

T.C.
BEYKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI
BİLGİSAYAR MÜHENDİSLİĞİ BİLİM DALI

**YAPAY ZEKA İLE MEME KANSERİ LENF NODU
ANALİZİ**
(Yüksek Lisans Tezi)

Tezi Hazırlayan:

Kulilik SÜER

İstanbul, 2019

T.C.
BEYKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI
BİLGİSAYAR MÜHENDİSLİĞİ BİLİM DALI

**YAPAY ZEKA İLE MEME KANSERİ LENF NODU
ANALİZİ**

(Yüksek Lisans Tezi)

Tezi Hazırlayan:

Kulilik SÜER

Öğrenci No:

160820039

Danışman:

Dr. Öğr. Üyesi Atınç YILMAZ

İstanbul, 2019

YEMİN METNİ

Yüksek Lisans Tezi olarak sunduğum “Yapay Zeka ile Meme Kanseri Lenf Nodu Analizi” başlıklı bu çalışmanın, bilimsel ahlak ve geleneklere uygun şekilde tarafımdan yazıldığını, yararlandığım eserlerin tamamının kaynaklarda gösterildiğini ve çalışmamın içinde kullanıldıkları her yerde bunlara atıf yapıldığını belirtir ve bunu onurumla doğrularım. 31.01.2019

Kulilik SÜER

T.C.
BEYKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZ SAVUNMA SINAVI SONUÇ TUTANAĞI

Beykent Üniversitesi
Fen Bilimleri Enstitüsü Müdürlüğü'ne,

Aşağıda tez adı belirtilen yüksek lisans öğrencisi 160820039 no'lu Ulusal Sığır 'in 31.01.2019 tarihinde yapılan tez savunma sınavı¹ sonucunda 45 dakika süreyle sunduğu ve savunduğu tezi hakkında² oybirliğiyle, KABUL kararı verilmiştir.

Bilgilerinize saygılarımızla arz ederiz.

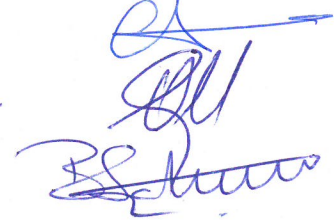
Anabilim Dalı : Bilgisayar Mühendisliği
Programı : Bilgisayar Mühendisliği
Tez Başlığı³ : Yapay Zeka ile Meme Kanseri Enf Madde Analizi

Tez Sınav Jürisi

Öğretim Üyesi

İmza

Danışman : Dr. Öğr. Üyesi Atıncı Yılmaz
Üye : Dr. Öğr. Üyesi Ediz Sımsıkçı
Üye : Dr. Öğr. Üyesi Y. Batu Salman



¹ Jüri üyeleri, söz konusu tezin kendilerine teslim edildiği tarihten itibaren en geç bir ay içinde toplanarak öğrenciyi tez sınavına alır. Tez savunma sınav süresi en az 45, en çok 90 dakikadır. Jüri üyeleri, sınav öncesi yapılacak toplantıda, kendi aralarından danışman dışında bir üyeyi başkan seçer. Tez sınavı, tez çalışmasının sunulması ve bunu izleyen soru-cevap bölümünden oluşur. Tez sınavı, öğretim elemanları, lisansüstü öğrenciler ve alanın uzmanlarından oluşan dinleyicilerin katılımına açık ortamlarda gerçekleştirilir. Belirlenen günde yapılamayan jüri toplantısı, katılanların hazırladığı bir tutanakla enstitü yönetimine bildirilir. Bu durumda, jüri en geç on beş gün içinde toplanarak adayı tez savunma sınavına alır. (05 Ağustos 2017 tarihli 30145 sayılı Resmi Gazetede Yayınlanan Değişiklik-Madde 29-3)

² Tez sınavının tamamlanmasından sonra jüri, tez hakkında salt çoğunlukla “kabul”, “düzeltme” veya “ret” kararı verir. Jüri başkanı, jüri üyelerince imzalanmış karar tutanağını, tez sınavını izleyen üç gün içinde ilgili enstitü yönetimine teslim eder. Tezi hakkında düzeltme kararı verilen öğrenci en geç üç ay içinde gerekli düzeltmeleri yaparak ve birinci fıkradaki usule göre tezini aynı jüri önünde yeniden savunur. Süresi içerisinde “düzeltme” savunmasına girmeyen öğrencinin enstitü ile ilişkisi kesilir. (Beykent Üniversitesi Lisansüstü Eğitim ve Öğretim Yönetmeliği-Madde 29-4)

³ İleride doğabilecek aksaklıkların engellenmesi için tezin başlığının yazılması gerekmektedir.

Adı ve Soyadı : Kulilik SÜER
Danışmanı : Dr. Öğr. Üyesi Atınç YILMAZ
Türü ve Tarih : Yüksek Lisans, 2019
Alanı : Bilgisayar Mühendisliği
Anahtar Kelimeler : Meme Kanseri, Yapay Sinir Ağları, K-Means, Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi, Genetik Algoritma, Tanı Testi, ROC

ÖZ

YAPAY ZEKA İLE MEME KANSERİ LENF NODU ANALİZİ

Dünya’ da en çok görülen kanser türünün akciğer kanseri olmasına rağmen kadınlarda en çok görülen kanser türü meme kanseridir. Meme kanserinde, hastalığın evresi ve buna bağlı olarak hangi tedavi yönteminin kullanılacağı konusunda birçok olgunun analiz edilmesinin yanında koltuk altı lenf nodu durumu önem taşımaktadır. Meme kanserinde koltuk altı lenf durumunun varlığı vücudun diğer organlarına yayılma riskini arttırmaktadır. Cerrahi işlemler gerektiren bu durum hastalığın ciddiyetini önemli kılmaktadır. Yapılan bu çalışmada İstanbul Gaziosmanpaşa Taksim Eğitim ve Araştırma Hastanesi’nden alınan meme kanseri olan hastaların koltuk altı lenf durumunu içeren klinik ve patolojik verileri, Yapay Zeka yöntemlerinden olan K-Means, Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi, Genetik Algoritma ve Yapay Sinir Ağları kullanılarak modeller oluşturulmuş ve meme kanseri lenf nodu durumu teşhisi için kullanılabilirliği analiz edilmiştir. Modellerin eğitimi için belirtilen yöntemler ile farklı iki hibrit model oluşturulmuştur. Farklı özelliklere sahip bu iki yöntemin verimliliğini görebilmek adına temel bir Yapay Sinir Ağı kullanılmıştır. Tıbbi olarak güvenilirliğini test etmek amacıyla bu çalışmada oluşturulan modellerin performanslarının karşılaştırılması tanı testleri ve ROC eğrisiyle ortaya konulmuştur.

Name and Surname : Kulilik SÜER
Adviser : Asst. Prof. Dr. Atınç YILMAZ
Degree and Date : Masters, 2019
Major : Computer Engineering
Keywords : Breast Cancer, Neural Networks, K-Means, Adaptive Neuro Fuzzy Inference System, Genetic Algorithm, Diagnostic Test, ROC

ABSTRACT

BREAST CANCER LYMPH NODE ANALYSIS USING ARTIFICIAL INTELLIGENCE

Despite the fact that the most frequent type of cancer in the world is lung cancer the most frequent type of cancer in women is breast cancer. In breast cancer, the stage of the disease and accordingly along with the analysis of many cases concerning the method of treatment method to be used, the posture of armpit lymph node is of importance. The existence of armpit lymph case increases the risk of metastasis to other organs of the body in breast cancer. This condition, which requires surgical procedures, makes the seriousness of the disease important. In this study, clinical and pathological data, including armpit lymph case gathered from breast cancer patients in İstanbul Gaziosmanpaşa Taksim Education and Research Hospital, models were built by using k-means which is an Artificial Intelligence method, Adaptive Neuro Fuzzy Inference System, Genetic Algorithm and Artificial Neural Networks and it was analyzed for the usability of diagnosis of breast cancer lymph case. Two different hybrid models were formed using specified methods for the training of the models. A basic artificial neural network was used in order to see the efficiencies of these two methods claiming different characteristics. In an attempt to test the medical authenticity, comparison of the performance models that were created in this study was introduced using diagnostic tests and ROC Curve.

İÇİNDEKİLER

	Sayfa No.
ÖZ.....	i
ABSTRACT.....	ii
TABLolar LİSTESİ	vi
ŞEKİLLER LİSTESİ	vii
KISALTMALAR	ix
GİRİŞ	1

BİRİNCİ BÖLÜM

MEME KANSERİ

1. MEME ANATOMİSİ	6
2. MEME KANSERİ TANIMI	6
3. MEME KANSERİNİN HİSTOLOJİK TİPLERİ	7
4. HİSTOLOJİK DERECELENDİRME SİSTEMİ	7
5. MEME KANSERİ EVLENDİRİLMESİ.....	9
6. HORMONAL RESEPTÖRLER	10
7. MEME KANSERİ TANI VE TEDAVİ	10

İKİNCİ BÖLÜM

YAPAY ZEKA

1. YAPAY ZEKA TANIMI.....	12
1.1. Yapay Sinir Ağları	13
1.1.1. Yapay Sinir Ağları' nın Yapısı.....	14
1.1.1.1. Biyolojik Sinir Hücresi	14
1.1.1.2. Yapay Sinir Hücresi.....	15
1.1.2. Yapay Sinir Ağı Modelleri	17
1.1.2.1. Tek Katmanlı Yapay Sinir Ağları	17
1.1.2.2. Çok Katmanlı Yapay Sinir Ağları	18
1.1.3. Yapay Sinir Ağları' nın Yapılarına Göre Sınıflandırılması	19
1.1.3.1. İleri Beslemeli Yapay Sinir Ağları	19

1.1.3.2. Geri Beslemeli Yapay Sinir Ağları	19
1.1.4. Yapay Sinir Ağları' nda Öğrenme	20
1.1.4.1. Danışmanlı Öğrenme	20
1.1.4.2. Danışmansız Öğrenme	20
1.1.4.2.1. K-Means	21
1.1.5. Geriye Yayılım Algoritması	21
1.1.6. Levenberg-Marquardt Algoritması	23
1.2. Bulanık Mantık	23
1.2.1. Üyelik Fonksiyonları	24
1.2.1.1. Üçgen Üyelik Fonksiyonu	24
1.2.1.2. Yamuk Üyelik Fonksiyonu	25
1.2.1.3. Gaussian Üyelik Fonksiyonu	25
1.2.1.4. Genelleştirilmiş Çan Eğrisi Üyelik Fonksiyonu	25
1.2.1.5. Sigmoid Üyelik Fonksiyonu	26
1.3. Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi (ANFIS)	26
1.3.1. ANFIS Yapısı ve İşleyişi	27
1.3.2. ANFIS Modeli	29
1.3.3. ANFIS Öğrenme Algoritması	30
1.4. Genetik Algoritma	30
1.4.1. Genetik Algoritma Adımları	32
1.4.1.1. Başlangıç Popülasyonunun Oluşturulması	32
1.4.1.2. Uygunluk Değeri (Amaç Fonksiyonu)	32
1.4.1.3. Seçim	32
1.4.1.3.1. Rulet Çemberi Seçim Yöntemi	33
1.4.1.4. Çaprazlama	33
1.4.1.4.1. Tek Nokta Çaprazlama Yöntemi	33
1.4.1.4.2. İki Nokta Çaprazlama	34
1.4.1.5. Mutasyon	35
1.4.1.5.1. Gauss Mutasyonu	35
1.4.1.6. Durdurma	35
1.4.1.7. Elitizm Stratejisi	35

ÜÇÜNCÜ BÖLÜM ÖNERİLEN MODELLER

1. ÖNERİLEN MODELLER VE UYGULAMALARI	36
1.1. KG-ANFIS Modeli.....	38
1.1.1. KG-ANFIS Modeli ve Uygulaması.....	39
1.2. AG-ANFIS Modeli.....	49
1.2.1. AG-ANFIS Modeli ve Uygulaması.....	50
1.3. YSA Modeli	58
1.3.1. YSA Modeli ve Uygulaması	58
2. ÖNERİLEN YÖNTEMLERİN KARŞILAŞTIRILMASI	60
2.1. YSA Modeli Karşılaştırılması.....	62
2.2. KG-ANFIS Modeli Karşılaştırılması	64
2.3. AG-ANFIS Modeli Karşılaştırılması	65
SONUÇ	67
KAYNAKÇA	69
EKLER	75
Ek 1: AG-ANFIS Modeli İçin EĞER – İSE Kural Görünümü	75

TABLULAR LİSTESİ

	Sayfa No.
Tablo 1. Meme Kanserinde Histolojik Derecelendirme	8
Tablo 2. Çalışmada Kullanılacak Veri Setinin Özellikleri.....	37
Tablo 3: Kümelere Ait Parametre İsimleri.....	39
Tablo 4: 1. ve 2. Kümenin Genetik Algoritmada Kullanılan Parametreleri	40
Tablo 5: 1.ve 2. Kümenin Uygunluk Fonksiyonu Değerleri ve Optimize Eden Parametre Değerleri.....	44
Tablo 6. KG-ANFIS Modeli için Diğer Üyelik Fonksiyon Değerleri	48
Tablo 7. Verimli Bulunan 6 Parametrenin Eğitim ve Test Datalarının RMSE Değerleri	54
Tablo 8. AG-ANFIS Modeli için Diğer Üyelik Fonksiyon Değerleri	57
Tablo 9. Man Whitney U Test Sonuçları	60
Tablo 10. Tanı Testi İçin Sınıflandırma Modeli	61
Tablo 11. YSA Modelinin Pearson Ki-Kare Test Sonuçları.....	63
Tablo 12. KG-ANFIS Modelinin Pearson Ki-Kare Test Sonuçları	64
Tablo 13. AG-ANFIS Modelinin Pearson Ki-Kare Test	66
Tablo 14. Tanı Testi ve ROC Eğrisi Sonuçları	66

ŞEKİLLER LİSTESİ

	Sayfa No.
Şekil 1. Biyolojik Sinir Hücresi.....	15
Şekil 2. Yapay Sinir Hücresi	15
Şekil 3. Tangent – Sigmoid	17
Şekil 4. Tek Katmanlı Yapay Sinir Ağları	18
Şekil 5. Çok Katmanlı Yapay Sinir Ağları	19
Şekil 6. ANFIS Yapısı	27
Şekil 7: Tek Nokta Çaprazlama.....	34
Şekil 8: İki Nokta Çaprazlama	34
Şekil 9: KG-ANFIS Modeli	38
Şekil 10: 1. Küme GA Grafıksel Sonuları	44
Şekil 11: 2. Küme GA Grafıksel Sonuları	45
Şekil 12: KG-ANFIS Modelinde ANFIS Eđitiminin Hata Grafiđi	45
Şekil 13: KG-ANFS Modeli iin Eđitilen ANFIS Eđitim Datası ile Gerek Sonularının Karşılaştıırılması	46
Şekil 14: KG-ANFS Modeli iin Eđitilen ANFIS Test Datası ile Gerek Sonularının Karşılaştıırılması	46
Şekil 15. KG-ANFIS Modelinin Sugeno Bulanık ıkarım Sistemi.....	47
Şekil 16. KG-ANFS Modeli iin Girdi Parametrelerin Üyelik Fonksiyon Gösterimi	47
Şekil 17. KG-ANFIS Modeli İin EĐER – İSE Kural Görünümü.....	49
Şekil 18. AG-ANFIS Modeli.....	49
Şekil 19. 1. Aşama Tek girdi kombinasyonu hata düzeyi	51
Şekil 20. 1. Aşama İki Girdi Kombinasyonu Hata Düzeyi	52
Şekil 21. 1. Aşama Ü Girdi Kombinasyonu Hata Düzeyi	52
Şekil 22. 2. Aşama Ü Girdi Kombinasyonu Hata Düzeyi	53
Şekil 23. AG-ANFIS Modelinde ANFIS Eđitiminin Hata Grafiđi	54
Şekil 24. AG-ANFS Modeli iin Eđitilen ANFIS Eđitim Datası ile Gerek Sonularının Karşılaştıırılması	55
Şekil 25. AG-ANFS Modeli iin Eđitilen ANFIS Test Datası ile Gerek Sonularının Karşılaştıırılması	55

Şekil 26. AG-ANFIS Modelinin Sugeno Bulanık Çıkarım Sistemi.....	56
Şekil 27. AG-ANFS Modeli için Girdi Parametrelerin Üyelik Fonksiyon Gösterimi.....	57
Şekil 28. YSA Modeli	58
Şekil 29. Tansig Algoritması ile Mse Hata Performansı için Regresyon Analizi	59
Şekil 30. YSA Modelinin ROC eğrisi	63
Şekil 31. KG-ANFIS Modelinin ROC eğrisi.....	64
Şekil 32. AG-ANFIS Modelinin ROC Eğrisi.....	65



KISALTMALAR

ALGA	: Artırılmış Lagrangian Genetik Algoritma
ANFIS	: Adaptive Neuro Fuzzy Inference System
ART	: Adaptif Rezonans Teorisi
DCIS	: Duktal Karsinom In Situ
ER	: Östrojen Reseptör
GA	: Genetik Algoritma
LCIS	: Lobüler Karsinom In Situ
OBJFUN	: Objective Function
PR	: Progesteron Reseptör
ROC	: Receiver Operating Characteristic
SOM	: Self Organizing Map
SPSS	: Statistical Cruncher Package For The Social Sciences
TNM	: Tümör – Nod – Metastaz
WHO	: Dünya Sağlık Örgütü
YSA	: Yapay Sinir Ağları

GİRİŞ

Yapay Zeka; bilgisayarlara ve bilgisayar destekli veya denetimli makinalara, insana özgü yetiler olarak varsayılan mana çıkarma, akıl yürütme, yargı, karar verme ve insanın en önemli özelliklerinden olan öğrenme gibi yeteneklerin kazandırılmasıdır. Yapay Zeka arařtırmalarının amacı da bu dođrultuda insan zekasına gereksinim duyulacak sistemlerin oluřturulmasıdır.

Bu alıřmada deđinilen ve kullanılan Yapay Zeka yontemlerinin bařlıcaları; Bulanık Mantık, Yapay Sinir Ađları, Uyarlamalı Sinirsel Bulanık ıkarım Sistemi ve Genetik Algoritmadır. Gnlk hayatta karřılařılan problemlerin belirsizlik iermesi ile özm yolu zorlařmaktadır. Bulanık Mantık' da gerek dnyada kesin olmayan yargılara kesin özmler bulabilmek adına, insanların bu gibi durumlar iin kullandıkları "EĐER – İSE" ihtimalleriyle sistemlere farklı kural tabanları oluřturarak makinalara karar verme yeteneđinin kazandırılmasıdır. Yapay Sinir Ađları ise makinaları biyolojik sinir ađı gibi modelleyebilmektir. Bu yontem ađa verilen bilgiler ile ezberlemek yerine insan beyni gibi ğrenebilme yetisine sahiptir ve bu dođrultuda yeni bilgiler retilen, hesaplama, sınıflandırma ve tahmin yapabilme gibi yetenekleri barındırmaktadır. Bulanık Mantık ve Yapay Sinir Ađları' nın özelliklerini veya yeteneklerini bir modelde toplayan yontem ise Uyarlamalı Sinirsel Bulanık ıkarım Sistemi' dir. Melez bir model olan bu yontem, diđer iki yontemin özelliklerine sahip glü bir yapıdır. Sezgisel bir yontem olan Genetik Algoritma ise dođadaki evrimsel sreci temel alan bir optimizasyon algoritmasıdır.

Gnmzde; teknoloji ve bilim dnyasının ortaklařa alıřmasıyla, Yapay Zeka' nın kullanım alanları artıř gstermektedir. Askeri alanda hedef tespiti, endstriyel alanda retim, robotlar, bilgisayar oyunları, mřteri davranıřları-eđilimleri, finansal, gvenlik, uzay ve mhendislik konuları gibi alanlarda kullanılmasının yanında tıp alanında da kendini gstermektedir.

Kompleks verileri analiz edebilme yeteneğine sahip olan Yapay Zeka, tıp alanında verileri anlamlı bir şekilde ilişkilendirebilme, tıbbi görüntüleri işleyebilme, bulanık olan kavramları anlamlandırıp sınıflayabilme gibi yeteneklerle bir çok tanı ve klinik teşhis işlemlerini gerçekleştirebilecek, sonucu tahmin edebilecek, tedavi yöntemlerine önerebilecek model veya modeller oluşturmak için kullanılmaktadır.

Tıp dünyasında kanser hastalığının sebebinin tam olarak kesin olmaması ve ölüm oranlarının fazla olması nedeniyle üzerinde en çok araştırmalar yapılan hastalıklardan biridir. Dünya’ da en çok görülen kanser türlerinden olan akciğer kanseri olmasıyla beraber kadınlarda en çok görülen kanser türü ise meme kanseridir.

Meme kanserinde, hastalığın evresi ve buna bağlı olarak hangi tedavi yönteminin kullanılacağı konusunda birçok olgunun analiz edilmesinin yanında koltuk altı lenf nodu durumu önem taşımaktadır. Bunun sebebi tümörün koltuk altı lenf bezinde bulunması, tümörün vücuttaki diğer organlara yayılım olma ihtimalini arttırmasıdır. Meme kanserinin yayılmadan önce erken teşhis edilmesi hastanın yaşam şansını büyük oranda arttırmaktadır.

Yapay Zeka yöntemleri ile yapılmış meme kanseri ve meme kanseri lenf nodu ile ilgili yapılan benzer incelenmiştir.

K. Şentürk ve ark., 2016 yılında El-Cezeri Fen ve Mühendislik Dergisi’ nde yayınladıkları 699 iyi huylu ve kötü huylu meme kanseri hasta verileri ile Yapay Sinir Ağı üzerinde çalışmıştır. Yapılan çalışmada 699 hastanın, 199’ u ile ağ test edilmiş ve başarı oranı %77 olarak bulunmuştur (Şentürk ve Şentürk 2016).

