil 4.2 Izgara Bölümleme yöntemi ile tahmin sonuçları


Oluşturulan üyelik fonksiyonları ve parametre sayısı seçiminden sonra Matlab üzerinde simülasyon işlemi gerçekleştirilmiştir. Seçilen 2 değişkenden alınan sonuç çıktısına göre Matlab surface viewer arayüzü üzerinden elde edilen görüntüler sırasıyla yer almaktadır:



Şekil 4.3 Bulanık çıkarım sistemine verilen 1. ve 2. girdiler ile sonuç ilişkisinin 3 boyutlu simülasyonu




Şekil 4.4 Bulanık çıkarım sistemine verilen 1. ve 3. girdiler ile sonuç ilişkisinin 3 boyutlu simülasyonu




Şekil 4.5 Bulanık çıkarım sistemine verilen 2. ve 4. girdiler ile sonuç ilişkisinin 3 boyutlu simülasyonu

Giriş değerlerinin 4 parametrelili seçilerek sisteme yüklenmesi, üyelik fonksiyonu tipinin gauss, üyelik fonksiyonu sayılarının [5 5 5 2] olarak seçildiği bir deneme için ortaya çıkan eğitim ve test hataları aşağıdaki şekildedir.




Şekil 4.6 ANFIS eğitim verisi sonucu




Şekil 4.7 ANFIS test verisi sonucu

Model oluşturulurken tanımlanan bu değerlere göre elde edilen sonuçlar aşağıdaki gibidir. Sonuçlar için Matlab fuzzy tool box üzerinde bulunan “Rule Viewer” kullanılmıştır.



Şekil 4.8 Modelde tanımlı kurallara göre sonuçların elde edilmesi

4 giriş ve 1 çıkış için oluşturulan bulanık mantık modelin kuralları ile birlikte yapısı şekil 4.9’da yer almaktadır.



Şekil 4.9 Giriş - çıkış değerleri ve üyelik fonksiyonlarının bulanık kurallar ile ilişkilendirilmesi ve elde edilen çıkış değeri

4.5.2 Subtractive Clustering Yöntemi ile oluşturulan model ve sonuçları

Alt kümeleme yönteminde de seçilen değişken değerleri ve çeşitli küme etki aralığı değerleri değiştirilerek elde edilen sonuçlar değerlendirilmiştir. Her bir deneme için iterasyon sayısı 20 olarak belirlenmiş, alınan 20 sonucun ortalaması tabloya yansıtılmıştır.

Çizelge 4.4 Alt kümeleme yöntemi ile elde edilen sonuçlar

[PCA_S] & [Cluster Range]	Influence	AVR_Accuracy [%] - RMSE [testing_data]
k=2 [0.25]		70%
		0.47817
k=2 [0.5]		74%
		0.41637
k=3 [0.25]		68%
		0.76196
k=3 [0.5]		75%
		0.42328
k=4 [0.25]		66%
		5.13970
k=4 [0.5]		79%
		0.38638
k=5 [0.25]		91%
		0.24014
k=5 [0.5]		92%
		0.29906
k=6 [0.25]		95%
		0.15731
k=6 [0.5]		90%
		1.02396
k=7 [0.25]		96%
		0.14468
k=7 [0.5]		84%
		0.76071
k=8 [0.25]		95%
		0.18455
k=8 [0.5]		94%
		0.26615
k=9 [0.25]		96%
		0.19801
k=9 [0.5]		95%
		0.19801
k=10 [0.25]		93%
		0.22873
k=10 [0.5]		96%
		0.15193

En iyi deęer 10 parametre ile %96'lık ortalama başarı oranı ve 0.15193'lük ortalama RMSE deęeri ile elde edilmiřtir.

Subtractive clustering için oluřturulan sözde kodda temel yaklařım ařaęıdaki řekildedir. FIS (Fuzzy Inference Systems - Bulanık ıkarım sistemi) oluřturulurken “*genfis*” komutundan yararlanılır.

Kümeleme opsiyonlarının hazırlanması:

```
opt = genfisOptions('SubtractiveClustering');  
opt.ClusterInfluenceRange = clusterInfluenceRange;  
opt.DataScale = dataScale;  
opt.SquashFactor = options(1);  
opt.AcceptRatio = options(2);  
opt.RejectRatio = options(3);  
opt.Verbose = options(4);
```

Burada örnek olarak *options* = [1.25 0.5 0.15 0] řeklinde hazırlanır ise sırasıyla *Squash factor*: 1.25, *Accept ratio*: 0.5, *Reject ratio*: 0.15, *Verbosity flag*:0 olarak atanır. *Squash factor* küme merkezlerinin etki aralıęını öleklendirmek için kullanılır, *AcceptRatio* ilk küme merkezi potansiyelinin bir kısmı olarak tanımlanabilecek kabul oranıdır. *RejectRatio* ise ilk küme merkezi potansiyelinin yine bir kısmı olarak tanımlanan reddetme oranıdır. Kabul oranı red oranından daha büyük olmalıdır. *Verbose* deęeri, kümeleme sırasında ilerleme bilgilerinin görüntülenip görüntülenemeyeceęini gösteren bilgi ekranı bayrağıdır ve false:0, true:1 olacak řekilde iki deęer almaktadır. Yarıap r_a olarak ifade edilen *clusterInfluenceRange* deęeri, küme merkezinin etki alanıdır. Küme yarıapı, veri alanını bir birim hiper küpü olarak görüldüğünde bir kümenin etki aralıęını gösterir. Küme merkezinin etki aralıęı, [0,1] aralıęında bir skaler deęerdir. Küme merkezinin etki aralıęını etkileyen bu deęer, kümelerin sayısına baęlı olarak deęiřen bulanık kural sayısını etkilemektedir. Daha küçük bir etki aralıęının belirlenmesi genellikle daha küçük ve daha fazla sayıda veri kümesi, bunun sonucu olarak da ok sayıda bulanık kural oluřturur.

