

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**ZEKİ SINIFLANDIRMA VE KÜMELEME YÖNTEMLERİNİN
TIBBİ TANİ VE TEDAVİDE KULLANIMI**

DOKTORA TEZİ

Uğur Erkin KOCAMAZ

Bilgisayar ve Bilişim Mühendisliği Anabilim Dalı

ŞUBAT 2024

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**ZEKİ SINIFLANDIRMA VE KÜMELEME YÖNTEMLERİNİN
TIBBİ TANİ VE TEDAVİDE KULLANIMI**

DOKTORA TEZİ

Uğur Erkin KOCAMAZ

Bilgisayar ve Bilişim Mühendisliği Anabilim Dalı

Tez Danışmanı: Prof. Dr. Harun TAŞKIN

ŞUBAT 2024

Uğur Erkin KOCAMAZ tarafından hazırlanan “Zeki sınıflandırma ve kümeleme yöntemlerinin tıbbi tanı ve tedavide kullanımı” adlı tez çalışması 15.02.2024 tarihinde aşağıdaki jüri tarafından oy birliği/oy çokluğu ile Sakarya Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar ve Bilişim Mühendisliği Anabilim Dalı’nda Doktora tezi olarak kabul edilmiştir.

Tez Jürisi

Jüri Başkanı :	Prof. Dr. Harun TAŞKIN (Danışman)
	Sakarya Üniversitesi
Jüri Üyesi :	Prof. Dr. Cemil ÖZ
	Sakarya Üniversitesi
Jüri Üyesi :	Prof. Dr. Yılmaz UYAROĞLU
	Sakarya Üniversitesi
Jüri Üyesi :	Doç. Dr. Halit ÖZTEKİN
	Sakarya Uygulamalı Bilimler Üniversitesi
Jüri Üyesi :	Dr. Öğr. Üyesi Selman HIZAL
	Sakarya Uygulamalı Bilimler Üniversitesi



ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Sakarya Üniversitesi Fen Bilimleri Enstitüsü Lisansüstü Eğitim-Öğretim Yönetmeliğine ve Yükseköğretim Kurumları Bilimsel Araştırma ve Yayın Etiği Yönergesine uygun olarak hazırlamış olduğum “ZEKİ SINIFLANDIRMA VE KÜMELEME YÖNTEMLERİNİN TIBBİ TANİ VE TEDAVİDE KULLANIMI” başlıklı tezin bana ait, özgün bir çalışma olduğunu; çalışmamın tüm aşamalarında yukarıda belirtilen yönetmelik ve yönergeye uygun davrandığımı, tezin içerdiği yenilik ve sonuçları başka bir yerden almadığımı, tezde kullandığım eserleri usulüne göre kaynak olarak gösterdiğimi, bu tezi başka bir bilim kuruluna akademik amaç ve unvan almak amacıyla vermediğimi ve 20.04.2016 tarihli Resmi Gazete’de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince Sakarya Üniversitesi’nin abonesi olduğu intihal yazılım programı kullanılarak Enstitü tarafından belirlenmiş ölçütlere uygun rapor alındığını, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun ortaya çıkması halinde doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi beyan ederim.

(05/01/2024).

Uğur Erkin KOCAMAZ



TEŞEKKÜR

Bu bilimsel çalışmanın ortaya çıkmasında bana yardımcı olan, ilgi ve desteğini hiç eksiltmeyen, yol gösterici olan, fikirlerime önem veren, engin bilgi ve tecrübesiyle beni yönlendiren değerli danışmanım Prof. Dr. Harun TAŞKIN'a teşekkür ederim. Ayrıca, tez izleme komitesine yer alan, tezin ilerlemesine katkı sağlayan Prof. Dr. Cemil ÖZ'e ve Prof. Dr. Yılmaz UYAROĞLU'na teşekkür ederim.

Benim bu aşamaya gelmemde en çok emeği geçen, her zaman maddi ve manevi desteklerini arkamda hissettiğim annem babam Cemile ve Numan KOCAMAZ'a ve kardeşim Çiğdem ALTUN'a en içten saygı, sevgi ve şükranlarımı sunarım.

Uğur Erkin KOCAMAZ



İÇİNDEKİLER

Sayfa

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ	v
TEŞEKKÜR	vii
İÇİNDEKİLER	ix
KISALTMALAR	xi
TABLO LİSTESİ	xiii
ŞEKİL LİSTESİ	xv
ÖZET	xvii
SUMMARY	xix
1. GİRİŞ	1
1.1. Tıbbi Tanı ve Tedavi	1
1.2. Tıbbi Tanı ve Tedavide Klasik Yöntemler	2
1.2.1. Tanısal laboratuvar testleri	2
1.2.2. Tanısal görüntüleme yöntemleri	3
1.3. Tedavi Yöntemleri	6
1.4. Karar Destek Sistemleri	7
1.4.1. Tıbbi karar destek sistemleri	8
1.4.2. Tıbbi karar destek sistemlerinin özellikleri	9
1.4.3. Tıbbi karar destek sistemlerinin etkileri	10
2. METOT VE YÖNTEMLER	11
2.1. Yapay Sinir Ağları	11
2.1.1. Öğrenmeli vektör niceleme sinir ağları	11
2.1.2. Olasılıksal sinir ağları	15
2.1.3. Örüntü tanıma sinir ağları	18
2.1.4. Kendi kendini düzenleyen haritalar	20
2.2. Bulanık Mantık	24
2.2.1. Bulanık kümeleme	25
3. DOĞUM YÖNTEMLERİ SINIFLANDIRMASI	29
3.1. Normal Doğum	29
3.2. Sezaryen Doğum	29
3.3. Yapay Zeka Yöntemleri ile Doğum Yöntemini Belirleme Çalışmaları	31
3.4. Doğum Yöntemi Veri Kümesi	32
3.5. Doğum Yöntemi Sınıflandırması	34
4. KANSER SINIFLANDIRMASI	43
4.1. Meme Kanseri Risk Faktörleri	44
4.2. Meme Kanseri Erken Tanı ve Tarama Yöntemleri	45
4.3. Meme Kanseri Tanısı	46
4.4. Meme Kanseri Tedavisi	47
4.5. Yapay Zeka Yöntemleri ile Kanser Teşhisi Çalışmaları	48
4.6. Kanseri Veri Seti	51
4.7. Kanseri Sınıflandırması	52
4.7.1. Model-I	53

4.7.2. Model-II	59
4.7.3. Model-III	65
4.7.4. Model-IV	70
5. DİYABET RİSK SINIFLANDIRMASI	79
5.1. Diyabet Tanısı	80
5.2. Diyabet Tedavisi.....	81
5.3. Diyabet Riski	82
5.4. Yapay Zeka Yöntemleri ile Diyabet Sınıflandırma Çalışmaları	83
5.5. Diyabet Veri Seti	86
5.6. Diyabet Sınıflandırması.....	87
6. TİROİD FONKSİYON SINIFLANDIRMASI	95
6.1. Tiroid Bezi Hastalıkları	95
6.2. Tiroid Hastalıkları Tanısı	97
6.3. Tiroid Hastalıkları Tedavisi.....	97
6.4. Yapay Zeka Yöntemleri ile Tiroid Fonksiyon Sınıflandırma Çalışmaları	97
6.5. Tiroid Veri Seti.....	99
6.6. Tiroid Sınıflandırması	100
7. SONUÇ VE ÖNERİLER.....	109
KAYNAKLAR.....	113
ÖZGEÇMİŞ	125

KISALTMALAR

ABD	: Amerika Birleşik Devletleri
BI-RADS	: Breast imaging reporting and data system
BT	: Bilgisayarlı tomografi
DCIS	: Duktal carsinoma in situ
DNA	: Deoksiribo nükleik asit
DSÖ	: Dünya sağlık örgütü
FCM	: Bulanık c-ortalamalar (fuzzy c-means)
GDM	: Gestasyonel diyabetes mellitus
HbA1C	: HemoglobinA1C
IDC	: Invaziv duktal carsinoma
KDS	: Karar destek sistemleri
LCIS	: Lobüler carsinoma in situ
LVQ	: Öğrenmeli vektör niceleme (learning vector quantization)
LVQNN	: Öğrenmeli vektör niceleme sinir ağları (learning vector quantization neural networks)
MR	: Manyetik rezonans
MRG	: Manyetik rezonans görüntüleme
MSE	: Ortalama karesel hata (mean squared error)
OGTT	: Oral glikoz tolerans testi
PNN	: Olasılıksal sinir ağları (probabilistic neural networks)
PRNN	: Örüntü tanıma sinir ağları (pattern recognition neural networks)
ROC	: Alıcı işletim karakteristiği (receiver operating characteristic)
SOM	: Kendi kendini düzenleyen haritalar (self-organizing maps)
TKDS	: Tıbbi karar destek sistemleri
TSH	: Tiroid uyarıcı hormon (tiroid stimulan hormon)
T3	: Triiyodotironin
T4	: Tiroksin
UCI	: University of California, Irvine
VKİ	: Vücut kitle indeksi
YSA	: Yapay sinir ağları



TABLO LİSTESİ

Sayfa

Tablo 3.1. Doğum yöntemi sınıflandırma nitelikleri.....	33
Tablo 3.2. Doğum yöntemi sınıflandırma sonuçları.....	41
Tablo 4.1. BI-RADS sınıflaması.	46
Tablo 4.2. Kanser sınıflandırma nitelikleri.....	52
Tablo 4.3. SOM ağının kümeleme verileri.	60
Tablo 4.4. FCM ağının kümeleme verileri.	65
Tablo 4.5. Geliştirilen modellerin (kanser sınıflandırma) doğruluk yüzdeleri.....	76
Tablo 4.6. Kanser sınıflandırma sonuçları.	77
Tablo 5.1. Diyabet tanı kriterleri.	81
Tablo 5.2. Diyabet riski sınıflandırma nitelikleri.	86
Tablo 5.3. Diyabet riski sınıflandırma sonuçları.	93
Tablo 6.1. Tiroid fonksiyonu sınıflandırma nitelikleri.	100
Tablo 6.2. Tiroid fonksiyonu sınıflandırma sonuçları.	107



ŞEKİL LİSTESİ

Sayfa

Şekil 1.1. Tıbbi karar destek sistemleri (TKDS) bileşenleri.	10
Şekil 2.1. LVQNN mimarisi.	12
Şekil 2.2. LVQNN aktivasyon fonksiyonları (a) $\text{compet}(n)$, (b) $\text{purelin}(n)$	12
Şekil 2.3. PNN mimarisi.	16
Şekil 2.4. PNN aktivasyon fonksiyonu $\text{radbas}(n)$	16
Şekil 2.5. PRNN mimarisi.	18
Şekil 2.6. PRNN aktivasyon fonksiyonları (a) $\text{tansig}(n)$, (b) $\text{compet}(n)$	19
Şekil 2.7. SOM sinir ağı.	21
Şekil 3.1. Gizli katmandaki nöron sayılarına göre LVQNN'nin eğitim ve test performansları.	34
Şekil 3.2. Sezaryen veri seti için kullanılan LVQNN mimarisi.	35
Şekil 3.3. Yayılma faktörüne göre PNN'nin eğitim ve test performansları.	35
Şekil 3.4. Sezaryen veri seti için kullanılan PNN mimarisi.	36
Şekil 3.5. Gizli katmandaki nöron sayılarına göre PRNN'nin eğitim ve test performansları.	36
Şekil 3.6. Sezaryen veri seti için kullanılan PRNN mimarisi.	37
Şekil 3.7. YSA eğitim ve test performansları.	38
Şekil 3.8. YSA histogram grafikleri.	38
Şekil 3.9. YSA ROC eğrileri.	39
Şekil 3.10. YSA karşılaştırma matrisi sonuçları.	40
Şekil 4.1. Gizli katmandaki nöron sayılarına göre LVQNN'nin eğitim ve test performansları (Model-I).	53
Şekil 4.2. Kanser veri seti için kullanılan LVQNN mimarisi (Model-I).	53
Şekil 4.3. Yayılma faktörüne göre PNN'nin eğitim ve test performansları (Model-I)	54
Şekil 4.4. Kanser veri seti için kullanılan PNN mimarisi (Model-I).	54
Şekil 4.5. Gizli katmandaki nöron sayılarına göre PRNN'nin eğitim ve test performansları (Model-I).	55
Şekil 4.6. Kanser veri seti için kullanılan PRNN mimarisi (Model-I).	55
Şekil 4.7. YSA eğitim ve test performansları (Model-I).	56
Şekil 4.8. YSA histogram grafikleri (Model-I).	56
Şekil 4.9. YSA ROC eğrileri (Model-I).	57
Şekil 4.10. YSA karşılaştırma matrisi sonuçları (Model-I).	58
Şekil 4.11. Kanser veri seti için optimum küme sayısı (a) Calinski–Harabasz, (b) Davies–Bouldin, (c) Silhouette katsayılarına göre.	60
Şekil 4.12. SOM modelinin kümeleme sonuç grafikleri.	61
Şekil 4.13. YSA eğitim ve test performansları (Model-II-A).	62
Şekil 4.14. YSA karşılaştırma matrisi sonuçları (Model-II-A).	63
Şekil 4.15. YSA eğitim ve test performansları (Model-II-B).	64
Şekil 4.16. YSA karşılaştırma matrisi sonuçları (Model-II-B).	65
Şekil 4.17. FCM modelinin kümeleme sonuç grafikleri.	66

Şekil 4.18. YSA eğitim ve test performansları (Model-III-A).....	67
Şekil 4.19. YSA karşılaştırma matrisi sonuçları (Model-III-A).	68
Şekil 4.20. YSA eğitim ve test performansları (Model-III-B).	69
Şekil 4.21. YSA karşılaştırma matrisi sonuçları (Model-III-B).....	70
Şekil 4.22. YSA eğitim ve test performansları (Model-IV-A).	71
Şekil 4.23. YSA karşılaştırma matrisi sonuçları (Model-IV-A).	72
Şekil 4.24. YSA eğitim ve test performansları (Model-IV-B).....	73
Şekil 4.25. YSA karşılaştırma matrisi sonuçları (Model-IV-B).	74
Şekil 4.26. YSA eğitim ve test performansları (Model-IV-C).....	74
Şekil 4.27. YSA karşılaştırma matrisi sonuçları (Model-IV-C).	75
Şekil 5.1. Gizli katmandaki nöron sayılarına göre LVQNN'nin eğitim ve test performansları.	87
Şekil 5.2. Diyabet veri seti için kullanılan LVQNN mimarisi.	87
Şekil 5.3. Yayılma faktörüne göre PNN'nin eğitim ve test performansları.....	88
Şekil 5.4. Diyabet veri seti için kullanılan PNN mimarisi.	88
Şekil 5.5. Gizli katmandaki nöron sayılarına göre PRNN'nin eğitim ve test performansları.	89
Şekil 5.6. Diyabet veri seti için kullanılan PRNN mimarisi.	89
Şekil 5.7. YSA eğitim ve test performansları.	90
Şekil 5.8. YSA histogram grafikleri.....	90
Şekil 5.9. YSA ROC eğrileri.....	91
Şekil 5.10. YSA karşılaştırma matrisi sonuçları.	92
Şekil 6.1. Gizli katmandaki nöron sayılarına göre LVQNN'nin eğitim ve test performansları.	101
Şekil 6.2. Tiroid veri seti için kullanılan LVQNN mimarisi.	101
Şekil 6.3. Yayılma faktörüne göre PNN'nin eğitim ve test performansları.....	102
Şekil 6.4. Tiroid veri seti için kullanılan PNN mimarisi.	102
Şekil 6.5. Gizli katmandaki nöron sayılarına göre PRNN'nin eğitim ve test performansları.	103
Şekil 6.6. Tiroid veri seti için kullanılan PRNN mimarisi.	103
Şekil 6.7. YSA eğitim ve test performansları.	104
Şekil 6.8. YSA histogram grafikleri.....	104
Şekil 6.9. YSA ROC eğrileri.....	105
Şekil 6.10. YSA karşılaştırma matrisi sonuçları.	106

ZEKİ SINIFLANDIRMA VE KÜMELEME YÖNTEMLERİNİN TIBBİ TANİ VE TEDAVİDE KULLANIMI

ÖZET

Bu tez çalışmasında, hastalıkların teşhis ve tedavisinde doktorların kararlarına destek olmak amacı ile makine öğrenmesi içeren sınıflandırma ve kümeleme algoritmaları kullanılmıştır. Önce, makine öğrenmesinin tıbbi tanı ve tedavideki yeri ve önemi hakkında bilgi verilmiştir. Sınıflandırma ve kümeleme aşamalarında kullanılan zeki algoritmalar anlatılmıştır. Bu kapsamda yapılmış bilimsel çalışmalar özetlenmiştir. Karar destek sistemleri, tıbbi karar destek sistemleri, tıbbi karar destek sistemlerinin özellikleri ve tıbbi karar destek sistemlerinin etkileri incelenmiştir. Sonra, dünyada en çok gerçekleştirilen cerrahi işlemlerden biri olan sezaryen ya da normal doğum kararı için önemli sınıflandırma algoritmaları Öğrenmeli Vektör Nicelleme Sinir Ağları (Learning Vector Quantization Neural Networks – LVQNN), Olasılıksal Sinir Ağları (Probabilistic Neural Networks – PNN) ve Örüntü Tanıma Sinir Ağları (Pattern Recognition Neural Networks – PRNN) kullanılmıştır. Bu üç yöntem karşılaştırılmış, sonuçlar başarı yönünden değerlendirilmiştir. Kanser günümüzün en sık görülen ölümcül hastalıklarından biridir. Tümörlerin iyi huylu ya da kötü huylu olduğunun tespiti için kümeleme yapay sinir ağı algoritması Kendi Kendini Düzenleyen Haritalar (Self-Organizing Maps – SOM) ile veri seti kümelerine ayrıldıktan sonra, sınıflandırma yapay sinir ağları LVQNN, PNN ve PRNN uygulanmıştır. Ayrıca, yine önemli yapay zeka kümeleme algoritmalarından Bulanık C-Ortalamlar (Fuzzy C-Means – FCM) ile de veri seti kümelerine ayrıldıktan sonra, sınıflandırma yapay sinir ağları LVQNN, PNN ve PRNN kullanılmıştır. SOM ve FCM değerlerinin girdi olarak ilave edildiği bir model daha uygulanmıştır. Bu kümeleme algoritmalarının sayesinde, nispeten daha düşük başarıda olan kanser sınıflandırmasının performansı artmıştır. Diyabet ve tiroid hastalıkları birçok organda hasara yol açabilen günümüzün en yaygın görülen kronik hastalıklarındandır. Erken tespiti önemlidir. Bu işlem için de LVQNN, PNN ve PRNN yöntemleri kullanılmış, oldukça başarılı sonuçlar elde edilmiştir.

Mevcut araştırma, farklı makine öğrenmesi sınıflandırma yöntemleri kullanarak en uygun yöntem sayesinde tahminlerdeki doğruluğu iyileştirmeyi amaçlamaktadır. Bu çalışma tıbbi tanı ve tedavinin sınıflandırmasında LVQNN, PNN ve PRNN algoritmalarının etkinliğini ortaya koymaktadır. Her birinin farklı hastalıkta daha başarılı olduğu görülmektedir. Ayrıca, bu çalışma SOM ve FCM kümeleme algoritmalarının sınıflandırma işlemlerine dâhil edilmesinin olumlu katkı sağladığını göstermektedir.



THE USAGE OF INTELLIGENT CLASSIFICATION AND CLUSTERING METHODS IN MEDICAL DIAGNOSIS AND TREATMENT

SUMMARY

In this thesis, classification and clustering algorithms including machine learning are used to assist the decisions of doctors in the diagnosis and treatment of diseases. First, information about the position and importance of machine learning techniques in medical diagnosis and treatment is given. The intelligent algorithms which are used for classification and clustering are explained. The scientific papers conducted in this area are summarized. Decision support systems, medical decision support systems, their features and effects are explained. Then, important classification algorithms, namely Learning Vector Quantization Neural Networks (LVQNN), Probabilistic Neural Networks (PNN) and Pattern Recognition Neural Networks (PRNN), are used for deciding on vaginal delivery or cesarean section, which is one of the most commonly performed surgical operations in the world. The results of these three algorithms are compared and evaluated in terms of success. Nowadays, cancer is one of the most common fatal diseases. To determine whether the tumors are benign or malignant, the data set is divided into clusters with the clustering neural network algorithm Self-Organizing Maps (SOM), then the classification neural networks LVQNN, PNN and PRNN are applied. In addition, the data set is divided into clusters with Fuzzy C-Means (FCM), which is one of the significant intelligent clustering algorithms, then the classification neural networks LVQNN, PNN and PRNN are again used. Another model is applied in which SOM and FCM values are added as input to the classification neural networks. Thanks to these clustering algorithms, the accuracy of cancer classification has increased. Diabetes and thyroid diseases are among the most common chronic diseases of today which can cause damage to many organs. Their early detection is important. LVQNN, PNN and PRNN algorithms are used for these diseases and very successful results are obtained.