Yıldız, 2012 yılında yapmış olduğu çalışmada meme kanseri hastalığında etkin olan genlerin belirlenmesi üzerine bir metot önermiştir. Hibrit bir model olan çalışma, gen ifade verileri Filtreleme Yöntemi ile daraltılmış ve meme kanserinde etkin olan genler Genetik Algoritma ile %96,15 oranında başarıyla tespit edilmiştir (Yıldız 2012).

Karakış, 2009 yılında koltuk altı lenf nodu durumunu tespit etmek amacıyla yapılan çalışmada Yapay Sinir Ağı modeli oluşturmuştur. Duyarlılık değeri %73 ve belirlilik değeri %90 olarak bulunan ağ, 12 veri ile oluşturulmuş ve ağın duyarlılık değeri %50 oranında ve belirlilik değeri %96 oranında bulunmuştur (Karakış 2009).

Lancashire ve ark., yapmış olduğu çalışmada, Geri Yayılımlı Sinir Ağı'yla gerçekleştirdiği yapıda koltuk altı lenf düğümlerinin tespiti için gen ekspresyon mikro dizi veri bilgilerini kullanmıştır. Ağ, %100 doğruluk oranları ile koltuk altı lenf düğümü ve ER (östrojen reseptör) durumunu belirlemiştir (Lancashire, ve diğerleri 2008).

Alharbi ve ark., 2016 yılında yapmış olduğu çalışmada, meme kanseri teşhisi için Bulanık Tabanlı Sistemler ve Genetik Algoritma'yı kullanarak hibrit bir model geliştirmiştir. Yapılan çalışmalar üzerine %97,33 ile doğruluk oranı ve %91 ile güven oranı tespit edilmiştir (Alharbi, Tchier ve Rashidi 2016).

Sepandi ve ark., 2017 yılındaki çalışması, mamografi sonuçları, risk faktörlerini ve klinik bulguları içeren veri seti ile hastalarda meme kanseri olasılığını Yapay Sinir Ağı ile teşhis etme üzerinedir. Yapılan çalışmada; AUC, duyarlılık, özgüllük, negatif ve pozitif tahmin değerleri sırasıyla 0,955, 0,82, 0,90, 0,90 ve 0,80 olarak tespit edilmiştir (Sepandi, ve diğerleri 2017).

Aalaei ve ark., 2016 yılında yayınladığı çalışmada meme kanseri teşhisi için özellik seçimini ele alınmaktadır. Özellik seçim etkinliğini değerlendirmek amacıyla Yapay Sinir Ağları, PS Sınıflandırıcı ve Genetik Algoritma tabanlı sınıflandırma yaklaşımlarıyla 3 farklı sınıflandırıcı kullanılmıştır. En iyi sınıflandırma %96,6 doğruluk oranıyla PS sınıflandırıcı olarak tespit edilmiştir (Aalaei, ve diğerleri 2016).

Zadeh ve ark., 2011 yılında yayınladıkları termal kameralar ile hasta görüntüleri alınmıştır. Genetik Algoritma yardımı ile önemli parametreler elde

edilmiştir. Bulanık Sinirsel Ağlar' da önemli bileşenler kümelenmiş meme kanseri için tanımlanmıştır ve yapılan analizler sonucu özgüllük oranı %97 oranında, duyarlılık oranı ise %93 oranında tespit edilmiştir (Zadeh, ve diğerleri 2011).

Alhasadi, 2016 yılında yapmış olduğu çalışmada meme kanseri tahmini için genelleştirilmiş Regresyon Sinir Ağı, Çok Katmanlı Perceptron ve Destek Vektör Makinesi yöntemleri yapılan analizler ile karşılaştırılmış ve Genelleştirilmiş Regresyon Sinir Ağı %79,9 oranı ile en iyi sonucu vermiştir (Alhasadi 2016).

Belciug ve ark., 2013 yılında yayınlamış olduğu çalışmada Genetik Algoritma ve Yapay Sinir Ağları kullanılmıştır. Ağırlıkları için Genetik Algoritma kullanılarak Çok Katmanlı Algılayıcı tasarlanan çalışmada kanser tespiti ve nük için dört farklı veri tabanı üzerinde tespitler yapılmıştır. Yapılan tespitler sonucu tasarlanan model standart sinir ağları ile karşılaştırıldığında daha başarı sonuçlar elde edildiği gözlenmiştir (Belciug ve Gorunescu 2013).

Karakış ve ark., 2013 yılında yayınladıkları çalışmada Çok Katmanlı Yapay Sinir Ağı ve Genetik Algoritma kullanılarak hibrit bir model önerilmiştir. Önerilen model ile Lojistik Regresyon Analizi doğruluk oranları karşılaştırıldığında, Lojistik Regresyon modelinin özgüllük ve doğruluk oranları sırası ile %86,1 ve %74,1, önerilen modelin özgüllük ve doğruluk oranları ise %96,565 ve %98,478 olarak tespit edilmiştir (Karakış, Tez, ve diğerleri 2013).

Balanica ve ark., Bulanık Mantık Yöntemi ile meme kanseri riski üzerinde çalışmıştır. Mamdani Tipi Bulanık Sistem kullanılan çalışmada klinik bulgulara ağırlık verilmiştir (Balanica, ve diğerleri 2011).

Caramihai ve ark., tarafından yapılan çalışmada meme kanseri risk değerlendirilmesi için Bulanık Mantık metodu kullanılmıştır. Kurallar içerisinde meme görüntüleme veri sistemi ağırlıklı giriş olarak hazırlanmıştır (Caramihai, ve diğerleri 2010).

Yılmaz, 2015 yılında yapmış olduğu çalışmada, kolon kanseri, meme kanseri ve prostat kanserlerinin risk durumları için Uyarlamalı Sinirsel Bulanık Sistemi (ANFIS), Einstein çarpımı tabanlı ANFIS, önerilen Değiştirilmiş Einstein Çarpımı Tabanlı ANFIS olmak üzere üç farklı yöntem kullanılmıştır. Yapılan çalışmalar ROC analizi ile kıyaslanmıştır (Yılmaz 2015).

Bu çalışmada, Yapay Zeka' nın farklı yöntemleri ile oluşturulan 3 ayrı modelin meme kanseri lenf nodu (bezi) durumunun teşhisi için kullanılabilirliği analiz edilecektir. Bu çalışmanın amacı, meme kanserli hastaların koltuk altındaki lenf bezlerinin durumunun ameliyat öncesi standart klinik ve patolojik verilerin Yapay Zeka yöntemleriyle oluşturulan modellerde belirlenmesi ve modellerin karşılaştırılmasıdır. Böylelikle hastalığın ameliyat öncesi evrelemesi daha doğru yapıpı hastanın en uygun tedaviyi almasına katkı sağlamaktır.

Giriş ve sonuç ile birlikte beş bölümden oluşan bu çalışma; giriş bölümünde, çalışmada ele alınan konular hakkında ön bilgi verilmiş ve çalışmanın amacı belirtilmiştir. Ayrıca bu bölümde benzer çalışmalar ele alınmıştır. Birinci bölüm, meme kanseri ve çalışmayı etkileyecek özelliklerin ele alınmasıdır. İkinci bölümde, Yapay Zeka' nın çalışmada kullanacak yöntemleri detaylandırılacaktır ve üçüncü bölümde ise çalışma için önerilecek modeller ile bu modellerin uygulamaları ele alınacak ve sonuçların karşılaştırılması yapılacaktır. Son kısım olan sonuç bölümünü, yapılan çalışmanın sonuçları ile beraber araştırmanın bütünsel olarak ele alınması oluşturacaktır.

BİRİNCİ BÖLÜM

MEME KANSERİ

1. MEME ANATOMİSİ

Memeler, göğüs kafesinin önünde, kas ve kemikten oluşan destekleyici bir sistemin üzerinde yerleşmiştir (Civcık 2013). Yağ dokusu, süt bezleri, süt kanalları, sinirler, kan ve lenf damarları memeyi oluşturan öğelerdir. Süt bezleri, her birine "Lob" adı verilen gruplar oluşturmaktadır ve her bir lob meme başına süt kanalları ile bağlanmaktadır. Süt taşıyan bu kanallara "Duktus" adı verilir.

2. MEME KANSERİ TANIMI

Kanser, hücre genomunda edinilmiş ya da doğuştan gelen değişiklikler sonucu oluşan kontrolsüz hücre çoğalması olarak tanımlanabilir. Kanserler, meydana geldikleri organın ötesine yayılım yapma (metastaz) eğilimindedir. Metastatik yayılım kabaca iki şekilde olmaktadır. Kanserli hücrelerin lenf kanallarına ulaşması ve lenf kanallarıyla yayılım (lenfatik yayılım) ve kanserli hücrelerin kan damarlarına ulaşarak kan damarlarını kullanarak başka bölgelere yayılması (hematojen yayılım) durumlarıdır. Meme de bulunan tek bir hücrenin kanserleşmesiyle de meme kanseri başlamaktadır.

Meme kanseri hücreleri, lenf sisteminde göğüsün yan tarafında bulunan lenf bezlerine yayılım gösterebilir ve yayılan kanserli hücreler kan yoluyla diğer organlara da yayılabilir. Yayılım gösteren kanserin oluşturduğu ve doktorlar tarafından 'metastatik hastalık' veya 'uzak' olarak adlandırılan yeni tümör, gelen kanserli hücrenin özelliğini taşır ve hastalığın aynı adını alır (Demirel 2008).

3. MEME KANSERİNİN HİSTOLOJİK TİPLERİ

Histolojik tiplerin ya da türlerin meme kanseri süreçlerinde önemli bilgiler vermektedir. Çünkü tümörün farklı özellikleri değerlendirildiğinde, hastalığın seyrini ve tedaviyi belirlemede büyük önem taşımaktadır.

Dünya Sağlık Örgütü'nün (WHO) sınıflandırması en çok kullanılan histopatolojik sınıflandırma sistemidir. Bu sınıflandırma sistemini, invaziv duktal karsinom vakaların %80' ini ve invaziv lobüler karsinom ise %10'unu oluşturmaktadır ((Çavuşoğlu) 2015).

İnvaziv duktal karsinom, en yaygın meme hastalıklarından olan bu histolojik tip, süt kanallarından çevre dokuya yayılan tümörü temsil etmektedir.

İnvaziv lobüler karsinom, bir bölgeyi işgal etme ve daha yapışkan olma özelliğini göstermektedir (Yılmaz. S 2015). Süt bezlerinden çevre dokuya yayılan tümörü temsil etmektedir.

4. HİSTOLOJİK DERECELENDİRME SİSTEMİ

Patologlar, genellikle hastalara ait kanserli tümörlere histolojik derecelendirmeler yaparlar. Bunun nedeni tümörün tipini tespit etmektir ve meme kanserinin tedavisine yön vermek amacıyla, günümüzde yaygın olarak kullanılan Scarff – Bloom – Richardson sistemi kullanılmaktadır. Scarff – Bloom – Richardson sisteminde borsal yapılar meydana getiren kanser hücrelerinin yapısı, hücrenin büyüklüğündeki değişimler ve hücrenin bölünme hızı özelliklerine dikkat edilir. Bu özelliklere 1 ila 3 değerleri arasında puanlar verilerek, sonuçlar toplanır ve derecelendirme yapılır (<https://map2heal.com/guide/histolojik-derecelendirme-sistemi-nedir-905>, E.T.: 10.01.2019).

Borusal Yapılar İçinde Bulunan Kanser Hücrelerinin Yüzdesi	Puan
%75' daha fazla	1
%10 - %70 arasında	2
%10' dan daha az	3

Hücre Yapısında ve Şeklinde Olan Değişikler

Küçük düzgün hücreler	1
Normal hücrelerden boy ve yapıda orta ölçekli farklılaşma	2
Belirgin farklılaşma	3

Hücre Bölünmesi

7' ye kadar	1
8 – 14 arası	2
15 veya daha fazla	3

Yapılan puanlama ile toplam sonuçların derecelendirilmeleri ve bu derecelerin isimleri Tablo 1' de gösterilmektedir.

Tablo 1. Meme Kanserinde Histolojik Derecelendirme

Derece (Grade)	Tanımlama	Puanlar	Derece İsimleri
1	Hücreler hızlı bölünmez, normal görünürler ve küçük tüp benzeri yapılar oluşturmaktadırlar.	3, 4, 5	İyi Diferansiye (İyi Farklılaşma)
2	1.derece ve 2.derece arasında özelliklere sahiptirler	6, 7	Orta Diferansiye (Orta Farklılaşma)
3	Hücreler normal görünmemekle birlikte, normal hücrelere göre daha hızlı bölünmekte ve büyümektedirler.	8, 9	Kötü Diferansiye (Kötü Farklılaşma)

Kaynak: Karakış, Rukiye. «Yapay Sinir Ağları ve Lojistik Regresyon Yöntemleri ile Meme Kanseri Koltuk Altı Lenf Nodu Durumunun Belirlenmesi.» *Yüksek Lisans Tezi*. Ankara: Gazi Üniversitesi, 2009.

5. MEME KANSERİ EVLENDİRİLMESİ

Meme kanseri evrelendirilmesi, tümörde yayılım olup olmamasına ve yayılım varsa ne kadar olduğunu belirlemek için yapılan işlemlerdir. Bu evrelendirme, hastalığın tedavisi ve ciddiyeti hususlarında yardımcı olmaktadır (<https://www.cancer.org/cancer/breast-cancer/understanding-a-breast-cancer-diagnosis/stages-of-breast-cancer.html>, E.T.: 29.10.2018)

Ortalama 5 ila 7 yıl içerisinde 1 cm boyuna ulaşan tümör; ilk olarak koltuk altı lenf bezlerine lenf kanalları ile yayılır. Daha sonra karaciğer ve kemik gibi organlara kan yoluyla yayılım göstermektedir (http://www.onkoloji.gov.tr./index.php?option=com_content&view=article&id=7339:meme-kanseri&catid=303:kanser-tuerleri&Itemid=1104, E.T.: 5.10.2018).

Meme kanseri evrenmesi, TNM (Tümör, Düğüm, Metastaz) yöntemi ile yapılmaktadır. TNM, kanserin nasıl görüldüğü ve nasıl davrandığı hakkında daha fazla ayrıntı sağlamak için araştırmacıların kullandıkları bir evreleme sistemidir (<https://www.cancer.org/cancer/breast-cancer/understanding-a-breast-cancer-diagnosis/stages-of-breast-cancer.html>, E.T.: 29.10.2018), (<https://www.breastcancer.org/symptoms/diagnosis/staging#stage0>, E.T.: 29.10.2018)

T (boyut) kategorisi, orijinal (birincil) tümörü tanımlar.

TX : Bulunamayan veya değerlendirilemeyen birincil (primer) tümör.

T0 : Birincil tümöre ait herhangi bir bulgunun olmaması.

Tis : Karsinoma in situ (DCIS (Duktal karsinom in situ), LCIS (Lobuler karsinom in situ) veya ilişkili tümör kitlesi olmayan meme ucunun paget hastalığı).

T1: T1a, T1b ve T1c içermektedir. Tümörün en büyük çapı 2 cm veya daha azdır.

T2: Tümör çapının 2 ila 5 arasındadır.

T3: Tümörün çapı 5 cm' den büyüktür.

T4: T4a, T4b, T4c ve T4d içermektedir. Cilde veya göğüs duvarına yayılım gösteren herhangi bir boyuttaki tümördür.

N (lenf nodu tutulumu) kategorisi, kanserin yakındaki lenf nodlarına ulaşım ulaşmadığını açıklar.

NX: Yakındaki lenf düğümlerinin değerlendirilememesi (örneğin, daha önce çıkarılması).

N0: Yakındaki lenf düğümlerinin kanserli olmaması.

N1, N2, N3: Bu değerler ilgili lenf nodlarının sayısını ve bunların ne kadar kanser bulunduklarına dair bilgi verir. Değerler arttıkça lenf nodu tutulumunun derecesi artmaktadır.

M (metastaz) kategorisi, kanserin vücutdaki diğer organlarına ulaşım ulaşmadığı yönünde bilgi vermesidir.

MX: Bulunamayan veya değerlendirilemeyen uzak metastaz.

M1: Uzak metastaz yok.

M2: Uzak metastaz var.

6. HORMONAL RESEPTÖRLER

Meme dokusunda östrojen hormonun bağlandığı yapıya östrojen (ER) reseptör ve progesteron hormonuna bağlanan yapıya ise progesteron (PR) reseptörleri denir. Meme kanserinde hormonal tedaviye cevap verme olasılığı bu iki hormonal reseptörlere bağlıdır (Badowska-Kozakiewicz, ve diğerleri 2015). ER ve PR' nin pozitif yani var olması durumu farklı tedavi seçeneklerini ortaya çıkarmaktadır.

7. MEME KANSERİ TANI VE TEDAVİ

Meme kanseri tedavisinde, hastaların genel sağlık durumu, kanserin geri oluşma riski, hastanın özellikleri gibi konular dikkatte alınarak birçok tanı ve tedavi yöntemleri uygulanmaktadır.

Tedavi için radyoterapi, kemoterapi, cerrahi yöntemler, biyolojik yöntemler ve hormon terapisi gibi farklı tedavi yaklaşımları bulunmaktadır.

Cerrahi yöntemlerden olan lenf bezi cerrahisinde, koltuk altı lenf bezlerinin incelenmesi tedavinin şeklini, bu doğrultuda tedavinin doğuracağı sonuçların ve kanserin evrelendirilmesi konusunda büyük önem taşımaktadır. Meme kanserinin koltuk altı lenf durumlarının belirlenmesi için birçok lenf bezi alınarak mikroskopla incelenir ve kanserli hücrelerinin lenf bezlerinde bulunması durumunda hastalığın kan dolaşımı ile vücudun diğer bölgelerine yayılmış olma olasılığını arttırmaktadır. Koltuk altı lenf bezlerinde bulunan bu kanserli hücreler, nasıl bir tedavi uygulanması gerektiği hakkında önemli rol oynar (<https://www.memorial.com.tr/meme-kanseri/>, E.T.: 13.01.2019).



İKİNCİ BÖLÜM

YAPAY ZEKA

1. YAPAY ZEKA TANIMI

Bilgisayarlar, insanlara göre karmaşık sayısal işlemleri çok hızlı çözebilmesine rağmen; insan beyni gibi, kavramlar arasındaki bağı yorumlayabilme, karar verebilme, gözlem ve öğrenme yoluyla bilgileri anlama ve kullanabilme yetilerine sahip değildir. Dolayısıyla insan beyni ve bilgisayarları karşılaştırdığımızda insan beynin daha üstün çıkmasının temelinde tecrübe ve deneyimle sorunları veya problemleri verilerin konularına göre analiz edebilmesi yatmaktadır. Yapay Zeka bu noktada devreye girerek bilgisayar sistemlerine insana özgü yetenekleri kazandırmaktadır. Bu yetenekler ile insan gibi önceden edinilmiş tecrübeler ile öğrenebilme, karar verebilme gibi yetilerini kazandırarak bilgisayar sistemlerini modellemektedir.

İnsana özgü yetiler olarak varsayılan yargı, mana çıkarma, fikir üretme ve akıl yürütme gibi yeteneklerin bilgisayarlara ve bilgisayar destekli veya denetimli makinalara bu yeteneklerin kazandırılması olarak tanımlanabilir.

Yapay zekanın amacı, bilgisayar denetimli makinalara insan zekasına ihtiyaç duyulan durumlardaki görevleri yerine getirebilen yetiler kazandırmak ve bu makineleri yapmaktır. Genel anlamda, doğal zekaya ihtiyaç duyulan ve gerektiren fonksiyonları yapabilecek sistemin oluşturulması olarak da niteleyebiliriz.

Bu durumda yapay zeka ve doğal zekayı karşılaştırmak gerekirse; doğal zeka için bilgi aktarımı yapay zekaya göre oldukça zaman alır ve işlemler daha zordur. Bununla birlikte bu verileri raporlama, belgelendirme ve sınıflandırma gibi analiz sonuçları makinelerde depolandığından daha kalıcı olmaktadır. Doğal zekanın deneyim ve tecrübe kazanmak için ihtiyaç duyulan eğitimlerden geçmesi Yapay Zeka'ya göre daha zor ve zaman almaktadır. Ayrıca doğal zeka edindiği bilgileri şahsi ve duygusal alanda karar verme yetisine sahip olduğu için karşılaşılan problemlerde farklı

tepkiler ve sonuçlar gözlemlenir. Bu sebeple yapay zeka, çıkardığı sonuçlarda daha istikrarlı ve kararlı olduğu için doğal zekaya göre daha tutarlıdır. Yapay Zeka' nın amacı doğal zekanın en önemli özeliği olan öğrenme yoluyla deneyimlerini hemen kullanabilme avantajını makinelerde sembollerle bu yetiyi çalışmaktır (Yılmaz 2017).

Mc Culloch ve Pitts, Yapay Zeka konusundaki ilk çalışmaları yapmıştır (Yılmaz 2015). Bu bilim adamlarının önerdiği çalışma, yapay sinir hücrelerinden yola çıkarak hesaplama modeli, önermeler mantığı, fizyoloji ve Turing'in hesaplama kuramına dayanmaktaydı. Bu çalışmada herhangi bir hesaplanabilir fonksiyonun, oluşan sinir hücrelerindeki ağlarla çözümlenebileceği ve mantıksal “ve” ve “veya” işlemlerinin oluşabileceği ya da gerçekleştirebileceğini ispatladılar. Bu ağ yapılarının en kullanabilir tanımları durumunda öğrenme yetisi kazanabileceğini de savundular. Hebb sayesinde sinir hücreleri arasındaki etkileşimlerini farklılaştırmak için daha basit bir kural önerince, öğrenebilen yapay sinir ağlarını mümkün kılmakta sağlanmıştı (Hebb 1949).