Giriş ve çıkış değişken verilerinin hazırlanması:

```
inputData = data(:,1:N);
```

```
outputData = data(:,N+1:end);
```

%inputData ve outputData, model oluşturulurken sisteme verilen girdi veri seti ve alınan sonuç çıktısıdır.%

Opsiyonlara göre FIS yapısının oluşturulması:

```
fis = genfis(inputData,outputData,opt);
```

Bulanık çıkarım sistemi oluşturulduktan sonra modelin eğitim verisi ile test verilerine yönelik çıktıları oluşturmak için ise “evalfis” komutu kullanılır:

```
resultOutput = evalfis(tstd(:,1:N); fis)
```

%tstd ise test işlemi için hazırlanan veridir. resultOutput en son elde edilen tahmin değeridir.%


Sonuçların RMSE hesaplamaları ise aşağıdaki şekilde oluşturulmuştur:

```
r=sqrt(sum((tsto(:)-resultOutput(:)).^2)/numel(tsto));
```

%tsto değeri test verisinin sonuç değeridir. r değeri sonucu, test için hazırlanan olması gereken gerçek sonuçlar ile sistemin verdiği sonuçlar için RMSE değeri hesaplamasıdır.%

Sonuçların doğruluk oranı ise Bölüm 4.5’te verilen denkleme göre hesaplanmış ve sonuç tablosuna işlenmiştir.


Test verisinde yer alan gerçek sonuçlar ve bulanık uzman sistemin sonuç çıktısı olan tahmin sonuçlarının dağılımı aşağıdaki gibidir.




Şekil 4.10 Alt kümeleme yöntemi ile tahmin sonuçları

Elde edilen çıktıların gerçek değerler ile karşılaştırılması sonucu hesaplanan doğruluk değerleri ve hesaplama süreleri göz önünde bulundurulduğunda, Grid Partitioning yönteminden daha performanslı bir modelin oluşturulduğu gözlemlenmiştir. Parametre sayısı arttıkça doğruluk seviyesinin de yükseldiği görülmüş olup ilk yöntemde olduğu gibi kural sayısının fazlalaşması sebebi ile hesaplama yapılamaması durumu bu metodun çalışma mantığı gereği gözlenmemiştir.


Oluşturulan üyelik fonksiyonları ve parametre seçiminden sonra oluşturulan simülasyonlar aşağıdaki gibidir.



Şekil 4.11 Bulanık çıkarım sistemine verilen 1. ve 2. girdiler ile sonuç ilişkisinin 3 boyutlu simülasyonu



Şekil 4.12 Bulanık çıkarım sistemine verilen 1. ve 3. girdiler ile sonuç ilişkisinin 3 boyutlu simülasyonu



Şekil 4.13 Bulanık çıkarım sistemine verilen 2. ve 3. girdiler ile sonuç ilişkisinin 3 boyutlu simülasyonu


4.5.3 Fuzzy-C Means yöntemi ile oluşturulan model ve sonuçları

Bulanık-C Ortalamalar yöntemi ile yapılan tüm deneylere göre en yüksek başarı oranı elde edilmiştir. Alt kümeleme yönteminde olduğu gibi, girdi sayısı arttırılırken doğruluk yüzdesi de genel olarak artış göstermiş olup parametre sayısı 10 seçildiğinde %100 başarı oranı elde edilmiştir. Modelin test verisi üzerinde uygulanması sonucunda elde edilen RMSE değerleri için de sonuçların, deneyi gerçekleştirilen diğer kümeleme metotlarından daha iyi sonuçlar verdiği gözlemlenmiştir.

Çizelge 4.5 Bulanık-C Ortalamalar yöntemi ile elde edilen sonuçlar


[PCA_s]	AVR_Accuracy [%] - RMSE [testing_data]
k=2	73%
	0.42065
k=3	70%
	0.41001
k=4	80%
	0.36155
k=5	89%
	0.28756
k=6	96%
	0.21072
k=7	98%
	0.19283
k=8	98%
	0.185185
k=9	99%
	0.13635
k=10	100%
	0.10615

Elde olan test verisi sonuç çıktıları ile ANFIS modelin sonuç çıktılarına eşik değer uygulanmadan önceki durumunun grafik dağılımları şekil 4.14'te yer almaktadır.




Şekil 4.14 Bulanık-C Ortalamalar yöntemi ile tahmin sonuçları


Oluşturulan üyelik fonksiyonları ve parametre seçiminden sonra oluşturulan simülasyonlar sırasıyla şekil 4.15, şekil 4.16 ve şekil 4.17'deki gibidir.