During pregnancy and childbirth period, the baby and mother may face many risks, and the type of delivery method should be decided after regular monitoring processes. Cesarean section is preferred in cases where vaginal delivery poses a risk of morbidity or mortality for the baby or mother. Cesarean section is one of the most commonly performed surgical operations across worldwide. Early and correct caesarean section decision would help reduce the problems which may occur for the mother and the baby. The appropriate delivery method can be determined by using some intelligent methods. For this purpose, in this thesis, 3 different classification neural network techniques are used, namely LVQNN, PNN and PRNN. Each neural network technique is first trained and then tested with the Tabriz Health Center data set, which includes the childbirth results of 80 pregnant women and information about their age, delivery number, delivery time, blood pressure and heart status. These neural networks classify data into two categories: vaginal delivery or cesarean section. Figures and tables show that all of the neural networks provide successful results in classifying the delivery method. LVQNN model has classified the delivery method with only 2 errors

in 20 test data and 10 errors in 60 training data. On the other hand, PNN and PRNN have produced the same results: a total of 66 (82.5%) delivery method results are classified correctly, 3 errors are made in the test set and 11 errors are made in the training set. Therefore, the LVQNN model gives better accuracy rates compared to the PNN and PRNN models. The results show that LVQNN is a better delivery classifier, reaching 83.33% and 90% accuracy rates in the training and testing phases, respectively. PNN and PRNN are capable of achieving 81.67% and 85% delivery classification accuracy for the training and testing data, respectively.

Cancer, one of the important diseases of our age, is the uncontrolled and continuous proliferation of some cells in the body due to damage of cell DNA under the influence of environmental and genetic factors. Cancer is the second disease that causes death after the cardiovascular diseases. In recent years, early diagnosis can be achieved through cancer screenings. Thanks to advances in surgical and medical treatments, cancer has become more treatable disease and survival rates have increased. In this thesis, a prediction system for the diagnosis of breast cancer, which is the most common type of cancer for women, is applied with the artificial neural networks. "Mammography Mass Breast Cancer" dataset obtained from the UCI machine learning database is used, which consists of patient records of the Erlangen–Nuremberg University Hospital. Different neural network models have been developed, trained and tested. During training, 2/3 of the 961 samples, that is 641, are used. The remaining 320 samples are used for testing. 355 of the samples used in training are benign, 286 are malignant, and 161 of the samples used in the test are benign and 159 belong to the malignant class. In Model-I, the tumor is classified as benign or malignant using LVQNN, PNN and PRNN. PNN with a spreading factor of 0.17 produced the best results. The accuracy rate of this network is $525/641 = 81.9\%$ for the training data and $274/320 = 85.63\%$ for the test data. In Model-II and Model-III, first the SOM and FCM networks and the breast cancer data set are divided into 2 clusters (clusters A and B), since the optimum number of clusters is determined as 2 according to the Davies–Bouldin and Silhouette methods, and then each set is trained and tested with LVQNN, PNN and PRNN. In Model-II, PRNN and LVQNN have produced the most successful results for in cluster A and B, respectively. For cluster A, the best results are obtained with a PRNN which has 46 neurons in its hidden layer and trained by the Levenberg–Marquardt learning algorithm. For cluster B, the best results are obtained with a LVQNN which has 34 neurons in its hidden layer and trained by the `learnlv2` learning function. The total accuracy rate of these two networks is calculated as $526/641 = 82.06\%$ for the training data and $279/320 = 87.19\%$ for the test data. In Model-III, where FCM is used, PRNN and LVQNN have produced again the most successful results for in cluster A and B, respectively. The total accuracy rate of these networks is calculated as $543/641 = 84.71\%$ for the training data and $279/320 = 87.19\%$ for the test data. In Model-IV, where SOM and FCM values are added as input, an accuracy rate of $275/320 = 85.94\%$ is obtained for the test data of both LVQNN, and PNN, and PRNN. Model-IV-C (both SOM and FCM values are input) gives the most successful result for the training data with $523/641 = 81.59\%$ accuracy. As a result, the proposed and applied Model-III is the best model which has increased the accuracy rate of tumor classification as benign-malignant.

Diabetes is one of the serious chronic diseases of our age, whose prevalence is increasing all over the world, can be seen at all ages, although it is more common in adults, and can cause organ and function losses and even death as a result of complications in different systems. It is known that approximately 400 million people

in the world have diabetes, this number is increasing rapidly every year, and it is estimated that millions of people are in the risk group for becoming diabetes. By identifying people in the diabetes risk group and starting treatment early, damage to different organs can be reduced. In this thesis, the Sylhet, Bangladesh early diabetes risk dataset obtained from the UCI machine learning database is used. This data set contains a total of 17 attributes of 520 patients. 320 people has got diabetes and 200 has not got. 2/3 of the data is used during training and the remaining 1/3 is used for testing. Classification for early diabetes risk diagnosis is made with LVQNN, PNN and PRNN. The PRNN, which has 49 neurons in its hidden layer and trained by the Levenberg–Marquardt learning algorithm, has produced the most successful test results. The accuracy rate of this network is calculated as $344/347 = 99.14\%$ for training data and $169/173 = 97.69\%$ for test data. LVQNN and PNN have performed the classification of test data with accuracy rates of $167/173 = 96.53\%$ and $166/173 = 95.95\%$, respectively.

Thyroid hormones secreted from the thyroid gland regulate the metabolic rate. It has effects on heart rate, blood pressure, blood lipids, appetite, digestive system, musculoskeletal system and nervous system. Thyroid hormone should be at normal levels for a healthy life. It is undesirable for the thyroid gland to work more or less. Due to the dysfunction of the thyroid gland, the functioning of many tissues and systems is negatively affected, and if left untreated, it may cause serious health problems. In this thesis, the thyroid function dataset consisting of 22 features of 7200 people from the Garavan Institute, Sydney, Australia, obtained from the UCI machine learning database, is used. 166 samples in this data set belong to the normal class, 368 to the hyperthyroidism class and 6666 to the hypothyroidism class. 2/3 of the data is used during training and the remaining 1/3 is used for testing. Classification for the diagnosis of thyroid function is made with LVQNN, PNN and PRNN. The PRNN, which has 3 neurons in the hidden layer and trained by the Bayesian learning algorithm, has produced the most successful test results. The accuracy rate of this network is calculated as $4780/4800 = 99.58\%$ for training data and $2377/2400 = 99.04\%$ for test data. LVQNN and PNN have performed the classification of test data with accuracy rates of $2228/2400 = 92.83\%$ and $2203/2400 = 91.79\%$, respectively.

This research aims to improve the accuracy of predictions using different machine learning classification algorithms. This study shows the effectiveness of LVQNN, PNN and PRNN algorithms in the classification of medical diagnosis and treatment. Each of them appears to be more successful in different diseases. Furthermore, this study shows that including SOM and FCM clustering algorithms to classification processes make positive contribution.



1. GİRİŞ

Sağlık, Dünya Sağlık Örgütü'nün (DSÖ) tanımına göre beden, ruhen ve sosyal yönden tam bir iyilik halidir. Sağlık, Maslow'un ihtiyaçlar hiyerarşisinin bir basamağı olan güvenlik ihtiyacı basamağında bulunmaktadır. Sağlık hizmetleri, bireylerin ve toplumların sağlıklarını sürdürebilmeleri için öncelikle toplumu eğitmeyi, bilinçlendirmeyi, hastalıkların oluşmasını ve ilerlemesini önlemeyi hedefler. Sağlık hizmetleri sağlığın korunması, oluşan hastalıkların erken dönemde teşhis edilip, ilerlemeden tedavi edilmesi, tedavi sonrasında da rehabilitasyonunu içeren geniş kapsamlı hizmetler bütünüdür.

Teknolojide yaşanan gelişmeler, her alanı pozitif yönde etkilemektedir. Tıp sektöründe bilgisayarlar ve yapay zeka, karmaşık verilerin analizi ve verilerden anlamlı sonuçların ortaya çıkarılması amacıyla kullanılmaktadır. Bir veri setindeki anlamlı ilişkileri bulma potansiyelleri sayesinde, birçok klinik vakada tanı koymayı, tedavi yöntemini belirlemeyi ve olası sonuçları tahmin etmeyi sağlamaktadır. Tıp alanındaki yapay zeka uygulamaları, daha etkin hastalık teşhisi, sınıflandırılması, öngörülmesi, risk derecelerinin tayini, tıbbi görüntülerin işlenmesi gibi faydaları sayesinde, maliyeti düşürmekte, hastaların refahını yükseltmektedir.

1.1. Tıbbi Tanı ve Tedavi

Hastalık, vücudun tamamı veya bir kısmını yapısal ve işlevsel olarak olumsuz etkileyen değişiklikler sonucu ortaya çıkan patolojik durum olarak tanımlanabilir. Hastaneler; hastane binaları, gelişmiş tıbbi cihazlar, doktor, hemşire ve yardımcı sağlık personelleri ile hastaların kabul edildiği, teşhis ve tedavilerinin yapıldığı sağlık kurumlarıdır. Hastaneler yaralı ve hastaların muayene, tetkik ve tedavileri yanında sağlıklı bireylerin de sağlıklarını koruyabilmeleri için tarama ve kontrollerinin yapıldığı, ayaktan veya yatarak hizmet veren kuruluşlardır.

Hastalıkların tanıları hastanın semptom ve belirtileri, muayene bulguları, laboratuvar sonuçları ve görüntüleme yöntemlerinden faydalanılarak konulur. Hastalıkların oluşmasını ve ilerlemesini önlemek tedavi etmeye göre daha kolay ve ucuz olduğu için

koruyucu sađlık hizmetleri b y k  nem tařımaktadır. Tedavi bedenene veya ruhen hastalanan, sađlığını kaybetmiř kiřilerin tekrar sađlığına kavuřup iyileřmesi i in uygulanan sađlık hizmetlerinin tamamıdır. T m hastalıkları tamamen tedavi edebilmek her zaman m mk n olmamaktadır. Rehabilitasyon ile hastalıklardan sonra oluřan kalıcı hasarları en aza indirme ama larıdır.

Sađlık biliřimi; matematik, biyoistatistik, m hendislik, bilgisayar ve biliřim teknolojilerini sađlık bilimleri ile birleřtirerek sađlık alanında veri toplama, iřleme, analiz, karar verme, bilimsel    mlleme ile sađlık uygulamalarında bilgi y netimine olanak sađlayan bir bilim dalıdır. Bilgi sistemleri ve iletiřim teknolojilerindeki geliřmeler ile sađlık alanındaki bir ok bilgi ve veri bilgisayar ortamına sayısal olarak aktarılmakta, saklanılmakta ve kolaylıkla tekrar eriřilebilmektedir.

1.2. Tıbbi Tanı ve Tedavide Klasik Y ntemler

1.2.1. Tanısal laboratuvar testleri

Biyokimya laboratuvarı: Hastane ve diđer sađlık kuruluřlarında v cuttan alınan  rneklerin (kan, idrar, beyin omurilik sıvısı, mide sıvısı, t k r k vb.) biyolojik analizlerinin yapıldığı ve yapılan testlerin yorumlandığı birimdir.

Biyokimya laboratuvarında uygulanan testler; tam kan sayımı, biyokimyasal testler, kan řekeri, kan gazı, pıhtılařma testleri, t m r belirte leri, hormon testleri, idrar testleri, karaciđer ve b brek fonksiyon testleri, ila  d zeyleri vb. testler olarak sıralanabilir. Bir ok hastalığın tanı, teřhis ve tedavi ařamalarında biyokimya laboratuvarları g rev almaktadır.

Mikrobiyoloji laboratuvarı: Mikrobiyoloji bakteri, vir s, mantar, maya, k f gibi mikroorganizmaları ve bu mikroorganizmaların neden olduđu hastalıkları inceleyen bilim dalıdır. Mikroorganizmaların bir ođu insanlarda farklı hastalıklara yol a ar.

 nsanlarda hastalığa neden olan bakterilerin tespit edilip  ođaltılması, bu bakterilere karřı duyarlı antibiyotiklerin belirlenmesi bakteriyoloji, vir slerin tanı testleri ile tespit edilmesi viroloji, yine  eřitli hastalıklara neden olan mantarların ve bunlara karřı etkili olan antifungal ila ların etkinliklerinin belirlenmesi mikoloji,  eřitli v cut sıvılarında parazitlerin arařtırılması parazitoloji, antijen veya anjenlere karřı oluřan antikorların tespit edilmesi ile hastalığa neden olan etkenin belirlenmesine yardımcı olan y ntem seroloji olarak tanımlanır.

Mikrobiyoloji laboratuvarında hastalardan alınan kan, idrar, balgam, gaita, doku örnekleri gibi numuneler gelişmiş mikroskoplar ve özel solüsyonlar kullanılarak değerlendirilir. Yapılan tetkikler mikroorganizma kaynaklı hastalıkların tanısı, tedavisi ve takibinde faydalı olmaktadır. Mikrobiyoloji laboratuvarlarında kullanılan testler, direkt mikroskopik inceleme, boyalı mikroskopik inceleme, kültür testleri, antibiyogram, antifungal duyarlılık testleri, antijen ve antikor testleri, parazitoloji testleri olarak sıralanabilir.

1.2.2. Tanısal görüntüleme yöntemleri

Radyoloji teknolojinin gelişimi ile birlikte hızla gelişmekte ve daha net görüntü kalitesine sahip sonuçları daha hızlı elde etmek mümkün olmaktadır. Elde edilen görüntüler dijital formatta değerlendirilebilmekte, gönderilebilmekte ve saklanabilmektedir.

Görüntüleme yöntemleri 3 grupta değerlendirilebilir:

1. Transmisyon: X-ışını tüpünden çıkan ışın demetinin hastayı geçerek ışınların filme düşmesi ile görüntü oluşur. Konvansiyonel radyografi, bilgisayarlı tomografi, anjiyografi ve floroskopi, transmisyon görüntüleme yöntemleridir.

2. Refleksiyon: Yansıma prensibini kullanır. Ultrason refleksiyon görüntüleme yöntemidir, dokulardan yansıyan yüksek frekanslı ses dalgaları ile görüntü elde edilir.

3. Emisyon: Yayılım, salınım prensiplerini kullanır. Manyetik rezonans ve nükleer tıp yöntemleri emisyon prensibine dayalı görüntüleme yöntemleridir. Görüntü oluşturmada manyetik rezonans görüntülemede hastadan kaynaklanan radyofrekans sinyalleri, nükleer tıpta ise gama ışınları ve pozitron salınımı kullanılır.

Tanısal görüntülemelerde görüntü oluşturmak için farklı enerji türleri kullanılmaktadır. Tanısal görüntüleme amacıyla kullanılan X-ışınları iyonizan radyasyondur. İyonizan radyasyon kimyasal ve elektronik bağların kırılmasına yetecek derecede enerjiye sahiptir ve atomu iyon haline getirmektedir.

Hasta için doğru görüntüleme yöntemi seçmek ve radyolojik görüntülerin yorumlanabilmesi için yeterli klinik bilgiye sahip olmak önemlidir. Hastanın yaşı, cinsiyeti, şikayeti, muayene bulguları, geçirdiği hastalıklar, uygulanan tedaviler gibi bilgiler radyolojik istem formunda belirtilmelidir. Patolojik görüntüyü anlayabilmek için incelenen bölgenin normal radyolojik görüntüsünü iyi bilmek gereklidir.

Ekstremiteler değerlendirilirken normal tarafı da içeren karşılaştırmalı görüntüleme yapmak patolojik bulguların daha kolay tanınmasına olanak sağlar. Radyolojik değerlendirmede görüntü kalitesi, hasta pozisyonunun doğruluğu, alınan kesitlerin yönü, sayısı doğru tanı için önemlidir.

Yaygın kullanılan tanısal görüntüleme yöntemleri şunlardır (Beyazova ve Gökçe-Kutsal, 2000):

Direkt grafi: Ucuz, hızlı, kolay uygulanabilir, güvenilir ve zorunlu hallerde taşınabilir olduğu için kas iskelet sistem patolojilerinde ilk tercih edilen ve en çok kullanılan görüntüleme yöntemidir. Kemik, kas ve diğer yumuşak dokuların görüntülenebilmesini sağlayan, farklı boyutlardaki alanları tek bir görüntüye sığdırabilen bu yöntemde iyonizan radyasyon kullanılmaktadır. Uzun kemik kırıkları ve bazı kemik tümörlerinin tanısında başka tetkike gerek kalmadan tek başına yeterlidir. Dezavantajı görüntülenen yapıların üst üste gelmesi yani süperpoze olmasıdır.

Bilgisayarlı Tomografi (BT): 1970'li yılların başında Godfrey Hounsfield ve Allan Cormack tarafından keşfedilmiş bir görüntüleme yöntemidir. Kesitsel bir görüntüleme yöntemidir. Konvansiyonel radyografilerde incelenmek istenen bölgenin film üzerinde basit geometrik projeksiyonları oluşturulurken, tomografi ile birden fazla planda projeksiyonlar elde edilip, bilgisayar aracılığı ile matematiksel olarak birleştirilip kesitsel görüntülere dönüştürülür. Helikal, kesitler alabilen, büyük bir anatomik bölgeyi birkaç saniye gibi çok kısa sürede tarayabilen gelişmiş cihazlardır. Direkt grafilerin dezavantajı olan süperpoze sorununu ortadan kaldırır. Standart X-ışınından çok daha yüksek kontrast rezolüsyonuna sahiptir. Azalmış saçılım, foton saptama etkinliğinde artma ile yumuşak dokuların birbirinden ayırımına olanak verir. Bilgisayarlı tomografinin üstünlükleri kesitsel görüntü alabilmesi, yüksek kontrast rezolüsyonu, geometrik doğruluk ve yumuşak doku farklılıklarını belirleyebilmesi olarak sıralanabilir. Yumuşak doku ve kemik kitlelerinin değerlendirilmesi, kanama yeri ve büyüklüğünün tespiti, akciğer nodülleri, karaciğer kitlelerinin tanısı, kanser tedavilerin etkinliklerinin değerlendirilmesi gibi birçok alanda kullanılır. Travma hastalarında çok kısa süre içinde birçok sistemin ayrıntılı değerlendirilmesi gerektiğinden çoğu kez ilk görüntüleme yöntemi olarak BT tercih edilmektedir.

Manyetik Rezonans (MR): Manyetik rezonans görüntüleme güçlü bir manyetik alan içerisinde bulunan atomlardaki salınım prensibine dayanır. İçerdiği proton ve nötronlar nedeni ile atom küçük bir mıknatıs gibi davranır, nükleusların çoğu çift sayıda nötron ve proton içerdiği için manyetizasyon oluşmazken tek sayıda nötron ya da protona sahip nükleuslarda bir manyetizasyon oluşur. Hidrojen atom çekirdeklerinde bulunan proton manyetik alanla uyarılır, hidrojen atom hareketlerine ve yoğunluklarına göre dokudaki görüntü oluşur. Dokuların farklı özelliklerini vurgulamak için çoklu manyetik değişken pulse sekanslara sahiptir. Elde edilen veriler bilgisayar algoritmaları ile kesitsel görüntülere dönüştürülür. Yumuşak doku çözünürlüğü yüksek görüntüler elde edilir. Beyin, karaciğer, omurilik, kas ve kalp gibi yumuşak dokular diğer görüntüleme yöntemlerine göre daha ayrıntılı şekilde görüntülenebilir.

Konvansiyonel radyografi ve bilgisayarlı tomografi gibi iyonizan radyasyon içermez. Harekete tomografiye göre daha duyarlıdır, çekim sırasında hasta uyumu önemlidir. Hastalarda kalp pili veya MR ile uyumlu olmayan metalik implantlar varsa, MR uygulanmamalıdır. Nörolojik rahatsızlıklarda; baş ağrısı, beyin tümörü şüphesi, migren ve epilepsi hastalarında, kas iskelet sistemi hastalıklarında; omurga yaralanmaları, spor yaralanmaları, boyun, sırt, bel bölgesi patolojileri, eklem, tendon ve ligaman hasarlarının tespiti, kemik ve yumuşak doku kitlelerinin değerlendirilmesinde kullanılır. Ayrıca akciğer, kalp, damar, karın içi organlardaki patolojilerin tespitinde büyük önem taşır.