1.1. Yapay Sinir Ağları

Bilgisayarlar insanlara göre karmaşık problemlere daha güçlü ve daha hızlı çözümler üretebilmektedir. Fakat insanın en önemli yeteneği olan öğrenme gücünden yoksundur. Yapay Zeka yöntemlerinden biri olan Yapay Sinir Ağları (YSA) ile bilgisayarlara veya makinelere bu yeteneği kazandıran bilgisayar tabanlı bir sistemdir. İnsan beynin öğrenme ve deneyimler yoluyla kazandığı bilgilerle çözüm ve yeni fikirler üretebilmesi, tahmin yürütebilmesi gibi yeteneklerini baz alarak modellenen YSA insan beynini taklit eder. Dolayısıyla farklı birçok konuların çözümlenmesinde kolaylık sağlamaktadır.

YSA insan beyni gibi, tecrübeler ve deneyimlerle öğrenme yeteneğine sahip olması tahmin edebilme özelliğini de beraberinde getirmekte ve bilgiler arasındaki karmaşık bağlantıları çözümlenebilmektedir.

İşlevsel olarak yapay sinir ağları, insan beyninin; öğrenme, sınıflandırma, genelleme, analiz ve ilişkilendirme gibi özelliklerini içeren konularda kullanılmaktadır (Yavuz ve Deveci 2012).

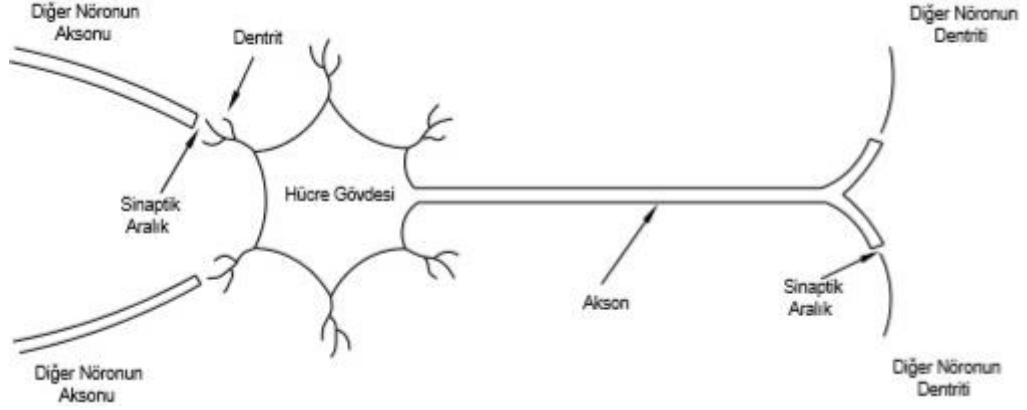
YSA' nın öğrenme yeteneği olması birçok uzmanlar tarafından cazip gelmektedir. Çünkü YSA' nın öğrenme başta olmak üzere sahip olduğu çoğu özellik klasik sistemlere göre avantaj ve üstünlükler sağlamıştır.

1.1.1. Yapay Sinir Ağları' nın Yapısı

1.1.1.1. Biyolojik Sinir Hücresi

Yapay sinir hücresi, biyolojik sinir hücresinden esinlenerek tasarlanan bir yapıya sahiptir. Biyolojik sinir sistemi, insan beyninde bilgiyi alan, aldığı bilgileri işleyerek yorumlayan ve bu doğrultuda elverişli bilgiler veya kararlar meydana getiren bir merkezdir. Sinir sisteminin esas birimi olan nöron olarak adlandırılan sinir hücreleri; hücre gövdesi, dendrit ve akson olarak üç temel ögeden oluşmaktadır.

Soma denilen hücre gövdesi, sinir hücrelerinin işleyişini takip eder ve hücrelerin kontrolünden sorumludur. Dendrit ve akson olmak üzere iki uzantıya sahip olan hücre gövdesi hücrelerin bütün etkinliklerini idare etmektedir. Dendrit iç yapısı olarak, sinir gövdesiyle aynıdır ve bir nöronda birden çok olabilmektedir. Sinir hücresinin sonlarında bulunan dendrit, diğer sinir hücrelerinde aldığı bilgilerini kendi sinir hücre gövdesine iletmekle görevlidir. Hücre gövdesi dendritten aldığı bilgileri toplar ve diğer sinir hücrelerine iletilmesini sağlanması amacıyla aksone gönderir. Akson hücre gövdesinden gelen bilgileri diğer sinir hücrelerine iletir ve her nöron da birer tane bulunmaktadır. Akson, diğer sinir hücrelerinin dendritlerine sinaps adı verilen bağlantı noktaları ile bağlanmaktadır. Sinapsın görevi, aksondan aldığı bilgileri diğer nöronların dendritlerine ilemesidir (Yılmaz 2017), (Sağiroğlu, Beşdok ve Erler 2003). Şekil 1' de biyolojik sinir hücresinin yapısı gösterilmektedir.




Şekil 1. Biyolojik Sinir Hücresi

Kaynak: Karakiş, Rukiye. «Yapay Sinir Ağları ve Lojistik Regresyon Yöntemleri ile Meme Kanseri Koltuk Altı Lenf Nodu Durumunun Belirlenmesi.» *Yüksek Lisans Tezi*. Ankara: Gazi Üniversitesi, 2009.

1.1.1.2. Yapay Sinir Hücresi

Biyolojik sinir sisteminden tasarlanan yapay sinir sistemi de birbiriyle bağlantılı bir yapıya sahiptir. Yapay sinir hücreleri (yapay nöronlar), oluşturdukları bağlantılarla YSA'nın yapısı oluşturmaktadır. Şekil 2' de yapay sinir hücresinin yapısı gösterilmektedir.



Şekil 2. Yapay Sinir Hücresi

Kaynak: Psikolojik.gen.tr. *Yapay Sinir Ağları*. <https://www.psikolojik.gen.tr/yapay-sinir-aglari.html> (erişildi: Ocak 5, 2019).

Proses elemanlar olarak isimlendirilen yapay sinir hücrelerinin 5 temel elemanı bulunmaktadır. Her bir yapay sinir hücrelerinin dışarıdan gelen bilgileri alan girdileri, gelen bilgileri işleyen ve bağlantıları oluşturan ağırlıklar, toplama fonksiyonu ve aktivasyon fonksiyonu, işlenen bilgileri dış dünyaya sunan çıktıları veya çıktı elemanları vardır. Bu elemanlar açıklamalarıyla birlikte aşağıdakiler gibidir.

Girdiler;

Diğer hücrelerden veya dış dünyadan gelen bilgileri temsil etmektedir. YSA'nın öğrenilmesi istenilen bilgiler, girdiler aracılığı ile yapay nöron (sinir) hücresine gönderilir (Öztemel 2006).


Toplama Fonksiyonu;

Toplam fonksiyonu, hücreye giren net girdiyi hesaplayan fonksiyondur. Genellikle toplam fonksiyonun oluşturduğu net girdi gelen girdi değerinin öz ağırlığının çarpılarak toplanmasıdır. Uygulanacak YSA modelleri kullanacağı toplama fonksiyonunu belirleyebilir (Öztemel 2006). Bu sebeple bir YSA modelinde tek bir toplama fonksiyonunu kullanmak şart değildir. Test edilerek en verimli toplama fonksiyonu belirlenebilmektedir.

Aktivasyon Fonksiyonu;

Aktivasyon fonksiyonu, toplama fonksiyonundan gelen net girdi değerinin işlenip yapay sinir ağına üreteceği çıktının belirlenme işlemidir. Farklı çeşitlere sahip olan aktivasyon fonksiyonu toplama fonksiyonu gibi YSA modeline göre en uygun olanın seçilmesiyle uygulanır (Öztemel 2006). Aktivasyon fonksiyonunun doğru seçilmiş olması modelin işleyişini için önemli bir kriterdir. Birçok aktivasyon fonksiyonu bulunmaktadır.

Bu çalışmada kullanılacak olan aktivasyon fonksiyonu Tangent-Sigmoid (tansig) fonksiyonudur ve Şekil 3’ de gösterilmektedir. Tangent-Sigmoid fonksiyonu, nöron toplam girişe bağımlı olarak $[-1,1]$ aralığında, doğrusal olmayan bir değişim göstermektedir (Altun, Eminoğlu ve Tezekici 2014).



Şekil 3. Tangent-Sigmoid

Kaynak: Altun, Halis, Ulaş Eminoğlu, ve Bekir Sami Tezekici. «Mlp Yapay Sinir Ağlarında Öğrenme Sürecinin Aktivasyon Fonksiyonu ve İstatiksel Değişim Gösteren Giriş Verilerine Bağımlılığı.» *ResearchGate*. Niğde: Niğde Üniversitesi, 2014.


Çıktı

Çıktı, aktivasyon fonksiyonun ürettiği çıktı değerini temsil etmektedir. Çıktı değeri, diğer bir hücreye veya dış dünyaya iletebilir.

1.1.2. Yapay Sinir Ağı Modelleri

1.1.2.1. Tek Katmanlı Yapay Sinir Ağları

Tek Katmanlı YSA, girdi ve çıktı katmanlarından oluşmaktadır. Şekil 4, Tek Katmanlı YSA yapısını göstermektedir. Birden fazla girdi ve bir çıktı değeri bulundurmaktadır ve çıktı katmanındaki her bir değer ağırlıklandırılmış girdi katmanındaki değerler ile bağlantılıdır. X ifadeleri girdileri, w ifadeleri her bağlantının ağırlıklarını temsil eder ve çıktının sıfır olmasını engelleyen bir eşik değerine sahiptir. Bu eşik değeri her zaman 1 değerini almaktadır (Öztemel 2006).



Şekil 4. Tek Katmanlı Yapay Sinir Ağları


Kaynak: Şengöz, Nilgün. *Yapay Sinir Ağları*. 4 Mart 2017.
<http://www.derinogrenme.com/2017/03/04/yapay-sinir-aglari/> (erişildi: Ocak 5, 2019).

Doğrusal bir sınıflandırıcı olarak kabul edilen Tek Katmanlı YSA' nın temel zayıflığı, doğrusal olmayan karmaşık problemleri çözme yeteneğinden yoksun olmasıdır. Fakat gerçek hayattaki problemlerin çoğu doğada doğrusal değildir (Namdev, Bhadoria ve Shrivastava 2013).

1.1.2.2. Çok Katmanlı Yapay Sinir Ağları

Çok Katmanlı YSA, girdi katmanı, ara katman (gizli katman) ve çıktı katmanı olmak üzere üç katmandan oluşmaktadır. Şekil 5, Çok Katmanlı YSA yapısını göstermektedir. Girdi katmanı öğrenilmesi istenilen bilgileri, ara katmana iletir. Ara katman, girdi katmanından aldığı bilgileri işleyerek çıktı katmanına gönderir. Bu katmanda birden çok ara katman bulunabilir. Çıktı katmanı ise aldığı bilgileri beklenen çıktı olarak dış dünyaya iletir. Doğrusal olmayan daha karmaşık problemlerde kullanılmaktadır.

Ağın ürettiği çıktı ile beklenen çıktı arasındaki fark geriye doğru yansıtılarak hata en aza indirilene kadar ağırlıklar güncellenir (Yılmaz 2017).



Şekil 5. Çok Katmanlı Yapay Sinir Ağları

Kaynak: HOSTINGDERGİ. *Yapay Zeka ve Sinir Ağları*. <https://www.hostingdergi.com.tr/yapay-zeka-ve-sinir-aglari/> (erişildi: Ocak 5, 2019).

1.1.3. Yapay Sinir Ağları' nın Yapılarına Göre Sınıflandırılması

1.1.3.1. İleri Beslemeli Yapay Sinir Ağları

İleri Beslemeli YSA, geriye doğru yönelmenin olmadığı, bilgi akışının yalnızca girdi katmanından çıktı katmanına doğru ileri yönde olduğu bir ağ yapısına sahiptir. Aynı katman içerisindeki yapay sinir hücrelerinin birbirleri ile bağlantısı yokken bir sonraki katmanın yapay sinir hücrelerine bağlantısı vardır. Çok Katmanlı Algılayıcılar, İleri Beslemeli YSA' lara örnektir.

1.1.3.2. Geri Beslemeli Yapay Sinir Ağları

Geri Beslemeli YSA, danışmansız öğrenme ile çözümlenen problemler için uygun ağlardır (Yılmaz 2017). Geriye doğru yönelmenin de olduğu bir ağ yapısına sahiptir.

Girdi katmanından ki sonraki ara katmanın ve çıkış katmanın çıkışları kendisinden bir önceki katmana doğru geri beslenmektedir. SOM (Self Organizing Map) ve Hopfield, Geri Beslemeli YSA' lara örnektir.

1.1.4. Yapay Sinir Ağları' nda Öğrenme

1.1.4.1. Danışmanlı Öğrenme

Danışmanlı öğrenme yönteminde, bir öğreticiye ihtiyaç duyulmaktadır. Bu öğrenme tipinde ilk olarak girdi ve çıktı değerleri ağın öğrenmesi için ağa sunulmaktadır. YSA gerçek çıkış ile istenen çıkış arasında kıyaslama yapmaktadır. Ağ tarafından rastgele değişen ağırlıklar ayarlanır ve bir sonraki döngüde istenen çıkış ile gerçek çıkış arasında daha yakın karşılaştırma üretilmesi sağlanır. Bu öğrenme ağı da anlık hataları en aza indirmeye çalışmaktadır. Ağın bulduğu gerçek çıkış ile istenen çıktının farkıyla hata hesaplanır. Kabul edilebilir doğruluğa ulaşıncaya dek ağırlıklar devamlı olarak güncellenerek hata azaltma işlemi devam eder. Danışmanlı öğrenmeye örnek olarak Çok Katmanlı YSA verilebilir.

1.1.4.2. Danışmansız Öğrenme

Danışmansız öğrenme yönteminde ağ, girdiler arasındaki ilişkilere göre bağlantı ağırlıklarını düzenler. Ağa çıktı değerleri girilmeden ve probleme ait sadece girdi değerleri sunuluyor ise danışmansız öğrenme yöntemi oluşmuş olmaktadır. Ağ, verilen girdilere göre giriş için modelleri veya örnekleri kendi aralarında sınıflayıp bir sınıflama kuralı oluşturur.

Oluşan bu sınıflama kuralına göre ağırlıklar sınıflandırmayı yapabilecek şekilde düzenlenir. Yapılan işlemler tamamlandığında öğrenme işlemi bitmiş olur. Danışmansız öğrenmeye örnek olarak ART (Adaptif Rezonans Teorisi), SOM (Self Organizing Map), K-Means verilebilir.

1.1.4.2.1. K-Means

Modelde kullanılan danışmansız öğrenme yöntemlerinden en yaygın olarak kullanılan K-Means algoritması, en eski kümeleme algoritmalarından biridir. J. B. MacQueen tarafından 1967 yılında geliştirilmiştir. Bu algoritmanın atama sistemi, her bilginin (verinin) yalnızca bir kümeye ait olabilmesine izin vermektedir (Işık ve Çamurcu 2007).

K-means algoritması, kullanıcı tarafından rastgele seçilen k adet küme merkezleri belirlenir. N tane veriden oluşan her bir veri kendisine en yakın merkeze yani merkez noktanın kümesine atanır. Daha sonra yeni küme merkezinin belirlenmesi için oluşan her bir kümenin ortalaması alınıp, verilerinin merkez uzaklıkları tekrar incelenir. Küme merkezi sabit kalana kadar algoritma çalışmaya devam eder.

1.1.5. Geriye Yayılım Algoritması

YSA' da, İleri Beslemeli YSA' nın parametrelerini güncellemek için literatürde yaygın olarak Geri Yayılım Algoritması kullanılmıştır. Bu yöntem, ağ parametrelerini ayarlayarak hata fonksiyonunu minimize etmeyi esas almıştır. Ağ yapısı çok katmanlı olup girdi, gizli ve çıktı katmanları olmak üzere en az 3 katmandan oluşmaktadır. Ortalama kare hatası bir eğitim seti için ölçüm kriteri olarak kabul edilir. Oluşan çıktı değeri ile beklenen çıktı arasındaki fark hatayı oluşturur ve çıkan hatayı minimize etmek için hata geriye doğru yayılır. Bu durum eğitim tekrar çalıştığında (iterasyon) hatanın minimize olmasına olanak sağlar (Güvenç 2014).

$$E_m = B_m - \zeta_m \quad (1)$$

$$\text{Toplam Hata} = \frac{1}{2} \sum_m E_m^2 \quad (2)$$

(1), m. proses elemanın (nöron) oluşturduğu hata değerinin matematiksel ifadesidir. ζ_m , m. nörona ait çıktı değeri, B_m , m. nöronun beklenen değerini, E_m ise m. proses elemanı için oluşan hatayı ifade etmektedir. (2), çıktı katmanında oluşan

bütün nöronların toplam hatasını ifade etmektedir. Hatanın sıfır çıkmaması için tüm çıktı hatalarının karesi alınarak toplam karesel hata bulunur. Toplam hatayı minimize etmek için ağırlıkların değiştirilmesi (hatanın dağıtılması) gerekmektedir. İki aşama ile gerçekleştirilen bu işlem, 1. aşaması olan ara katman ile çıktı katmanı arasındaki ağırlıkların değiştirilmesidir. 1. aşamanın t. iterasyondaki değişim miktarı (3)' de gösterilmektedir (Öztemel 2006).

Formüldeki ΔA^a , ara katmandaki j. nöronu çıktı katmanında bulunan m. nörona bağlayan ağırlığın değişim katsayısını, çok katmanlı ağlarda ağırlık öğrenmesinin optimum noktada takılı kalmaması için ağırlık değişim değerinin belirlenmiş bir oran ile bir sonraki değişime ilave etmesini sağlayan momentum katsayısı, α ile ifade edilmektedir. λ , öğrenme katsayısı yani ağırlıkların değişim miktarını ifade etmektedir. δ_m ise çıktı katmanındaki m. çıktı katmanının hatasını temsil etmektedir. Bu değer formülasyonu (4)' de gösterilmektedir. Formülde bulunan $f'(NET)$ kullanılan aktivasyon fonksiyonunun türevini ifade etmektedir. Değişim miktarının hesaplanmasının ardından ağırlıkların t. iterasyon için elde edeceği yeni değerler (5)' de ki gibi gösterilmektedir (Öztemel 2006).

$$\Delta A_{jm}^a(t) = \lambda \delta_m \zeta_j^a + \alpha \Delta A_{jm}^a(t-1) \quad (3)$$

$$\delta_m = f'(NET) E_m \quad (4)$$

$$A_{jm}^a(t) = A_{jm}^a(t-1) + \Delta A_{jm}^a(t) \quad (5)$$

2. aşama ise ara katman ile girdi katmanı arasındaki ağırlıkların değiştirilmesidir. Benzer hesaplamalar yapılmaktadır. Fakat 1. aşamada dikkate alınan bir nöronun hatası iken 2. aşamada tüm hatalar dikkate alınmaktadır [25]. (Yılmaz 2017) 2. aşamada yapılan işlemler (6), (7), (8)' dekiler gibidir;

$$\Delta A_{kj}^i(t) = \lambda \delta_j^a \zeta_k^i + \alpha \Delta A_{kj}^i(t-1) \quad (6)$$

$$\delta_j^a = f'(NET) \sum_i \delta_m A_{jm}^a \quad (7)$$

$$A_{kj}^i(t) = A_{kj}^i(t-1) + \Delta A_{kj}^i(t) \quad (8)$$

(6)' da ağırlıkların değişim miktarı gösterilmektedir (ΔA^i). (7)' de ki δ^a , kullanılacak aktivasyon fonksiyonuyla hata değerinin hesaplanmasıdır. Hata değerinin hesaplanmasıyla değişim miktarı bulunmaktadır ve ağırlıkların yeni değeri (8)' de ki gibi gösterilmektedir (Öztemel 2006).

1.1.6. Levenberg-Marquardt Algoritması

Bir çeşit en küçük kareler yaklaşımı olan bu algoritma, maksimum komşuluk fikrine dayanmaktadır. Genel anlamda Levenberg-Marquardt algoritması yavaş yakınsama sorunundan etkilenmez (Sağiroğlu, Beşdok ve Erler 2003), (Levenberg 1944).

$$\Delta w = (J^T J + \mu I)^{-1} J^T e \quad (9)$$

Formüldeki J, Jacobien matrisini ifade etmektedir. Jacobien matrisi, ağın meydana getirdiği hata değerlerinin ağırlıkları baz alınarak 1. dereceden türevlerden meydana gelmektedir [37]. (Açanal 2017) u kombinasyon katsayısını, I birim matrisini, e hata vektörünü, w ise ağırlık vektörünü ifade etmektedir. u değeri küçüldükçe Newton metodu, büyüdüğü Yöntem Dik İniş metodu gibi davranmaktadır (Çavuşlu, Becerikli ve Karakuzu 2012).

1.2. Bulanık Mantık

İnsanlar için birçok sorunla karşılaşmasının yanında muğlak ve tam anlaşılamayan sorunların çözümünde karar vermekte zorlanmaktadır. Bulanık Mantık' ın temelinde gerçek dünyadaki bu belirsizlik durumunu yatmaktadır.

Bulanık Mantık' ın amacı, insanların bu gibi durumlar için kullandıkları "EĞER-İSE" ihtimalleriyle sistemlere farklı kural tabanları oluşturarak makinalara karar verme yeteneğinin kazandırılması ve kesin çözümler üretmesidir. Zadeh, 1965 yılında bulanık küme mantığını ortaya koymuş ve Aristo düşüncesinde yer alan 'bir

obje kümenin ya elemanıdır ya da elemanı değildir.' şeklindeki klasik mantığa belirsizlik anlamı katmıştır (Yılmaz 2017).