Şekil 4.15 Bulanık çıkarım sistemine verilen 1. ve 2. girdiler ile sonuç ilişkisinin 3 boyutlu simülasyonu



Şekil 4.16 Bulanık çıkarım sistemine verilen 1. ve 3. girdiler ile sonuç ilişkisinin 3 boyutlu simülasyonu



Şekil 4.17 Bulanık çıkarım sistemine verilen 2. ve 3. girdiler ile sonuç ilişkisinin 3 boyutlu simülasyonu

Alt kümeleme yönteminde olduğu gibi Bulanık-C Ortalamalar yönteminde de kümeleme opsiyonları hazırlanmıştır. İlk etapta diğer yöntemlerde olduğu gibi bulanık çıkarım sistemi modellenmiştir.

Kümeleme opsiyonlarının hazırlanması aşağıdaki şekildedir.

```
opt = genfisOptions('FCMClustering');  
opt.NumClusters = Nc;  
opt.Exponent = options(1);  
opt.MaxNumIteration = options(2);  
opt.MinImprovement = options(3);  
opt.Verbose = options(4);
```

Burada *NumClusters* küme sayısının alacağı değer olarak tanımlanır. *Exponent* değeri ise kümeler arasındaki örtüşme miktarını kontrol etmektedir, büyük değerler daha büyük bir çakışma derecesini göstermektedir. Veri kümemiz potansiyel kümeler arasında çok fazla çakışmaya sahipse hesaplanan küme merkezleri birbirlerine çok yakın olabilir. Bu durumda da her veri noktası, tüm kümelerde yaklaşık olarak aynı dereceye sahip olabilir. Bu sebepten, kümeleme işlemi sonucunda elde edilen sonuçları geliştirebilmek için, kümeleme esnasında bulanık çakışmayı sınırlandıran bu değeri azaltmak gerekir. *MaxNumIteration* değeri maksimum iterasyon sayısına denk gelmektedir ve pozitif bir sayı olmalıdır. *MinImprovement*, iki ardışık iterasyon arasındaki amaç fonksiyon için minimum iyileştirme miktarıdır. *Verbose* değeri, alt kümelemede olduğu gibi her iterasyondan sonra objektif fonksiyon değerinin görüntülenip görüntülenmeyeceğini gösteren bilgi ekranıdır ve true/false olarak değer alır.

Giriş ve çıkış değişken verilerinin hazırlanması da aynı şekilde gerçekleştirilir.

```
inputData = data(:,1:N);  
outputData = data(:,N+1:end);
```

Opsiyonlara göre FIS yapısının oluşturulması, bulanık çıkarım sistemi oluşturulduktan sonra modelin eğitim verisi ve test verilerine yönelik çıktıları oluşturulması ve son olarak hata oranı hesaplamaları gerçekleştirilmiştir.

```
fis = genfis(inputData,outputData,opt);  
resultOutput = evalfis(tstd(:,1:N); fis)  
r=sqrt(sum((tsto(:)-resultOutput(:)).^2)/numel(tsto));
```

Değişen her bir değişken değeri için sonuçların tabloda görüldüğü gibi tatmin edici olduğu ve hesaplama süreleri açısından da iyi performanslar elde edildiği gözlemlenmiştir.

5. TARTIŞMA VE SONUÇ

Çağımızda teknolojinin devamlı ilerlemesi ve yenilikler içinde olması sebebiyle birçok alanda olduğu gibi özellikle medikal alanda da teknolojik gelişmelerden yararlanılmaktadır. Bu ilerlemelere ek olarak her geçen gün değişen yaşam koşulları, değişim içerisinde olan çevre ve çeşitli faktörler sebebi ile yeni hastalıklar da ortaya çıkmaktadır, buna bağlı olarak da sağlık alanında gerçekleştirilen teknolojik çalışmalar her geçen gün daha da artar şekilde devam etmektedir.

Hastalık tespiti amacıyla gerçekleştirilen uygulamalara katkı sağlayabilmek ve bazı kesinliği zor durumlarda teşhise kolaylık sağlayabilmek amacıyla bulanık mantık ve yapay zekanın çeşitli tekniklerinden faydalandığı görülmektedir. Medikal alanda teşhis tabanlı gerçekleştirilen çalışmalarda bulanık mantık ve yapay zekanın birleşiminden oluşan ANFIS yaklaşımı ile çeşitli çalışmalar gerçekleştirilmektedir. ANFIS esasında, Sugeno tipi bulanık sistemlerin, sinirsel öğrenme kabiliyetine sahip bir ağ yapısı olarak temsilinden ibarettir. Pek çok hastalığın tedavisinde son derece önemli olan hastalığa doğru tanı koyabilme durumu, hastalığın derecesinin ileri seviyelere taşınmasını önleme ve hızlı müdahale edebilme açısından teşhisi zor olabilen ve kritik bir hastalık olan Mezotelyoma hastalığı için de büyük bir öneme sahiptir.