Ultrasonografi: Ultrasonografi hızlı, iyonizan radyasyon içermeyen, yumuşak doku çözünürlüğü yüksek, güvenilir bir görüntüleme yöntemidir. Yüzeysel dokularda duyarlılığı yüksek, derin dokularda daha düşüktür. Gerçek zamanlı bir görüntüleme yöntemi olması dinamik incelemeler yapılmasına olanak sağlar. Doğru sonuç için ultrasonografi, deneyimli bir radyolog tarafından gerçekleştirilmelidir.

Yüksek titreşimli ses dalgası üretebilen, bunları dokulara ileten ve dokulardan geri gelen dalgaları algılayabilme özelliğine sahip problar kullanılır. Probda piezo-elektrik kristalleri bulunur, bu kristaller elektrik akımını mekanik basınç dalgalarına dönüştürür, oluşan ses dalgaları dokulara gönderilir, her dokunun ses dalgalarına farklı dirençleri vardır, dokulara gönderildikten sonra yansıyor tekrar geri dönen ses dalgaları piezo-elektrik kristalleri ile elektrik akımına çevrilip görüntü oluşturulur. Akustik empedansları farklı dokular arası geçişlerde ses dalgası yansıma ve kırılmalara uğrar. Dokuların ses dalgasına karşı farklı dirençlerinin olması dokuların

farklı tonlarda görüntülenmesi ile sonuçlanır. Fazla yansıtıcı olduğu için kemik, böbrek ve safra taşları görüntüde beyaza yakın gri, ses dalgalarını iyi geçirdiği az yansıttığı için mesane ve damarlar görüntüde siyaha yakın gri, karaciğer gibi organlar ise orta düzey gri renkte görüntülenir.

Ultrasonografi birçok hastalığın tanısında ve güvenilirliği nedeniyle hamilelerde gebelik takibinde kullanılır. Kalp ve ana damarların yapısı, kalp kapakçıklarının işlevi, kalp yetmezliği, safra kesesi, karaciğer, böbrek, dalak, mesane gibi iç organ hastalıkları, tiroid, paratiroid, meme, testis ve overlerdeki kitleler, bebeklerde kalça ve beyin ultrasonografi ile değerlendirilebilir.

Nükleer tıp (Sintigrafik yöntemler): Nükleer tıp kişilere radyoaktif madde verilerek organ fonksiyonlarını ve metabolik aktivitelerini görüntülemeyi sağlayan bir görüntüleme ve tedavi uygulama yöntemidir. Görüntüleme amacı ile elektromanyetik karakterde gama ışınımı yapan radyonüklidler, tedavi amacıyla ise daha ağır ve iyonizasyon gücü yüksek, partiküler karakterdeki alfa ve beta ışınları saçarak bozulan radyoizotoplar kullanılmaktadır. Verilen radyofarmasötiklerden yayılan gama ışınları, gama kameralar ile tespit edilerek görüntü oluşturulur. Kemik, beyin, böbrek ve kalp sintigrafisi ile ilgili organların fonksiyonları değerlendirilir.

1.3. Tedavi Yöntemleri

Başlıca tedavi yöntemleri koruyucu, tedavi edici (medikal, cerrahi) ve rehabilitatif tedavidir:

Koruyucu tedavi: Birey ve toplum sağlığının korunması, hastalıkların, sakatlıkların engellenmesi, hastalık bulguları ortaya çıkmadan erken tanı konması ve tanı konulan hastalıkların en kısa sürede tedavisine başlanması koruyucu sağlık hizmetlerinin hedefleridir. Sağlık eğitimi, bulaşıcı hastalıklardan korunmak için aşılama, erken tanı için tarama testleri, aile planlaması, beslenme ve hijyen eğitimleri, temiz su kaynaklarının sağlanması, hava kirliliğinin önlenmesi, atık kontrolü ile hastalıkları oluşmadan önlemek, kişileri ve toplumu hastalıklara karşı güçlü kılmak mümkün olur.

Tedavi edici: Sağlık durumu bozulup hastalıkların oluşması sonrasında tedavi amaçlı yapılan medikal (ilaç) ve cerrahi müdahale gibi uygulamaları içerir.

Rehabilitatif tedavi: Hastalık veya kaza sonucu oluşan kalıcı sakatlıkların sonuçlarını en aza indirmek, kişinin fiziksel, ruhsal ve mesleki potansiyellerini en üst seviyeye

çıkarmak, rezidüel sakatlığa karşı optimal fonksiyonu sağlamak, başkalarına bağımlılığı azaltmak amacıyla uygulanan tedavileri kapsar. Rehabilitasyonda temel amaç kişinin günlük yaşamda olabildiğince bağımsız olarak işlev görme yeteneğinin geliştirilmesidir.

Bedensel engellerin mümkün olabildiği kadar düzeltilmesi ve kişinin kendi kendine yetebilecek düzeye gelmesi için uygulanan rehabilitasyon tıbbi rehabilitasyon; kaza veya hastalıklar nedeniyle çalışma hayatından uzaklaşan kişinin işine en kısa zaman içinde dönmesini sağlamayı hedefleyen ya da engeli nedeniyle işine dönemeyecek kişilerde mevcut durumuna uygun iş bulma, işi öğretme amacıyla uygulanan rehabilitasyon mesleki rehabilitasyon olarak isimlendirilir.

1.4. Karar Destek Sistemleri

Karar verme işlemi, farklı seçenekler, yollar, imkanlar arasından kişinin kendi amaçları ve hedefleri için en iyi ve en uygun olanı seçebilmesi olarak tanımlanabilir. Karar verme sürecini kararın önemi, karar verme süresi, seçeneklerin sayısı, potansiyel sonuçları gibi birçok değişken etkileyebilmektedir. Farklı duygu, düşünce, muhakeme, zihinsel ve ruhsal fonksiyonların beraber çalışması ile sonuca varılabilir. Bu süreçte güvenilir bilgi ve doğru kaynaklara ihtiyaç duyulur, en doğru karara ulaşabilmek için farklı seçeneklerin değerlendirilmesi ve sonuçlarının analizi gerekmektedir. Doğru ve hızlı kararlar verebilmek için, sorunlara ait verilerin uygun bir sürede karar vericilere aktarılması önemlidir.

Karar Destek Sistemleri (KDS), farklı kaynaklardan elde edilen verileri entegre ederek kurumsal ve uzmanlık gerektiren alanlarda hızlı ve doğru kararlar verebilmesi için kullanılır. Sağlık sektöründe hastalık belirti ve bulgularının, laboratuvar ve görüntüleme yöntemlerinin hızlı analizi, doğru tanı, erken teşhis, etkili ve verimli bir tedavi için büyük önem taşır. Tanı koyma süreci birçok hastalıkta benzer belirti ve bulguların olması, ayırıcı tanıda çok sayıda hastalığın olması nedeniyle karmaşık olabilmektedir. Klinik karar destek sistemleri, hastaya özgü bilgilerin yanında güncel bilimsel bilgileri kullanarak, hekimlerin hastayı en iyi biçimde değerlendirmesine olanak sağlar (Ömürbek ve ark., 2013).

1.4.1. Tıbbi karar destek sistemleri

KDS 1950'lerin ortalarından itibaren sağlık sektöründe kullanılmaya başlanmış, Tıbbi Karar Destek Sistemleri (TKDS) olarak isimlendirilmiştir. TKDS sağlık personellerinin tıbbi alanda karar vermelerinde destek sağlayan bilgisayar programlarıdır. Sistemin gelişimi için sağlık çalışanları ve bilgi teknolojileri uzmanları birlikte çalışmaktadırlar. Bu sistemler hastaya ait verileri analiz ederek teşhis ve tedavi ile ilgili kararlarda sağlık uzmanlarına yardımcı olurlar. Tıbbi verilere ihtiyaç duyulduğunda farklı yerlerden erişilmesine de olanak sağlarlar. TKDS sağlık hizmeti ve eğitimi veren kurumlarda tıp, diş hekimliği, eczacılık gibi farklı disiplinler tarafından kullanılmaktadır.

Elektronik sağlık kaydı sistemleri ile kişiye ait bilgiler (boy, kilo, yaş, vb.), teşhisler, kronik hastalıklar, yapılan tetkikler, radyolojik görüntülemeler, reçete edilen ilaçlar, bireysel uyarılar (alerji vb.), geçirilen operasyonlar, ailedeki genetik geçişli hastalıklar, gebelik takibi, çocuklarda aşı takibi gibi birçok bilgi elektronik ortamda depolanır. Depolanan bu bilgiler bir sonraki hastane başvurusunda hasta ve hekime kolaylık sağlamaktadır.

Bilişim sistemlerinden sağlık kuruluşları, verilerin hızlıca işlenmesi, bilgilerin depolanması, hastalık teşhisleri, alternatif tedavi yöntemleri, laboratuvar hizmetleri gibi birçok alanda faydalanmaktadır. TKDS, sisteme girilen verileri kullanarak kullanıcılarına alternatif öneriler oluştururlar. Destek sistemleri yöneticiler tarafından hastane yönetimini desteklemek için idari ve mali işlerde de kullanılmaktadır.

Yaygınlaşan ve gelişen teknolojiler sayesinde daha fazla dijital veriye sahip olunabilmektedir. TKDS farklı kaynaklardan elde ettiği verileri işleyerek ve değerlendirerek daha doğru kararlar verilmesine olanak sağlarlar. Makine öğrenimi, derin öğrenme algoritmaları ve yapay zeka teknolojilerinin kullanılması ile insan hatasını en aza indiren, daha doğru karar veren destek sistemleri geliştirilebilecektir.

TKDS'nin geliştirilmesinde genellikle kural tabanlı yaklaşımlar, yapay sinir ağları, bulanık mantık ve zeki etmenler gibi yöntemlerden faydalanılmaktadır. Bu tür TKDS, bilgi tabanlı sistemler olarak da nitelendirilir. Bilgi tabanlı sistemler, yapay zeka teknik ve yöntemlerinin bir ürünüdür. Analitik araçları, matematiksel model ve algoritmaları, sezgisel yaklaşımları ve makine öğrenmesi algoritmalarını kullanarak oluşturduğu kararların kanıtlanabilirliği ve güvenilirliği yüksektir. Yapay zeka, algılama, öğrenme,

kavramları birleştirme, düşünme, akıl yürütme, problem çözme, doğal dil anlama, iletişim kurma ve karar verme gibi insan zekasına özgü gelişmiş bilişsel etmenleri ve otonom davranışları gerçekleştirmesi için tasarlanmış yapay sistemlerdir. Yapay zeka teknolojilerini kullanılan TKDS, hastanelerde doktorların ve sağlık personelinin var olan datayı daha doğru ve hızlı anlamasını ve kullanmasını sağlamaktadır.

1.4.2. Tıbbi karar destek sistemlerinin özellikleri

TKDS, Şekil 1.1'de gösterildiği gibi, genel olarak veritabanı, çıkarım motoru, kullanıcı arayüzü, açıklama modülü ve çalışma belleği olarak üzere 5 temel öğeden oluşmaktadır:


Veritabanı: Başlangıçta tıp alanındaki uzmanlar ile bilişim uzmanları yardımı ile hastaya ait veriler girilir, saklanır, daha sonraki süreçte kitap, makale, bilgisayar uygulamaları gibi kaynaklardan hastalıklarla ilgili veriler toplanır.

Çıkarım motoru: Sistemin ana parçasıdır. Veritabanı modülünden alınan bilgiler çıkarım motoru tarafından kullanılır. Hasta ile ilgili bilgileri ve sistemdeki bilgileri kullanarak belirli durumlar ile ilgili sonuçlar çıkarır. Çıkarım motorunun görevi sistem tarafından yapılması gereken tüm işlemleri denetlemektir.

Çalışma belleği: Hastaların yaş, cinsiyet, geçirilmiş hastalıkları, alerjisi olup olmadığı, kullandığı ilaçlar, geçirdiği operasyonlar gibi bilgiler toplanır ve bunlar hasta kayıtları veritabanına kaydedilebilir veya uyarı mesajı olarak saklanabilir. Hasta ile ilgili toplanan bilgiler ve kayıtlar çalışma belleği olarak adlandırılır.

Kullanıcı arayüzü: Sistemi kullanan sağlık personeli ile çıkarım motoru ile arasındaki etkileşimi sağlayan, bu işlemi gerçekleştirirken açıklama modülünü de kullanan kısımdır. Hastaya ait gerekli bilgilerin sisteme girildiği ve sonucun sistemde görüntülendiği ekrandır. Kullanıcı arayüz tasarımlarının amacına hizmet ederken kullanıcı dostu da olması, sağlık sektöründe kıymetli olan zamanın daha etkin kullanılmasını sağlar.

Açıklama modülü: Bu modül çalışma belleğindeki hasta verileri ile çıkarım motoru tarafından elde edilen sonuçların gerekçelerinin oluşturmasından sorumludur. Klinik karar verme sürecinde farklı aşamalarda belirsizlikler oluşabilir. Bu aşamadaki belirsizlikler eksik bilgi, hatalı laboratuvar sonuçları, beklenmeyen ilaç yan etkisi, hastaların farklı fizyolojik özellikleri vb. nedenlerden kaynaklanabilir.



Şekil 1.1. Tıbbi karar destek sistemleri (TKDS) bileşenleri.

Tıbbi klinik KDS eş zamanlı (senkron) veya eş zamanlı olmayan (asenkron) şekilde çalışabilir. Eş zamanlı çalışan destek sistemleri, sistemden çıkış bekleyen kullanıcı ile doğrudan iletişim kurarlar. Örneğin hastaya ilaç yazarken yazılan ilaçların birbiri ile etkileşimi varsa ya da hastada daha önce alerjik reaksiyona neden olan bir ilaçsa sistem bunun denetlenmesini sağlar ve kullanıcıya uyarıcı bilgi verir. Eş zamanlı olmayan (asenkron) modda ise sistemden çıkış bekleyen herhangi bir kullanıcıdan bağımsız olarak kararlar gerçekleştirilir. Asenkron TKDS'ne örnek olarak yıllık check-up ziyaretinin hatırlatılması verilebilir (Pala, 2013).

1.4.3. Tıbbi karar destek sistemlerinin etkileri

TKDS hastaya ait bilgileri ve veritabanındaki tüm bilgileri doğru ve hızlı şekilde analiz edip filtreleyerek klinisyenler tarafından verilen sağlık hizmetlerinin gelişmesine ve kolaylaşmasına yardımcı olurlar. Gerekli tıbbi bilgilere kolayca ulaşılması, önlenabilir hastalıkların zamanında taranması, hastalıklara doğru teşhis konması, tedavi takibi TKDS ile etkili şekilde yapılabilmektedir. Karar vermedeki olumlu etkisi dışında, hastanın daha önce yapılan laboratuvar ve radyolojik tetkiklerine ulaşılabilmesi, tekrarlanan testlere karşı klinisyeni uyarması maliyeti düşürmekte hasta ve ülke ekonomisine yarar sağlamaktadır. Klinisyenler kendi bilgi birikimleri, mesleki tecrübeleri yanında TKDS'nin önerilerini gözden geçirerek, hasta için en doğru kararı rahatlıkla verebilirler (Pala, 2013).

2. METOT VE YÖNTEMLER

Bu tez çalışmasında, doğum yönteminin belirlenmesi (sezaryen ya da normal doğum), tümörün iyi-kötü huylu teşhisi, erken diyabet riski tanısı ve tiroid fonksiyon hastalıkları için makine öğrenmesi algoritmalarından faydalanılması hedeflenmiştir. Bu amaç doğrultusunda, bu bölümde, kullanılan zeki sınıflandırma ve kümeleme teknikleri açıklanmıştır. Sonraki bölümlerde ise, bu hastalıklar ve veri setleri hakkında bilgi verilmiş, uygulanan sınıflandırma adımları anlatılmıştır.


2.1. Yapay Sinir Ağları (YSA)

Bir YSA, bilinen gerçek dünya verilerini iterasyonlarla kendi işlemesiyle öğrenir. YSA, katmanlardan, bağlantılı düğümlerden ve ağırlıklardan oluşur. Bir YSA'nın çıktı değeri, girdilerin, ağırlıkların ve bias değerlerinin toplama, çarpma ve bölme işlemleriyle hesaplanır. Eğitilen veriler ağırlıklarında kodlanır. YSA, eğitimleri esnasında önceki ağırlıklardan gelen hata değerlerini geri besleme yeteneğine sahiptir; burada bu hata değerleri, bir sonraki yinelemede ağırlıkların ayarlamak için kullanılır. YSA, fonksiyonel yaklaşım, zaman serisi tahmini, sınıflandırma, örüntü tanıma, veri işleme, kümeleme, doğrusal olmayan sistemleri tanıma ve kontrol gibi farklı alanlarda kullanılmaktadır. Algılayıcı, çok katmanlı, ileri beslemeli, kademeli ileri beslemeli, Hopfield, zaman gecikmeli, NARX, radyal tabanlı, genelleştirilmiş regresyon ve kendi kendini düzenleyen haritalar (SOM) sinir ağları gibi çeşitli YSA modelleri vardır. Ayrıca, LVQNN, PNN ve PRNN sınıflandırma işlemi için özelleştirilmiş YSA modelleridir.

2.1.1. Öğrenmeli vektör niceleme sinir ağları (learning vector quantization neural networks – LVQNN)

Tuevo Kohonen tarafından 1984 yılında sınıflandırma probleminin çözümü için geliştirilen LVQ (Learning Vector Quantization) sinir ağı, hızlı sonuç üretmesi ve performansının yüksek olması nedenleri ile sınıflandırma işlemlerinde yaygın kullanılan YSA'lardan biridir. LVQNN'nin diğer ağlardan farkı, yine Kohonen'in daha önce geliştirmiş olduğu SOM modelindeki Kohonen katmanına sahip olmasıdır.


Bu ağ girdi ve çıktıları vektör olarak almakta, öğrenirken bunları haritalamaktadır. LVQNN eğitimi, girdi vektörünün hangi çıktı vektör seti tarafından temsil edilmesi gerektiğini ayarlamaktır. Çıktı vektör seti, referans vektörü olarak da isimlendirilmektedir. Amaç, makine öğrenmesi ile girdi vektörleri için bu referans vektörlerinin doğruluğunu sağlamaktır. Şekil 2.1’de, LVQNN ağının mimari yapısı gösterilmektedir. Bu ağ 3 katmandan oluşmaktadır ve ileri beslemeli bir YSA’dır.



Şekil 2.1. LVQNN mimarisi (Beale ve ark., 2011).

Şekil 2.1’de, R , p , S^1 ve S^2 sırasıyla giriş vektöründeki eleman sayısı, girdi matrisi, rekabetçi (competitive) katmandaki nöron sayısı ve çıkış vektöründeki sınıf sayısıdır. $\mathbf{IW}_{1,1}$ ve $\mathbf{LW}_{2,1}$ rekabet ve doğrusal çıktı katmanlarındaki ağırlık matrislerini temsil etmektedir. İlk katmandaki kümelerin sayısı, n_1 ile ifade edilen gizli nöronların sayısına göre belirlenir.

LVQNN’in iç yapısında kullandığı $\text{compet}(n_1)$ ve $\text{purelin}(n_2)$ aktivasyon fonksiyonları Şekil 2.2’de verilmiştir.



Şekil 2.2. LVQNN aktivasyon fonksiyonları (a) $\text{compet}(n)$, (b) $\text{purelin}(n)$ (Beale ve ark., 2011).

LVQNN’de, girdi ile Kohonen katmanları arasındaki bağlantı tam, Kohonen ile çıkış katmanları arasındaki ise kısımdır. Giriş katmanındaki her bir nöron Kohonen katmanındaki tüm nöronlar ile bağlantıya sahiptir. Kohonen katmanındaki nöronlar ise çıkış katmanındaki bir nörona bağlıdır. Kohonen ile çıkış katmanları arasındaki ağırlıklar 1 değerine sahiptir, bu değer sabittir, değişmez. Sadece giriş ile Kohonen katmanları arasındaki ağırlıklar değişir. Ağın eğitimi, bu ağırlık değerlerinin güncellenmesi ile gerçekleşir (Bayır, 2006).