Klasik küme mantığında bir nesne kümenin ya elemanıdır ya da değildir. Kümenin elemanı ise 1 değerini alırken, kümenin elemanı değil ise 0 değerini alır. Fakat bulanık küme mantığında alınan değerler [0,1] aralığındadır. 1'e yakınsadıkça kümenin elemanı olma ihtimali artar, tam tersi durumunda ise yani 0'a yakınsadıkça kümenin elemanı olma ihtimali azalır.

1.2.1. Üyelik Fonksiyonları

Bulanık kümede, bir eleman bir kümeye [0,1] aralığında değişen üyelik dereceleriyle bir kümeye ait olmaktadır. Bir bulanık küme içerisindeki bir elemanın üyelik derecesi üyelik fonksiyonun değeri ile gösterilir.

Birden çok üyelik fonksiyonları vardır, probleme göre en uygunu yapılır. Kullanılan bazı üyelik fonksiyonları aşağıdakiler gibidir;

1.2.1.1. Üçgen Üyelik Fonksiyonu

Üçgen üyelik fonksiyonunda, üç parametre kullanılır. Başlangıç noktası veya üçgenin sol minimum noktası (a), en çok üyelik derecesine sahip olunan nokta veya üçgenin tepe noktası (b) ve bitiş noktası veya üçgenin sağ minimum noktası (c) şeklindedir (Arslan 2012).

Matematiksel gösterimi;

$$\mu(x; a, b, c) = \begin{cases} a < x < b \rightarrow \frac{(x-a)}{(b-a)} \\ b < x < c \rightarrow \frac{(c-x)}{(c-b)} \\ x < a \text{ veya } x > c \rightarrow 0 \end{cases} \quad (10)$$

1.2.1.2. Yamuk Üyelik Fonksiyonu

Yamuk üyelik fonksiyonunda, dört parametre kullanılır. Yamuğun, sol minimum noktası (a), sol ve sağ tepe noktaları (b, c), sağ minimum noktası (d) şeklindedir (Arslan 2012).

Matematiksel gösterimi;

$$\mu(x; a, b, c, d) = \begin{cases} a < x < b \rightarrow \frac{(x-a)}{(b-a)} \\ b < x < c \rightarrow 1 \\ c < x < d \rightarrow \frac{(d-x)}{(d-c)} \\ x < a \text{ veya } x > d \rightarrow 0 \end{cases} \quad (11)$$

1.2.1.3. Gaussian Üyelik Fonksiyonu

Bu fonksiyon tipi, üyelik fonksiyonunda genişlik değerinin küçük olduğu durumlarda tercih edilir. Gaussian üyelik fonksiyonunda iki parametre kullanılır. Bunlar dağılımın merkezi (m) ve merkezden dağılım genişliği (σ) parametreleridir. σ değeri arttıkça dağılım daha basık, azaldıkça daha sivri şekilde olmaktadır (Eravcı 2016).

Matematiksel gösterimi;

$$\mu(x; m, \sigma) = \exp\left(\frac{-(x-m)^2}{2\sigma^2}\right) \quad (12)$$

1.2.1.4. Genelleştirilmiş Çan Eğrisi Üyelik Fonksiyonu

Cauchy-Lorentz olasılık dağılım fonksiyonundan türetilen bu üyelik fonksiyonunda, dağılım genişliği (a), eğrinin tavan genişliği (b), eğrinin merkezi (c) olmak üzere üç parametre ile kullanılır (Eravcı 2016).

Matematiksel gösterimi

$$\mu(x; a, b, c) = \frac{1}{1 + \left| \frac{x-c}{a} \right|^b} \quad (13)$$

1.2.1.5. Sigmoid Üyelik Fonksiyonu

Sigmoid Üyelik Fonksiyon tipi a, b olmak üzere iki parametre ile kullanılır. (a) parametresi eğimi verirken, (b) parametresi ise geçiş noktasını temsil etmektedir (Eravcı 2016).

Matematiksel gösterimi;

$$\mu(x; a, b) = \frac{1}{1 + e^{-a(x-b)}} \quad (14)$$

1.3. Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi (ANFIS)

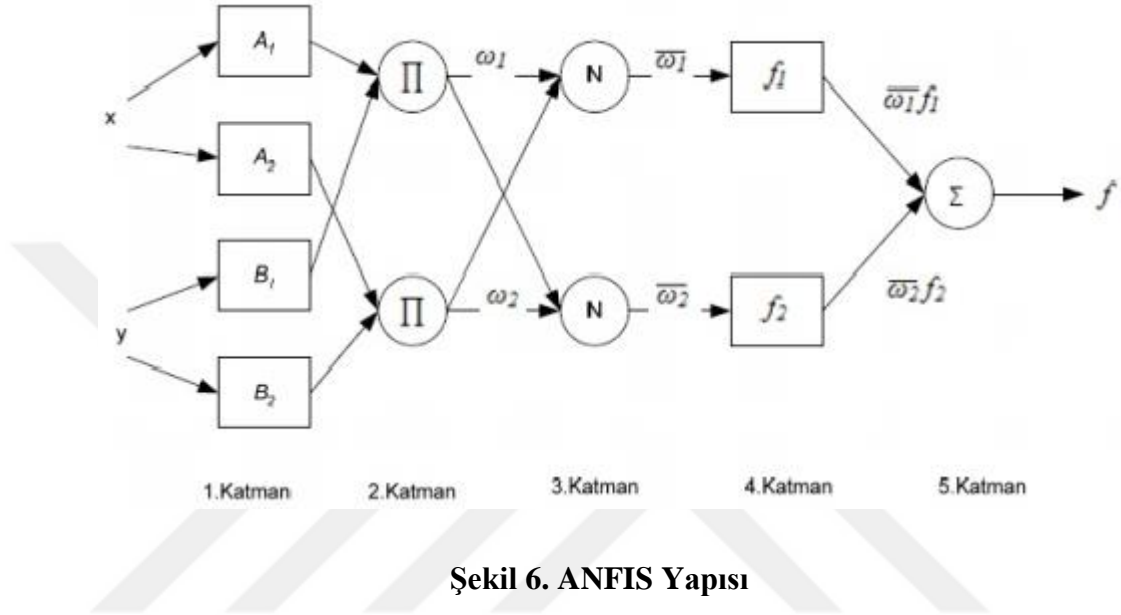
ANFIS, Adaptive Neuro Fuzzy Inference System isminin baş harflerinden oluşan bir kısaltmasıdır. Literatürde Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi olarak çevrilen ANFIS modeli, Sinirsel Bulanık Çıkarım Sistem yöntemlerinden biridir.

ANFIS, YSA' nın öğrenme becerisi ile Bulanık Mantık' ın karar verme üstünlüğünü bir modelde hibrit bir yapı şeklinde toplanmasıdır. Hem YSA' nın hem de Bulanık Mantık' ın ilkelerini tek bir modelde taşıdığı için iki yönteminde avantajlarını yakalayabilen uyarlanabilir (adaptif) bir ağ yapısına sahiptir. Uyarlanabilir bir yapıya sahip olma nedeni uzman bilgisi olmadan belirsizlikleri modelleyebilmeyi sağlamasıdır.

Bulanık EĞER-İSE kuralları ile insan bilgisini yansıtan girdi ve çıktı bilgilerini kullanan bir yapıya sahiptir. Bu yapıda girdi ve çıktı bilgilerinin arasındaki bağlantı EĞER-İSE kuralları ile dilsel ifadeler şeklinde tanımlanır (Aksu ve Güzeller 2018).

1.3.1. ANFIS Yapısı ve İşleyişi

ANFIS, belirli işlevleri gerçekleştirilme görevine sahip katmanlar halinde yerleştirilmiş ve her katmana ait düğümlerin birleşmesiyle oluşan bir ağ yapısına sahiptir.



Şekil 6. ANFIS Yapısı

Kaynak: Demirel, Özkan, Adnan Kakilli, ve Mehmet Tektaş. «Anfis ve Arma Modelleri ile Elektrik Enerjisi Yük Tahmini.» *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi* 25, no. 3 (2010): 601-610.

Şekil 6, 2 girdili bir ANFIS yapısını göstermektedir. Toplam 5 katmandan oluşan ANFIS' in kural yapısını şekildeki girdiler ile şu şekilde ifade edilir;

Kural 1: Eğer $x_1 = A_1$ ve $x_2 = B_1$ ise $f_1 = p_1 x_1 + q_1 x_2 + r_1$

Kural 2: Eğer $x_1 = A_2$ ve $x_2 = B_2$ ise $f_2 = p_2 x_1 + q_2 x_2 + r_2$

A ve B üyelik fonksiyonlarını, x ve y üyelik fonksiyonlarını, f_i çıkış değişkenini son olarak p_i, q_i, r_i sonuç parametrelerini ifade etmektedir.

ANFIS yapısının işleyişi açıklamalarıyla birlikte sırasıyla aşağıdakiler gibidir;

1.Katman: Girdi veya bulanıklaştırma katmanı olarak adlandırılır. Bu katmanda her bir düğüm giriş parametrelerinin bulanık kümelere ait üyelik fonksiyonlarını ifade eder ve kullanılan üyelik fonksiyonuna göre her bir düğümün çıkışı üyelik derecelerini temsil eder.

Bu katmanın çıkışı şu şekilde ifade edilir;

$$O_i^1 = \mu_{A_i}(x_1) \text{ ve } O_i^1 = \mu_{B_i}(x_2) \quad (15)$$

x_1 , x_2 değerleri i . düğüme ait girdi değerlerini, A_i , B_i sözel ifadelerle belirtilen bulanık kümeleri, μ_{A_i} ve μ_{B_i} değerleri bu kümelere ilişkin üyelik fonksiyonlarının derecesini belirtmektedir. Problem çözümüne göre Yamuk, Üçgen, Gauss gibi farklı üyelik fonksiyonları kullanılabilir.

2. Katman: Kural katmanıdır. Bu katmandaki her bir düğüm Bulanık Mantık modeli ile oluşturulan kuralları ve kural sayısını ifade etmektedir.

Bu katmanın hesaplanması şu şekilde ifade edilir;

$$w_i = \mu_{A_j}(x_1) * \mu_{B_j}(x_2) \dots \mu_{T_j}(x_k) \quad (16)$$

Her bir kural düğümünün çıkışı bulanıklaştırma katmanından gelen üyelik derecelerinin çarpımına eşittir. Formüldeki w_i girdi katmanın çıktı değerini, i ise girdi katmanındaki düğüm sayısını ifade etmektedir. w_i değeri aynı zamanda ateşleme seviyesini temsil eder.

3. Katman: Normalizasyon katmanı olan bu katmandaki her düğüm bir önceki katmandan gelen ateşleme seviyelerini düğümlerin girdisi olarak kabul eder. Normalizasyon katmanı, tüm kuralların ateşleme seviyelerinin toplamına oranı olarak hesaplanır.

Bu katmanın hesaplanması şu şekilde ifade edilir;

$$\bar{w}_i = \frac{w_i}{\sum_{k=1}^n w_k} \quad (17)$$

w_i i. kural için bir önceki katmandan gelen sonuç değerini, n değeri ise sonucu üreten çıkış küme sayılarını ifade etmektedir.

4. Katman: Sonuç katmanı veya arındırma katmanı olarak ifade edilir. Her bir düğüm de verilen kuralın sonuç ağırlıkları değerini hesaplar.

Bu katmanın hesaplanması şu şekilde ifade edilir;

$$\bar{w}_i f_i = \bar{w}_i (p_i + q_i + r_i) \quad (18)$$

Formül de belirtilen w_i değeri normalizasyon katmanının çıkış değeri yani normalize edilmiş ateşleme seviyesidir. p_i, q_i ve r_i ise i. kurala bağlı ayarlanabilen sonuç parametrelerini ifade etmektedir.

5. Katman: Çıkış veya toplam katmanı olan bu katmanda sadece bir düğüm bulunmaktadır. Bir önceki katmandan gelen bütün sinyallerin toplamı alınarak sistemin çıkış değeri olan f değerini hesaplar.

Bu katmanın hesaplanması şu şekilde ifade edilir;

$$f_{\text{çıkış}} = \sum_{i=1}^n \bar{w}_i \cdot f_i \quad (19)$$

1.3.2. ANFIS Modeli

1993 yılında Jang tarafından geliştirilmiş olan ANFIS modeli, Takagi-Sugeno Bulanık Çıkarım Modeli' ne sahiptir. Bulanık Mantık' da da kullanılan Takagi-Sugeno modelinde, çıktı üyelik fonksiyonları sadece lineer ya da sabittir. Bulanık ifadeler kullanılan sistemlerde modeli oluştururken matematiksel ifadeler kullanılmaktadır (Yılmaz 2017). Dolayısıyla Takagi-Sugeno modeli, dilsel ve matematiksel ifadeleri bir arada kullanan bir çıkarım modelidir.

"EĞER-İSE" kuralı ile bulanık kurallar türeten bu modelin her bir sonucu fonksiyon ile hesaplanan kesin değerlerdir. Eğer çıktı üyelik fonksiyonları sadece bir sabiti ifade ediliyor ise Sıfırıncı Derece Sugeno Bulanık Modeli, çıktı üyelik fonksiyonları birinci derece doğrusal bir fonksiyonu ifade ediliyor ise Birinci Derece Sugeno Bulanık Modeli olarak isimlendirilir. İki girişe sahip Birinci Derece Sugeno Modeli' nin yapısı aşağıdaki gibidir;

Kural 1: Eğer $x = A_1$ ve $y = B_1$ ise $f_1 = p_1 x + q_1 y + r_1$

Kural 2: Eğer $x = A_2$ ve $y = B_2$ ise $f_2 = p_2 x + q_2 y + r_2$

1.3.3. ANFIS Öğrenme Algoritması

ANFIS, hibrit öğrenme algoritmasını kullanmaktadır. Hibrit öğrenme algoritması, en küçük kareler yöntemi ile geri yayımlı öğrenme algoritmasının birleşiminden oluşan melez (hibrit) bir öğrenme algoritmasına sahiptir. Bu öğrenme algoritması ileriye doğru hesaplama ve geriye doğru hesaplama olarak iki aşamadan oluşmaktadır. İleriye doğru hesaplamada, girdi parametreleri sabit tutulup, çıktı parametreleri en küçük kareler yöntemi ile hesaplanır. Geriye doğru hesaplamada ise, çıktı parametreleri sabit tutularak, girdi parametreleri geri yayımlı öğrenme algoritması ile hesaplanır.

1.4. Genetik Algoritma

Sezgisel bir yöntem olan Genetik Algoritma (GA) doğada ki evrimsel süreci temel almaktadır ve İngiliz biyolog ve doğa tarihçisi Charles Darwin' in evrim teorisinin temel prensibi olan doğal seçilimi ilham alınarak oluşturulmuştur.

GA' lar evrimsel süreci temel alarak çalışan bir optimizasyon ve arama algoritmasıdır. Belirli bir problem için en iyi çözümü hesaplamayı veya en yakın çözüme ulaşmayı amaçlar.

Dođal seim veya dođal seleksiyon yani gcl olan hayatta kalır mantıđını benimseyen GA iřleyiřinde, evrim sonucunda hayata kalan birey en iyi sonu olarak kabul edilir (Altay 2007).

GA' lar tek bir aday ozm yerine birden fazla aday ozmler ile arama iřlemi yapar ve bu zelliđi GA' yı diđer optimizasyon yntemlerinden farklı kılmaktadır. Bu zelliđi ile ozm uzayının taranması birden fazla bařlangı noktası ile sađlanmıř olur (Akkuř ve Demir 2016).

GA, ozm uzayındaki her bir noktayı ikili bit dizisi řeklinde kodlar. Bu ikili bit dizisine kromozom adı verilir. Her bir noktanın kendisine ait bir uygunluk deđeridir ve algoritma tek bir nokta yerine, btn noktalar kmesini tek bir poplasyon olarak muhafaza eder. aprazlama ve mutasyon gibi operatrler ile her nesilde yeni bir poplasyon retir. Bu sre Charles Darwin' in dođal seime ve rassal mutasyona dayanan evrim modellerini andırmaktadır (Kubat 2014). Ayrıca ikili kodlama ynteminden bařka uygulanacak probleme gre farklı kodlama yntemleri de vardır (Emel ve Tařkın 2002).

GA' nın temel ilkeleri 1960' li yıllarda John Holland tarafından ortaya atılmıřtır. John Holland, *Adaptation in Natural and Artificial Systems* (Dođal ve Yapay Sistemlerde Adaptasyon) kitabında GA' yı teorik olarak aıklamıřtır. Fakat 1985 yılında John Holland' ın doktora đrencisi olan David E. Goldberg doktora alıřmasında birok kollara ayrılmıř gaz borularında, gaz akıřını kontrol etmek ve dzenlemek iin GA ile bir uygulama yapmıřtır. Bu alıřma ile National Science Foundation Gen Arařtırmacı dln kazanan David E. Goldberg, GA' nın sadece bir teorik alıřma deđil pratikte de kullanılabilirliđini gstermiř oldu (Kubat 2014).

1.4.1. Genetik Algoritma Adımları

1.4.1.1. Başlangıç Popülasyonunun Oluşturulması

GA' da kullanılacak ebeveynler (bireyler) bu adımda oluşturulur. Problemin çözümü için genellikle rastgele n tane bireylerden oluşan bir popülasyon oluşturulur. Oluşturulan popülasyon kodlanır ve problem için çözüm uzayı oluşur. Çözüm uzayındaki her bireye yani çözüme kromozom adı verilir.

Popülasyonun büyüklüğü (birey sayısı) her problem tipi için farklılıklar göstermektedir. Birey sayısının az olması algoritmada kullanılacak pek çok değer kullanılmadan atlanmasına yol açar. Birey sayısının fazla olması ise her döngüde daha fazla bireyin incelenmesine yol açacağı için algoritmanın yavaşlamasına ve verimliliğin azalmasına neden olur (Altay 2007).

1.4.1.2. Uygunluk Değeri (Amaç Fonksiyonu)

Popülasyon oluşturulduktan sonraki adım popülasyondaki bireylerin uygunluk değerlerinin hesaplanmasıdır. Uygunluk değerleri her bir bireyin çözümde gösterdikleri başarı değerlerini göstermektedir. İyi çözümlerin gelişimi için kullanılmaktadır. Uygunluk değeri, popülasyondaki her bir birey için bir uygunluk fonksiyonu ile hesaplanır ve her problem için farklı uygunluk fonksiyonları bulunur. Problem için en iyi uygunluk değerine sahip olan bireyin bir sonraki nesle geçme olasılığı diğer bireylere göre daha yüksektir (Akkuş ve Demir 2016).

1.4.1.3. Seçim

Yeni nesilde popülasyonun en iyi bireylerden oluşması için bir seçim mekanizması kullanılır. Seçim mekanizması bireyleri bir sonraki nesil için uygunluk değerine göre seçer. En uygun bireyleri kopyalarken en kötü olanları kopyalamaz. Seçim operatörü; Rulet Tekerliği Seçimi, Sabit Durum Seçimi, Stokastik Seçim ve Turnuva Seçimi yöntemlerine sahiptir.

1.4.1.3.1. Rulet Çemberi Seçim Yöntemi


Rulet çemberi seçim yöntemi, rulet çemberin de her aralık bir bireyi temsil edecek şekilde n adet aralığa bölünür. Her bireyin uygunluk değerleri aralıklara yazılır. Tüm bireylerin uygunluk değeri toplam uygunluk değerine bölünür ve [0-1] aralığında elde edilir. Bu değerler çember de yerlerini alır. Daha sonra tekrar üreme için rulet döndürülür ve sıfır ile toplam uygunluk değeri arasında rastgele bir sayı üretilir. Üretilen sayının çemberdeki hangi aralığa denk geldiği tespit edilerek, çemberin bir defa ile bir sonraki nesle hangi bireyin aktarılacağı seçilir. Diğer bireylerde benzer şekilde belirlenerek en iyi uygunluk değerine sahip bireyler eşleştirme havuzuna alınır. Diğer nesle ait bireyler oluşturularak, genetik adımlar ile yeni nesil elde edilir (Elmas 2016).

1.4.1.4. Çaprazlama

Çaprazlama işlevinin temel amacı çözüm havuzunun potansiyelini ve çeşitliliği arttırmak için yeni nesillerin önceki nesillerden farklı nesiller üretmesidir. Bu amaç ile iki ebeveyn (birey) yeni ebeveynler (nesiler) oluşturulmak için birleştirilir ve seçilen bireyler çaprazlama oranına göre yeni nesiller üretilmek için çaprazlanır.

1.4.1.4.1. Tek Nokta Çaprazlama Yöntemi

Tek Nokta Çaprazlama Yöntemi, çaprazlanacak bölge diziden rastgele seçilir. Eşleşecek olan iki dizi rastgele seçilen bölgelerin sonraki kısımları yer değiştirerek yeni bireyler oluşur. Şekil 7' de tek nokta çaprazlama gösterilmektedir.




Şekil 7: Tek Nokta Çaprazlama

Kaynak: Altay, Ayça. «Genetik Algoritma ve Bir Uygulama.» *Yüksek Lisans Tezi*. İstanbul: İstanbul Teknik Üniversitesi, 2007.

1.4.1.4.2. İki Nokta Çaprazlama

İki Nokta Çaprazlama da ise dizilerden rastgele iki bölge seçilir ve seçilen iki bölge arasındaki kısımlar yer değiştirir ve dolayısıyla iki yeni birey oluşur. Şekil 8’ de iki nokta çaprazlama gösterilmektedir.