Bu çalışmada, tıp literatüründe Malignant Mesothelioma olarak geçen ve akciğer zarı kanseri olarak adlandırılan Mezotelyoma hastalığı için, bulanık mantık tabanlı hastalık tahmin modeli oluşturulmaya çalışılarak bir karar destek sisteminin geliştirilmesi amaçlanmıştır. Hastalık tahminlerinin en doğru ve tutarlı bir şekilde yapılması ve optimal bir sisteme ulaşılması amacıyla gerçekleştirilen bu çalışmanın yanı sıra, bu hastalık ile ilgili akademik alanda gerçekleştirilen başka çalışmalar da mevcuttur. Literatürde yer alan bu çalışmalarda Mezotelyoma teşhisi için çeşitli yöntemler kullanıldığı görülmüştür. Detayları Bölüm 2.2’de verilen çalışmalarda kullanılan yöntemler için, sınıflandırma alanında kullanılan çeşitli algoritmalar (J48, Bayes Net, SMO, LMT, Logistic, Multi Class Classifier, Random Committee, PART ve ANN, SMO, J48, Random Forest) Contourlet ve Curvelet dönüşümleri sayılabilir.

Bu tez çalışmasında ise Mezotelyoma teşhisinde daha önce kullanılmamış olması gerekçesine dayanılarak yapay zeka teknolojisi kullanılmak istenmiş, bulanık mantık tabanlı çözüm geliştirilmesi amacıyla YSA ve Bulanık Mantık kombinasyonu olan ANFIS metodu ile model oluşturulması amaçlanmıştır. Literatürdeki diğer hastalıklar için gerçekleştirilen ANFIS yaklaşımlı çalışmalardan farkı ise, kümeleme yöntemlerinin entegrasi ile sistemin oluşturulması ve en iyi performansı sergileyecek yöntemin bulunmak istenmesidir. Çalışma sonucunda performans sonuçları değerlendirilmiş ve diğer çalışmalardaki yaklaşımlar ile karşılaştırılmıştır.

Çalışmada kullanılan ve gerçek verilerden oluşan veri seti, modele uygun bir şekilde standartize edilerek ön işleme safhalarından geçirilmiş ve çalışmaya uygun hale getirilmiştir. Veri seti, modelin oluşturulması ve test edilmesi için eğitim ve test olmak üzere % 80 - % 20 oranlarında rastgele bölünmüştür. Sonrasında bulanık kurallardan oluşacak karmaşıklığın yaşanmaması ve veri setinin daha anlamlı bir hale getirilerek performansın artırılması amacıyla boyut azaltım yöntemlerinden PCA uygulanmıştır. Sırasıyla Grid Partitioning, Subtractive Clustering ve Fuzzy-C Means kümeleme yöntemleri uygulanarak bulanık çıkarım sistemleri eğitim setleri üzerinde oluşturulmuştur. Kümeleme metotları denenirken PCA ile parametre sayılarının seçilmesinin, iterasyon sayılarının ve Bölüm 3.5'te detayları verilen her bir yöntem için bazı spesifik parametrelerin model performansını nasıl etkilediği test verileri üzerinde denenmiş, bulanık çıkarım sistemi sonucunda elde edilen sağlıklı/mezotelyoma şeklinde sınıflandırılmış verilerin doğruluğu hesaplanırken ortalama hata ve oluşturulan doğruluk matrisine göre yüzde doğruluk değerleri hesaplanmıştır. Çalışma MatlabR2017b ortamında hazırlanan kodlar ile gerçekleştirilmiştir. Matlab üzerindeki Fuzzy Logic Toolbox içerisinde yer alan ANFIS grafiksel kullanıcı arayüzünün de kullanılabilirliğini göstermek amacıyla örnek olarak grid partitioning için alınan görüntüler eklenmiştir.

Kümeleme yöntemleri ile oluşturulan ANFIS tabanlı modelden elde edilen sonuçlar karşılaştırıldığında, Grid Partitioning için curse of dimensionality olarak adlandırılan ve Bölüm 3.5.1'de detayları paylaşılan, girdi sayısının artması ile orantılı olarak bulanık kural sayısının artması ve buna bağlı olarak hesaplama sürelerinin uzaması, belirli bir kural sayısından sonra yöntemin işlevsizliği gibi metodun çeşitli çalışma

prensiplerinden kaynaklı neticeler gözlemlenmiş, elde edilmek istenen başarı seviyeleri genel olarak karşılanamamıştır. Subtractive Clustering ve Fuzzy C-Means yöntemlerinde, Grid Partitioning'e göre daha avantajlı sonuçlar elde edilmiş, Fuzzy C Means yöntemi ile parametre sayısının artmasını takiben % 100 doğruluk sonucu ve % 0.10615 RMSE değeri ile elde edildiği görülmüştür. Bu hastalık ile ilgili diğer çalışmalarda da gerçekleştirilen sınıflandırma sonuçlarına bakıldığında diğer çalışmalarda olduğu gibi yüksek başarı oranı elde edilmiş ve bulanık mantık yaklaşımının da tahmin yöntemi olarak kullanılabileceği kanısına varılmıştır. Oluşturulan bulanık çıkarım sistemi ile yeni verilecek girdiler ile hastalığın teşhisinde emin olunamayan durumlarda ya da otomatik olarak teşhisin gerçekleştirilebilmesi amacıyla karar destek sistemi olarak önemli bir katkı sağlayacağı değerlendirilmektedir.