LVQNN, öğrenme kuralı olarak niceleme (quantization) algoritmasını kullanmaktadır. LVQNN, danışmansız öğrenmenin bir alt türü olan rekabetçi öğrenmeyi (competitive learning) kullanan yöntemlerden birisidir. Eğitim esnasında, önce, girdi ve referans vektörleri arasındaki en kısa mesafe aranır. Girdi vektörünün en yakın mesafede bulunan vektör sınıfının üyesi olduğu varsayılır. Ağın ağırlıkları değiştirilerek, girdileri doğru sınıflara yönlendirecek referans vektörler saptanmaktadır. Çıktı değerlerinin belirlenmesinde “kazanan herşeyi alır (winner takes all)” stratejisi kullanılır. Yani, LVQNN eğitilirken her iterasyonda ağın ürettiği çıktının sayısal değeri yerine sadece doğru olup olmadığına bakılır. Sadece girdi vektörüne en yakın olan vektörün (kazanan vektörün) değerleri (bu vektöre ait ağırlıklar) değiştirilir (Tuskan, 2012).

LVQNN’de, hem Kohonen hem de çıkış katmanlarındaki her bir nöronun çıktıları ikili değer (0 ya da 1) almaktadır. Sadece bir nöronun çıktı değeri 1 (bir) olmakta, diğerleri ise 0 (sıfır) olmaktadır. Çıktı değerinin 1 olması girdinin, ilgili çıktının temsil ettiği sınıfın üyesi olduğu anlamına gelmektedir (Koltan Yılmaz, 2014).

Öğrenme kuralı, Kohonen katmanındaki nöronların birbirleriyle yarışması ilkesine dayanmaktadır. Rekabet ölçütü olarak, girdi ve referans vektörleri arasındaki Öklid (Euclid) mesafesi alınır. Girdi vektörü X , referans vektörü W ve aralarındaki mesafe d ile gösterilirse; i . nöronun mesafesi aşağıdaki denklem ile hesaplanır (Gauri, 2010):

$$d_i = \|W_i - X\| = \sqrt{\sum_j (w_{ij} - x_{ij})^2}, \quad (2.1)$$

burada w_{ij} ve x_{ij} sırasıyla ağırlık ve girdi vektörlerinin j . değerlerini temsil etmektedir. Tüm girdi ve referans vektörlerinin aralarındaki mesafe tek tek hesaplanır. Bunlardan, referans vektörü girdi vektörüne en yakın olanı yarışmayı kazanır. Eğitim aşamasında, sadece girdi katmanını bu nörona bağlayan ağırlık değerleri güncellenir. Ağırlıkların

değiştirilmesi denklem 2.2’de verilen formül ile gerçekleştirilir (Gauri, 2010; Koltan Yılmaz, 2014):

$$W_i = W_i(t) + \lambda * h_i(t) * [X(t) - W_i(t)] \quad (2.2)$$

Bu formüldeki λ öğrenme katsayısıdır, değeri 0 ile 1 arasında zamanla değişmektedir, 0 (sıfır) değerine yakınsayacak biçimde monoton olarak azaltılır. Bunun sebebi, girdi vektörünün referans vektörüne çok yaklaştığında durmasını sağlamak ve ters yönde öğrenmemeye dönüşmemesi içindir. Sınıflandırma doğru ise $h_i(t) = +1$ alınır ve ağırlıklar girdi vektörüne yaklaştırılır; sınıflandırma yanlış ise $h_i(t) = -1$ alınır ve ağırlıklar girdi vektöründen uzaklaştırılır (Gauri, 2010; Öztemel, 2012).

Daha önce belirtildiği üzere, Kohonen ve çıkış katmanları arasındaki ağırlıklar (α) sabit ve 1 değerine sahiptir ve bu değerler eğitim esnasında değiştirilmez. Çıktı y_j^k ise, yarışı kazanırsa 1 (bir), aksi durumlarda 0 (sıfır) değerini almaktadır. Bu işlem için, denklem 2.3’teki formül ile ağırlık çıktıları hesaplanır (Öztemel, 2012; Tuskan, 2012):

$$y_i = \sum_j y_j^k \alpha_{ki} \quad (2.3)$$

LVQ ağırlık çıktıları hesaplandıktan sonra çıktının doğru sınıflanıp sınıflanmadığı sorgulanır. Çıkan cevaba göre Kohonen katmanındaki yarışmayı kazanan nöronu girdi katmanına bağlayan ağırlıklar değiştirilir. Eğitim setindeki tüm örnekler doğru sınıflandırılincaya kadar ya da maksimum iterasyon sayısına erişilinceye kadar bu işlemler tekrarlanır. Anlatılan bu metot standart LVQ modelidir (Bayır, 2006).

LVQNN modeli bazı dezavantajlar içermektedir. Bunlardan ilki, öğrenme katsayısı λ ’nın zamanında 0 (sıfır) değerine yakınsamamış olması durumunda, LVQ ağırlık doğru ağırlık değerlerinden uzaklaşabilmesidir. Ayrıca bazı veri setlerinde aynı referans vektörü yarışmayı çok sık kazanmaktadır, bu da ağırlık öğrenme performansını düşürmektedir. Diğer dezavantajı ise, tam ortada veya orta sınıra çok yakın bulunan vektörlerin hangi sınıfta yer aldıklarının doğru belirlenememesidir (Bayır, 2006). Bu sorunlara çözüm üretmek için farklı LVQNN modelleri önerilmiştir. LVQ2 ağı, özellikle sınır değerlerindeki yanlış sınıflandırmayı azaltmak amacıyla, yine Kohonen tarafından geliştirilmiştir. LVQ2 ağı, standart LVQ’dan farklı olarak, eğitim esnasında 2 koşula bağlı olarak aynı anda 2 referans vektörünün ağırlıklarını değiştirmektedir. Bu iki vektör W_1 ve W_2 olarak adlandırılırsa, bu koşullar şunlardır (Tuskan, 2012):

1. Girdi vektörüne en yakın ağırlık vektörü W_1 , ondan sonraki en yakın ağırlık vektörü W_2 olmak üzere W_1 yanlış, W_2 ise doğru sınıftandır.

2. Girdi vektörleri W_1 ve W_2 , belirlenmiş bir mesafe aralığı içerisinde bulunmaktadır.

Bu iki koşulun birlikte sağlanması durumunda W_1 ve W_2 vektörlerinin ağırlıklarının yeni değerleri şu şekilde değiştirilir:


$$\begin{aligned} W_1 &= W_1 - \lambda(X - W_1), \\ W_2 &= W_2 - \lambda(X - W_2), \end{aligned} \tag{2.4}$$

burada λ öğrenme katsayısını, W_1 ve W_2 ağırlık vektörlerinin değerlerini (eşitliğin solu yeni değeri, eşitliğin sağı değişmeden önceki hali) temsil etmektedir (Tuskan, 2012). Böylece, LVQ2 ile sınıflar arasında kalan örnekler daha iyi sınıflandırılabilir.

2.1.2. Olasılıksal sinir ağları (probabilistic neural networks – PNN)


Donald Specht tarafından 1988 yılında geliştirilen PNN, sınıflandırma, haritalama, örüntü tanıma, benzerlik oranı tahminleme gibi işlemlerde kullanılan bir YSA modelidir. Denetimli öğrenme kullanan statik bir ağıdır. PNN, Bayes kuralını kullanan bir sınıflandırıcıdır. Bayes kuralı ise, olasılıksal yoğunluk fonksiyonlarını ve Parzen pencerelerini kullanır. Olasılık, bir şeyin gerçekleşmesinin ne kadar olası olduğunun matematiksel değeridir, yüzdesidir. PNN, bilinmeyen olasılık yoğunluklarını tahmin etmekte ve sınıfları n -boyutlu bir Gauss fonksiyonu çevresinde merkezlemektir (Koçak, 2010). PNN, radyal tabanlı bir ağ çeşididir.

PNN'in giriş katmanında girdi vektörünün eğitim vektörlerine yakınlık mesafesi hesaplanır. Her sınıf için hesaplanan değerler gizli radyal katmanında toplanır ve olasılık belirten bir vektör elde edilir. Radyal katmandaki ağırlıklar, doğrudan eğitim kümesindeki vektörler sayesinde belirlenir. Gizli katmandaki düğümlerin her biri, bir sınıfı gösterecek biçimde kümeler ayrışmışlardır. Son olarak, çıkışta yarışmacı bir yapı kullanılarak hesaplanan olasılık değerlerinden en büyük olanı seçilir, seçilen sınıf için 1 (bir) değeri diğer sınıflara ise 0 (sıfır) değeri atanır. Yani, girdi vektörünün ait olabileceği sınıf, her sınıf için bir olasılık değerinin hesaplanması ve en olası sınıfın seçilmesi ile bulunur (Çekli ve Uzunoğlu, 2011). PNN ağının mimari yapısı Şekil 2.3'te gösterildiği gibidir.



Şekil 2.3. PNN mimarisi (Beale ve ark., 2011).

Şekil 2.3'te R , Q ve K sırasıyla girdi vektöründeki nitelik, girdi/hedef çiftlerindeki eleman ve çıktı veri sınıflarındaki nitelik sayısıdır. Bu ağ, girdi vektörünü, doğru olma olasılığı en yüksek olan bir K sınıfına sınıflandırır. PNN'in gizli katmanında kullanılan radyal tabanlı aktivasyon fonksiyonu Şekil 2.4'te verilmiştir.



Şekil 2.4. PNN aktivasyon fonksiyonu $\text{radbas}(n)$ (Beale ve ark., 2011).

Radyal tabanlı aktivasyon fonksiyonu denklem 2.5'te verilen formül ile ifade edilir:

$$\text{radbas}(n) = e^{-n^2}, \quad (2.5)$$

burada $e = 2,7182...$ Euler sayısıdır.

Herhangi bir x giriş vektörü için j . sınıfın i . öznitelik vektörü ile ilgili Gauss denklemlerinin çıkışı aşağıdaki formüle göre hesaplanır:

$$Q_{ij}(x) = \left(\frac{1}{\sqrt{(2\pi\sigma^2)^m}} \right) e^{\left(-\frac{\|x - x_j^i\|^2}{2\sigma^2} \right)}, \quad (2.6)$$

burada m vektör boyutu, σ Gauss fonksiyonunun hassasiyetini düzenleyen yayılma faktörü (spread factor), $\pi = 3,1415...$ Pi sayısı, $e = 2,7182...$ ise Euler sayısıdır.

Sonrasında, j . sınıfının örnekleme katmanından gelen değerleri denklem 2.7’de verilen formül ile toplanır. Buna, Parzen penceresi denilmektedir.

$$P_j(x) = \left(1/\sqrt{(2\pi\sigma^2)^m}\right) \frac{1}{i} \sum_i e^{\left(-\|x-x_j^i\|^2/(2\sigma^2)\right)}. \quad (2.7)$$

Herhangi bir giriş vektörü x , çıkış katmanındaki her bir Gauss toplam işlevine uygulanır ve en büyük değere sahip olan seçilerek giriş vektörünün sınıfı belirlenir (Bunjaku, 2014). Sadece en büyük değere sahip olan düğüme 1 değeri atanır, diğerleri 0 değerini alır. Çıkış düğümleri denklem 2.8’de verilen eşitsizlikteki gibi karşılaştırılır:

$$\sum_i e^{\left(-\|x-x_j^i\|^2/(2\sigma^2)\right)} > \sum_p e^{\left(-\|x-x_p^i\|^2/(2\sigma^2)\right)} \quad (2.8)$$

Bu denklemden görüldüğü üzere x girdi vektörünün i . sınıfa ait olma olasılığı p ’den daha büyüktür.

Yayılma derecesi σ , öznitelik vektörlerinin birbirlerine ne kadar yakınlaştıklarının, birbirinden ne kadar uzaklaştıklarının bir ölçütüdür. Bu değer sıfıra yakın alındığında, öznitelik vektörünün sınıfı olarak en yakınındaki vektörün sınıfı atanır ve PNN en yakın komşu sınıflandırıcısı gibi çalışır. Büyük alındığında ise, giriş vektöründen sapma büyür ve daha uzaktaki vektörlere de bakılır, hassasiyet azalır. Radyal tabanlı fonksiyonların önemli bir parametresidir. Fakat yayılma faktörü tek başına ağırlık başarımını aşırı miktarda değiştiren bir parametre değildir.


Ayrıca, eğitim seti oluşturulurken birbirine yakın özniteliktekiler elimine edilirse, başarımlar açısından özellikle çok sınıflı problemlerde faydalı olmaktadır. Çünkü, yakın değer sağlayan öznitelikler çok sayıda Gauss işlevi ile daha çok hata oluşturabilmektedir (Çekli ve Uzunoğlu, 2011).

PNN’in eğitiminin hızlı olması onu avantajlı kılar. Sınıflandırmayı çoğu zaman çok katmanlı algılayıcı YSA’dan daha doğru yapar. PNN, aykırı değerlere nispeten duyarsızdır. Dezavantajı ise yapısının veri sayısına bağlı olmasıdır; eğitim kümesinin tamamını düğüm olarak içereceğinden dolayı boyutu büyür, modeli depolamak için daha fazla bellek alanı gerekir ve ağ yavaşlar.

2.1.3. Örüntü tanıma sinir ağları (pattern recognition neural networks – PRNN)

Örüntü tanıma sinir ağları (PRNN), girdileri hedef sınıflara göre sınıflandırmak üzere eğitilebilen ileri beslemeli YSA'lardır. Örüntü tanıma, verilerdeki örüntülerin ve düzenliliklerin algoritma, yapay zeka, makine öğrenimi gibi birtakım işlemlerle tanınması anlamına gelmektedir. Örüntü tanıma, çıktı değerini kategorize etmek için kullanılan bir prosedürdür. PRNN, örüntü tanıma ve sınıflandırma problemlerinin çözümünde yaygın olarak kullanılmaktadır.

Şekil 2.5'te gösterildiği gibi PRNN yapısında giriş, ara katman veya ara katmanlar ve çıkış katmanı bulunmaktadır. Ağa sunulacak ya da girilecek bilgi sayısı, giriş katmanındaki nöron sayısını belirler. Çıkış katmanı da ağdan sınıflandırılması istenen sınıf sayısı kadar nörondan oluşur. Bu hedef veriler vektör olarak ifade edilir, yani, üyesi olunan sınıf ögesindeki 1 hariç, tümü 0 (sıfır) değerine sahip vektörlerden oluşur.



Şekil 2.5. PRNN mimarisi.

MatlabTM programında, patternnet fonksiyonu ile, Şekil 2.5'teki bir gizli katmana, bir eğitim fonksiyonuna ve bir performans fonksiyonuna sahip PRNN oluşturulabilir.


PRNN'de ara katman nöron sayısı ve katman sayısı belirlenirken, kesin bir kural yoktur. Çözülmesi istenen problemdeki parametreler arası ilişkinin karmaşıklığı göz önünde bulundurulur. Ağın istenildiği kadar öğrenememesi durumunda yapılacak işlem ara katmandaki nöronların sayısını arttırmaktır. Nöron sayısının çok artırılması ise eğitim setine daha iyi, test setine daha kötü sonuç üretmesinden dolayı optimum nöron sayısının belirlenmesi YSA'da önemlidir.

PRNN'de, ara katmanlardaki çıktı değerleri denklem 2.9'daki eşitlik ile hesaplanır:

$$H(j) = f\left(\sum_{i=1}^n [X(i) * w(i, j)] + b(j)\right), \quad (2.9)$$

burada X girdi vektörünü, H gizli katmanı, i giriş katmanı eleman numarasını, j ara katman eleman numarasını, f aktivasyon fonksiyonunu, n veri sayısını, w ağırlığı ve b bias değerini temsil etmektedir.

PRNN gizli katmanında $\text{tansig}(n_1)$ ve çıkış katmanında $\text{compet}(n_2)$ aktivasyon fonksiyonlarını kullanmaktadır, bunlar Şekil 2.6'da verilmiştir:



Şekil 2.6. PRNN aktivasyon fonksiyonları (a) $\text{tansig}(n)$, (b) $\text{compet}(n)$ (Beale ve ark., 2011).

Netice olarak, çıktı değerleri ise aşağıdaki formül kullanılarak hesaplanır:

$$Y(k) = f_2(w_2 * f_1(w_1 * X + b_1) + b_2), \quad (2.10)$$

burada X girdi vektörünü, Y çıkış vektörünü, k sınıf numarasını, f aktivasyon fonksiyonlarını, w ağırlıkları ve b bias değerlerini temsil etmektedir (Dieste-Velasco, 2021).

PRNN denetimli öğrenme stratejisine göre çalışır. Yani, ağıın eğitilmesi sürecinde hem girdiler, hem de çıktı olan sınıflar ağına verilir. Denklem 2.10 ile elde edilen sonuç ile olması beklenen hedef sınıf değeri arasındaki fark hatayı oluşturur. PRNN'de hata miktarı genellikle çapraz-entropi (cross-entropy) fonksiyonu ile hesaplanır, bu denklem aşağıda verilmiştir (Gao ve ark., 2022):

$$CE = -\sum_{i=1}^n [Y_i \ln(T_i) + (1 - Y_i) \ln(1 - T_i)], \quad (2.11)$$

buradaki T hedef (gerçek) çıktı değerlerini temsil etmektedir. Hesaplanan bu hata, geriye doğru kendisini oluşturan ağırlıklara yansıtılır. Levenberg–Marquardt (trainlm), Bayesian Regularization (trainbr), Scaled Conjugate Gradient (trainscg) gibi hızlı

eğitim algoritmaları tercih edilir. Eğitim işlemine, tüm örnekler için elde edilen ortalama hata değeri önceden belirlenmiş kabul edilebilir bir hata değerinden düşük oluncaya kadar ya da maksimum iterasyon sayısına erişilinceye kadar devam edilir.

2.1.4. Kendi kendini düzenleyen haritalar (self-organizing maps – SOM)


Teuvo Kohonen tarafından 1981 yılında geliştirilen SOM algoritmasının amacı bir girdi vektörü içerisindeki önemli eğilimleri bir öğretmen olmadan keşfetmektir (Kohonen, 1981). Bunu, giriş verilerini haritalandıran yerel bir takım kurallara sahip olması ile yapmaktadır (Haykin, 1994). Bir veri analizi metodudur. SOM ağları, kümeleme işleminin yanısıra boyut indirgeme ve görselleştirme aracı olarak da kullanılmaktadır. Denetimsiz öğrenme yöntemi olan bu ağlar bazı kaynaklarda Kohonen ağları olarak da isimlendirilmektedir.

Sınıflama işleminde, verilerin grupları bilinmekte ve sonradan gelen verinin hangi gruptan olabileceği tahmin edilmektedir. Kümeleme işleminde ise, verilerin grupları bilinmemekte ve veri kümesi benzerliklerine ve farklılıklarına göre alt kümelere ayrılmaktadır. Diğer bir deyişle, kümeleme, verileri gruplara ayırmaktır. Özellikle, aynı kümede yer alan nesnelerin benzerliği nispeten yüksekken, farklı kümelerde bulunan nesneler çok düşük benzerlikler gösterirler.

SOM ağları, girdi uzayındaki çok boyutlu verilerin, çıktı uzayında 1 ya da 2 boyutlu haritalar ile görselleştirilmesine olanak tanıyan, girdi verileri arasındaki topolojik ilişkileri koruyan bir YSA modelidir. Bu ağda bir giriş, bir de çıkış katmanı bulunmaktadır. Diğer YSA çeşitlerinde olan gizli katman, SOM ağında yoktur. Çıkış katmanına Kohonen katmanı da denilmektedir. Girdi değerlerinin ağa sunulduğu giriş katmanı ile haritanın oluşturulduğu çıkış katmanındaki nöronlar birbirlerine referans vektörleri olarak da adlandırılan ağırlık vektörleri ile bağlıdır. Kohonen katmanındaki nöronlar genellikle 2 boyutlu olacak biçimde düzenlenirler. Diğer YSA’lardan farklı olarak, nöronların çıkış katmanındaki dizilimi oldukça önemlidir. Farklı şekil ve boyuttaki dizilimler, değişik topolojilere sahip haritalar oluşturur. Doğrusal, dikdörtgensel, altıgen, kübik gibi yapılarda olabilen dizilimlerden en sık tercih edileni ve genelde daha başarılı sonuçlar üreteni altıgen dizilimdir (Şahin, 2016). Buradaki dizilim önemlidir çünkü topolojik komşuluğu etkiler. Bu topolojik komşuluk, SOM sinir ağının eğitim sırasında, yarışmayı kazanan referans vektörüyle birlikte komşu

vektörlerin ağırlıklarının da güncellenmesine etki eder. Yani, komşuluk alanı içindeki tüm elemanlar, kazanan nöron ile birlikte düşünülmektedir.