Şekil 8: İki Nokta Çaprazlama

Kaynak: Altay, Ayça. «Genetik Algoritma ve Bir Uygulama.» *Yüksek Lisans Tezi*. İstanbul: İstanbul Teknik Üniversitesi, 2007.

1.4.1.5. Mutasyon

Mutasyon işlevleri, GA' nın daha geniş bir çözüm alanında araştırma yapmasını ve genetik çeşitliliği sağlamak amacıyla kullanılır. Popülasyondaki ebeveynlerin genlerinde ya da DNA dizilerinde küçük rastgele oynamalar yapar (Nguyen, ve diğerleri 2015).

1.4.1.5.1. Gauss Mutasyonu

Gauss Mutasyonu, standart sapması istenilen değer olan, sıfır ortalamalı bir Gauss dağılımını kullanmaktadır. Her gene Gauss dağılımı ile üretilen rastgele bir değer eklenir. Genin aldığı değer için alabileceği değer aralığında olup olmadığı kontrol edilir. Değer aralığının aşılması durumunda değer alt sınırdan daha az bir değerde ise alt sınıra, üst sınırdan daha büyük bir değerde ise üst sınıra taşınarak kırılmış olur (Demirkıran 2004).

1.4.1.6. Durdurma

Problem istenilen hedefe ulaşana kadar veya önceden belirlenen belirli kuşak sayısı ya da durdurma kriterine ulaşana kadar işlem devam eder. Durdurma kriteri ile istenilen hassasiyete göre bir iterasyon değeri belirlenir ve belirlenen değere geldiğinde yeni kuşak oluşumu durur (Emel ve Taşkın 2002).

1.4.1.7. Elitizm Stratejisi

Bu yöntem en iyi bireyin kaybolmasını önleyerek saklanmasını esas almaktadır. Popülasyondaki en iyi birey o popülasyondan alınarak hiçbir değişikliğe uğratılmadan yeni nesile taşınır. Böylelikle çözüme en uygun dizi bir sonraki nesile kopyalanmış olur.

ÜÇÜNCÜ BÖLÜM

ÖNERİLEN MODELLER

1. ÖNERİLEN MODELLER VE UYGULAMALARI

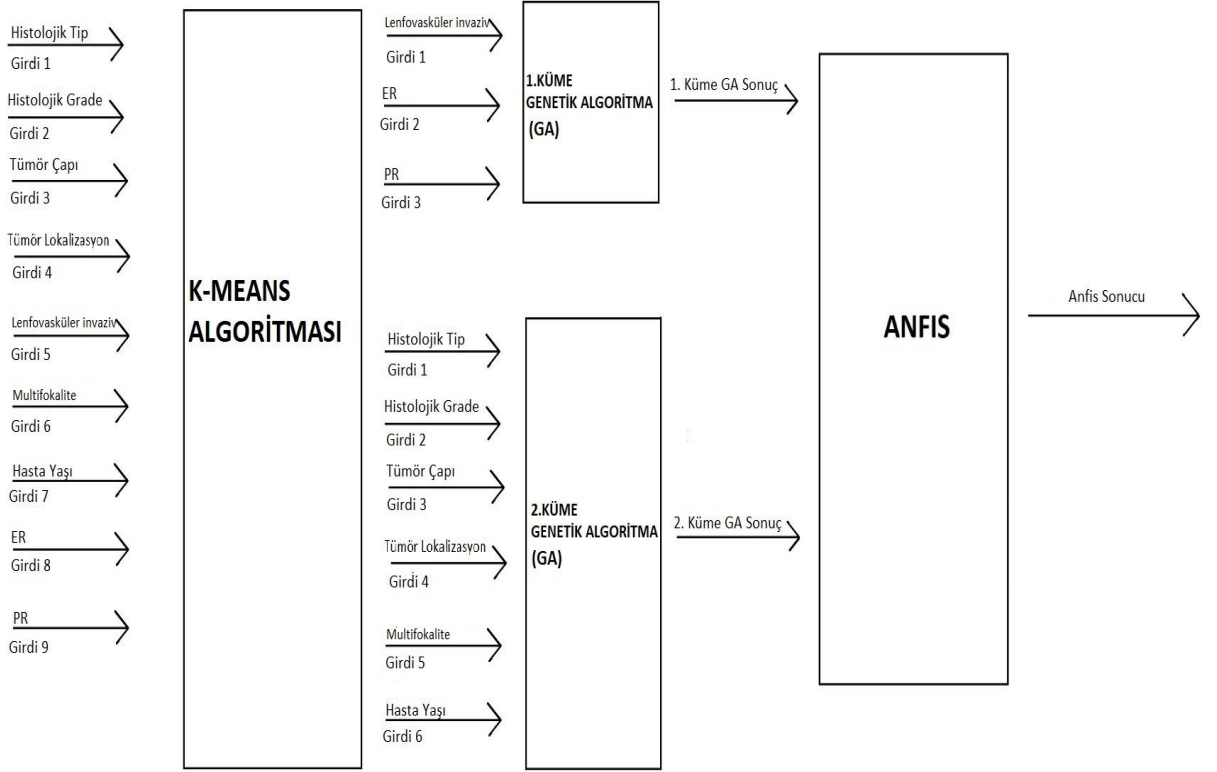
Bu çalışmada İstanbul Gaziosmanpaşa Taksim Eğitim ve Araştırma Hastanesi'ne ait meme kanseri hastalarının tıbbi bilgilerini içeren verileri kullanılmıştır. Kullanılan veri seti, sadece kadın hastaların bilgisini içeren homojen bir yapıya ve 9 özelliğe sahiptir. Uzman doktor tarafından Yapay Zeka modellerinin analizi için eksik veya aynı bilgilere sahip veriler veri setinden çıkartılmış ve toplam 203 meme kanserli hastanın koltuk altı lenf bezi durumunu belirten klinik ve patolojik bilgileri bu çalışmada analizi yapılmak üzere kullanılmıştır. Veri setinde bulunan parametre özellikleri Tablo 2' de gösterilmektedir.

Çalışmada Yapay Zeka yöntemlerini içeren 3 farklı model koltuk altı lenf bezi durumu teşhisi için eğitilmiştir. Çalışmada kullanılacak veri setinin 9 özelliği modellerin iyileştirilmesi için farklı işlemlerden geçmiştir. Yapay Zeka yöntemlerinden olan K-Means, GA, ANFIS, YSA yöntemleri MATLAB R2015a programında eğitim için kullanılacaktır. Modelin eğitildikten sonraki karşılaştırılması ve istatistiksel analizleri için ise SPSS (Statistical Cruncher Package For The Social Sciences) programı kullanılmıştır. Bu analizler için Whitney U testi ve Pearson Ki-Kare testi ve modellerin karşılaştırılması için tanı testleri ve ROC Eğrisi kullanılmıştır.

Tablo 2. Çalışmada Kullanılacak Veri Setinin Özellikleri

Veri İsimleri	Verilerin Özellikleri
Histolojik Tip	1- İnvaziv Duktal Karsinom 2- İnvaziv Lobüler Karsinom 3- Diğer
Histolojik Grade	1- İyi Diferansiye 2- Orta Diferansiye 3- Kötü Diferansiye
Tümör Çapı	Tümörün santimetre (cm) cinsinden boyutu
Tümör Lokalizasyon (Tümörün bulunduğu bölge/bölgeler)	1- Üst Dış Kadran 2- Üst İç Kadran 3- Alt İç Kadran 4- Alt Dış Kadran 5- Areola
Lenfovasküler İnvaziv (Tümör hücrelerinin lenf damarlarına yayılımı)	1- Var 0- Yok
Multifokalite (Tek tümör veya birden fazla tümör)	1- Var 0- Yok
Hasta Yaşı	Sayısal
ER	1- Var 0- Yok
PR	1- Var 0- Yok
Aksilla Tutulumu	1- Var 0- Yok

1.1. KG-ANFIS Modeli



Şekil 9: KG-ANFIS Modeli

KG-ANFIS modeli, 3 aşamadan oluşmaktadır ve Şekil 9’ da modelin mimarisi gösterilmektedir. Önerilen model normalize edilmiş 9 girdi parametresinin K-Means algoritması ile çıktı parametresinden bağımsız olarak kümelenebilmesiyle başlamaktadır. Birçok defa kümelenen girdi parametrelerinin 2 kümeye ayrılması model için en uygunu olarak tespit edilmiştir. Oluşturulan 2 küme ayrı olarak GA ile optimize işlemlerinden geçmiştir. Bu iki kümenin oluşan optimize sonuçları son olarak ANFIS’ de eğitilerek uygulama için en uygun beklenen sonuç tespit edilmeye çalışılmıştır.

Bu modelin amacı, problemin sonucu verilmeden danışmansız öğrenmenin ve sezgisel yöntemin sonuçlarının istenilen sonuca nasıl yaklaşabileceğini ANFIS ile tespit etmektir.

Aynı zamanda ANFIS modelinin optimize olmuş az girdiler ve bunun sonucunda az kuralları ile daha hızlı ve probleme daha uygun sonuçların verilmesi amaçlanmıştır. Model, birden fazla Yapay Zeka algoritmalarının özellikleriyle oluşan hibrit bir modeli temsil etmektedir. Dolayısıyla Yapay Zeka' nın birçok özelliğiyle modelin verimliliği ve başarısı bu oranda artış gösterdiği gözlenmektedir.

1.1.1. KG-ANFIS Modeli ve Uygulaması

Uygulama da GA' da kullanılacak 9 girdi parametre ve 203 veriden oluşan veri seti MATLAB ortamında K-Means algoritması ile kümelere ayrılmıştır.

Kullanıcı tarafından küme sayısı 2 ile 4 değerleri arasında denemeler yapılmış ve küme sayısı arttıkça parametrelerin kendi içlerinde kümelere ayrıldığı gözlenmiştir. Dolayısıyla en iyi kümeleme sınıflanmasının Tablo 3' de gösterildiği gibi 2 olduğu tespit edilmiştir. Tablo 3' de kümelere ait girdi parametreleri sırası ile verilmiştir.

Tablo 3: Kümelere Ait Parametre İsimleri

1.KÜME PARAMETRE İSİMLERİ		2.KÜME PARAMETRE İSİMLERİ	
1.Girdi	Lenfovasküler İnvaziv	1.Girdi	Histolojik Tip
2.Girdi	ER	2.Girdi	Histolojik Grade
3.Girdi	PR	3.Girdi	Tümör Çapı
		4.Girdi	Tümör Lokalizasyonu
		5.Girdi	Tümör Fokalite
		6.Girdi	Yaş

Kümelere ayrılan bu iki küme GA' da ayrı ayrı ele alınmış ve ANFIS de kullanılmak üzere optimize işlemleri yapılmıştır.

Birinci kümeye ait 3 girdi parametre verileri ve ikinci kümeye ait 6 girdi parametreleri 2 ayrı alt veri setine bölünerek MATLAB ortamında GA için kullanılmıştır. GA' nın optimum sonuçları ve gerçek sonuçlara yakınsama oranı

dikkate alınmıştır ve bu doğrultuda GA parametreleri birçok kez farklı yöntemler ile denemeler yapılarak, en uygun model sonucuna ulaşana kadar başarı oranları ANFIS’ de karşılaştırılmıştır.

Kullanılan değerler ve yöntemler birinci küme ve ikinci küme için en iyi sonuçları vermiştir. MATLAB’ de GA optimizasyon problemleri için birçok parametre mevcuttur. Bu model için sonuca en uygun çıktıyı oluşturabilmek amacıyla farklı pek çok parametre işlemleriyle yapılan çalışmalar sonucunda oluşturulan GA parametreleri Tablo 4’ de verilmektedir.

Tablo 4: 1. ve 2. Kümenin Genetik Algoritmada Kullanılan Parametreleri

	1. KÜME	2. KÜME
Popülasyon Türü	Double Vector	Double Vector
Popülasyon Büyüklüğü	203	203
Seçim	Rulet Seçimi	Rulet Seçimi
Çaprazlama	İki Nokta Çaprazlama	Tek Noktalı Çaprazlama
Çaprazlama Oranı	0,8	0,8
Mutasyon	Gauss	Gauss
Ölçeklendirme Parametresi	1	1
Shrink Parametresi	1	1
Ölçeklendirme İşlevi	Top	Orantılılık
Elitizm	200	200
Başlangıç Aralığı	[0;1]	[0;1]
Göç	İleri	İleri
Göç Oranı	0,2	0,2
Göç Aralığı	20	20
Oluşturma Fonksiyonu	Constraint Dependent	Constraint Dependent
Durdurma Kriterleri		
Nesiller	300	600
Zaman Sınırı,	Inf	Inf
Uygunluk Limiti	-Inf	-Inf
Durma Kuşakları	50	50
Durma Süresi Sınırı	Inf	Inf
Durma Testi	Average Change	Average Change
Fonksiyon Toleransı	1,00E-06	1,00E-06
Kısıt Toleransı	1,00E-03	1,00E-03

Popülasyon büyüklüğü veri setindeki hasta sayısı kadar alınmıştır. Bunun nedeni ANFIS’ de kullanılacak girdi değerlerinin çıktı sayısı kadar olması gerektiğindedir. Popülasyon türü olarak Double Vector kullanılmıştır. Popülasyondaki bireylerin çift tipte olması durumunda veya karışık tam sayılı programlama olması durumunda kullanılmaktadır. Çalışmanın birinci küme bireylerinin çift tipte ve ikinci kümenin karışık tam sayı değerleri içerdiği için bu popülasyon türü uygun sonuçlar vermiştir.

Modelde, ölçeklendirme işlevinin kullanılmasındaki amaç, amaç fonksiyonunun döndürdüğü uyumluluk sonuçlarını, seçim işlemi için uygun aralıktaki değerlere dönüştürmesidir. Ölçeklendirme işlevinin birden fazla yöntemi bulunmaktadır ve bu model için kullanılan Top ölçeklendirme işlevi, en uygun uyumluluk değerlerindeki bireyleri eşit derecede ölçeklendirmektedir. Orantılık ise beklentinin ham uyumluluk skoruyla orantılı olmasını sağlamaktadır.

Başlangıç aralığı, başlangıç popülasyonundaki değerlerin alt ve üst sınırları belirtilir. Bu model için iki kümenin [0;1] aralığında olması en verimli sonuçları doğurmuştur.

Modelde, en iyi bireyleri bir sonraki nesle aktarmak için elitizm stratejisi kullanılmıştır. Bir sonraki nesil için hayatta kalmayı garantileyen bireyleri ifade etmektedir.

Mutasyon işleminde, Gauss yöntemi için Ölçeklendirme ve Shrink parametreleri olarak iki seçenek kullanılmıştır. Ölçeklendirme parametresi, ilk kuşaktaki standart sapmayı belirlerken, Shrink parametresi, kuşaklar boyu standart sapmaların nasıl azaldığını kontrol eder. 0 değerini alması durumunda standart sapma sabit kalır, 1 olması durumunda ise son kuşağa ulaşıldığında standart sapma 0’ da doğru gider.

Göç, popülasyonun 1' den büyük olmasıyla algoritma alt popülasyonlar oluşturur ve oluşan bir alt popülasyondaki en iyi birey ile farklı bir alt popülasyondaki en kötü birey arasında yer değişikliği olur ve göç ileriye doğru olunca geçişler ileri yöne doğru son alt popülasyona varana kadar devam eder. Göç oranı, alt popülasyonlar arasında kaç bireyin hareket ettiğini kontrol etmektedir. Aralık ise göçler arasında kaç kuşağın geçtiğini kontrol etmektedir. Bu modelde, 20 nesilde bir alt popülasyonlar arasında göç gerçekleşmektedir.

Oluşturma fonksiyonu, başlangıç popülasyonunu oluşturan işlevdir. Modelde Constraint Dependent seçilmesinin nedeni, problem için varsayılan oluşturma işlevini kullanmaktadır ve bu işlemi 3 olasılık durumuna bakarak yapmaktadır. “Tamsayı kısıtlamaları varsa ya da doğrusal kısıtlamalar yoksa, tamsayı kısıtlamaları ve doğrusal kısıtlamalar yoksa, tamsayı kısıtı yoksa doğrusal olmayan kısıtlamalar vardır” şeklinde 3 varsayım ile işlem yapmaktadır.

Problemin amaç fonksiyonu olarak objfun (objective function) işlevi kullanılmıştır. Amaç, her değişkenin problemde optimize edilecek değere ne kadar katkıda bulunduğunu göstermektedir. Bu işlev aşağıdaki genel formu alır; (https://www.courses.psu.edu/for/for466w_mem14/Ch11/HTML/Sec1/ch11sec1_ObjFn.htm#Top, E.T.: 9.01.2019)

$$\text{Maksimizasyon ya da minimizasyon} \quad Z = \sum_{i=1}^n c_i X_i \quad (20)$$

c_i = i. değişkene karşılık gelen objektif (amaç) fonksiyon katsayısı

X_i = i. karar değişkeni

Amaç fonksiyonunun katsayıları, ilgili değişkenin bir biriminin amaç fonksiyonunun değerine katkısını göstermektedir.

Yukarıda gösterilen genel amaç fonksiyonunun yazıldığı şekilde, her değişkenin amaç fonksiyonunda bir katsayısı bulunmaktadır. Fakat, bazı değişkenler fonksiyona katkıda bulunmayabilir. Bu durumda, değişkeni sıfır katsayısına sahip olarak düşünebilir veya değişkeni işlevde hiç olmadığını düşünebilirsiniz.

Ayrıca modelde MATLAB' de bulunan Artırılmış Lagrangian Genetik Algoritma (ALGA) yöntemi kullanılmıştır. Genetik algoritma, doğrusal olmayan kısıtlı problemlerini, tamsayı kısıtlamaları olmadan çözmek için ALGA' yı kullanmaktadır. Kısıtlı bir optimizasyon problemini bir dizi kısıtsız problemle değiştirmeleri ve hedefe bir ceza süresi eklemesi nedeniyle ihlalleri ele alan ceza yöntemleriyle benzerlik göstermektedir. Bu yöntem, Lagrange çarpanını taklit etmek amacıyla tasarlanmış başka bir terim kullanmaktadır.

$$\min f(x) \quad (21)$$

Yukarıdaki fonksiyon kısıtlı bir problem çözümü için olduğu düşünülürse, bu problem sınırlandırılmamış bir minimizasyon problemi olarak çözülebilir. Artırılmış Lagrangian yöntemi ile çözülmesi aşağıda gösterilen gibidir;

$$\Theta(x, \lambda, s, \rho) = f(x) - \sum_{i=1}^m \lambda_i s_i \log(s_i - c_i(x)) + \sum_{i=m+1}^{mt} \lambda_i ceq_i(x) + \frac{\rho}{2} \sum_{i=m+1}^{mt} ceq_i(x)^2 \quad (22)$$

λ_i vektörünün λ bileşenleri, negatif değildir ve Lagrange çarpan tahminleri olarak bilinir.

s_i vektörünün s elementleri, negatif olmayan kaymalar

ρ , pozitif ceza parametreleridir.

Durdurma kriterlerine ulaşıncaya kadar bu işlemler güncellenir ve ulaştığında ise işlem sonlanmaktadır.


Modelde kullanılan durdurma kriterleri en uygun parametreler olacak şekilde denenmiş ve en iyi sonuç veren değerler algoritmanın girişte sunduğu değerler olarak tespit edilmiştir.

Bu işlemlerin sonucunda iki küme için yeni popülasyonlar oluşturulmuştur. Algoritmaların sonucunda 2 küme için ayrı olarak oluşan uygunluk fonksiyonun

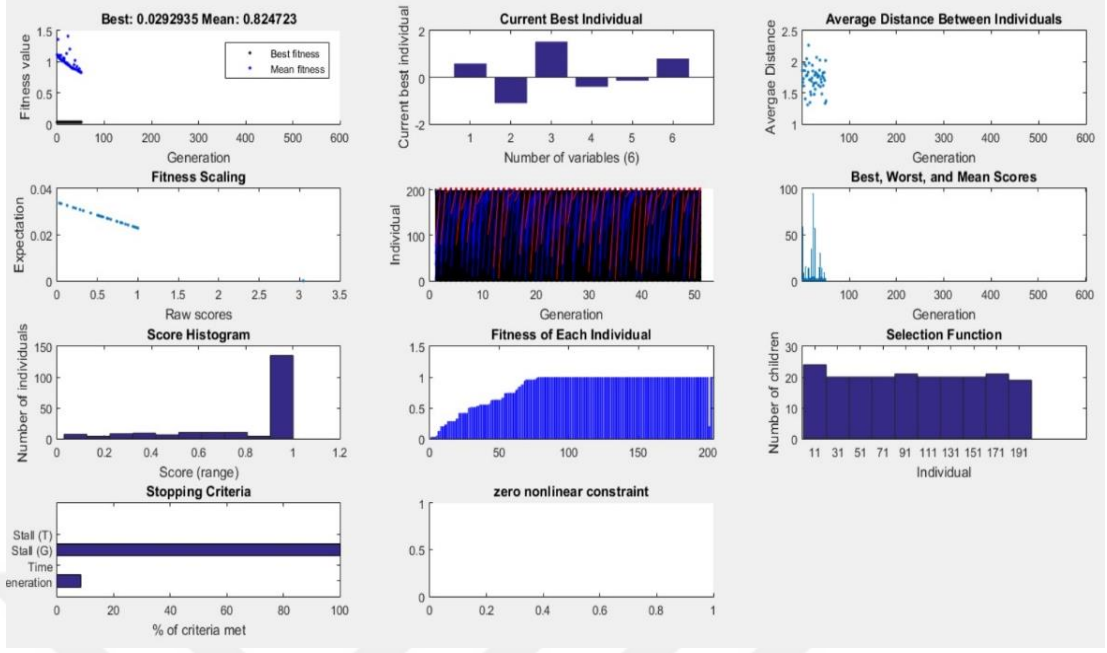
değeri ve uygunluk fonksiyonunu optimize eden girdi parametrelerinin değerleri Tablo 5’ de gösterilmektedir.