Oluşturulan bulanık çıkarım tabanlı sistemin daha da geliştirilmesine yönelik ileride yapılacak çalışmalarda, girdi değişkenleri belirlenirken kullanılan boyut azaltım metotları açısından farklı metotlar denenerek veri sayısının ve test edilecek bu boyut azaltım yöntemlerinin performansa katkısı, iyileşme sağlayıp sağlayamadığı irdelenebilir. Test verisi üzerinde deneyler gerçekleştirilirken belirli bir sayı olarak belirlenen iterasyon sayısı için en iyi sonucun elde edilmesine katkı sağlayacak şekilde optimum iterasyon sayısının bulunması amacıyla çalışmalar gerçekleştirilebilir. Son olarak bulanık çıkarım sistemi sonucu elde edilen sınıflandırılmış verilerin, gerçek değerler ile karşılaştırılması için belirli bir eşik değer karşısında bulanık değerlerden gerçek değerlere evrilmesi için belirlenecek cut-off değerinin optimum değerde belirlenebilmesine yönelik çalışma sağlanabilir.

KAYNAKLAR

- Abbasimehr, H., Setak, M. and Tarokh, M.J. 2011. A Neuro-Fuzy Classifier for Customer Churn Prediction. International Journal of Computer Applications, 19(8), 35-41.
- Abduljabar, J.S. 2011. Bulanık Mantık Yöntemleri Kullanılarak Gazlı İçeceklerde Karbondioksit Kontrolü. Yüksek Lisans Tezi. Ankara Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı, Ankara.
- Ağyar, Z. 2015. Yapay Sinir Ağlarının Kullanım Alanları ve Bir Uygulama. Mühendis ve Makina Dergisi, 56(662), 22-23.
- Akıllı, A., Atıl, H. ve Kesenkaş, H. 2014. Çiğ Süt Kalite Değerlendirmesinde Bulanık Mantık Yaklaşımı. Kafkas Üniversitesi Veterinerlik Fakültesi Dergisi, 20 (2), 223-229.
- Akpınar, E. 2010. Malign Plevral Mezotelyomalarda Doku Mikroarray Yöntemiyle İmmünprofilin İncelenmesi. Tıpta Uzmanlık Tezi, Ankara Üniversitesi, Tıp Fakültesi, Patoloji Anabilim Dalı, Ankara.
- Akyol, S. ve Alataş, B. 2016. Kedi Sürüşü Optimizasyon Algoritmasıyla Doğru ve Anlaşılabilir Nümerik Sınıflandırma Kurallarının Otomatik Keşfi. Journal of the Faculty of Engineering and Architecture of Gazi University, 31(4), 839-857.
- Alı, Z.N. 2011. Bulanık Mantık ile Grup Asansör Kontrol Sisteminin Tasarımı ve Simülasyonu. Yüksek Lisans Tezi. Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı, Konya.
- Altaş, İ.H. 1999. Bulanık Mantık: Bulanık Denetim, Enerji, Elektrik, Elektromekanik-3e. Bileşim Yayıncılık A.Ş., 64, 76-81.
- Anonim. 2018a. Web Sitesi: <https://docplayer.biz.tr/18796878-Bulanik-mantik-denetleyicileri.html> Erişim Tarihi: 10.02.2018.
- Anonim. 2018b. Web Sitesi: http://78.189.53.61/-/bs/ess/k_sumbuloglu.pdf Erişim Tarihi: 05.07.2018.
- Anonim. 2018c. Web Sitesi: <https://www.saglikocagim.net/mezotelyum-nedir/> Erişim Tarihi: 27.08.2018
- Anonim. 2018d. Web Sitesi: <https://www.drozdogan.com/malign-mezotelyoma-akciger-zari-kanseri-asbestle-iliskili-bu-hastalik-icin-umut-veren-iki-yeni-tedavi/> Erişim Tarihi: 12.06.2018
- Anonim 2018e. Web Sitesi: <https://multiyasam.com/mezotelyoma-belirtileri-ve-tedavisi/> [<http://www.yenibiyoloji.com/mezotelyoma-nedir-belirtileri-nedenleri-tedavisi-ve-teshisi-4237/>] Erişim Tarihi: 07.05.2018
- Anonim. 2018f. Web Sitesi: <http://www.yenibiyoloji.com/mezotelyoma-nedir-belirtileri-nedenleri-tedavisi-ve-teshisi-4237/> Erişim Tarihi: 15.09.2018