Şekil 2.7’de görüldüğü üzere SOM ağları sadece giriş ve çıkış nöronlarından oluşan ağlardır; verilerin ağı sunulduğu bir giriş katmanı ile Kohonen katmanı olarak da bilinen bir çıkış katmanından oluşmaktadır. Giriş katmanındaki nöronlarının sayısı veri setindeki niteliklerin sayısı kadardır. Her bir giriş nöronu tüm çıkış nöronlarına (referans vektörlerine) birer ağırlık katsayısı ile bağlıdır. Çıkış katmanındaki düğüm sayısını belirlemek için net bir kural bulunmamaktadır, isteğe bağlı olarak belirlenir. Ağı çıkış katmanı genelde 2 boyutlu bir düzlem olarak alınır. Giriş katmanı ise dağıtım katmanı görevi görür. Çıktı değerinin belirlenmesinde “kazanan herşeyi alır (winner takes all)” stratejisi kullanılır. Çıkış katmanındaki nöronlar birbirleri ile yarışmakta, yarışmayı kazanan nöron 1 (bir) diğer nöronlar 0 (sıfır) değerini almakta ve kazanan nöron giriş vektörünün kümesini göstermektedir. SOM ağlarının girdi vektörlerinin dağılımını öğrenme başarımı çok yüksektir. Eğitimden sonra nöronlar değerlendirilerek, görüntülerinin harita üzerindeki dağılımlarına göre etiketlenirler.



Şekil 2.7. SOM sinir ağı.

SOM ağları, danışmansız öğrenme algoritmasını kullanan ileri beslemeli YSA’lardır. Danışmansız öğrenme algoritmaları, ağı giriş ile çıkışı arasındaki ilişkileri öğrenebilmek için, danışmalı öğrenme algoritmalarından farklı olarak, ağı giriş-çıkış vektör çiftlerinin sunulmasına ihtiyaç duymaz. SOM ağını eğitmek için sadece giriş

vektörü yeterlidir. Ağın eğitilmesi, çıkış nöronlarına ait referans vektörlerinin giriş vektörüne olan mesafelerine göre yarıştırılmasına, yani rekabetçi öğrenme esasına dayanmaktadır. Önce, her bir çıkış elemanı için mesafeler hesaplanır ve mesafe miktarı en düşük değere sahip eleman “kazanan nöron” olur. Sonra, bu nöronun komşuları topoloji ile belirlenir. Yarışmayı kazanan nöron ile birlikte komşu nöronların da ağırlık değerleri güncellenir. Böylece, ağırlık vektörleri küme merkezlerine doğru hareket eder ve eğitim sonunda kümeleri temsil eden referans vektörler elde edilir. Benzer desenlerin uzaysal kümelenmesi, hem kazanan nöronun hem de bu nörona komşu olan diğer nöronların ağırlıklarının değiştirilmesiyle elde edilmektedir. Bu sayede, n boyutlu giriş uzayında birbirlerine benzeyen kümeler, 2 boyutlu çıkış uzayında da birbirleri ile komşu olurlar.

SOM modelleri ile başarılı kümeleme çalışmaları yapmak için birtakım faktörlere dikkat edilmesi gerekmektedir. Bunlar sadece bir çerçeve çizmek amacıyla verilmiştir, bağlayıcı kural değildirler. En uygun SOM, genellikle deneme-yanılma yöntemi ile bulunur. Giriş vektörü ile referans vektörü arasındaki fark hata olarak kabul edilirse, en küçük mutlak hata ortalamasına sahip modelin en iyi model olduğu söylenebilir. Kümelemeyi etkileyen bu faktörler şunlardır (Zontul, 2004):

Çıkış katmanındaki nöron sayısı: Bu faktör, küme sayısını belirlemektedir. Küme sayısının çok fazla olması bazı kümelerde yoğunluğunun sıfıra yaklaşmasına, küme sayısının az olması ise iç içe geçmiş ve aykırı değerler içeren kümelerle neden olmaktadır. Bunlar, kümeleme algoritmasının performansını düşürmektedir. Veri kümesindeki öge sayısının %10’u ya da yarısının karekökü ($\sqrt{n/2}$) civarında çıkış nöronu tercih edilmektedir.

Verilerin normalleştirilmesi: Genellikle, tüm değişkenler aynı ölçme düzeyinde ölçülmezler. Veri setindeki bazı değişkenlerin boylamsal olarak farklı düzeylerde olmasından dolayı, bu değerler normalize edilmektedir. Kazanan nöronun belirlenmesinde ve kazanan nöronla beraber komşu nöronların ağırlıklarının güncellenmesinde uzaklık ölçülmektedir. Uzaklık mesafesi ölçülürken, farklı değer aralıklarında bulunan değişkenlerin aynı değer aralığında temsil edilmesi ile bütün değişkenlere eşit şans verilir ve sonuçların büyük değerli değişkenler tarafından çarpıtılması önlenir. Sütun bazında yapılan normalleştirme işlemi değişik şekillerde tercih edilmektedir (Zontul, 2004):

- a) Her bir değişken değeri, sütunun standart sapmasına bölünür.
- b) Her bir değişken değeri, sütunun ortalaması çıkartılarak sütunun standart sapmasına bölünür. Böylelikle, ortalaması 0 ve standart sapması 1 olan bir dağılım elde edilir.
- c) Her bir değişken değeri, sütunun vektör uzunluğuna bölünür.

Referans vektörlerine ilk değer atanması: SOM algoritmasında, başlangıç ağırlık vektörlerinin belirlenmesi de, kritik öneme sahip olabilmektedir. Farklı yöntemler kullanılmaktadır. Bunlardan en çok tercih edileni, eğitimin rastgele değerlerde atanmış ağırlık vektörleri ile başlatılmasıdır. İkinci yöntem, bütün referans vektörlerine 0'dan çok az büyük değerler atanması ve öğrenme katsayısının 1'e yakın bir değerden başlatılarak azaltılmasıdır. Diğer bir yöntem ise, doğrusal sıralanmış ağırlıklar ile başlanarak eğitimin yapılmasıdır.

Uzaklık ölçüsü: SOM algoritmasında, uzaklık ölçüsü ağırlık eğitimi esnasında kullanılan önemli bir faktördür. Giriş vektörleri ile referans vektörleri arasındaki uzaklığın karelerinin toplamının karekökü olarak hesaplanan Öklid uzaklığı, en yaygın kullanılan uzaklık ölçüsüdür. City-block (Manhattan), Minkowski, Mahalanobis gibi farklı uzaklık fonksiyonlarının da literatürde kullanıldığı görülmektedir.

Öklid (Euclid) uzaklığı denklem 2.12'de verilen formül ile hesaplanır:

$$d_{ij} = \sqrt{\sum_k (x_{ik} - x_{jk})^2}, \quad (2.12)$$

burada, d_{ij} i . ve j . birimlerin birbirlerine olan uzaklığını, x_{ik} i . birimin k . değişkeni değerini, x_{jk} j . birimin k . değişkeni değerini temsil etmektedir.

City-block (Manhattan) uzaklığı, birimler arasındaki mutlak uzaklık değerlerinin toplamı olarak hesaplanan uzaklık ölçüsüdür:

$$d_{ij} = \sum_k |x_{ik} - x_{jk}|. \quad (2.13)$$

Minkowski uzaklığı ise denklem 2.14'te verilmiştir:

$$d_{ij} = \left[\sum_k (x_{ik} - x_{jk})^q \right]^{1/q}. \quad (2.14)$$

Bu uzaklık ölçüsü daha genel bir uzaklık ölçü birimidir: $q = 1$ olduğunda City-block uzaklık ölçüsüne, $q = 2$ olarak alınırsa Öklid uzaklık ölçüsüne dönüşür.

Mahalanobis uzaklık ölçüsü 2 değişken arasındaki varyans ve kovaryansları toplayarak korelasyonu ayarlayan uzaklık ölçü birimidir. Formülü, denklem 2.15'te verilmiştir:

$$d_{ij} = (x_{ik} - x_{jk})' S^{-1} (x_{ik} - x_{jk}), \quad (2.15)$$

burada S örneklem kovaryans matrisini temsil etmektedir (Eşmen, 2020).

Öğrenme katsayısı ve komşuluk değişkeni: Öğrenme katsayısı 0 ile 1 arasında bir değerle başlatılmaktadır. Komşuluk değişkeni, genellikle 1, 5 ya da 10 gibi bir değerle başlatılmaktadır. Bunlar, döngü boyunca genellikle lineer olarak azaltılmaktadır. Bu işlem, denklem 2.16'da verilen fonksiyon ile yapılabilir:

$$\alpha(t) = \alpha(t) - \frac{A}{t + B}, \quad (2.16)$$

burada α öğrenme katsayısı veya komşuluk değişkeni, t döngü sayısı, A ve B ise fonksiyon değerini ayarlama da kullanılan diğer katsayılardır (Zontul, 2004).

2.2. Bulanık Mantık

Lotfi A. Zadeh tarafından 1965 yılında yayınlanan “bulanık kümeler” isimli makale ile küme sınırlarının yumuşatılması önerilmiş ve sonrasında bulanık mantık kavramı ortaya çıkmıştır. Bulanık mantık, klasik kümeler yerine bulanık kümeler kullanır. Bulanık mantık, klasik mantığın genişletilmiş belirsizlikler de içeren halidir. İnsanların ifade etme ve akıl yürütme biçimini modelleyebilen bir yapay zeka yöntemidir. Bulanıklık, kesin olmayan belirsizlik içeren bilgiyi ifade etmektedir. Bulanık mantık ise, kesin dilsel niteleyiciler kullanmak yerine belirsizliklerle çalışır. Bulanık mantıkta az, normal veya çok; soğuk, ılık veya sıcak; çok düşük, düşük, orta, yüksek veya çok yüksek; karanlık, biraz karanlık, biraz aydınlık veya aydınlık gibi dilsel niteleyici kelimeler ile değerler ifade edilirler. Böylece, karmaşık bir sistem sözel değişkenlerle tanımlanıp yönetilebilir. Bulanık mantık klasik mantıktan daha avantajlıdır, çünkü sistemin kesin bir modeline ihtiyaç duymaz, belirsizlikleri işleyebilir, her şeyin doğru ya da yanlış olduğunu varsaymaz ve karmaşık problemleri genel bir çerçevede alıp çözebilir.

Aristo mantığı olarak da bilinen klasik mantıkta, önermeler yanlış ya da doğru, 0 ya da 1 değerlerine sahip olurlar. Bulanık mantık ve bulanık küme teorisi, klasik mantık ve klasik küme teorisinin genişletilmiş matematiksel versiyonudur. Doğru/yanlış, evet/hayır gibi geleneksel değerlendirmeleri esnetir. Klasik kümelerde her bir eleman ya o kümenin üyesidir ya da değildir, değeri 1 ya da 0'dır. Bulanık kümelerde ise her bir eleman 0 ile 1 arasında değişen bir üyelik değerine sahip olur. Yani, bulanık mantık kısmi üyelik olarak adlandırılan, bir kümeye tam üye olma ile o kümeye üye olmama durumları arasında dereceli geçiş imkanı sunar.

2.2.1. Bulanık kümeleme

Kümeleme, araştırmada incelenen birimlerin benzerliklerine göre gruplandırılmasını, birimlerin ortak özelliklerinin gösterilmesini ve bu gruplar hakkında genel tanımlamalar yapılmasını sağlama işlemidir. Amaç, veriler arasındaki benzerlikleri dikkate alarak, benzer verileri aynı kümede toplamaktır. Verilerdeki benzerlikleri belirlemek için uzaklık ölçüleri, korelasyon veya katsayı karşılaştırma ölçütleri kullanılmaktadır (Erilli ve Karaköy, 2015).

Kümeleme algoritmaları, verileri benzerliklerine göre sınıflandırmak için kullanılan denetimsiz öğrenme yöntemleridir. Dunn (1973) tarafından tanıtılan ve sonrasında Bezdek (1981) tarafından geliştirilen Bulanık C-Ortalamlar (Fuzzy C-Means – FCM) algoritması, bulanık mantığa dayalı denetimsiz bir kümeleme yöntemidir. Bulanık küme teorisi ile kümelemenin birleşimidir. Görüntü analizi, hedef tanıma, mühendislik gibi alanlarda başarı uygulamaları bulunan bu algoritma, önemli ve popüler kümeleme tekniklerinden biri olarak kabul edilmektedir (Ghosh ve Dubey, 2013).

FCM algoritması, birimlerin aitlik düzeylerine göre farklı kümelerin üyesi olabilmesine olanak tanır. Amaç, birimleri üyelik derecelerini kullanarak en uygun kümeye ayırmaktır. Bu yaklaşım, kümelerin birbirinden açıkça ayrılmadığı veya bazı birimlerin küme üyeliğinden emin olunamadığı durumlara da uygun, esnek mimariye sahip bir yöntemdir. Sıra dışı verilerin etkisi, üyelik derecelerinin düşük olması nedeniyle azdır. Örtüşen kümeleri belirleme performansı yüksektir. FCM yöntemi ile kümeleme, tanımlanmış bir amaç fonksiyonunun minimize edilmesiyle gerçekleşir (Zeybekoğlu, 2018).

FCM kümeleme algoritması, $X = \{x_i, i = 1, 2, \dots, n \mid x_i \in \mathbb{R}^n\}$ veri noktaları kümesi olmak üzere, X veri noktaları kümesini U üyelik matrisi yardımıyla c sayıda örtüşen

kümeye ayırmaktadır. Her bir x_i elemanı birden fazla alt kümeye belli derecelerde üye olabilmektedir. U üyelik matrisi, eşitlik 2.17’de verilen, her bir k ($k = 1, 2, \dots, c$) kümesindeki x_i veri noktası vektörünün üyelik derecelerinden oluşan $c \times n$ boyutunda bir matris ile ifade edilmektedir:

$$U = \begin{bmatrix} \mu_{11} & \cdots & \mu_{c1} \\ \vdots & \ddots & \vdots \\ \mu_{1n} & \cdots & \mu_{cn} \end{bmatrix}. \quad (2.17)$$

μ_{ik} , U matrisindeki i . veri noktası vektörünün k . kümedeki üyelik derecesi olmak üzere, $\forall_{i,k}$ için $\mu_{ik} \in [0, 1]$ ’dir. Üyelik matrisinde her bir x_i elemanının üyelik dereceleri toplamı 1’e eşittir: $\forall_k$ için $\sum_{i=1}^c \mu_{ik} = 1$ olur. Ayrıca, $\forall_i = 1 \dots n$ için $0 < \sum_{k=1}^c \mu_{ik} < n$ koşulunu sağlar. c kümesi ve n veri noktalarını içeren kümeleme için bulanık üyelik dereceleri matris ailesi M_{fc} aşağıdaki eşitlikte verilmiştir:

$$M_{fc} = \left\{ U \in \mathbb{R}^{c \times n} \mid \mu_{ik} \in [0, 1], \forall_{i,k}; \sum_{i=1}^c \mu_{ik} = 1, \forall_k; 0 < \sum_{k=1}^c \mu_{ik} < n, \forall_i \right\} \quad (2.18)$$

FCM kümeleme algoritmasında maliyet fonksiyonu $J_m(U, v)$ denklem 2.19’da verilen formül ile hesaplanır. Amaç, minimum maliyet fonksiyonu değerini elde etmektir.

$$J_m(U, v) = \sum_{k=1}^c \sum_{i=1}^n \mu_{ik}^m d_{ik}^2, \quad (2.19)$$

burada v parametresi küme merkezini, m parametresi bulanıklaştırıcıyı, d_{ik} uzaklık ölçüsünü ifade etmektedir. $V = \{v_i, i = 1, 2, \dots, c \mid v_i \in \mathbb{R}^c\}$ olmak üzere, i . küme merkezi olan v_i , c boyutlu bir vektöre denk gelmektedir. Bulanıklaştırıcı (fuzzifier) katsayısı $1 \leq m \leq \infty$ kümelerin örtüşme derecesini belirlemektedir. Veri noktası x_k ve i . alt küme merkezi v_i arasındaki uzaklık $d_{ik} = \|x_k - v_i\|$ metriği ile belirtilir. Genellikle, Öklid uzaklık ölçüsü kullanılmaktadır, denklemini aşağıdaki eşitlikte verilmiştir:

$$d_{ik} = d(x_k - v_i) = \|x_k - v_i\| = \sqrt{\sum_{j=1}^m (x_{kj} - v_{ij})^2}. \quad (2.20)$$

FCM bir yinelemeli optimizasyon yöntemidir. Bu algoritma aşağıda verilen adımlardan oluşmaktadır (Ross, 2010; Izakian ve Abraham, 2011):

Adım 1. m ($m \geq 1$) bulanıklaştırıcı ve c ($2 \leq c < n$) küme sayıları belirlenir. $U^{(0)} \in M_{fc}$ olmak üzere, U matrisi rastgele değerler ile başlatılır.

Adım 2. $\{v_i^{(r)}\}$, ($r = 0, 1, \dots$) küme merkezi aşağıda verilen denklem ile bulunur:

$$v_{ij}^{(r)} = \frac{\sum_{k=1}^n (\mu_{ik})^m x_{kj}}{\sum_{k=1}^n (\mu_{ik})^m} \quad (2.21)$$

Adım 3. $\{d_{ik}^{(r)}\}$, ($r = 0, 1, \dots$) Öklid uzaklıkları hesaplanır.

Adım 4. $U^{(r)}$ matrisi μ_{ik} değerleri r . adım için denklem 2.22 kullanılarak güncellenir:

$$\mu_{ik}^{(r+1)} = \frac{1}{\sum_{j=1}^c \left(\frac{d_{ik}^{(r)}}{d_{jk}^{(r)}} \right)^{2/(m-1)}}, \quad i = 1, \dots, n; k = 1, \dots, c \quad (2.22)$$

Adım 5. Eğer $U^{(r+1)} - U^{(r)} \leq \varepsilon$ ise algoritma durdurulur, değilse Adım 2'ye dönülür (Çalışkan ve ark., 2021).

FCM modelinde kümelemeyi etkileyen faktörler şunlardır (Kaya, 2018):

Küme sayısının seçimi: FCM algoritmasının performansını etkileyen en önemlisi c parametresi küme sayısıdır. Çoğu durumda küme sayısı önceden bilinmemektedir. Küme sayısı olması gereken gerçek küme sayısından az ya da çok olmamalıdır. Eğer değeri büyük alınırsa, bir ya da daha fazla kompakt küme fazladan bölünür, küme sayısı düşük belirlendiğinde ise ayrı olması gereken bazı kümeler birleşir. Dolayısıyla, doğru küme sayısının belirlenmesi önemlidir. Veri kümesindeki eleman sayısının %10'u ya da yarısının karekökü ($\sqrt{n/2}$) civarında küme tercih edilmektedir.

Bulanıklaştırıcı katsayısı: Bulanıklaştırıcı parametresi m , verilerin kaç adet kümeye aynı anda üye olabileceğini belirler. Değeri 1'e yaklaşırsa, küme katılaşır ve FCM, "Sert C-Ortalamlar" algoritmasına dönüşür. Değeri çok büyük alınırsa, üyelik dereceleri $1/c$ değerine yaklaşacaktır ve elemanların kümelere etkisi azalacaktır. Bulanıklaştırıcı katsayısının değeri genellikle 2 olarak tercih edilmektedir.

Durdurma kriteri: FCM eğitilirken, eğer bir önceki U üyelik matrisi ile sonraki arasındaki fark, durdurma kriteri ε 'den küçük ise algoritma durdurulur. Bu parametrenin değeri çoğu zaman 0,01 ya da 0,001 olarak alınmaktadır.

Başlangıç üyelik matrisi: Üyelik matrisindeki her bir μ_{ik} üyelik derecesine başta rastgele değerler atanır. Bu sayede, v_i küme merkezleri de rastgele değerler ile başlatılmış olur. Eğitim sürecinde bu değerler değişir. Küme merkezi başlangıç değerleri, FCM algoritmasının performansını oldukça etkilemektedir. Daha başarılı sonuçlara ulaşmak için, FCM algoritması farklı başlangıç değerleri ile denenmektedir (Avcı, 2006). Böylece, lokal minimum noktalarına olası takılmaların önüne geçilir.

FCM çok iyi bir kümeleme algoritması olmasına rağmen, gerçek dünya verilerinin üyeliklerin ait olduğu derecelere her zaman iyi uymamasından ve aykırı değerlerin de üyelik değerleri hesaplamasında kullanılmasından dolayı yanlış sonuçlar üretebilir (Kaya, 2018).



3. DOĞUM YÖNTEMLERİ SINIFLANDIRMASI

Gebelik ve doğum yaşamın doğal sürecinin bir parçasıdır, vücudun sağlıklı ve normal bir fonksiyonudur. İki temel doğum yöntemi vardır: normal doğum ve sezaryen doğum.