Tablo 5: 1.ve 2. Kümenin Uygunluk Fonksiyonu Değerleri ve Optimize Eden Parametre Değerleri

1.KÜME UYGUNLUK FONKİSYON DEĞERİ		2.KÜME UYGUNLUK FONKİSYON DEĞERİ	
	0,0594		0,0292935
1.Girdi	0,3989	1.Girdi	0,05881
2.Girdi	- 0,9974	2.Girdi	-1,10742
3.Girdi	1,7683	3.Girdi	1,532513
		4.Girdi	-0,40643
		5.Girdi	-0,14573
		6.Girdi	0,802935




Şekil 10: 1. Küme GA Grafiksel Sonuçları



Şekil 11: 2. Küme GA Grafiksel Sonuçları

Şekil 10 ve Şekil 11 genetik algoritmada yapılan işlemlerin grafiksel çıktısını göstermektedir.

GA' dan gelen 2 kümenin optimize sonuçları eğitimin girdi parametresi ve çalışmanın veri setindeki aksilla tutulumu ise eğitimin çıktı parametresi olarak ANFIS' de eğitilmek üzere kullanılmıştır. Toplam 203 verinin %70' i eğitim, %30' u ise test için ayrılmış ve MATLAB ortamında model için en iyi sonuca ulaşana kadar üzerinde çalışılmıştır.




Şekil 12: KG-ANFIS Modelinde ANFIS Eğitiminin Hata Grafiği

ANFIS modelin 50. iterasyon da eğitim verilerinin hata büyüklüğü 0,0089805 olarak bulunmuştur. Şekil 12’ de KG-ANFIS modelinin ANFIS’ de kaç iterasyon (epoch) sayısı ile eğitildiğini ve ANFIS eğitiminin hata grafiği gösterilmektedir. Görüldüğü gibi 43. iterasyondan sonra hata büyüklüğü aynı değerde devam etmiştir ve bu da eğitimin durduğunu göstermektedir. Dolayısıyla model için maksimum 50 iterasyon sayısı yeterli bulunmuştur.



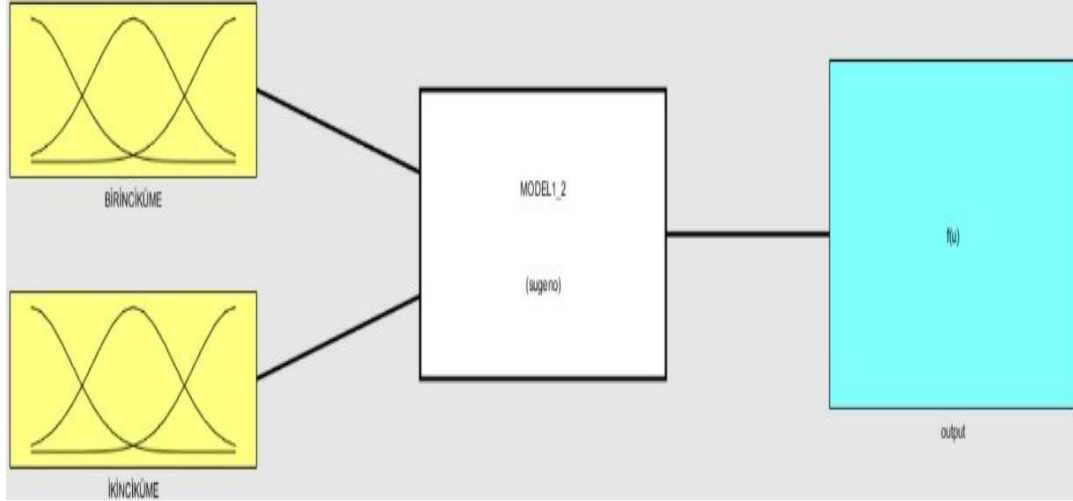
Şekil 13: KG-ANFIS Modeli için Eğitilen ANFIS Eğitim Datası ile Gerçek Sonuçlarının Karşılaştırılması



Şekil 14: KG-ANFIS Modeli için Eğitilen ANFIS Test Datası ile Gerçek Sonuçlarının Karşılaştırılması

Şekil 13 ve Şekil 14, eğitim ve test verilerinin gerçek veriler ile karşılaştırılmasını göstermektedir. Şekil 13’ de altta kalan mavi ile gösterilen içi boş yuvarlaklar gerçek eğitim verilerini, Şekil 14’ de ise altta kalan mavi noktalar gerçek test verilerini ifade etmektedir. Her iki şekildeki kırmızı ile gösterilen sırası ile ANFIS’ in sırasıyla eğitim çıktılarını ve test çıktılarını göstermektedir.

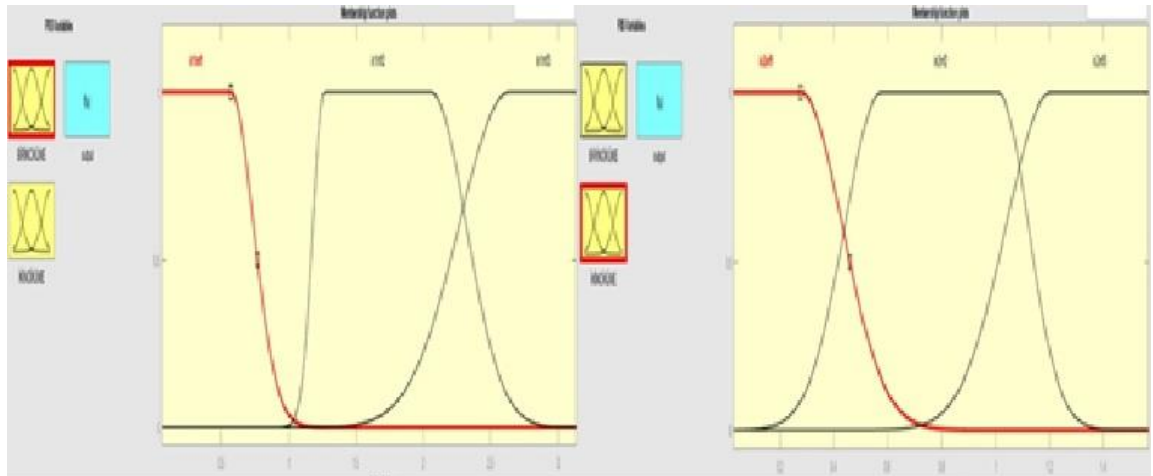
ANFIS’ in eğitim dataları ile test dataları karşılaştırıldığında gerçek çıktılara çok yakın olduğu, eğitim datasının ortalama hata değerinin 0,0089805 ve test datasının ortalama hata değeri ise 0,25635 olduğu gözlenmektedir. Dolayısıyla bu modelde kullanılan diğer iki yöntemin ANFIS’ i ne kadar verimli hale getirdiği görülmektedir.



Şekil 15. KG-ANFIS Modelinin Sugeno Bulanık Çıkarım Sistemi

Şekil 15, Sugeno Bulanık Çıkarım Sistem modelini göstermektedir. Birinci Dereceden Sugeno Bulanık Çıkarım Sistemi kullanılan modelde her iki girdi için en uygun üyelik fonksiyon sayıları 3 değeri ve en uygun üyelik fonksiyonu ise gauss2mf olarak tespit edilmiştir. Kullanılan üyelik fonksiyonu gauss üyelik fonksiyonun bileşimidir. Matematiksel ifadesinin gösterimi ve Şekil 16’ da girdi parametrelerinin üyelik fonksiyon gösterimi aşağıda verilmiştir.

$$\text{gauss2mf} = \mu(x; m, \sigma) = e^{\exp\left(\frac{-(x-m)^2}{2\sigma^2}\right)} \quad (23)$$



Şekil 16. KG-ANFIS Modeli için Girdi Parametrelerin Üyelik Fonksiyon Gösterimi

Bulanık çıkarım sistemi için girdi parametreleri dilsel olarak ‘BİRİNCİKÜME’ ve ‘İKİNCİKÜME’ şeklinde belirtilmiştir. ‘BİRİNCİKÜME’, GA’ dan gelen 1. Küme optimum girdi parametresini, ‘İKİNCİKÜME’ ise GA’ dan gelen 2. Küme optimum girdi parametresini temsil etmektedir. Şekil 16, bu iki girdi parametresinin eğitimden önceki atanan 3 üyelik fonksiyonunun her bir girdisi için grafiği gösterilmektedir.

Aynı iterasyon sayısı ve üyelik dereceleri ile yapılan diğer üyelik fonksiyonları için çıkan hata değerleri Tablo 6’ da gösterilmektedir.

Tablo 6. KG-ANFIS Modeli için Diğer Üyelik Fonksiyon Değerleri

ÜYELİK FONKSİYONLARI	EĞİTİM HATA DEĞERLERİ
trimf	0,07075
trapmf	0,038326
gbellmf	0,033859
gaussmf	0,02919
Pimf	0,025791
dsigmf	0,026658
psigmf	0,026658

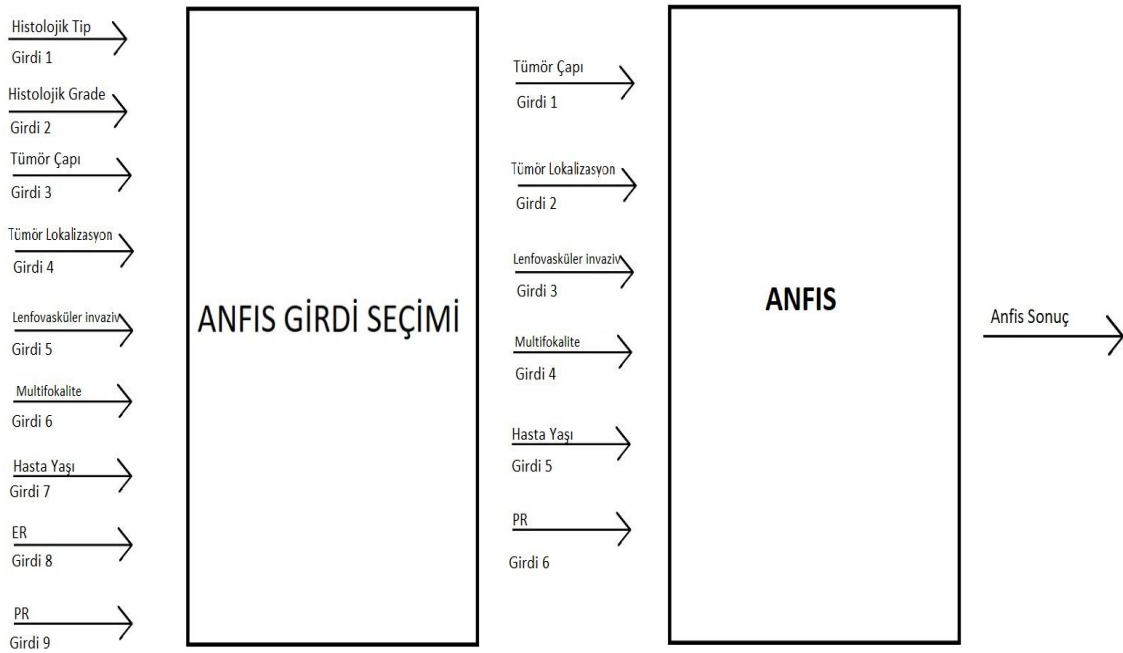
Genetik algoritmanın sonuçları kullanıldığı için kural tabanındaki her bir ifade MATLAB' in isimlendirmesi şeklinde kalmıştır. Üyelik fonksiyonlarının derecelerine göre modelin kural yapısı Şekil 17’ de ki gibidir. Girdi parametre sayısının az olmasıyla modelde 9 kural oluşmuştur. Bu da modelin hata değerinin düşük ve verimli bir şekilde çalışmasını sağlamıştır.

1. If (BİRİNCİKÜME is in1mf1) and (İKİNCİKÜME is in2mf1) then (output is out1mf1) (1)
2. If (BİRİNCİKÜME is in1mf1) and (İKİNCİKÜME is in2mf2) then (output is out1mf2) (1)
3. If (BİRİNCİKÜME is in1mf1) and (İKİNCİKÜME is in2mf3) then (output is out1mf3) (1)
4. If (BİRİNCİKÜME is in1mf2) and (İKİNCİKÜME is in2mf1) then (output is out1mf4) (1)
5. If (BİRİNCİKÜME is in1mf2) and (İKİNCİKÜME is in2mf2) then (output is out1mf5) (1)
6. If (BİRİNCİKÜME is in1mf2) and (İKİNCİKÜME is in2mf3) then (output is out1mf6) (1)
7. If (BİRİNCİKÜME is in1mf3) and (İKİNCİKÜME is in2mf1) then (output is out1mf7) (1)
8. If (BİRİNCİKÜME is in1mf3) and (İKİNCİKÜME is in2mf2) then (output is out1mf8) (1)
9. If (BİRİNCİKÜME is in1mf3) and (İKİNCİKÜME is in2mf3) then (output is out1mf9) (1)

Şekil 17. KG-ANFIS Modeli İçin EĞER-İSE Kural Görünümü

Genetik algoritmanın sonuçları kullanıldığı için kural tabanındaki her bir ifade MATLAB' in isimlendirmesi şeklinde kalmıştır. Her bir girdi parametresi için 9 kural elde edilmiştir.

1.2. AG-ANFIS Modeli



Şekil 18. AG-ANFIS Modeli

Gerçek dünyada bir uygulamanın modellenmesinde problem çözümü için çoğunlukla birçok girdi değişkenleri var olabilir. Uygulamanın potansiyelini ve hızını arttırmak amacıyla, çıktıya en çok etki eden girdi değişkenlerine öncelik verilmesi

gerekir. Bu sebeple, çalışmanın bu modelinde en etkili girdi parametreleri ile karmaşıklığı azaltmak ve problem çözümünde potansiyeli arttırmak amacı ile 1996 yılında, Jang tarafından ortaya konulmuş ANFIS Girdi Seçimi Yaklaşımı ile ANFIS modelinde tahminleme yapılmıştır. Şekil 18’ de bu modelin mimarisi gösterilmektedir.

Jang, ANFIS Girdi Seçimi Yaklaşımı’ nı çalışmasında doğrusal olmayan iki uygulamada kullanmıştır. ANFIS modelinde problemlerin çok girdili olması halinde üyelik fonksiyonların ve kuralların sayısı artmasıyla problemin karmaşıklığı artar ve uygulanabilirliği azalır. Bu nedenle Jang, potansiyeli fazla olan girdilerin önceliklerini hızlı bir şekilde belirlemek ve bu parametreleri uygun bir şekilde kullanmak amacıyla bu yöntemi önermiştir.


ANFIS Girdi Seçimi Yaklaşımı, veri setinden eğitim için seçilmek istenen kriter ve veri setinde bulunan özelliklerin yapacağı kombinasyon ile oluşacak her bir durum için ANFIS’ in bir iterasyon eğitimi ile seçilen kriterlerin en küçük hatalı olanı bulmasıyla girdi seçimi işlemi sonlanmaktadır.

Bu modelin önceki modelden farkı, girdi parametrelerin çıktı parametrelerine bağımlı olarak en iyi şekilde ANFIS eğitimine sokulmasıdır. Modelin amacı, veri setindeki bütün parametreleri kullanmak yerine modelin verimli çalışabilmesi için sonuca en etkili olan parametrelerle verimliliği arttırmaktır.

1.2.1. AG-ANFIS Modeli ve Uygulaması

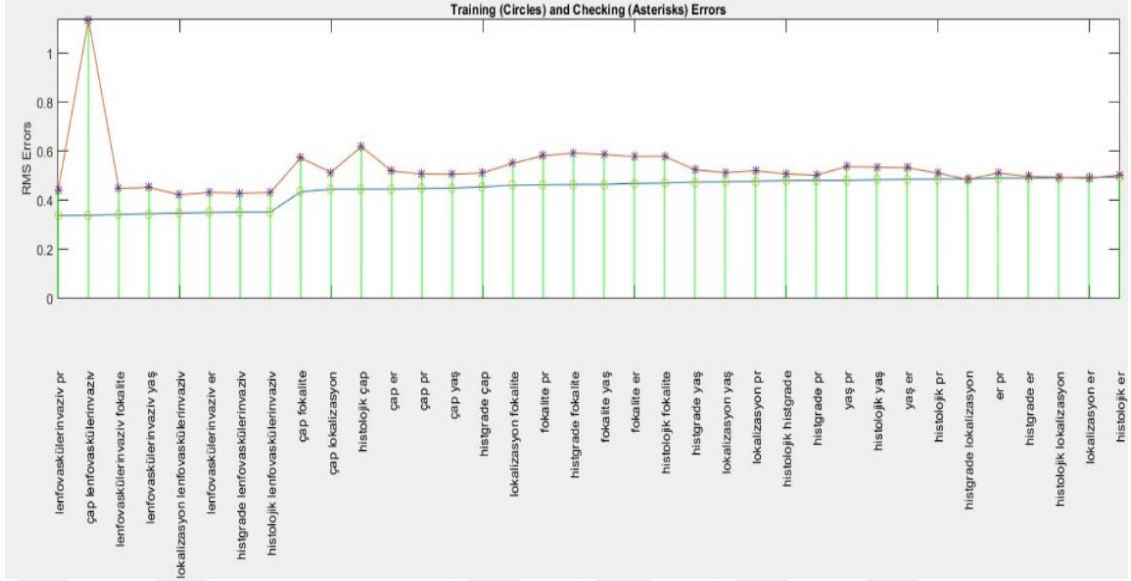
Uygulama, normalize edilmiş, 9 parametrelili ve 203 hasta verisinden oluşan veri setinin %70’ i eğitim ve %30’ u ise test dataseti olarak ayrılmış ve girdilerin belirlenmesi işlemi ile başlanmıştır. MATLAB programında eğitilecek olan model, ANFIS girdi seçimi yöntemi ile çıktı parametresine en çok etki eden girdi parametreleri belirlenmiştir.

İlk aşamada çıktı parametresine en çok etki eden girdi parametreleri tek tek ele alınmıştır. Daha sonra 2' li ve 3' lü kombinasyon şeklinde ele alınarak 9 girdi parametresi arasından önceliği fazla olan 3 girdi parametresi seçilmiştir.



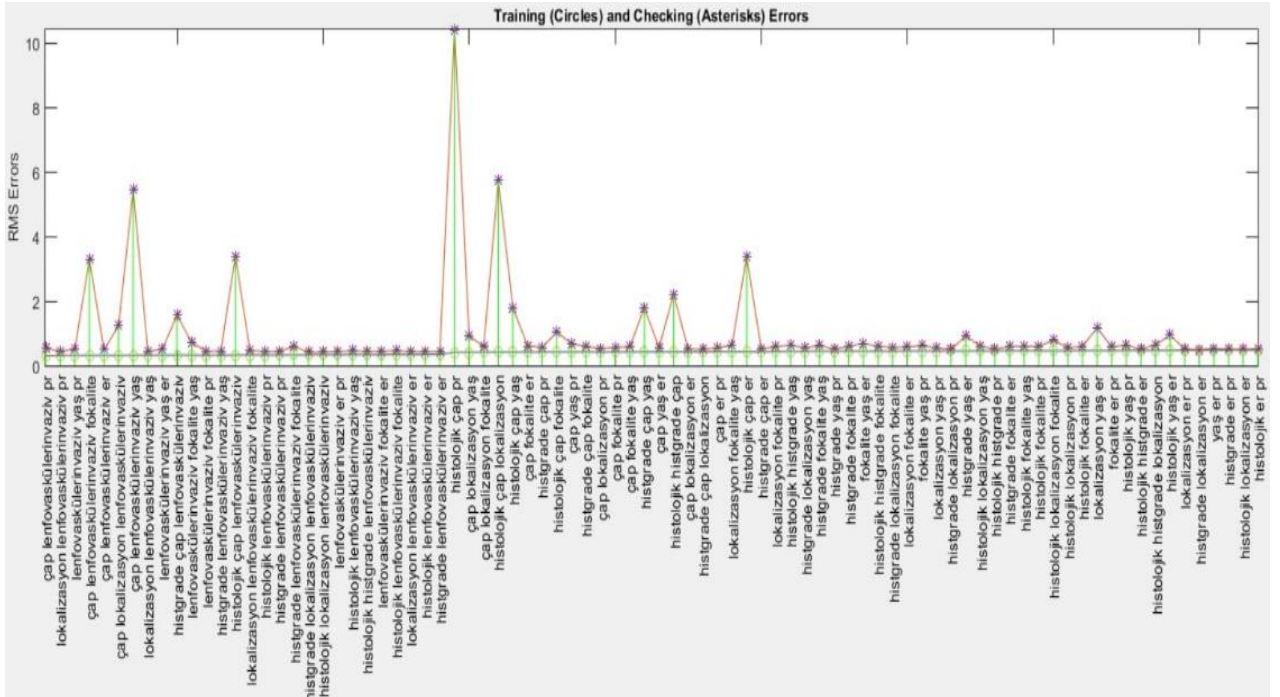
Şekil 19. 1. Aşama Tek Girdi Kombinasyonu Hata Düzeyi

Şekil 19, her bir girdi parametrenin, çıktı parametresine etkisini grafik üzerinde göstermektedir. Grafikte girdi parametrelerinin hata oranı incelendiğinde 'lenfovaskülerin vaziv' en düşük hataya sahip olduğu gözlenmektedir. Bir başka deyişle çıktı üzerinde en etkili girdi parametresi için 'lenfovaskülerin vaziv' olduğunu diyebiliriz. Grafikte eğitim datasının hata büyüklüğü çemberli ifade ile test datasının hata büyüklüğü ise yıldızlı ifade ile tanımlanmaktadır.