- Anonim. 2018g. Web Sitesi: <http://www.biyolojidersnotlari.com/denetleme-ve-duzenleme-sistemi-sinir-sistemi-ve-endokrin-sistem.html> Erişim Tarihi: 14.05.2018
- Anonim. 2018h. Web Sitesi: <https://www.psikolojik.gen.tr/yapay-sinir-aglari.html> Erişim Tarihi: 03.01.2018
- Anonim. 2018i. Web Sitesi: <https://medium.com/@yasinguzel/yapay-zeka-ders-notlar%C4%B1-5-%C3%A7ok-katmanlı%C4%B1-yapay-sinir-a%C4%9F%C4%B1-4c6af075e1fe> Erişim Tarihi: 03.02.2018
- Anonim. 2018j. Web Sitesi: http://omerfarukbay.com/userfiles/file/BulanikMantik/BM_2_BulanikKumeler.pdf Erişim Tarihi: 12.06.2018
- Anonim. 2018k. Web Sitesi: <https://slideplayer.biz.tr/slide/1919131/> Erişim Tarihi: 01.10.2018
- Anonim. 2018l. Web Sitesi: <https://archive.ics.uci.edu/ml/datasets/Mesothelioma%C3%A2%E2%82%AC%E2%84%A2s+disease+data+set+> Erişim Tarihi: 04.01.2018
- Atalay, A. ve Tortum A. 2010, Türkiye’deki İllerin 1997-2006 Yılları Arası Trafik Kazalarına Göre Kümeleme Analizi. Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi, 16(3), 335-343.
- Ayana, E.K. 2016. Öznitelik Seçiminin Geliştirilen Bir Yapay Sinir Ağı Sınıflandırılması Üzerine Etkisi. Yüksek Lisans Tezi. Yıldız Teknik Üniversitesi, Kontrol ve Otomasyon Mühendisliği Anabilim Dalı, İstanbul.
- Aytaç, E. 2011. Kalite İyileştirme Sürecinde Bulanık Mantık Yaklaşımı ile Hata Türü ve Etkileri Analizi ve Uygulama Örneği. Yüksek Lisans Tezi. Adnan Menderes Üniversitesi, Sosyal Bilimler Enstitüsü, İşletme Anabilim Dalı, Aydın.
- Bahadır, E. 2017. Bulanık Mantık Yaklaşımının Eğitim Çalışmalarında Kullanılmasının Alan Yazın Işığında Değerlendirilmesi. International Journal of Social and Educational Sciences, 4(7), 28-42.
- Baykal, N. ve Beyan, T. 2004. Bulanık mantık ilke ve temelleri. Bıçaklar Kitabevi, Ankara.
- Bayrakçı, N. ve Barışçı, N. 2008. Mitral kapak Doppler İşaretlerinin Bulanık Kümeleme İle Sınıflandırılması. ELECO 08, Bursa.
- Berber, N. ve Boru, A. 2013. Adaptif Ağ Yapısına Dayalı Bulanık Çıkarım Sistemi İle Hava Tahmini. Lisans Tezi. Gaziantep Üniversitesi, Endüstri Mühendisliği, Gaziantep.
- Bey, K.B., Benhammedi, F. and Sebbak F. 2013. Fuzzy Subtractive Clustering Based Prediction Approach for CPU Load Availability. The Fourth International Conference on Cloud Computing, GRIDs, and Virtualization, 215-220.
- Bhuvaneswari, A.N.G. 2013. An Intelligent Approach Based on Principal Component Analysis and Adaptive Neuro Fuzzy Inference System for Predicting the Risk Of

Cardiovascular Diseases. Fifth International Conference on Advanced Computing (ICoAC).

- Bokde, P.R. 2017. An ECG Beat Classification Using Adaptive Neuro-Fuzzy Inference System. International Research Journal of Advanced Engineering and Science, 2(2), 354-358.
- Budak, H. 2018. Özellik Seçim Yöntemleri ve Yeni Bir Yaklaşım. Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 22, 21-31.
- Cömert, Z. 2015. Temel Bileşenler Analizine Genel Bir Bakış. <http://www.zafercomert.com/IcerikDetay.aspx?zcms=78> Erişim Tarihi: 12.01.2018
- Çinicioğlu, E.N., Atalay, M. ve Yorulmaz, H. 2013. Trafik Kazaları Analizi için Bayes Ağları Modeli. Bilişim Teknolojileri Dergisi, 6(2), 41-52.
- Devi, K.Y. and Sasikala, M. 2016. Contourlet and Curvelet Transform Aiding in Diagnosis of Mesothelioma. International Conference on Current Research in Engineering Science and Technology (ICCREST), 35-40.
- Doğan, O. 2016. Uyarlamalı Sinirsel Bulanık Çıkarım Sisteminin (ANFIS) Talep Tahmini için Kullanımı ve Bir Uygulama. Dokuz Eylül Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 31(1), 257-288.
- Eravcı, D.B. 2016. Bulanık Mantık ile Silikozisin Tespit Edilmesi. Yüksek Lisans Tezi. Ankara Üniversitesi, Sağlık Bilimleri Enstitüsü, Biyoistatistik Anabilim Dalı, Ankara.
- Er, O., Tanrıku, Ç. and Abakay, A. 2015. Use of Artificial Intelligence Techniques for Diagnosis of Malignant Pleural Mesothelioma. Dicle Medical Journal, 42(1), 5-11.
- Erilli, N.A. ve Karaköy Ç. 2015. Türk Cumhuriyetlerinin Bulanık Kümeleme Analizi ile Belirlenen Ekonomik Göstergelerle Sınıflandırılması. International Conference on Eurasian Economies, Kazan, Russia.
- Fattahi, H. ve Bayatzadehfard, Z. 2017. A Comparison of Performance of Several Artificial Intelligence Methods for Estimation of Required Rotational Torque to Operate Horizontal Directional Drilling. International Journal of Optimization in Civil Engineering, 7(1), 45-70.
- Fattahi, H. 2017. Prediction Of Slope Stability Using Adaptive Neuro-Fuzzy Inference System Based On Clustering Methods. Journal of Mining & Environment, 8(2), 163-177.
- Güney, E. 2009. Kavramsal Radyo Sistemlerinde Yapay Sinir Ağına Dayalı Kanal Seçme Yöntemi Tasarımı. Yüksek Lisans Tezi. İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı, İstanbul.
- Haznedar, B. ve Kalınlı, A. 2015. Trombofili Hastalığı ile Genetik Bozukluklar Arasındaki İlişkinin Adaptif Ağ Tabanlı Bulanık Çıkarım Sistemi (ANFIS) ile tespit edilmesi. SAÜ Fen Bilimleri Dergisi, 20(1), 13-21.