3.1. Normal Doğum

Normal doğum, memelilerde doğum kanalı yoluyla yavruların doğmasıdır (wikipedia.org, 2021). Doğal doğum yöntemi olduğu için en yaygın yol normal doğumdur. Normal doğum, gebeliğin 37-42. haftaları arasında uterus başlangıçta başlayan kasılmalarda birlikte rahim ağzında açılma, sonrasında bebeğin doğum kanalından geçerek dünyaya gelmesi olarak tanımlanabilir. Bebek ve anne gebelik, doğum ve doğum sonrası dönemde birçok riskle karşı karşıya kalabilmektedir. Bu nedenle bu süreçlerde bebek ve anne düzenli şekilde takip edilerek doğum şekline karar verilmelidir. Normal doğum sonrası sezaryen doğuma göre annenin iyileşme ve hastanede kalma süresi daha kısadır. Normal doğum yapan annelerde oksitosin hormonunun hızlı ve etkin salgılanması annenin bebeğini kısa sürede emzirmeye başlamasını sağlamaktadır. Doğum kanalından geçerken bebeğin bağışıklık sisteminin güçlenmesini sağlayan faydalı bakterilerle karşılaşması ve akciğerdeki amniyon sıvısının kolaylıkla atılması, solunum sıkıntısının az olması normal doğumun diğer avantajlarıdır.

3.2. Sezaryen Doğum

Sezaryen doğum, doğal yolla doğumun anne veya bebek için risk oluşturduğu şartlarda karın ve uterus duvarına yapılan insizyonlarla doğumun gerçekleştirilmesidir. Normal doğumun güvenli şekilde tamamlanamayacağı, bebek veya anne için morbidite ve mortalite riskinin arttığı durumlarda sezaryen doğum tercih edilmelidir. Sezaryen en sık uygulanan cerrahi operasyonlardan biridir. Baş pelvis uyumsuzluğu, bebekte duruş bozukluğu, iri bebek, fetal distress, daha önceki doğumun sezaryen olması, çoklu gebelik, distosi gibi durumlar sezaryen endikasyonlarıdır. Ülkemize ve dünyada

normal doğum oranı azalmakta, sezaryen doğum oranı artmaktadır. DSÖ sezaryen oranının %15'den fazla olmamasını önermektedir.

DSÖ'nün tanımlarına göre erken doğum, 37 tamamlanmış gebelik haftasından önce herhangi bir doğum; zamanında doğum, 37 tamamlanmış haftadan 41 tamamlanmış gebelik haftasına kadar olan doğum; geç doğum ise 41 tamamlanmış gebelik haftasından sonraki herhangi bir doğumdur (Liu ve ark., 2012). Erken ve geç doğum, artan fetal ve neonatal mortalite ve morbidite riskinin yanısıra artan maternal morbidite ile ilişkilidir. Erken ve geç doğumlarda normal doğum veya sezaryen doğum kararı genellikle fetal ve maternal riskler değerlendirilerek verilir.

Doğumun farklı aşamalarında ortaya çıkan problemler nedeniyle doğumun normal seyrinde ilerlemediği durumlar distosi (zor doğum eylemi) olarak tanımlanır. Distosi doğum kanalı ile ilgili kemik ve yumuşak doku kaynaklı sorunlar, bebekte prezentasyon bozukluğu (makat geliş, omuz geliş), uterus kasılmaları ilgili sorunlardan (hipertonik uterus, hipotonik uterus) kaynaklanabilir. Doğum eylemi sırasında fetal kalp hızı anormallikleri, hipertansiyon, umbilikal kord, plasenta anormallikleri, çoğul gebelik gibi problemlere bağlı farklı sorunlar da gelişebilir. Fetal distres, doğumdan önce ve doğum sırasında fetüsün iyi olmadığını gösteren işaretlerin varlığını ifade eder. Tipik olarak fetüs yeterli oksijen almadığında ortaya çıkar (americanpregnancy.org, 2014). Kalp atış hızı anormallikleri, fetal sıkıntı belirtileridir. Bunlar taşikardi (anormal derecede hızlı bir kalp hızı), bradikardi (anormal derecede yavaş bir kalp hızı), değişken yavaşlamalar (kalp hızında ani düşüşler) ve geç yavaşlamalardır (kasılma sonrası temel kalp hızına geç dönüş). Fetal kalp hızı gebelik ve doğum boyunca izlenmelidir.

Hamilelik sırasında anormal kan basıncı, anne ve bebek için sorunlara neden olabilir. Amerikan Kardiyoloji Koleji/Amerikan Kalp Derneği'ne göre, gebelik sırasındaki hipertansiyon, iki ayrı durumda ölçülen Sistolik Kan Basıncının (SBP) ≥ 140 mmHg ve/veya Diyastolik Kan Basıncının (DBP) ≥ 90 mmHg değerlerinde saptanmasıdır (Whelton ve ark., 2018). Maternal, fetal ve neonatal sorunlara neden olan hipertansif bozukluklar gebeliklerin yaklaşık %5-10'unu etkiler. Anneye yönelik rahatsızlıklar arasında preeklampsi (kan basıncında ani yükselme) ve eklampsi (daha şiddetli ve nöbet veya koma olabilir) bulunur. Bu bozukluklar gebeliğin sonlandırılmasını gerektirebilir. Hızlı doğum gerektiren obstetrik veya klinik durumlar varsa sezaryen

doğum gerekli olabilir. Gebelikte yaşamı tehdit eden komplikasyonlardan kaçınmak için kan basıncı yakından izlenmelidir.

Anne ve bebek açısından bir diğer risk faktörü ileri anne yaşıdır. İleri anne yaşı; anne yaşının 35 yaş ve üstü olması olarak tanımlanır. İleri anne yaşında gebeliğe bağlı hipertansiyon, gestasyonel diyabet, sezaryen doğum riski belirgin şekilde artış gösterir.

Çoğul gebelik, erken doğum, düşük, hipertansiyon ve diyabet gibi farklı komplikasyonlar için riskleri artırır. İkiz doğumlarda, her iki fetus de vertex pozisyonundaysa ve başka bir komplikasyon yoksa normal doğum mümkündür. Normal doğumla ilişkili ana risk, ikinci ikizin anoksi olasılığı ile bağlantılıdır. Doğum şekline karar vermede en önemli faktörler fetüsün pozisyonu, gebelik yaşı ve fetüsler arasındaki ağırlık veya ağırlık farkıdır. Planlı normal doğum sıklıkla gerçekleştirilebilse de, sezaryen gerektirebilecek önemli risklere karşı hazırlıklı olunmalıdır (Taylor, 2006).

3.3. Yapay Zeka Yöntemleri ile Doğum Yöntemini Belirleme Çalışmaları

YSA, iyi bilinen özellikli bir makine öğrenmesi tekniğidir. Biyolojik sinir ağlarının işlevleri ve bağlantılarından geliştirilmiş bir matematiksel modeldir. Giriş-çıkış çiftlerinden öğrenme yeteneğine sahiptir. YSA tahmin, optimizasyon, sınıflandırma ve kümeleme amaçları için kullanılmaktadır. Bazı makalelerde, YSA'nın büyük tıbbi veritabanlarıyla sonuçları tahmin etmek için ideal araçlar olduğu gösterilmiştir.

Sağlık hizmetlerinde yapay zeka metodolojileri giderek daha talep edilir ve daha gerekli hale gelmektedir. Son yıllarda doğum yönteminin belirlenmesi için bazı zeki uygulamalar yapılmıştır. Van Dyne ve ark. (1994) hamile kadınlarda erken doğumu tahmin etmek için istatistiksel analizi, makine öğrenmesini ve uzman sistemleri kullanmışlardır. Frize ve ark. (2004) sınıflandırıcı olarak ileri beslemeli YSA ve bulanık mantık sınıflandırıcısı algoritmalarını kullanarak doğumlar için klinik sonuçları öngörmüşlerdir. Gharehchopogh ve ark. (2012) sezaryen veri setlerinde veri madenciliği yapmak için karar ağacı algoritmasını kullanmışlardır. Sodsee (2014) yeni bir k -en yakın komşular algoritması geliştirerek Tayland'daki sezaryen doğumları tahmin etmiştir. Robu ve Holban (2015), Bayes algoritmaları aracılığıyla doğum verilerinin analizini ve sınıflandırmasını gerçekleştirmişlerdir. Amin ve Ali (2017), doğum yönteminin belirlenmesi için rastgele orman, lojistik regresyon, Naive Bayes,

k-en yakın komşular ve destek vektör makinesi algoritmalarını kullanmışlardır. Abbas ve ark. (2018) doğum yöntemi sınıflandırması yapabilmek için AdaBoost, rastgele ormanlar, *k*-en yakın komşular, doğrusal diskriminat analizi, destek vektör makinesi, Naive Bayes ve ileri beslemeli YSA yöntemlerini uygulamışlar, rastgele orman yönteminin diğerlerine göre daha iyi sonuç verdiğini göstermişlerdir. Suwarno ve Santo (2019), uygun doğum yöntemini belirlemek için geri yayımlı çok katmanlı YSA kullanmışlardır.

Ayrıca, uzun dönemdeki sezaryen oranlarını tahmin etmek için yapay zeka algoritmalarından yararlanılmıştır. Fergus ve ark. (2017) derin öğrenme, rastgele orman ve Fisher'in lineer diskriminant analiz algoritmalarını Çekya'nın Brno şehrindeki Üniversite Hastanesi ve Prag şehrindeki Çek Teknik Üniversitesi verileri ile fetal kalp atış hızı sinyallerini kullanarak sezaryen ve normal doğum sayısını tahmin etmek için modellemişlerdir. Fergus ve ark. (2018) Fisher lineer diskriminant analizi, rastgele orman ve destek vektör makinesi sınıflandırıcıları ile kardiyotokografi izlerini kullanarak sezaryen ve normal doğum sayısını tahmin etmişlerdir. Senyefia ve ark. (2019) otoregresif entegre hareketli ortalama modeli ile Gana'daki sezaryen doğumların zaman serisi analizini ve tahminini yapmışlardır. Nyoni ve Nyoni (2020) Zimbabve'deki Kwekwe Genel Hastanesi'nde yeni sezaryen vakalarını tahmin etmek için ileri beslemeli YSA kullanmışlardır.

Öğrenmeli Vektör Niceleme Sinir Ağları (LVQNN), Olasılıksal Sinir Ağları (PNN), Örüntü Tanıma Sinir Ağları (PRNN) veri kümelerini sınıflandırmak için kullanılan güçlü üç temel Yapay Sinir Ağı (YSA) tekniğidir. Sezaryen tahmininde bu tekniklerin performansı analiz edilmiştir. Doğum yöntemi sınıflandırması için literatürde herhangi bir LVQNN, PNN ya da PRNN uygulamasına rastlanılmamıştır. Bu makine öğrenme tekniklerinin doğum yöntemi sınıflandırması için incelenmesi göz ardı edilmemelidir.

3.4. Doğum Yöntemi Veri Kümesi

Sezaryen, en sık yapılan cerrahi operasyonlardan biridir. Dünyada son yıllarda sezaryen oranları önemli oranda yükselmiştir. ABD'de 1996'dan 2006'ya %60 artmıştır (Hamilton ve ark., 2007). 2017 yılında ABD'de sezaryen doğum oranı tüm doğumların %32'siydi (Hamilton ve ark., 2018). Son yıllardaki doğum istatistiklerine göre ABD'de yaklaşık her üç gebeden biri sezaryen ile doğum yapmıştır. Sezaryen, komplikasyon riski taşıyan ve anne veya bebeğin hayat kurtarıcısı olabilecek

gebeliklerde uygulanmaktadır. DSÖ %15 sezaryen oranını önermektedir (BBC News, 2010). Hastanelerde doğumlarla ilgili kayıtlar tutulabilmektedir.

Bu çalışmadaki sezaryen veri seti Gharehchopogh ve ark. (2012) tarafından Tebriz Sağlık Merkezi'nden toplanmıştır. Sonrasında, bu veri seti başka makalelerde de kullanılmıştır (Amin ve Ali, 2017; Suwarno ve Santo, 2019). Veri seti, yaş, doğum sayısı, doğum süresi, kan basıncı ve kalp durumu olmak üzere doğum problemlerinin en baskın 5 faktörü olan 80 gebenin sezaryen sonuçlarından oluşturulmuştur. Toplanan verilerdeki gözlemler, 17 yaşından 40 yaşına kadar değişen farklı özelliklerdeki hamile kadınları içermektedir. Toplanan verilerdeki doğum sayıları 1 ile 4 arasındadır. Doğum süresi, zamanında, erken ve geç olarak sınıflandırılmaktadır. Kan basıncı, düşük, normal ve yüksek olmak üzere üç durumda değerlendirilmektedir. Kalp sorunu yok ya da var olarak nitelendirilmektedir. Çıktı olarak iki sınıf vardır: normal doğum veya sezaryen. Bu nitelikler Tablo 3.1'de özetlenmiştir.

Tablo 3.1. Doğum yöntemi sınıflandırma nitelikleri.


Değişken	Öznitelik	Sınıflandırma
Girdi 1	Yaş	$17 \leq \text{yaş} \leq 40$
Girdi 2	Doğum Sayısı	1, 2, 3, 4
Girdi 3	Doğum Süresi	0 = zamanında, 1 = erken, 2 = geç
Girdi 4	Kan Basıncı	0 = düşük, 1 = normal, 2 = yüksek
Girdi 5	Kalp Sorunu	0 = yok, 1 = var
Çıktı	Sezaryen	0 = Hayır, 1 = Evet

Veri seti, aralıklı seçim sağlanarak eğitim ve test verileri olarak ayrılmıştır. Veri setinin %75'i eğitim verisi, kalan %25'i ise test verisi olarak kullanılmıştır. Böylece, eğitim ve test veri setleri sırasıyla toplam 60 ve 20 veriye sahip olmuştur.

Ayrıca, girdi verileri $[0,1 - 0,9]$ aralığına normalize edilmiştir.


3.5. Doğum Yöntemi Sınıflandırması

Tezin bu kısmında, Tebriz Sağlık Merkezi veri seti üzerinden sezaryen doğumunun modellenmesi ve sınıflandırılması LVQNN, PNN ve PRNN yöntemleri ile gerçekleştirilmiştir. Önceki bölümde anlatıldığı üzere, kullanılan veri seti 80 gebe kadının doğum sonuçlarını içermektedir. Her hamile kadın için 5 giriş parametresinden (yaş, doğum sayısı, doğum süresi, kan basıncı ve kalp durumu) ve 2 sınıftan (normal doğum veya sezaryen) oluşmaktadır. Bu sınıflandırma modeli, doktorların doğum yöntemlerinin risklerini değerlendirmesine ve doğru kararı vermesine yardımcı olabilir. MATLAB™ programı, LVQNN, PNN ve PRNN modellerinin eğitimi ve testi için kullanılmıştır. Şekil 3.1’de gizli katmandaki nöron sayılarına göre LVQNN’nin eğitim ve test performansları, learnlv1 ve learnlv2 LVQ öğrenme fonksiyonları ile gösterilmiştir.




Şekil 3.1. Gizli katmandaki nöron sayılarına göre LVQNN’nin eğitim ve test performansları (a) learnlv1, (b) learnlv2 LVQ öğrenme fonksiyonları ile.

Şekil 3.1 incelendiğinde, en iyi test sonucunun 0,1 MSE ile hem gizli katmanında 10 nöron bulunan learnlv1 LVQ öğrenme fonksiyonuna sahip LVQNN ağı ile hem de gizli katmanında 17 nöron bulunan learnlv2 LVQ öğrenme fonksiyonuna sahip LVQNN ağı ile elde edildiği görülmektedir. Eğitim seti sonucu incelendiğinde ise gizli katmanında 10 nöron bulunan learnlv1 LVQ öğrenme fonksiyonuna sahip LVQNN ağının 0,1667 MSE ile daha düşük hata değeri ürettiği görülmektedir. Bu LVQNN mimarisi Şekil 3.2’de verilmiştir.




Şekil 3.2. Sezaryen veri seti için kullanılan LVQNN mimarisi.

Şekil 3.3'te yayılma faktörüne (spread factor) göre PNN'nin eğitim ve test performansları gösterilmiştir.




Şekil 3.3. Yayılma faktörüne göre PNN'nin eğitim ve test performansları.

Şekil 3.3 incelendiğinde, en iyi test sonucunun 0,15 MSE ile 0,24 yayılma faktörlü PNN ağı ile elde edildiği görülmektedir. Bu PNN mimarisi Şekil 3.4'te verilmiştir.




Şekil 3.4. Sezaryen veri seti için kullanılan PNN mimarisi.

Şekil 3.5’de gizli katmandaki nöron sayılarına göre PRNN’nin eğitim ve test performansları, Levenberg–Marquardt ve Bayesian öğrenme algoritmaları ile gösterilmiştir.



Şekil 3.5. Gizli katmandaki nöron sayılarına göre PRNN’nin eğitim ve test performansları (a) Levenberg–Marquardt, (b) Bayesian öğrenme algoritmaları ile.


Şekil 3.5 incelendiğinde, en iyi test sonucunun 0,15 MSE ile gizli katmanında 3 nöron bulunan Levenberg–Marquardt öğrenme algoritması ile eğitilmiş PRNN ağı ile elde edildiği görülmektedir. Bu PRNN mimarisi Şekil 3.6’da verilmiştir.




Şekil 3.6. Sezaryen veri seti için kullanılan PRNN mimarisi.

Üç farklı YSA yaklaşımı doğumlar için sonuçların tahmin edilmesinde eğitilmiş, test edilmiş ve karşılaştırılmıştır. Şekil 3.7’de YSA eğitim ve test performansları, gizli katmanı 10 nöronlu ve learnlv1 öğrenme fonksiyonuna sahip LVQNN, yayılma faktörü = 0,24 olan PNN, ve gizli katmanı 3 nöronlu ve Levenberg–Marquardt öğrenme algoritması ile eğitilmiş PRNN için gösterilmiştir.


Her sınıflandırma işlemi, metotlar kesinlik (yanlış pozitifleri eleme kabiliyeti) ve hassasiyet (pozitif değerlerin ne kadarının pozitif olarak sınıflandırıldığı) arasındaki dengeyi kurmakla uğraşmaktadır. Alıcı işletim karakteristiği ya da daha çok bilinen İngilizce adıyla ROC (Receiver Operating Characteristic) eğrisi, kısaca doğru pozitiflerin sayısının, yanlış pozitiflere olan kesri olarak çizilmesiyle oluşmaktadır. En başarılı LVQNN, PNN ve PRNN ağlarının histogram ve ROC eğrisi grafikleri sırasıyla Şekil 3.8’de ve Şekil 3.9’da verilmiştir.



(a)




(b)




(c)


Şekil 3.7. YSA eğitim ve test performansları (a) LVQNN, (b) PNN, (c) PRNN.



(a)




(b)




(c)


Şekil 3.8. YSA histogram grafikleri (a) LVQNN, (b) PNN, (c) PRNN.



(a)




(b)




(c)

Şekil 3.9. YSA ROC eğrileri (a) LVQNN, (b) PNN, (c) PRNN.


Karşılaştırma matrisi (confusion matrix), uygulanan yöntemin yaptığı sınıflandırma sonucunda, tahmin sonucu ve gerçek durum arasındaki bilgileri içeren bir tablodur. Karşılaştırma matrisinde, doğru pozitif, yanlış pozitif, doğru negatif, yanlış negatif değerleri ve yüzdeleri bulunur. Algoritmaların performansı değerlendirilirken bu matristeki değerler dikkate alınır. En başarılı LVQNN, PNN ve PRNN ağlarının karşılaştırma matrisi grafikleri Şekil 3.10'da verilmiştir.



(a)



(b)



(c)

Şekil 3.10. YSA karşılaştırma matrisi sonuçları (a) LVQNN, (b) PNN, (c) PRNN.

Karşılaştırma matrisi Şekil 3.10 sonuçlarına göre 20 test sezaryen/normal doğum tahmininde LVQNN modeli 2 hata (%90 doğruluk), PNN ve PRNN modelleri 3 hata (%85 doğruluk) ile sınıflandırma işlemini başarmıştır. 60 eğitim seti verisinde ise, LVQNN modeli 10 hatalı (%83,3 doğru), PNN ve PRNN modelleri 11 hatalı (%81,7 doğru) sonuç üretmiştir. Dolayısıyla, LVQNN modeli, PNN ve PRNN modellerine kıyasla doğum yöntemi sınıflandırma işlemi için daha iyi doğruluk oranları vermiştir.