Şekil 20. 1. Aşama İki Girdi Kombinasyonu Hata Düzeyi

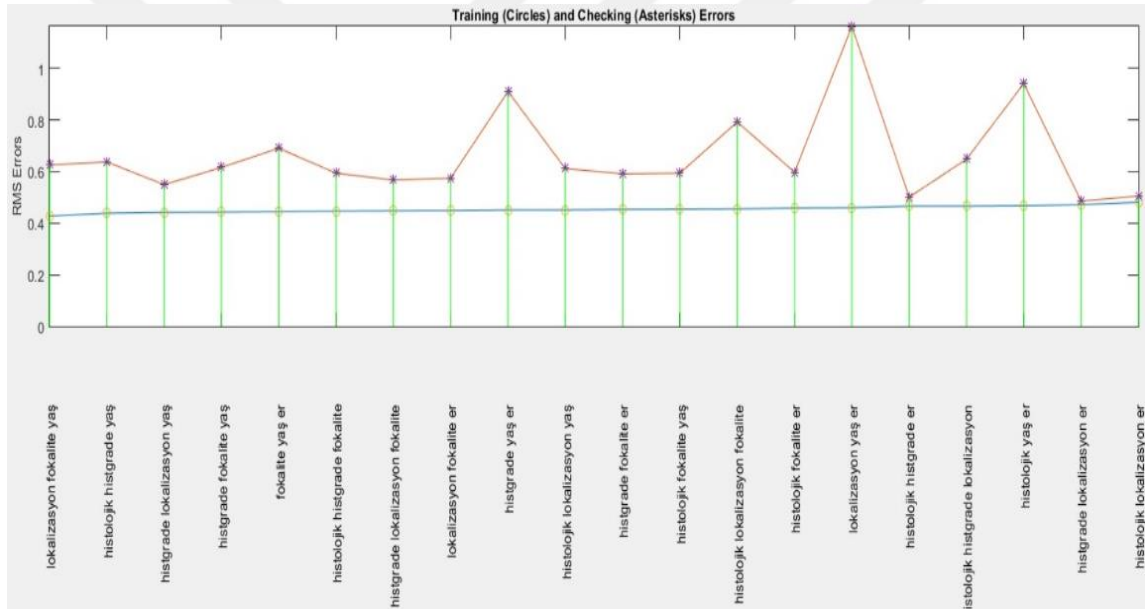
Şekil 20, girdi parametrelerinin 2' li kombinasyonu için, aksiller lenf nodu tutulumuna etkisini göstermektedir. Grafikte hata oranları incelendiğinde 'lenfovaskülerinvaziv' girdi parametresini, 'pr' takip etmektedir. Dolayısıyla en düşük hata oranına sahip ve çıktıya en çok etki eden girdi parametreleri 'lenfovaskülerinvaziv' ve 'pr' olarak gözlenmektedir.



Şekil 21. 1. Aşama Üç Girdi Kombinasyonu Hata Düzeyi

Şekil 21, girdi parametrelerinin 3' lü kombinasyonunu göstermektedir. Grafikte aksiller lenf nodu tutulumuna en etkili girdi parametreleri olarak 'lenfovaskülerinvaziv' ve 'pr' ' yi 'çap' takip etmektedir.

Birinci aşamada 'çap', 'lenfovaskülerinvaziv' ve 'pr' girdi parametreleri ANFIS eğitimi için ayrılmış ve ikinci aşama için bu üç girdi parametre veri setinden çıkartılarak kalan 6 parametre için yukarıda yapılan işlemler tekrar yapılmıştır. Bunun nedeni hastalık teşhisi için 3 girdi parametresi ile çalışmak gerçekçi ve ANFIS eğitiminin başarısı için yeterli bulunmamıştır. ANFIS' de bulunan bu 3 parametre eğitilmiş ve hata oranı çok fazla çıkmıştır. Dolayısıyla geri kalan 6 girdi parametresi ve 203 hasta veriden oluşan yeni veri seti tekrar %70' i eğitim ve %30' u test için ayrılmıştır.



Şekil 22. 2. Aşama Üç Girdi Kombinasyonu Hata Düzeyi

Şekil 22, incelendiğinde grafikte girdi parametrelerinin 3' lü kombinasyonu için 'lokalisasyon', 'fokalite' ve 'yaş' girdileri, çıktı için en etkili girdi parametreleri olarak bulunmuştur.

Bu üç parametrenin çıktı için hata oranları diğer kombinasyonlara göre daha düşük bulunmuştur. Ayrıca bu üç parametre için her birini tek tek ve 2' li kombinasyonlarla yapıldığında en düşük hata oranına 3' lü kombinasyon olarak tespit


edilmiştir. 'lokalizasyon', 'fokalite' ve 'yaş' için eğitim RMSE değeri= 0,4272, test RMSE değeri=0,6253 olarak en uygun girdi parametreleri 2.aşama için bulunmuştur.

ANFIS Girdi Seçimi ile bulunan RMSE değerleri ile birlikte Tablo 7' de gösterilmektedir. Bu iki aşamanın sonunda ANFIS eğitimi için kullanılacak girdi parametreleri ANFIS Girdi Seçimi Yöntemi ile model için verimli 6 girdi parametre ile yeni veri seti oluşturulmuştur.

Tablo 7. Verimli Bulunan 6 Parametrenin Eğitim ve Test Datalarının RMSE Değerleri

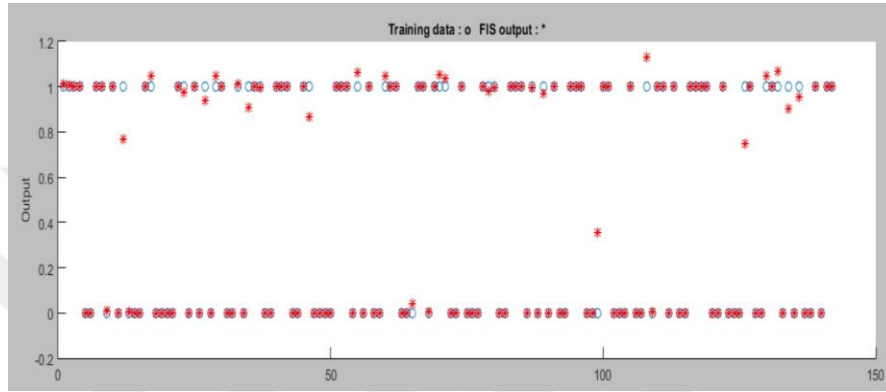
	1. AŞAMA			2.AŞAMA	
	Eğitim RMSE	Test RMSE		Eğitim RMSE	Test RMSE
lenfovaskülerinvaziv	0,3513	0,4269	fokalite	0,4703	0,571
lenfovaskülerinvaziv - pr	0,3354	0,4373	Lokalizasyon - fokalite	0,4586	0,549
lenfovaskülerinvaziv – pr - çap	0,3026	0,5329	Lokalizasyon – fokalite- yaş	0,4272	0,6253

Yukarıdaki iki aşamanın sonunda ANFIS tahmin modeli için eğitilecek veri seti 6 girdi parametresine ve 203 hasta verisine sahip olarak hazırlanmıştır. Kullanılacak eğitim ve test dataları tekrar aynı şekilde %70' i eğitim, %30' u ise test için ayrılarak modele ait bazı işlemler yapılmıştır.




Şekil 23. AG-ANFIS Modelinde ANFIS Eğitiminin Hata Grafiği

Şekil 23' AG-ANFIS modelinin ANFIS' de kaç iterasyon (epoch) sayısı ile eğitildiğini ve ANFIS eğitiminin hata grafiği gösterilmektedir. Grafik yaklaşık 26. iterasyondan sonra hata oranının aynı değerde kalacağını yani eğitim işleminin durduğunu ifade etmektedir. Dolayısıyla çalışmada iterasyon değeri 30 olarak alınmıştır. Modelin 30 iterasyonda eğitim verilerinin hata büyüklüğü 0,048068 olarak tespit edilmiştir.




Şekil 24. AG-ANFIS Modeli için Eğitilen ANFIS Eğitim Datası ile Gerçek Sonuçlarının Karşılaştırılması



Şekil 25. AG-ANFIS Modeli için Eğitilen ANFIS Test Datası ile Gerçek Sonuçlarının Karşılaştırılması

Şekil 24' de ve Şekil 25' de eğitim sonuçları ile test sonuçlarının gerçek sonuçlar ile karşılaştırılması yapılmıştır. ANFIS' in eğitim dataları ile test dataları karşılaştırıldığında eğitim datasının gerçek çıktılara çok yakın olduğu görülmektedir. Eğitim datasının ortalama hata değerinin 0,048068 ve test datasının ortalama hata değeri ise 0,82754 olduğu tespit edilmiştir. Test sonuçları, eğitim sonuçlarına göre


başarısız çıkmıştır ve bu model önceki modele göre uygulama için verimi düşük kalmıştır. Bunun nedeni bu model için ANFIS' de eğitilen girdi parametrelerinin ve kural sayısının daha fazla olmasından kaynaklanmaktadır.



Şekil 26. AG-ANFIS Modelinin Sugeno Bulanık Çıkarım Sistemi

Modelde Birinci Dereceden Sugeno Bulanık Çıkarım Sistemi kullanılmıştır ve Şekil 26, AG-ANFIS modelinin Sugeno Bulanık Çıkarım Sistem modeli gösterilmektedir.

Modelde esas teşkil eden girdi parametreleri dilsel ifadeler ile bulanık çıkarım sisteminde ifade edilmiştir. Model için MATLAB' de bütün üyelik fonksiyonları denenmiş ve en iyi sonucun Gauss üyelik fonksiyonu olduğu ve en az hata oranını verdiği tespit edilmiştir. ANFIS' in uzman görüşü almadan oluşturacağı kurallar için üyelik değerleri çalışmada tavsiyesi alınan uzman doktor ile ' 3 5 2 2 2 2 ' olarak belirlenmiştir. Bunun nedeni kullanılacak girdi parametrelerinin olası ihtimalleri ile kural tabanını oluşturabilmesidir. ANFIS modelinin gerçek dünya problemine uygun bir kural tabanı oluşturulması için bu yol izlenmiştir. Modelin sonucuna etki eden her bir kriterin üyelik fonksiyonları aldığı değer aralıklarına göre Şekil 27' de görüldüğü gibi tanımlanmıştır.



Şekil 27. AG-ANFIS Modeli için Girdi Parametrelerin Üyelik Fonksiyon Gösterimi


Aynı iterasyon sayısı ve üyelik dereceleri ile yapılan diğer üyelik fonksiyonları için çıkan hata değerleri Tablo 8’ de gösterilmektedir.

Tablo 8. AG-ANFIS Modeli için Diğer Üyelik Fonksiyon Değerleri

ÜYELİK FONKSİYONLARI	EĞİTİM HATA DEĞERLERİ
trimf	0,077013
trapmf	0,072765
gbellmf	0,061462
gauss2mf	0,056762
pimf	0,065605
dsigmf	0,056947
psigmf	0,056947

Birinci Dereceden Sugeno Bulanık Çıkarım modelinde kurulan ANFIS’ de uzman görüşü alınmadan her bir kriteri için toplam 240 kural elde edilmiştir. ANFIS eğitimi için en iyi Sugeno modeli bu işlemler ile oluşturulmuş ve çalışma sonlanmıştır. Modelin “EĞER-İSE” kural görünümü Ek 1’ de gösterilmektedir.

1.3. YSA Modeli



Şekil 28. YSA Modeli

Bu modeli önceki modellerden farklı kılan, veri setinde bulunan 9 girdi parametrenin değerleri normalize işlemi dışında sınıflandırma gibi başka bir işlemden geçmeden eğitilmesidir. Amaç, bütün parametrelerin tek bir öğrenme algoritması ile gerçek çıktıya nasıl yakınsayacağını gözlemlemektir. Modelin eğitimi için Çok Katmanlı YSA kullanılmaktadır. Şekil 28’ de bu modelin mimarisi gösterilmektedir.

1.3.1. YSA Modeli ve Uygulaması


YSA modeli için gerçekleştirilen eğitim ve test işlemleri MATLAB ortamında yapılmıştır. Bu modelde normalize edilen veri setinin 9 girdi parametresi ve 1 çıktı parametresi ile YSA modeli kurulmuştur. 203 hasta verisinden oluşan veri setinin %70’ i eğitim, %30’ u ise test işlemi için ayrılmıştır.

YSA modelinde, Çok Katmanlı İleri Beslemeli Geriye Yayılım (feed-forward backpropagation) ağ tipi kullanılmıştır. Ağın eğitimi için Levenberg-Marquardt

(trainlm) öğrenme algoritması ve öğrenme amacıyla kullanılan adaptasyon öğrenme algoritması Gradient Descent with Momentum Weight and Bias Learning Function (learn_gdm) kullanılmıştır. Modelde ağın performans fonksiyonu olarak Hata Kare Ortalaması (Mean Squared Error) kullanılmıştır. Bu model için kullanılan transfer (aktivasyon) fonksiyonu Hiperbolik tanjant sigmoid fonksiyonu (tansig) fonksiyonudur.

YSA modelinin ağ mimarisinde gizli katman için katman sayısı ve gizli katmandaki nöron sayıları MATLAB programı üzerinde değiştirilebilmektedir ve deneme yanılma yoluyla modelin en iyi sonucuna ulaşana kadar parametreler düzenlenmiştir.

Modelde iterasyon değeri (epoch) 1000 ve durdurma kriteri olarak minimum hata değeri 0,001, minimum performans gradyan değeri 10^{-7} değerleri verilmiştir. Ağ belli bir iterasyon değerine geldiğinde, ağa verilen minimum hata değerine veya minimum gradyan değerine ulaştığında ağın eğitimi durmaktadır.



Şekil 29. Tansig Algoritması ile Mse Hata Performansı için Regresyon Analizi

Şekil 29, modelde kullanılan tansig fonksiyonu ile hata performansı için oluşan regresyon analizi grafikleri gösterilmektedir. R = 0,84601 modelin eğitimini, R = 0,76076 testini, R = 0,92087 validasyonu ve R = 0,84448 bütün sonucu göstermektedir.

2. ÖNERİLEN YÖNTEMLERİN KARŞILAŞTIRILMASI

Modellerin karşılaştırılması için yapılan işlemler SPSS programı ile yapılmıştır. Çalışmada kullanılan veri setinde %48,8’inde (n=99) meme kanseri lenf nodu durumu negatifken, %51,2’sinde (n=104) meme kanseri lenf bezi durumu pozitif görülmektedir. Önerilen modeller tıp alanında çok kullanılan tanı testleri ile karşılaştırılacaktır. Fakat tanı testi için önerilen üç modelin sonuçları normal dağılıma uymadığı saptanmıştır. Dolayısıyla normal dağılıma uymayan sonuçlar için (+) pozitif hasta ve (-) negatif hasta grupları Man Whitney U Testi ile aralarında anlamlı farklılıkların olup olmaması değerlendirilmiştir. Normal dağılım göstermeyen verilerin iki grup karşılaştırmalarında Mann Whitney U testi kullanılır. Bu test, grupların genellikle medyan değerlerini karşılaştırmaktadır ve çalışma için yapılan iki grubun ortanca (medya) değerleri bulunup test edilmiştir. Bu değerlendirmenin sonucunda iki grup arasında medyanlar açısından istatistiksel olarak anlamlı farklılıklar saptanmıştır ve Tablo 9’ da değerleri ile gösterilmektedir. Her üç model de meme kanseri lenf nodu durumu pozitif olanların değerleri daha yüksek çıkmıştır.

Tablo 9. Man Whitney U Test Sonuçları

		HASTA (-) (n=99; %48,8)	HASTA (+) (n=104; %51,2)
YSA	<i>Min-Mak</i>	0,001– 1,000	0,001– 0,999 (0,846)
	<i>(Medyan)</i>	(0,036)	
	<i>Ort±Ss</i>	0,23±0,30	0,77±0,25
KG- ANFIS	<i>Min-Mak</i>	-0,14– 1,667	0,661– 1,029 (0,999)
	<i>(Medyan)</i>	(0,001)	
	<i>Ort±Ss</i>	0,028±0,194	0,993±0,047
AG- ANFIS	<i>Min-Mak</i>	-0,130– 2,833	-0,364– 2511 (0,999)
	<i>(Medyan)</i>	(0,001)	
	<i>Ort±Ss</i>	0,157±0,453	0,902±0,422

Bu anlamlılıktan yola çıkarak YSA, KG-ANFIS ve AG-ANFIS modelleri için cut off noktası hesaplanması yapılmıştır. Meme kanseri lenf nodu tutulum durumunun varlığına göre cut off (kesme değeri) noktasını saptamada Receiver Operating Characteristic (ROC) analizi- ROC eğrisi ve tanı testleri (duyarlılık, özgüllük, doğruluk, pozitif kestirim değeri (PKD), negatif kestirim değeri (NKD)) kullanılmıştır.

Tıpta çok fazla kullanılan bir terim olan cut off, ayırım değeri veya kesme değeri olarak bilinir. Hastalığın hangi düzeyde pozitiflik veya negatiflik gösterdiği belli değildir ve bu cut off değeri hastalığın hangi düzeyde olduğunu belirlemek için kullanılmaktadır. Yapılan her çalışma için değişen cut off değeri, sonuçların kesme değerinin üstünde kalan değerler (+) hastaları, altında kalan değerler ise (-) değerini göstermektedir.

Tablo 10. Tanı Testi İçin Sınıflandırma Modeli

	(-) HASTA	(+)HASTA
T(-)	Doğru Negatif(DN)	Yanlış Negatif(YN)
T(+)	Yanlış Pozitif(YP)	Doğru Pozitif(DP)

Tablo 10' da tan testi için kullanılan sınıflandırmayı göstermektedir. Tanı testleri, Tablo 10' da gösterildiği gibi oluşturulan sınıflandırma ile aldığı değerlerin sonuçların değerlerine göre duyarlılık, özgüllük, doğruluk pozitif kestirim test ve negatif kestirim oranları bulunmaktadır ve bulunan değerler çalışmanın güvenilirliğini ve verimliliğini test etmektedir. Tıpta kullanılan bu testler hastalığa tanı koymadaki güvenilirliği arttırmaktadır. Tanı testi için kullanılan tanımları ile birlikte formülleri aşağıda belirtildiği gibidir (Karakış, 2009), (Dirican 2001).

Duyarlılık: Gerçek hastalar içinden testin hastaları belirleyebilme özelliğidir.

$$DP / (DP + YN) \quad (24)$$

Özgüllük: Gerçek sağlamlar içinden testin sağlamları belirleyebilme özelliğidir.

$$DN / (DN + YP) \quad (25)$$

Doğruluk: Testin hastaları hasta, hasta olmayanları ise hasta değil şeklinde sınıflandırma oranıdır.

$$(DP + DN) / N \quad (26)$$

Pozitif Kestirim Değeri (PKD): Test pozitif (hasta) sonucu verdiği zaman, sonucun gerçekten hasta olması durumunun koşullu olasılığının ölçüsüdür.

$$DP / (DP + YP) \quad (27)$$

Negatif Kestirim Değeri (NKD): Test negatif (sağlam) sonucu verdiği zaman, sonucun gerçekten sağlıklı olma olasılığıdır.


$$DN / (DN + YN) \quad (28)$$

ROC eğrisi ise bulunan hata testlerinin sonuçları ile gerçek sonuçların grafiksel gösterimidir. Eğimin altında kalan bölge testin etkinliğini veya başarısını göstermektedir. Ayrıca ROC eğrisi, her bir nokta için verdiği değerler ile çalışmanın cutt of değeri bulunmaktadır.

2.1. YSA Modeli Karşılaştırılması

YSA modeli için cut off noktası 0,563 ve üzeri olarak saptanmıştır. Bu modelin 0,563 kesme değeri için; duyarlılık %90,38, özgüllük %78,79, pozitif kestirim değeri %81,74, negatif kestirim değeri %88,64 ve doğruluk %84,73' dür.

Şekil 30' YSA modelinin ROC eğrisi gösterilmektedir. Elde edilen ROC eğrisinde altta kalan alan %89,3 standart hatası %2,4 olarak saptanmıştır.



Şekil 30. YSA Modelinin ROC eğrisi

Tablo 11. YSA Modelinin Pearson Ki-Kare Test Sonuçları

		YSA			
		< 0,563		≥ 0,563	
		n	%	n	%
TEST SONUCU	(-)	78	78,8	21	21,2
	(+)	10	9,6	94	90,4

Gerçek data ile YSA model düzeyinin 0,563 kesme değeri arasında istatistiksel olarak anlamlı ilişki saptanmıştır.


Tablo 11, Tablo 12 ve Tablo 13’ de Pearson Ki-Kare Test gösterilmektedir. Nitel verilerin karşılaştırılmasında kullanılmaktadır. İstatistiksel nitelik hakkındadır. Tablo 11, cut off değerlerinin altında kalan hasta değerleri ile üstünde kalan hasta değerlerinin kaç tanesinde yanlış saptama olduğunu göstermektedir. (Tablo 12 ve Tablo 13 aynı şekilde belirtmektedir.)

0,563 cut off değerinin üzerinde olan 115 hasta bulunmaktadır. 94 tanesi doğru bulunmuşken 21 hasta yanlış teşhis edilmiştir. Altında kalan 88 hastanın 78’ i doğru tespit edilmiştir.

2.2. KG-ANFIS Modeli Karşılaştırılması

KG-ANFIS modeli için cut off noktası 0,661 ve üzeri olarak saptanmıştır. Bu modelin 0,661 kesme değeri için; duyarlılık %100, özgüllük %97,98, pozitif kestirim değeri %98,11, negatif kestirim değeri %100 ve doğruluk %99,01' dir.