- İçen, D. ve Günay, S. 2014. Uzman Sistemler ve İstatistik. İstatistikçiler Dergisi: İstatistik&Aktüerya, Sayı: 7, 37-45.
- İncekara, H. 2010. Tıbbi Tahlil Sonuçlarının Analizinde Web Arayüzü Bulanık Uzman Sistem Tasarımı. Yüksek Lisans Tezi. Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Elektronik ve Bilgisayar Sistemleri Eğitimi Anabilim Dalı, Konya.
- Kaftan, İ., Balkan, E. ve Şalk, M. 2013. Bulanık Mantık (Fuzzy Logic) ve Jeofizikte Kullanım Alanları:Sismoloji Örneği. DEÜ Mühendislik Fakültesi Mühendislik Bilimleri Dergisi, 15(2), 15-29.
- Kara, A. 2008. Developing An Expert-System For Diabetics By Supporting With ANFIS. Master Thesis. Bahçeşehir University, Institute of Science Computer Engineering, 40, İstanbul.
- Keskenler, M.F. ve Keskenler, E.F. 2017. Bulanık Mantığın Tarihi Gelişimi. Takvim-i Vekayi, 5(1), 1-10.
- Khalifa, S. and Komarizadeh, M.H. 2012. An Intelligent Approach Based On Adaptive Neuro-Fuzzy Inference Systems (ANFIS) For Walnut Sorting. Australian Journal of Crop Science, 6(2), 183.187.
- Köse, M., Terzi, Ö., İlker A. ve Ergin, G. 2011. Uyarlamalı Ağ Tabanlı Bulanık Mantık Çıkarım Sistemi ile Kızılırmak Nehri'nin Akım Tahmini. 6th International Advanced Technologies Symposium (IATS'11), 162-165.
- Lafta, H.A. 2010. Solving Overfitting Problem in Fuzzy Subtractive Clustering. Global Conference on Power Control and Optimization, Gold Coast, Australia, 2,4.
- Mahmood, M.S. 2010. Bulanık Mantık Kullanılarak Trafik Kontrolünün Tasarımı ve Uygulaması. Yüksek Lisans Tezi. Ankara Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı, Ankara.
- Mandal, D. 2018. Adaptive Neuro-Fuzzy Inference System Based Grading of Basmati Rice Grains Using Image Processing Technique. Applied System Innovation, 1-19.
- Narayanan, K., Singumahanti, J.C. ve Jacob S.G. 2016. A Comparative Study on the Performance of Classifiers in Prediction of Rare Clinical Ailments: A Case-Study with Mesothelioma. Middle-East Journal of Scientific Research, 24(12), 3833-3837.
- Nauck, D., Klawonn, F. and Kruse, R. 1992. Fuzzy Sets, Fuzzy Controllers, and Neural Networks. Journal of the Humboldt-University of Berlin, Series Medicine 41(4).
- Nizam, H. ve Akın S.S. 2014. Sosyal Medyada Makine Öğrenmesi İle Duygu Analizinde Dengeli ve Dengesiz Veri Setlerinin Performanslarının Karşılaştırılması. XIX. Türkiye'de İnternet Konferansı, Yaşar Üniversitesi, İzmir, 27-29.
- Ok, Y. 2010. Adaptif Sinirsel Bulanık Çıkarım Sistemi (ANFIS) İle Türkiye'de Orta Dönemli Elektrik Enerjisi Talep Tahmini. Yüksek Lisans Tezi. Gazi Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Anabilim Dalı, Ankara.