Literatürdeki Tebriz Sağlık Merkezi veri seti normal doğum/sezaryen sınıflandırma çalışmalarında ve bu doktora tezinde elde edilen doğruluk oranları sonuçları Tablo 3.2’de verilmiştir.

Tablo 3.2. Doğum yöntemi sınıflandırma sonuçları.

Çalışma	Yöntem	Doğruluk Oranı
Gharehchopogh ve ark. (2012)	C4.5 Karar Ağacı	%86,25
Amin ve Ali (2017)	Rastgele Orman	%95,00
	<i>k</i> -En Yakın Komşular	%95,00
	Lojistik Regresyon	%77,50
	Naive Bayes	%76,25
	Destek Vektör Makinesi	%76,25
Suwarno ve Santo (2019)	Çok Katmanlı YSA	%77,50
Kocamaz (2024)	LVQNN	%90,00
	PNN	%85,00
	PRNN	%85,00

Tablo 3.2’ye bakıldığında, doğum yöntemi sınıflandırma işlemi için en başarılı doğruluk oranının %95 ile Amin ve Ali (2017)’nin kullandığı rastgele orman ve *k*-en yakın komşular algoritmaları ile, sonrasında da %90 oranı ile bu doktora tezinde uygulanan LVQNN modeliyle elde edildiğini görülmektedir.



4. KANSER SINIFLANDIRMASI

Kanser, çevresel ve genetik faktörlerin etkisiyle hücre DNA'sında hasar oluşması ve buna bağlı olarak hücrelerin kontrol dışı büyümesi ve çoğalmasdır. Genellikle oluştukları dokuya, vücut kısmına veya mikroskopik görünümüne göre adlandırılırlar. Erkeklerde görülen kanserler sıklığına göre akciğer, prostat, kolorektal, mesane ve mide kanseri olarak sıralanabilir. Kadınlarda en fazla meme kanseri, sonrasında tiroid, kolorektal, akciğer ve rahim kanserleri görülmektedir. Değişik kanserlerin büyüme hızı, yayılımı ve tedaviye cevapları birbirinden farklı olduğu için kanserin tipine göre uygun tanı ve tedavi yöntemleri tercih edilmelidir.

Meme kanseri, meme dokusunu oluşturan hücrelerdeki kontrolsüz çoğalmayla ortaya çıkar. Kadınlarda görülen kanserlerin başında gelir ve akciğer kanserinden sonra kansere bağlı ölümlerde ikinci sırayı alır.

Meme kanseri noninvaziv ve invaziv grup olarak iki ana gruba ayrılır.

Noninvaziv meme kanserleri; kanser oluşmaya başladığı bölgededir, bazal membranı geçmemiş, meme dokusu çevresine yayılım olmamıştır. Hücrelerdeki dönüşüm süt kanallarında ise Duktal Carsinoma In Situ (DCIS), meme lobüllerinde ise Lobüler Carsinoma In Situ (LCIS) olarak adlandırılır. DCIS meme kanserlerinin %12-15'ini oluşturur, tedavi edilmezse Invaziv Duktal Carsinoma (IDC) ilerleyebilir. Memede süt üreten bezlerde oluşan ve lobüller içinde sınırlı kalan LCIS sıklıkla premenopoz dönemindeki kadınlarda görülür, yavaş ilerler. Genellikle invaziv kansere dönüşmediği için kanser olarak kabul edilmez. Kişinin meme kanseri açısından gelecekte yüksek riske sahip olduğunu gösterir. Bu risk nedeniyle LCIS hikayesi olan kişilere 6-12 ayda bir muayene ve yıllık mamografi ile kontrol önerilir.

İnvaziv meme kanserleri; invaziv duktal karsinom, invaziv lobüler karsinom, meme başının Paget hastalığı, inflamatuvar meme kanseri, filloides tümör ve nadir meme kanserleri olarak alt gruplara ayrılır.

IDC meme kanserleri içinde en sık görülen türdür. Tümör genellikle sert, düzensiz kenarlı, sınırları meme dokusundan net şekilde ayıramamaktadır. Cilde, fasya ve

kaslara invazyon yapabilir. Dermal lenfatiklerde etkilenme olursa ciltte karakteristik tanı bulgularından biri olan portakal kabuğu görünümü oluşur. Kanserin evresi ilerledikçe lenf yoluyla bölgesel lenf nodlarına, hematojen yolla kemik, karaciğer, akciğer ve overlere metastaz yapabilir.

İnvaziv lobüler kanserler, invaziv meme kanserlerinin %10'unu oluşturur, IDC'den sonra ikinci en sık görülen meme kanseridir. Kanser yavaş şekilde ilerleyerek memede kalınlaşmaya, sertleşmeye neden olarak kitle oluşturmada normal meme dokusu ile yer değiştirir. Bu nedenle muayene ve mamografi ile tanı koymak zorlaşır.

Meme başının Paget hastalığı, meme başı ve areolada egzama bulguları ile kendini gösteren biyopsi ile tanı konulan meme kanseri türüdür.

İnflamatuvar meme kanseri nadir görülür ancak agresif seyreder, meme kanserleri içinde en kötü prognoza sahip olanıdır. Cilt ve dermal lenfatik kanalların tutulumu memede şişlik, kızarıklık ve portakal kabuğu görünümüne neden olur.

Filloides tümör bağ dokusundan kaynaklanan oldukça nadir görülen bir tümördür. Hızlı ilerler, büyük kitlelere neden olur. Temel tedavisi cerrahidir.

4.1. Meme Kanseri Risk Faktörleri

Cinsiyet: Kadınlarda meme kanseri oranı erkeklere göre oldukça fazladır. Vakaların çok azı yaklaşık %1'i erkeklerde görülür.

Yaş: Meme kanseri riski yaşla beraber artar, gençlerde nadir görülür, vakaların çoğu 50 yaş üzerindedir.

Geçirilmiş meme kanseri öyküsü: Meme kanseri tanısı almış, tedavi olmuş kadınlarda ikinci kez kanser gelişme riski daha fazladır.

Aile öyküsü: Anne, kız kardeş gibi birinci derece yakınlarında meme kanseri öyküsü, kişinin meme kanserine yakalanma riskinin daha fazla olduğunu gösterir.

Doğurganlık süresi: Menarşın erken (12 yaşından önce) ve menopozun geç olması (55 yaşından sonra) daha uzun süreli östrojen maruziyetine neden olduğu için kanser gelişme riski artar.

Doğum öyküsü: Daha önce doğum yapmamış olmak veya doğum yapma yaşının 30'dan sonra olması riski arttırmaktadır.

Emzirme: Meme kanseri riskini azaltır.

Sigara ve alkol kullanımı: Sigara içerdiği kanserojen bileşenler nedeniyle meme kanseri riskini arttırmaktadır. Alınan alkol miktarı ile orantılı olarak meme kanseri riski de artmaktadır.

Obezite: Yağ dokusu tarafından üretilen östrojen meme kanseri riskini artırır. Bu nedenle özellikle menopoz sonrası kilolu olan kişilerde meme kanseri gelişme riski artar.

Radyasyona maruz kalma: Radyasyon meme kanseri de dâhil pek çok kanserde risk faktörleri arasında yer alır.

4.2. Meme Kanseri Erken Tanı ve Tarama Yöntemleri

Son yıllarda meme kanserinin sıklığı artmakta ama meme kanseri nedeniyle ölüm oranları azalmaktadır. Tarama yöntemleri hastalıkların erken döneminde tespit edilmesini böylece tedavi şansının artmasını sağlar. Bu nedenle belirti ve bulgusu olmayan kişilerde meme taraması yapılması çok önemlidir.

Kendi kendine meme muayenesi, klinik meme muayenesi ve mamografi önerilen tarama yöntemleridir.

Kendi kendine meme muayenesinin her ay düzenli şekilde yapılması önerilir. Meme cildinde kızarıklık, meme başında renk ve şekil değişikliği, memede veya koltuk altında kitle varlığı değerlendirilir.

Klinik meme muayenesinin 40 yaş üstü kadınlara her yıl uzman hekimler tarafından yapılması önerilmektedir.

Mamografi, düşük dozda X-ışınıyla memenin yağ ve glandüler yapılarının incelenmesini sağlayan görüntüleme yöntemidir. Tarama amaçlı kullanımı ile henüz şikayeti olmayan kişilerde erken evre meme kanseri tanısı konulabilmektedir. Meme kanseri tanısında önerilen altın standart görüntüleme yöntemi mamografidir.

Genç yaşlarda meme glandüler doku ile kaplı iken, kırklı yaşlarda glandüler dokunun yerini yağ dokusu almaya başlar. Bu nedenle postmenopozal dönemde mamografi ile değerlendirme yapmak kolaylaşır, mamografinin duyarlılığı artar. Mamografinin, risk faktörleri değerlendirilerek 40 yaş sonrası 1 ya da 2 yılda bir, 50 yaş sonrası yılda bir çekilmesi önerilir.

Mamografi ile kitle, distorsiyon, kalsifikasyonlar, dansite, aksilladaki lenf nodları, cilt ve meme başında görülen değişiklikler değerlendirilir. Tespit edilen kitlenin şekli, kenar yapısı ve dansitesi kitlenin iyi veya kötü huylu olduğuna dair ipuçları verir. Kitleler yuvarlak, oval, lobüler ve irregüler olabilir. Malign olma riski mikrolobüle ve irregüler şekilli olanlarda daha fazladır. Meme dokusu ile kitle arasındaki kenar keskinse iyi sınırlı, kitleden çevreye ışınal uzanımlar varsa spiküler olarak tanımlanır. Dansite kitlenin X-ışını geçirgenliğidir. Radyolüsen kitleler iyi huyludur, fibroadenom ve kistler düşük dansiteli radyoopak, kötü huylu kitleler yüksek dansiteli radyoopak görüntüler verir. Her iki meme dokusu simetriktir, iki memenin görüntülerinin birlikte değerlendirilmesi asimetrik görüntünün tespitini kolaylaştırır. Daha önce yapılan mamografilerin yenileri ile kıyaslanması saptanmış ve izleme alınmış lezyonlardaki büyüme ve değişimi değerlendirmek açısından önemlidir.

Mamografi ve diğer tetkik sonuçlarına göre izlenecek yolu gösteren BI-RADS (Breast Imaging Reporting And Data System) sınıflaması bir raporlama sistemidir.

Tablo 4.1. BI-RADS sınıflaması.

Kategori	İzlenecek Yol
Kategori 0	Yetersiz tetkik (ilave görüntüleme yöntemlerine ihtiyaç var)
Kategori 1	Normal bulgular
Kategori 2	Kesinlikle benign bulgular
Kategori 3	Muhtemelen benign bulgular (kısa aralıklarla takip önerilir)
Kategori 4	Malignite şüpheli bulgular (biyopsi önerilir)
Kategori 5	Yüksek ihtimalle malignite düşündüren bulgular (biyopsi ve tanı gereklidir)
Kategori 6	Biyopsi ile meme kanseri saptanmış olan hastalar

4.3. Meme Kanseri Tanısı

Muayene ve mamografide memede patoloji saptanan kişilerde tanı için ilave tetkikler gerekebilir. Mamografi, tarama için kullanılmasının yanında şüpheli durumlarda tanı için de kullanılır.

Ultrasonografi: Meme dokusun ses dalgaları kullanılarak incelenmesidir, kitlenin katı veya kistik yapıda olduğunu gösterir. Radyasyon içermez, yer yaşıta ve hamilelik döneminde kullanılabilir. Biyopsi gereken durumlarda rehberlik amacıyla da kullanılır.

Manyetik Rezonans Görüntüleme (MRG): Radyo dalgaları aracılığıyla güçlü bir manyetik alanda görüntü oluşturulur. Muayene, mamografi ve ultrasonografi ile tespit edilen lezyonların incelenmesinde, kanser tanısı almış hastalarda operasyon öncesi farklı odak olup olmadığının, kanserin diğer meme ya da karşı memeye yayılımının değerlendirilmesinde kullanılır.

Biyopsi: Diğer tetkiklerle kanserden şüphelenilen lezyon tespit edildiğinde kesin tanı için biyopsi gereklidir. Farklı yöntemlerle şüpheli dokudan örnekler alınır ve mikroskop ile değerlendirilerek patolojik tanı konulur.

4.4. Meme Kanseri Tedavisi

Meme kanserinde tedavi, hastanın özelliklerine, meme kanserinin evresine göre bir veya birkaç tedavi yönteminin birlikte kullanılması şeklinde uygulanabilir. Tedavi yöntemleri cerrahi tedavi, radyoterapi, kemoterapi, hormonoterapi ve hedefe yönelik tedavidir.

Cerrahi tedavi: Memenin bir kısmının (meme koruyucu) ya da memenin tamamının (mastektomi), etkilenen lenf nodları ile birlikte alındığı işlemdir. Tümörün büyüklüğü, memenin büyüklüğü, tümör sayısı, yerleşim yeri ve hastanın tercihi göz önüne alınarak uygulanacak cerrahi yönteme karar verilir.

Radyoterapi: Yüksek enerjili iyonizan ışınların belirli dozlarda tümörün bulunduğu alana verilmesidir. Tümörü tedavi etmek, büyük bir tümörün küçülmesini sağlayıp opere edilebilir duruma gelmesini sağlamak, cerrahi sonrası mikroskopik düzeyde kalabilecek olan kanser hücrelerini yok etmek için kullanılır. Meme koruyucu cerrahi tedavi yapılan tüm hastalara uygulanır.

Kemoterapi: Kanserli hücrelerin damar yolu ya da ağızdan alınan kuvvetli ilaçlar ile yok edilmesini sağlayan tedavi yöntemidir. Operasyon öncesi uygulanması tümörde küçülme sağlar, operasyon sonrası uygulanması kanserin nüks etme riskini azaltır. İleri evre kanserli hastalarda yaşam süresini ve kalitesini arttırmak için kullanılır.

Hormonoterapi: Tümör hücrelerinde hormon reseptörü varsa yani tümör östrojen veya progesteron hormonlarına duyarlı ise bu hormonların olumsuz etkilerini ortadan kaldırmak için uygulanan tedavidir.

Hedefe Yönelik Tedavi: İnsan epidermal büyüme faktörü reseptörü 2 (Human Epidermal growth factor Receptor 2 – HER2) pozitif tespit edilen kanser hücrelerini hedef alan akıllı ilaçlar kullanılarak uygulanan tedavidir.

4.5. Yapay Zeka Yöntemleri ile Kanser Teşhisi Çalışmaları

Makine öğrenimi tıp da dâhil birçok bilim ve üretim alanında kullanılır. Makine öğrenimi sayesinde hasta ve hastalıkları sınıflandırmak, bir hastalığın en belirleyici bulgularını tespit etmek, hastalığın seyrini ve sonucunu tahmin etmek, yan etki ve komplikasyonları değerlendirmek ve hasta için en uygun tedaviyi seçebilmek kolaylaşmıştır. Günden güne artan veri sayısı, bu verilerin girilmesi, depolanması ve kontrolüyle ilgili farklı sıkıntıları da beraberinde getirmiştir. Gelişen bilgisayar teknolojileri ile verileri sabit disklerde, veritabanlarında depolamak mümkün olmuş, işlemlerin daha az hata oranı ile daha hızlı şekilde ilerlemesi sağlanmıştır. Bilgisayar teknolojileri sadece verilerin depolanmasına değil, eldeki verilerin analizi ile farklı birçok alanda ileriye yönelik gerçekçi tahminler yapabilmesine olanak sağlamıştır.

Meme kanseri kadınlarda sık görülen ve ölüme neden olabilen kanserlerden biridir. Kadınlarda daha sık, erkeklerde ise nadiren görülmekte, her 8 kadından birinde tespit edilmektedir. Meme kanserinin yaş, aile öyküsü, sigara, alkol, obezite, radyasyon, hormon ilaçları gibi risk faktörleri bilinmekte, fakat bunları tamamen ortadan kaldırmak mümkün olamamaktadır. Tedavide yaşanan gelişmeler ile meme kanserine bağlı ölüm oranları azalmış bu nedenle tarama ve erken tanının önemi artmıştır. Meme kanseri tarama ve tanısında en sık kullanılan yöntem mamografidir.

Meme kanseri tanısının YSA kullanılarak tahmin edilmeye çalışıldığı pek çok çalışma literatürde yerini almıştır. YSA'nın farklı özellikleri kullanılarak meme kanseri ve farklı kanser türleri tanısı ile ilgili uygulamalar yapılmıştır. Tıp alanında sadece kanser hastalığı değil, geniş bir yelpazede birçok konu çalışılmaktadır. Çalışmalarda, YSA'nın diğer sezgisel yöntemlerle birlikte kullanımı ile daha başarılı sonuçlar elde edildiği görülmektedir.

Fogel ve ark. (1997), meme kanseri tanısı için YSA ile hasta yaşı ve radyoaktif özellikleri kullanmışlar, verileri eğitmişlerdir. Revett ve ark. (2005) ve Gorunescu ve ark. (2007), meme kanseri için Rough kümelerini ve PNN içeren melez modele dayalı TKDS tasarlamışlardır. Hsiao ve ark. (2009), meme tümörlerinin iyi ya da kötü huylu olduğunu belirlemek için damarlanma indekslerini (harmonik ve harmonik olmayan 3D güç Doppler görüntüleme) kullanmışlar, sınıflandırma işlemini çok katmanlı algılayıcılar ile gerçekleştirmişlerdir. Vadivel ve Surendiran (2013), önce bulanık kurallar ile mamografi görüntülerindeki meme tümörlerini karakterize etmiş, sonra C5.0 algoritması ile sınıflandırmışlardır. Mihaylov ve ark. (2019), makine öğrenmesi yöntemlerini kullanarak klinik verilere dayalı doğru teşhis ile meme kanseri sağ kalım süresini tahmin eden bir çalışma yapmışlardır. Vijayarajeswari ve ark. (2019), 95 mamografi görüntüsü üzerinde Hough dönüşüm algoritması ve destek vektör makinesi yöntemini kullanarak mamogramların özelliklerini belirlemişlerdir. Alzu'bi ve ark. (2021) çalışmalarında, King Abdullah Üniversite Hastanesi verileri ve makine öğrenmesi algoritmaları ile meme kanserinin nüksetme olasılıklarını hesaplamışlardır. Kumari ve Jagadesh (2022), Mamografik Görüntü Analizi Derneği veri seti üzerinde meme kanserini sınıflandırmak için gradyan artırma, rastgele orman, k -en yakın komşular, YSA ve destek vektör makinesi yöntemlerini kullanmışlar, en yüksek başarıyı gradyan artırma algoritması ile elde etmişlerdir. Wang ve ark. (2022), 288 adet mamografi görüntüsünü öznetelik seçim algoritması ve destek vektör makinesi yöntemini kullanarak iyi-kötü huylu tümör olarak sınıflandırmışlardır.

UCI makine öğrenmesi veritabanında bulunan Madison'daki Wisconsin Üniversitesi Hastanesi'nin hasta kayıtlarından oluşturulan Wisconsin meme kanseri veri seti yapay zeka algoritmalarında sıkça kullanılmaktadır. Çevik ve Koçer (2013), Karapınar Şentürk ve Şentürk (2016), ve Kiknadze ve Gürhanlı (2020), bu veri setini kullanarak YSA ile meme kanseri tümörünün iyi-kötü huylu olduğunu tahmin eden çalışmalar yapmışlardır. Asri ve ark. (2016), destek vektör makinesi, Naive Bayes, k -en yakın komşular ve C4.5 algoritmalarını kullanmışlar, en başarılı performansı destek vektör makinesi ile elde etmişlerdir. Nilashi ve ark. (2017), meme kanseri sınıflama işlemi için bulanık mantık ile bilgi tabanlı bir sistem geliştirmişlerdir. Amrane ve ark. (2018), bu veri seti üzerinde k -en yakın komşular ve Naive Bayes algoritmalarının doğruluk yüzdelelerini karşılaştırmışlardır. Gupta ve Garg (2020), k -en yakın komşular, lojistik regresyon, karar ağacı, rastgele orman, destek vektör makinesi ve derin öğrenme

yöntemlerini meme kanserinin sınıflandırılmasında uygulamışlardır. Al-Azzam ve ark. (2021), lojistik regresyon, Gaussian Naive Bayes, lineer destek vektör makinesi, Radyal tabanlı destek vektör makinesi, karar ağacı, rastgele orman, gradient boosting, XGBoost ve k -en yakın komşular olmak üzere 9 farklı makine öğrenmesi algoritması sonuçlarını karşılaştırmışlardır. Gopal ve ark. (2021), çalışmalarında çok katmanlı algılayıcı, lojistik regresyon ve rastgele orman algoritmalarını kullanmışlar, en yüksek doğruluk oranını çok katmanlı algılayıcılar ile bulmuşlardır. Wu ve Hicks (2021), Naive Bayes ve k -en yakın komşular algoritmalarını kullanmış ve bu iki algoritma arasında çapraz doğrulama yaparak daha yüksek verimlilik elde etmişlerdir. Aydındağ Bayrak ve ark. (2022), k -en yakın komşular, destek vektör makinesi, Naive Bayes, karar ağacı ve YSA makine öğrenmesi yöntemlerini kullanmışlar, en yüksek doğruluk değerini YSA ile bulmuşlardır. Khan ve ark. (2022), rastgele orman, karar ağacı, k -en yakın komşular ve lojistik regresyon yöntemlerini uygulamışlar, en iyi sonuca lojistik regresyon yöntemi ile ulaşmışlardır.