Şekil 31' KG-ANFIS modelinin ROC eğrisi gösterilmektedir. Elde edilen ROC eğrisinde altta kalan alan %98,5 standart hatası %1,1 olarak saptanmıştır.



Şekil 31. KG-ANFIS Modelinin ROC eğrisi

Tablo 12. KG-ANFIS Modelinin Pearson Ki-Kare Test Sonuçları

		KG-ANFIS			
		< 0,661		≥ 0,661	
		n	%	n	%
TEST SONUCU	(-)	97	98,0	2	2,0
	(+)	0	0	104	100


Geçek data ile KG model düzeyinin 0,661 kesme değeri arasında istatistiksel olarak anlamlı ilişki saptanmıştır.

0,661 cut off deęerinin üzerinde olan 106 hasta bulunmaktadır. 104 tanesi doęru bulunmuşken 2 hasta yanlış teşhis edilmiştir. Altında kalan 97 hastanın ise tamamı doęru saptanmıştır.

2.3. AG-ANFIS Modeli Karşılaştırılması

AG-ANFIS modeli için cut off noktası 0,387 ve üzeri olarak saptanmıştır. AG-ANFIS model düzeyinin 0,387 kesme deęeri için; duyarlılık %89,42, özgüllük %89,90, pozitif kestirim deęeri %90,29, negatif kestirim deęeri %89,00 ve doęruluk %89,66'dır.

Şekil 32' AG-ANFIS modelinin ROC eğrisi gösterilmektedir. Elde edilen ROC eğrisinde altta kalan alan %89,2 standart hatası %2,9 olarak saptanmıştır



Şekil 32. AG-ANFIS Modelinin ROC Eğrisi

Tablo 13. AG-ANFIS Modelinin Pearson Ki-Kare Test

		EXH-ANFİS			
		< 0,387		≥ 0,387	
		n	%	n	%
Meme CA	(-)	89	89,9	10	10,1
	(+)	11	10,6	93	89,4

0,387 cut off değerinin üzeri olan 103 hasta bulunmaktadır. 93 tanesi doğru bulunmuşken 10 hasta yanlış teşhis edilmiştir. Altında kalan 100 hastanın 89' u doğru tespit edilmiştir. Bütün modeller için yapılan tanı testi ve ROC eğrisi sonuçları Tablo 14' de gösterilmektedir.

Tablo 14. Tanı Testi ve ROC Eğrisi Sonuçları

	Tanı Tarama				ROC Eğrisi			95% Güven Aralığı
	Cut off	Doğruluk	Duyarlılık	Özgüllük	Pozitif Kestirim Değeri	Negatif Kestirim Değeri	Alan	
YSA	≥0,563	%84,73	%90,38	%78,79	%81,71	%88,64	0,893	847-0,939
KG- ANFİS	≥0,661	%99,01	%100	%97,98	%98,11	%100	0,985	963-1,000
AG- ANFİS	≥0,387	%89,66	%89,42	%89,90	%90,29	%89,00	0,892	836-0,948

SONUÇ

Bu çalışma, İstanbul Gaziosmanpaşa Taksim Eğitim ve Araştırma Hastanesi'ne ait 203 meme kanserli hastanın lenf nodu durumunu içeren hasta verileri ile çalışılmıştır. Çalışmada kullanılan veriler klinik ve patolojik bilgilerinden oluşan hasta verilerinin koltuk altı lenf nodu durumunu farklı Yapay Zeka yöntemleri ile tahminlemesi yapılmış ve başarıları kıyaslanmıştır. Uzman doktor tarafından belirlenen girdi bilgileri ile Yapay Zeka modelleri oluşturulmuş ve etkileri Yapay Zeka'nın farklı yöntemleri ile analiz edilmiştir.

Çalışmada kullanılan iki hibrit modelde ANFIS' in çıktı verileri olmadan oluşturulan girdi değerleri ile çıktı verilerine bağımlı olarak oluşturulan girdi değerleri iki ayrı modelde kullanılarak meme kanseri teşhisi için nasıl sonuçlar doğuracağı üzerinde durulmuştur. Ayrıca kullanılan temel bir YSA modeli ile diğer modellere göre verimliliği test edilmiştir. Oluşturulan modellerin sonuçları ROC analizi ve tanı testleriyle duyarlılık, özgüllük, doğruluk, pozitif ve negatif kestirim oranlarının farkları üzerinde durulmuş ve kıyaslamalar yapılmıştır.

Çalışmanın birinci modeli olan KG-ANFIS modelinde, YSA'nın danışmansız öğrenme algoritmalarından biri olan K-Means algoritması ile girdi verileri kümelere ayrıştırılmıştır. Oluşan kümeler ayrı olarak sezgisel bir yöntem olan GA ile optimize edilerek ANFIS eğitimi için iyileştirilmiştir. Yapay Zeka yöntemlerinden olan YSA, GA ve ANFIS yöntemleri oluşturulan bu hibrit model ile yapılan işlemlerin sonucunda hata oranları düşük çıkmış ve modeli kanser teşhisi için verimli kılmıştır. Fazla girdi parametreleri ile düşük başarılar gösterebilen ANFIS, bu model ile hastaneden alınan bütün girdi değerlerini kullanarak K-Means ve GA ile avantaja çevrilebileceği gözlenmektedir.

Diğer model olan AG-ANFIS modeli, ANFIS' in çok sayıda parametre ile başarısız sonuçlarının önüne geçebilmesi için ANFIS Girdi Seçimi Yöntemi kullanılmıştır. Diğer yöntemden farklı olarak bu modelde girdi değerleri çıktı verilerine göre analiz edilmiştir. Genel olarak sadece çıktı için verimli olan parametreler ile ANFIS eğitimi üzerinde durulan ANFIS Girdi Seçimi Yöntemi, bu çalışmada 2 aşamalı olarak kullanılmıştır. Verimli parametreleri kombinasyon yaparak

bulan ve aralarında bağlantı kuran ANFIS Girdi Seçimi kullanılarak çıktı için en verimli parametreler bulunmuştur. Verimli bulunan parametreler ANFIS' de eğitilmiş ve teşhisi yapacak ANFIS eğitimi için sonuçlar analiz edilmiştir. Yapılan işlemler diğer hibrit modele göre daha başarısız olsa da geçerli bir başarı oranı yakalamıştır. Bu çalışma için ve gerçek hayatta meme kanseri teşhisi için bütün verilerin önemli olduğu gözlenmiş ve çalışmada önerilen bu model ile bütün veriler yerine az sayıda parametrelerin kullanılabilirliği gösterilmiş olsa da KG-ANFIS modeli gibi kural sayılarının azaltılmasıyla verimliliğin daha çok artabileceği gözlenmektedir. Diğer modellerin karşılaştırılması için yapılan temel bir Çok Katmanlı YSA modeli, diğer modellere göre başarı oranı düşük çıkmıştır.

Yapılan işlemlerin tıbbi açıdan güvenilirliğinin sınanması için tanı testleri ve ROC eğrisiyle modellerin karşılaştırılması yapılmıştır. Modellerin sonuçlarının tanı testi için kullanılabilirliğini analiz edebilmek için Man Whitney U Testi yapılmıştır. Normal dağılımda olamayan sonuçların anlamlı farklılıklar olup olmasını saptamak için yapılan bu testte, tanı testlerine uygun olarak anlamlı farklılıklar bulunmuştur. Tanı testleriyle doğruluğu, duyarlılığı, özgüllüğü sınanmıştır. YSA modeli için doğruluk oranı %84,73, duyarlılık oranı %90,38, özgüllüğü %78,79 bulunmuştur. KG-ANFIS modeli için doğruluk oranı %99,01, duyarlılık oranı %100, özgüllüğü %97,98 bulunmuştur. AG-ANFIS doğruluk oranı %89,66, duyarlılık oranı %89,42, özgüllüğü %89,90 bulunmuştur.

Önerilen üç modelin tanı testinin sonuçlarına göre çalışma için kullanılabilir olduğu gözlenmektedir. Bununla birlikte YSA modeli, diğer iki yöntem ile karşılaştırıldığında, iyileştirilen verilerin ANFIS eğitiminde daha etkili olduğu gözlenmektedir.

AG-ANFIS modeli, KG-ANFIS modeline göre geride kalmıştır. Tanı testlerindeki oranları düşük çıkmasa da benzer çalışmalar için farklı yöntem veya verilerle iyileştirilebilir bir model olduğu görülmektedir.

KG-ANFIS modeli, tanı testindeki başarı oranı ile kullanılan yöntemlerin ANFIS tahmini için verimliliği ve ANFIS eğitimi ile yapılacak çalışmalara önerilecek bir model olduğu ispatlanmıştır.

KAYNAKÇA

- (Çavuşoğlu), Aydan Çelebiler. «İnvaziv Meme Kanserinde 34 Genin Epigenetik İncelenmesi ve Gen Ekspresyon Analizi.» *Doktora Tezi*. İzmir: Dokuz Eylül Üniversitesi, 2015.
- Aalaei, Shokoufeh, Hadi Shahraki, Alireza Rowhanimanesh, ve Saeid Eslami. «Feature Selection Using Genetic Algorithm for Breast Cancer.» *Iranian Journal of Basic Medical Sciences* 19, no. 5 (2016): 476-482.
- Açanal, Mehmet Haşim. «Türk Müziği Enstrümanlarının Öznitelik Vektörlerinin Çıkarılması ve Yapay Sinir Ağları Kullanılarak Sınıflandırılması.» *Yüksek Lisans Tezi*. İstanbul: İstanbul Teknik Üniversitesi, 2017.
- Akkuş, Özge, ve Emre Demir. «İki Düzeyli Olasılık Modellerinde Klasik ve Meta Sezgisel Optimizasyon Tekniklerinin Performansı Üzerine Bir Çalışma.» *İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi* 15, no. 30 (2016): 107-131.
- Aksu, Gökhan, ve Cem Oktay Güzeller. *Matlab Yapay Zeka ve İstatistik Uygulamaları*. Ankara: Maya Akademi Yayınları, 2018.
- Alharbi, Abir, F Tchier, ve MM Rashidi. «Using a Genetic-Fuzzy Algorithm as a Computer Aided Breast.» *Asian Pasific Journal of Cancer Pevention* 17, no. 7 (2016): 3651-3658.
- Alhasadi, Aymen Fathalla H. «Predicting Breast Cancer By Using Artificial Neural Network.» *Yüksek Lisans Tezi*. Ankara: Atılım Üniversitesi, 2016.
- Altay, Ayça. «Genetik Algoritma ve Bir Uygulama.» *Yüksek Lisans Tezi*. İstanbul: Teknik Üniversitesi, 2007.
- Altun, Halis, Ulaş Eminoğlu, ve Bekir Sami Tezekici. «Mlp Yapay Sinir Ağlarında Öğrenme Sürecinin Aktivasyon Fonksiyonu ve İstatistiksel Değişim Gösteren Giriş Verilerine Bağımlılığı.» *ResearchGate*. Niğde: Niğde Üniversitesi, 2014.
- American Cancer Society. *Breast Cancer Stages*. <https://www.cancer.org/cancer/breast-cancer/understanding-a-breast-cancer-diagnosis/stages-of-breast-cancer.html> (erişildi: Ekim 29, 2018).

- Ankara Onkoloji Eğitim ve Araştırma Hastanesi. *Meme Kanseri*.
http://www.onkoloji.gov.tr/index.php?option=com_content&view=article&id=7339:meme-kanseri&catid=303:kanser-tuerleri&Itemid=1104 (erişildi: Ekim 5, 2018).
- Arslan, Mihriban Coşkun. «Kısıtlar Teorisi ile Maliyet-Hacim-Kar Analizlerinde Bulanık Mantık Uygulamaları.» *Doktora Tezi*. Tokat: Gaziosmanpaşa Üniversitesi, 2012.
- Badowska-Kozakiewicz, Anna M., Janusz Patera, Maria Sobol1, ve Jacek Przybylski. «The Role of Oestrogen and Progesterone Receptors in Breast Cancer – Immunohistochemical Evaluation of Oestrogen and Progesterone Receptor Expression in Invasive Breast Cancer in Women.» *Contemporary Oncology* 19, no. 3 (2015): 220-225.
- Balanica, Victor, Loan Dumitrache, Mihai Caramihai, William Rae, ve Charles Herbst. «Evaluation of Breast Cancer Risk By Using.» *Universitatea Politehnica Bucuresti Buletin Stiintific Series* 73, no. 1 (2011): 53-64.
- Belciug, Smaranda, ve Florin Gorunescu. «A Hybrid Neural Network/Genetic Algorithm Applied to Breast Cancer Detection and Recurrence.» *Expert Systems* 30, no. 3 (2013): 243-254.
- BREASTCANCER.ORG. Breast Cancer Stages.*
<https://www.breastcancer.org/symptoms/diagnosis/staging#stage0> (erişildi: Ekim 29, 2018).
- Caramihai, Mihai, Irina Severin, A Blidaru, ve Horia Balan. «Evaluation of Breast Cancer Risk By Using Fuzzy Logic.» *Proceedings of the International Conference on Applied Computer Science*. ResearchGate, 2010. 324-326.
- Civcik, Levent. «Görüntü Zenginleştirme ve Hücresel YSA Kullanılarak Meme Kanseri Teşhisi.» *Doktora Tezi*. Konya: Selçuk Üniversitesi, 2013.

- Çavuşlu, Mehmet Ali, Yaşar Becerikli, ve Cihan Karakuzu. «Levenberg-Marquardt Algoritması ile YSA Eğitiminin Donanımsal Gerçeklenmesi.» *Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi* 5, no. 1 (2012).
- Demirel, Burçin. «Meme Kanseri Tedavi Yöntemlerinin Veri Madenciliği ile Belirlenmesi.» *Yüksek Lisans*. Isparta: Süleyman Demirel Üniversitesi, 2008.
- Demirel, Özkan, Adnan Kakilli, ve Mehmet Tektaş. «Anfis ve Arma Modelleri ile Elektrik Enerjisi Yük Tahmini.» *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi* 25, no. 3 (2010): 601-610.
- Demirkıran, Fulya. «Evrimsel Algoritma İçin Uygulama Ve Geliştirme Yazılım Altyapısı.» *Yüksek Lisans Tezi*. İstanbul: İstanbul Teknik Üniversitesi, 2004.
- Dirican, Ahmet. «Tanı Testi Performanslarının Değerlendirilmesi ve Kıyaslanması.» *Cerrahpaşa Tıp Dergisi* 32, no. 1 (2001): 25-30.
- Elmas, Çetin. *Yapay Zeka Uygulamaları*. Ankara: Seçkin Yayıncılık, 2016.
- Emel, Gül Gökay, ve Çağatan Taşkın. «Genetik Algoritmalar ve Uygulama Alanları.» *İktisadi ve İdari Bilimler Fakültesi Dergisi* 21, no.1 (2002): 129-152.
- Eravcı, Deniz Boz. «Bulanık Mantık ile Silikozisin Tespit Edilmesi.» *Yüksek Lisans Tezi*. Ankara: Ankara Üniversitesi, 2016.
- Güvenç, Seyit Ahmet. «Ön Kol Yüzey Emg Sinyallerinin Örüntü Tanıma Tabanlı Analizi ve Yapay Sinir Ağları ile Sınıflandırılması.» *Yüksek Lisans Tezi*. Trabzon: Karadeniz Teknik Üniversitesi, 2014.
- Hebb, Donald O. *The Organization of Behavior: A Neuropsychological Theory*. Newyork, London: McGill Universty, 1949.
- HOSTINGDERGİ. *Yapay Zeka ve Sinir Ağları*. <https://www.hostingdergi.com.tr/yapay-zeka-ve-sinir-aglari/> (erişildi: Ocak 5, 2019).
- Işık, Meltem, ve A. Yılmaz Çamurcu. «K-Means, K-Medois VE Bulanık C-Means Algoritmalarının Uygulamalı Olarak Performanslarının Tespiti.» *İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi* 6, no. 11 (2007): 31-45.

- Karakış, Rukiye. «Yapay Sinir Ağları ve Lojistik Regresyon Yöntemleri ile Meme Kanseri Koltuk Altı Lenf Durumunun Belirlenmesi.» *Yüksek Lisans*. Ankara: Gazi Üniversitesi, 2009.
- Karakış, Rukiye, Mesut Tez, Yusuf Alper Kılıç, Yusuf Alper Kılıç, Bekir Kuru, ve İnan Güler. «A Genetic Algorithm Model Based on Artificial Neural Network for Prediction of The Axillary Lymph Node Status in Breast Cancer.» *Engineering Applications of Artificial Intelligence* 26, no. 3 (2013): 945-950.
- Kubat, Cemalettin. *Matlab Yapay Zeka ve Mühendislik Uygulamaları*. İstanbul: Pusula Yayıncılık, 2014.
- Lancashire, Lee J., Robert C. Rees, Graham R. Ball. «Identification of Transcript Signatures Predictive for Estrogen Receptor and Lymph Node Status Using a Stepwise Forward Selection Artificial Neural Network Modelling Approach.» *Artificial Intelligence in Medicine* 43, no. 2 (2008): 99-100.
- Levenberg, Kenneth. «A Method For The Solution Of Certain Problems In Least Squares.» *Quarterly of Applied Mathematics* 2, no. 2 (1944): 164-168.
- Memorial. *Meme Kanseri Tedavisi*. <https://www.memorial.com.tr/meme-kanseri/> (erişildi: Ocak 2019, 13).
- Namdev, Rajesh, Mahendra Singh Bhadoria, ve Deshdeepak Shrivastava. «Aplication Of Artificial Neural Network In Electrical Based Power Industry.» *International Journal of Advanced Research in Electrical, Electronics and Instrumentation Engineering* 2, no. 10 (2013): 4704-4711.
- Nguyen, Thanh, Saeid Nahavandi, Douglas Creighton, ve Abbas Khosravi. «Mass Spectrometry Cancer Data Classification Using Wavelets and Genetic Algorithm.» *FEBS Letters* 589, no. 24 (2015): 3879-3886.
- Öztemel, Ercan. *Yapay Sinir Ağları*. İstanbul: Papatya Yayıncılık, 2006.
- PennState Information Technology. *What is the Objective Function?*. https://www.courses.psu.edu/for/for466w_mem14/Ch11/HTML/Sec1/ch11sec1_ObjFn.htm#Top (erişildi: Ocak 9, 2019).

- Psikolojik.gen.tr. *Yapay Sinir Ağları*. <https://www.psikolojik.gen.tr/yapay-sinir-aglari.html> (erişildi: Ocak 5, 2019).
- Sağiroğlu, Şeref, Erkan Beşdok, ve Mehmet Erler. *Mühendislikte Yapay Zeka Uygulamaları-1 Yapay Sinir Ağları*. Kayseri: Ufuk Kitap Kırtasiye-Yayıncılık, 2003.
- Sepandi, Mojtaba, Maryam Taghdir, Abbas Rezaianzadeh, ve Salar Rahimikazerooni. «Assessing Breast Cancer Risk with an Artificial Neural Network.» *Asian Pacific Journal Cancer Prevention* 19, no. 4 (2017): 1017-1019.
- Şengöz, Nilgün. *Yapay Sinir Ağları*. 4 Mart 2017. <http://www.derinogrenme.com/2017/03/04/yapay-sinir-aglari/> (erişildi: Ocak 5, 2019).
- Şentürk, Zehra Karapınar, ve Arafat Şentürk. «Yapay Sinir Ağları ile Göğüs Kanseri Tahmini.» *El-Cezeri Fen ve Mühendislik Dergisi* 3, no.2 (2016): 345-350.
- Tükel, Selma. *Histolojik Derecelendirme Sistemi Nedir?*. <https://map2heal.com/guide/histolojik-derecelendirme-sistemi-nedir-905> (erişildi: Ocak 10, 2019).
- Yavuz, Selahattin, ve Muhammet Deveci. «İstatiksel Normalizasyon Tekniklerinin Yapay Sinir Ağın Performansına Etkisi.» *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi* no. 40 (2012): 167-187.
- Yıldız, Oktay. «Dna Mikrodizi Analizleri ile Meme Kanseri Hastalarında Prognozun Genetik Algoritma Kullanılarak Belirlenmesi.» *Doktora Tezi*. Ankara: Gazi Üniversitesi, 2012.
- Yılmaz, Atınç. «Sinirsel Bulanık Mantık Modeliyle Kanseri Risk Analizi.» *Doktora Tezi*. Sakarya: Sakarya Üniversitesi, 2015.
- Yılmaz, Atınç. *Yapay Zeka*. İstanbul: Kodlab, 2017.
- Yılmaz, Sakine. «Meme Epiteli ve Meme Kanseri Hücrelerinde Caytaxin Protein Ekspresyonunun Belirlenmesi.» *Yüksek Lisans*. Malatya: İnönü Üniversitesi, 2015.

Zadeh, Hossein Ghayoumi, Omid Pakdelazar, Javad Haddadnia, Gholamali Rezaifarad, ve Mohammad Mohammad-Zadeh. «Diagnosing Breast Cancer with The Aid of Fuzzy Logic Based on Data Mining of a Genetic Algorithm in Infrared Images.» *Middle East Journal of Cancer* 3, no. 3 (2011): 119-129.



ÖZGEÇMİŞ

26 Haziran 1992 Diyarbakır' da doğdu. İstanbul' da Sadabad Koleji' nde lise eğitimini tamamladıktan sonra lisans eğitimini Beykent Üniversitesi' de Matematik-Bilgisayar bölümünde tamamladı. Lisans eğitiminin ardından 2016 yılında aynı üniversitede Bilgisayar Mühendisliği Bölümü' nde yüksek lisans eğitimine başladı.

Kulilik SÜER