- Onan, A. 2015. Şirket İflaslarının Tahmin Edilmesinde Karar Ağacı Algoritmalarının Karşılaştırmalı Başarım Analizi. Bilişim Teknolojileri Dergisi, 8(1), 9-19.
- Öztemel, E. 2012. Yapay Sinir Ağları. Papatya Yayıncılık, 3rd Edition.
- Sadouki, L. and Haddad, B. 2016. Adaptive Neuro-Fuzy Inference System for Echoes Classification in Radar Images. 11th Joint Conference on Computer Vision, Imaging and Computer Graphics Theory and Applications (VISIGRAPP 2016), 4, 159-166.
- Senel, B., Senel, F.A. and Kahriman M. 2017. Linear Behaviour Modelling of SBB5089Z Power Amplifier Module with Data Mining. International Journal of Scientific and Technological Research, 3(5), 20-29.
- Sinecen, M. 2002. Klima Sistem Kontrolünün Bulanık Mantık ile Modellenmesi. Yüksek Lisans Tezi. Pamukkale Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik Elektronik Mühendisliği Anabilim Dalı, Denizli.
- Sorias, S. 2015. Psikiyatrik Tanıda Betimsel ve Kategorik Yaklaşımların Kısıtlılıklarını Aşmak: Bayes Ağlarına Dayalı Bir Öneri. Türk Psikiyatri Dergisi, 26 (1), 1-12.
- Şahinler, S., Bek, Y. ve Görgülü, Ö. 2006. Sağlık Alanında Bulanık Mantık Yöntemlerinin Uygulanabilirliği. IX. Ulusal Biyoistatistik Kongresi, Zonguldak.
- Şengöz, N. ve Özdemir, G. 2016. Combined Use of Principal Component Analysis and K-Clustering Method: A Case Study. Mehmet Akif Ersoy Üniversitesi Sosyal Bilimler Enstitüsü Dergisi, 8(15), 85-94.
- Tiryaki, A. ve Kazan, R. 2007. Bulaşık Makinesinin Bulanık Mantık ile Modellenmesi. Mühendis ve Makina Dergisi, 48(565), 3-8.
- Tutuncu, K. ve Çataltaş, O. 2017. Diagnosis of Mesothelioma Disease Using Different Classification Techniques. International Journal of Intelligent Systems and Applications in Engineering (IJISAE), 7-11.
- Tür, R. ve Balas, C.E. 2010. Belirgin Dalga Yüksekliklerinin Neuro-Fuzy Yaklaşımı ile Tahmini: Filyos Deniz Yöresi Örneği. Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi, 25(3), 505-510.
- Vaidhehi, V. 2014. The Role of Dataset in Training ANFIS System for Course Advisor. International Journal of Innovative Research in Advanced Engineering (IJIRAE), 1(6), 249-253.
- Varol, S. 201g. Tüketici Fiyat Endeksinin Uyarlamalı Ağa Dayalı Bulanık Çıkarım Sistemi ile Kestirimi. İnsan&İnsan, 3(8), 59-71.
- Yaman, S. 2014. Echo State Network ile Sistemlerin Modellenmesi. Yüksek Lisans Tezi. İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Kontrol ve Otomasyon Mühendisliği Anabilim Dalı, İstanbul.
- Yaşar, H. 2015. Medikal Görüntülerin Çoklu Çözünürlük Metotları ile Analizi. Yüksek Lisans Tezi. Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği Anabilim Dalı, Konya.

- Yıldız, K., Çamurcu, Y. ve Doğan, B. 2010. Veri Madenciliğinde Temel Bileşenler Analizi ve Negatıfsız Matris Çarpanlarına Ayırma Tekniklerinin Karşılaştırmalı Analizi. Akademik Bilişim'10-XII. Akademik Bilişim Konferansı Bildirileri, 207-213.
- Yılmaz, A. 2012. Demir Eksikliği Anemisi Teşhisi İçin Bir Bulanık Uzman Sistem Tasarımı. Yüksek Lisans Tezi. Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Elektronik ve Bilgisayar Sistemleri Eğitimi Anabilim Dalı, Konya.
- Yücel, A. and Güneri, A.F. 2010. Application of Adaptive Neuro Fuzzy Inferency System to Supplier Selection Problem. Journal of Engineering and Natural Sciences, Sigma 28, 224-234.
- Zadeh, L.A. 1965. Fuzzy Sets. Information and Control , Department of Electrical Engineering and Electronics Research Laboratory, University of California, Berkeley, 8 (3), 338-353.
- Ziasabounchi, N. and Askerzade, I. 2014. ANFIS Based Classification Model for Heart Disease Prediction. International Journal of Electrical & Computer Sciences, 14(2), 7-12

ÖZGEÇMİŞ

Adı Soyadı : Hilal KAYA
Doğum Yeri : Zonguldak
Doğum Tarihi : 12.10.1989
Medeni Hali : Bekar
Yabancı Dili : İngilizce

Eğitim Durumu (Kurum ve Yıl)

Lise : Cumhuriyet Anadolu Lisesi (2017)
Lisans : Süleyman Demirel Üniversitesi Mühendislik Mimarlık Fakültesi
Bilgisayar Mühendisliği (2012)
Yüksek Lisans : Ankara Üniversitesi Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı (09.2012- 12.2018)

Çalıştığı Kurum/Kurumlar ve Yıl

Türk Telekomünikasyon A.Ş. / Aralık 2012 - Nisan 2017
Turkish Airlines A.O. / Mayıs 2017 - Temmuz 2017
T.C. Cumhurbaşkanlığı Savunma Sanayii Başkanlığı / Temmuz 2017 - halen

Uluslararası Kongre Sunum

Kaya, H. and Askerzade, I. 2018. Diagnosis of Lung Diseases Using Adaptive Neuro-Fuzzy Inference System Based on Clustering Methods. II. International Conference on Theoretical and Applied Computer Science and Engineering, 29-30 June, Istanbul, Turkey.

Yayınlar

Kaya, H. and Askerzade, I. A Comparative Study on the Performance of ANFIS-Based Clustering Algorithms for Prediction of Malignant Mesothelioma. Communications Faculty of Sciences University of Ankara Series A2-A3: Physical Sciences and Engineering. (İbraz edildi. Tahmini yayım yılı: 2019).