UCI makine öğrenmesi veritabanındaki Mammography Mass meme kanseri veri seti de birçok çalışmada kullanılmış, tümörün iyi ya da kötü huylu olduğu sınıflandırması yapılmıştır. Luo ve Cheng (2012) değişik karar ağaçları, destek vektör makinesi ve minimal optimizasyon algoritmalarını özellik seçim algoritması ile birleştiren topluluk öğrenmesi yöntemiyle sınıflandırmayı yapmışlardır. Güzel ve ark. (2013), eksik verileri tamamlayan, Naive Bayes ve k -en yakın komşular algoritmalarını kullanan modeller geliştirmişlerdir. Hassim ve Ghazali (2016), yapay arı kolonisi ve ateşböceği algoritmalarını YSA ile entegre etmişler, mamografik sınıflandırma başarımını arttırmışlardır. Kaushik ve Kaur (2016), çok katmanlı algılayıcı, rastgele ağaç ve rastgele orman algoritmalarını tümleşik kullanarak daha iyi sonuçlar elde etmişlerdir. Yan ve ark. (2017), YSA, çoklu-granülasyon ve bagging (torbalama) yöntemlerini kullanmışlar, en başarılı sonucu bagging yöntemi ile almışlardır. Zahriah ve ark. (2017), Naive Bayes, C4.5, karar kütüğü, rastgele ağaç, rastgele orman ve destek vektör makinesi algoritmalarını karşılaştırmış, Naive Bayes ile daha yüksek doğruluk oranları bulmuşlardır. Bakırarar ve ark. (2019), çok katmanlı algılayıcılar ile rastgele orman algoritmasının performanslarını incelemişlerdir. Pickens ve Sengupta (2021), k -ortalama ve FCM ile kümeleme, parçacık sürü optimizasyonlu YSA ile sınıflandırma yapmışlardır. Williamson ve ark. (2022), k -en yakın komşular ve rastgele orman algoritmalarını birleştiren hibrit bir model geliştirmişlerdir.

Son yıllarda, derin öğrenme yöntemiyle de önemli kanser teşhisi ve sınıflandırma çalışmaları yapılmıştır. Nawaz ve ark. (2018), BreakHis meme kanseri histopatolojik görüntüsü veri setinin sınıflandırmasını konvolüsyonel sinir ağları ile uygulamışlardır. Lopez-Cabrera ve ark. (2020), Mamografik Görüntü Analizi Derneği mini veri tabanındaki görüntüleri Inception-v3 ve evrişimli sinir ağları ile sınıflandırmışlardır. Elmannai ve ark. (2021), histopatoloji görüntülerinden oluşan bir veri seti üzerinde meme kanserini benign, in situ, invaziv ya da normal olarak sınıflandırabilmek için evrişimsel sinir ağı modeli geliştirmişlerdir. Hawrami (2022), meme kanserinin teşhisi için Wisconsin veri setini kullanarak derin öğrenme algoritmaları ile sınıflandırma yapmıştır. Korkmaz (2023), Kaggle platformundaki “Breast Histopathology images” veri kümesini kullanmış, meme kanserinin sınıflandırılmasını makine öğrenmesi ve derin öğrenme yöntemleri ile gerçekleştirmiştir.

Yapılan çalışmalar erken tanı konulduğunda kanserin tedavi şansının arttığını göstermektedir. Kadınlarda en sık görülen ve kansere bağlı ölümlerde üst sıralarda yer alan meme kanseri tanısında bilgisayar destekli karar verme sistemleri uzman hekimlere yardımcı olmaktadır.

4.6. Kanser Veri Seti

Uygulamada UCI makine öğrenmesi veritabanından edinilen Mammography Mass Breast Cancer veri seti kullanılmıştır. Bu veri seti Erlangen–Nuremberg Üniversitesi Hastanesi’ne ait 2003-2006 yılları hasta kayıtlarından oluşturulmuştur (Elter ve ark., 2007). Veritabanında 961 örneğe ait veriler ve bunların dâhil olduğu 2 sınıf mevcuttur. Veri setinde toplamda 6 nitelik vardır. Bunlar ve değer aralıkları Tablo 4.2’de gösterilmektedir. BI-RADS’da 2, yaşta 5, kitle şeklinde 31, kitle kenarında 48, kitle yoğunluğunda 76 olmak üzere bazı örneklerde eksikler vardır. Benign (iyi huylu) ve malignant (kötü huylu) olacak şekilde sınıflandırılır. 516 örnek benign sınıfa, 445 örnek malignant sınıfa aittir. Veri setindeki benign ve malignant dağılımı homojendir.

Meme kanseri teşhisi uygulaması tahmininde kullanılan öznitelikler yaş dışında genellikle 1 ile 5 arasındaki değerlere sahip özniteliklerdir. Eksik verilerde, o niteliğin ortalama değeri kullanılmıştır. Veritabanında hastalık teşhisinde kullanılan 5 adet öznitelik bulunmaktadır. Giriş katmanında 5, çıkış katmanında 2 nöron bulunur. Son öznitelik sınıf bilgisini içermektedir, sonuç kısmında görülmekte, tümör benign (iyi huylu) ise 1, malignant (kötü huylu) ise 2 değerini almaktadır.

Tablo 4.2. Kanser sınıflandırma nitelikleri.

Değişken	Öznitelik	Değer Aralığı
Girdi 1	BI-RADS	0 – 6
Girdi 2	Yaş	$18 \leq \text{yaş} \leq 96$
Girdi 3	Kitle Şekli	1 – 4 (yuvarlak = 1, oval = 2, lobüler = 3, irregüler = 4)
Girdi 4	Kitle Kenarı	1 – 5 (sınırlı = 1, mikrolobüle = 2, belirsiz = 3, iyi tanımlanamayan = 4, dikenli = 5)
Girdi 5	Kitle Yoğunluğu	1 – 4 (yüksek = 1, izodens = 2, düşük = 3, yağ içerikli = 4)
Çıktı	Sınıf	1 = İyi Huylu, 2 = Kötü Huylu


Veri seti, aralıklı seçim sağlanarak eğitim ve test verileri olarak ayrılmıştır. Veri setinin 2/3'ü eğitim verisi, kalan 1/3'ü ise test verisi olarak kullanılmıştır. Böylece, eğitim ve test veri setleri sırasıyla toplam 641 ve 320 veriye sahip olmuştur. Ayrıca, girdi verileri [0,1 – 0,9] aralığına normalize edilmiştir.

4.7. Kanser Sınıflandırması

Bu bölümde yapılan çalışmanın amacı, meme kanseri teşhisi ile ilgili bir analiz yaparak teşhis sürecini hızlandırmak, zaman kaybını azaltmak, tedaviye bir an önce başlanmasını sağlayabilmektir. Bu doktora çalışmasında, Elter ve ark. (2007) veri seti kullanılarak YSA ile meme kanseri tümörünün iyi huylu ya da kötü huylu olduğu tahmin edilmiştir. SOM, FCM, LVQNN ve PNN yöntemlerinden yararlanılmıştır. Önce, LVQNN, PNN ve PRNN ile tümörün iyi-kötü huylu olduğu sınıflandırması yapılmıştır. II. model olarak, SOM ağırları ile giriş verileri kümelendirilmiş ve bu kümeleme sonuçlarından elde edilen veriler kullanılarak LVQNN, PNN ve PRNN ile sınıflandırma yapılmıştır. III. modelde SOM yerine FCM ile kümeleme yapılmış ve sonrasında LVQNN, PNN ve PRNN ile sınıflandırma yapılmıştır. IV. model olarak, SOM ve FCM ağırlarının ürettiği değerler de YSA'lara girdi olarak verilip LVQNN, PNN ve PRNN ile sınıflandırma yapılmıştır. Sonuçlar karşılaştırmalı olarak sunulmuştur. Uygulamalar MATLAB™ programı ortamında gerçekleştirilmiştir.


4.7.1. Model-I

Şekil 4.1’de gizli katmandaki nöron sayılarına göre LVQNN’nin eğitim ve test performansları, learnlv1 ve learnlv2 LVQ öğrenme fonksiyonları ile gösterilmiştir.




Şekil 4.1. Gizli katmandaki nöron sayılarına göre LVQNN’nin eğitim ve test performansları (Model-I) (a) learnlv1, (b) learnlv2 LVQ öğrenme fonksiyonları ile.

Şekil 4.1 incelendiğinde, en iyi test sonucunun gizli katmanında 23 nöron bulunan learnlv1 LVQ öğrenme fonksiyonuna sahip LVQNN ağı ile elde edildiği görülmektedir. Bu LVQNN mimarisi Şekil 4.2’de verilmiştir.




Şekil 4.2. Kanseri veri seti için kullanılan LVQNN mimarisi (Model-I).

Şekil 4.3'te yayılma faktörüne (spread factor) göre PNN'nin eğitim ve test performansları gösterilmiştir.




Şekil 4.3. Yayılma faktörüne göre PNN'nin eğitim ve test performansları (Model-I).

Şekil 4.3 incelendiğinde, en iyi test sonucunun 0,17 yayılma faktörlü PNN ağı ile elde edildiği görülmektedir. Bu PNN mimarisi Şekil 4.4'te verilmiştir.




Şekil 4.4. Kanseri veri seti için kullanılan PNN mimarisi (Model-I).

Şekil 4.5'te gizli katmandaki nöron sayılarına göre PRNN'nin eğitim ve test performansları, Levenberg–Marquardt ve Bayesian öğrenme algoritmaları ile gösterilmiştir.




(a)



(b)

Şekil 4.5. Gizli katmandaki nöron sayılarına göre PRNN'nin eğitim ve test performansları (Model-I) (a) Levenberg–Marquardt, (b) Bayesian öğrenme algoritmaları ile.


Şekil 4.5 incelendiğinde, en iyi test sonucunun 0,153125 MSE ile gizli katmanında 9 nöron bulunan Bayesian öğrenme algoritması ile eğitilmiş PRNN ağı ile elde edildiği görülmektedir. Bu PRNN mimarisi Şekil 4.6'da verilmiştir.



Şekil 4.6. Kanseri veri seti için kullanılan PRNN mimarisi (Model-I).


Üç farklı YSA yaklaşımı tümörün iyi-kötü huylu olduğunun tespiti için eğitilmiş, test edilmiş ve karşılaştırılmıştır. Şekil 4.7'de YSA eğitim ve test performansları, gizli katmanı 23 nöronlu ve learnlv1 öğrenme fonksiyonuna sahip LVQNN, yayılma

faktörü = 0,17 olan PNN, ve gizli katmanı 9 nöronlu ve Bayesian öğrenme algoritması ile eğitilmiş PRNN için gösterilmiştir.




Şekil 4.7. YSA eğitim ve test performansları (Model-I) (a) LVQNN, (b) PNN, (c) PRNN.

En başarılı LVQNN, PNN ve PRNN ağlarının histogram grafikleri Şekil 4.8’de verilmiştir.




Şekil 4.8. YSA histogram grafikleri (Model-I) (a) LVQNN, (b) PNN, (c) PRNN.


En başarılı LVQNN, PNN ve PRNN ağlarının ROC eğrisi grafikleri Şekil 4.9’da ve karşılaştırma matrisi grafikleri Şekil 4.10’da verilmiştir.



(a)




(b)




(c)


Şekil 4.9. YSA ROC eğrileri (Model-I) (a) LVQNN, (b) PNN, (c) PRNN.



(a)



(b)



(c)

Şekil 4.10. YSA karşılaştırma matrisi sonuçları (Model-I) (a) LVQNN, (b) PNN, (c) PRNN.

Karşılaştırma matrisi Şekil 4.10 sonuçlarına göre 320 test iyi-kötü huylu tümör tahmininde LVQNN ve PNN modelleri 46 hata (%85,63 doğruluk), PRNN modeli 49 hata (%84,69 doğruluk) ile sınıflandırma işlemini başarmıştır. 641 eğitim seti verisinde ise, PNN modeli 116 hatalı (%81,9 doğru), LVQNN modeli 121 hatalı (%81,12 doğru) sonuç üretmiştir. PRNN modeli ise 114 hatalı (%82,22 doğru) sınıflandırma yapmıştır. Dolayısıyla, PNN modeli, LVQNN ve PRNN modellerine kıyasla kanser sınıflandırma işlemi için daha iyi doğruluk oranları vermiştir.


4.7.2. Model-II

Calinski–Harabasz, Davies–Bouldin ve Silhouette katsayıları, küme elemanlarının kendi kümesine ne kadar benzediğini ölçerek veri kümelerinin ne kadar iyi sınıflandırıldığını ortaya çıkaran, küme tutarlılığını yorumlama yöntemleridir. Veri setindeki uygun küme sayısının belirlenmesi amacı ile kullanılmaktadırlar.


Calinski–Harabasz endeksi, kümelenme geçerliliğini, kümeler arası varyansın, küme içi varyansa oranına göre değerlendirir. Yüksek Calinski–Harabasz endeks değeri, değerlendirilen küme bölümlenmesinde farklı kümeler arasındaki mesafenin büyük, aynı küme içindeki mesafenin ise küçük olduğunu ifade etmektedir. Dolayısıyla, en yüksek endeks değerine sahip küme, en uygun küme sayısını verir. Davies–Bouldin endeksinde, her bir küme için seçilen küme ve diğer tüm kümeler arasındaki benzerlik oranı hesaplanır ve bu küme benzerliklerinin ortalaması endeks değerini verir. Bu endeks sonucunun küçük olması, kümelemenin daha iyi olduğunu göstermektedir. Silhouette endeksi ise, kümelenme performanslarını, kümelerin birbirleri arasındaki ve küme içindeki mesafelerin karşılıklı farkına dayanarak doğrular. En yüksek Silhouette endeks değeri ile, optimum küme sayısı tespit edilir (Eriş Hasırcı, 2019; Petriçli, 2020; Yıldırım, 2022).

Geliştirilen Matlab kodu ile, önce, Erlangen–Nuremberg meme kanseri veri seti için optimum küme sayısını belirlemek amacı ile bu yöntemler kullanılmış ve sonuçlar Şekil 4.11’de gösterilmiştir.


Calinski–Harabasz ve Silhouette yöntemlerine göre katsayının en yüksek olduğu değer, Davies–Bouldin yöntemine göre ise katsayının en düşük olduğu değer optimum küme sayısını vermektedir. Şekil 4.11’de gösterilen sonuçlar incelendiğinde, Calinski–Harabasz yönteminin 2970,86 değeri ile 10 küme, Davies–Bouldin yönteminin 0,612 değeri ile 2 küme ve Silhouette yönteminin 0,722 değeri ile 2 küme kullanılmasını daha uygun bulduğu görülmektedir. Dolayısıyla, bu kanser veri seti için optimum küme sayısı 2 olarak alınmıştır.



(a)



(b)



(c)


Şekil 4.11. Kanser veri seti için optimum küme sayısı (a) Calinski–Harabasz, (b) Davies–Bouldin, (c) Silhouette katsayılarına göre.

Sonrasında, yine geliştirilen Matlab kodu ile, SOM ağı kullanılarak Erlangen–Nuremberg meme kanseri giriş verileri 2 ayrı kümeye ayrılmıştır ve sonuçlar Tablo 4.3’te sunulmuştur.

Tablo 4.3. SOM ağının kümeleme verileri.


	SOM	
	A kümesi	B kümesi
İyi Huylu	299	217
Kötü Huylu	101	344
Toplam	400	561

SOM sonuçlarına göre 2 kümeye ayrılan veriler Şekil 4.12’de sunulmuştur.




Şekil 4.12. SOM modelinin kümeleme sonuç grafikleri.



Şekil 4.13'te SOM A kümesine göre en iyi sonuç üreten YSA'lar olan; gizli katmanı 48 nöronlu ve learnlv2 öğrenme fonksiyonuna sahip LVQNN, yayılma faktörü = 0,18 olan PNN, ve gizli katmanı 46 nöronlu ve Levenberg–Marquardt öğrenme algoritması ile eğitilmiş PRNN ağlarının eğitim ve test performansları gösterilmiştir.



Şekil 4.13. YSA eğitim ve test performansları (Model-II-A) (a) LVQNN, (b) PNN, (c) PRNN.


En başarılı LVQNN, PNN ve PRNN karşılaştırma matrisi grafikleri Şekil 4.14'te verilmiştir.






Şekil 4.14. YSA karşılaştırma matrisi sonuçları (Model-II-A) (a) LVQNN, (b) PNN, (c) PRNN.


Şekil 4.15'te SOM B kümesine göre en iyi sonuç üreten YSA'lar olan; gizli katmanı 34 nöronlu ve learnlv2 öğrenme fonksiyonuna sahip LVQNN, yayılma faktörü = 0,39 olan PNN, ve gizli katmanı 6 nöronlu ve Levenberg–Marquardt öğrenme algoritması ile eğitilmiş PRNN ağlarının eğitim ve test performansları gösterilmiştir.



(a)




(b)




(c)

Şekil 4.15. YSA eğitim ve test performansları (Model-II-B) (a) LVQNN, (b) PNN, (c) PRNN.


En başarılı LVQNN, PNN ve PRNN karşılaştırma matrisi grafikleri Şekil 4.16’te verilmiştir.



(a)



(b)



Şekil 4.16. YSA karşılaştırma matrisi sonuçları (Model-II-B) (a) LVQNN, (b) PNN, (c) PRNN.

Sonuç olarak, Model-II A kümesi için 0,137931 MSE ile gizli katmanı 46 nöronlu ve Levenberg–Marquardt öğrenme algoritması ile eğitilmiş PRNN (Şekil 4.13), Model-II B kümesi için ise 0,207895 MSE ile gizli katmanı 34 nöronlu ve learnlv2 öğrenme fonksiyonuna sahip LVQNN (Şekil 4.15) daha az hata yaparak daha başarılı test sonuçları vermiştir. Şekil 4.14 ve Şekil 4.16’daki karşılaştırma matrislerinden bu iki ağın toplam doğruluk oranı, yani Model-II’nin doğruluk oranı, eğitim seti için $(225+201)/641 = \%82,06$, test seti için $(124+155)/320 = \%87,19$ olarak bulunmuştur.


4.7.3. Model-III

Bir önceki modelde, Calinski–Harabasz, Davies–Bouldin ve Silhouette yöntemlerine göre Erlangen–Nuremberg meme kanseri veri seti için optimum küme sayısı 2 olarak tespit edilmişti. Geliştirilen Matlab kodu ile, tespit edilen bu küme sayısına göre FCM ağı kullanılarak Erlangen–Nuremberg meme kanseri giriş verileri 2 ayrı kümeye ayrılmıştır ve sonuçlar Tablo 4.4’te sunulmuştur.

Tablo 4.4. FCM ağıının kümeleme verileri.

	FCM	
	A kümesi	B kümesi
İyi Huylu	309	207
Kötü Huylu	103	342
Toplam	412	549


FCM sonuçlarına göre 2 kümeye ayrılan veriler Şekil 4.17’de sunulmuştur.



Şekil 4.17. FCM modelinin kümeleme sonuç grafikleri.


Şekil 4.18’de FCM A kümesine göre en iyi sonuç üreten YSA’lar olan; gizli katmanı 54 nöronlu ve learnlv2 öğrenme fonksiyonuna sahip LVQNN, yayılma faktörü = 0,18 olan PNN, ve gizli katmanı 5 nöronlu ve Levenberg–Marquardt öğrenme algoritması ile eğitilmiş PRNN ağlarının eğitim ve test performansları gösterilmiştir.

Best Train Performance is 0.143911, Best Test Performance is 0.11347!




(a)

Best Train Performance is 0.147601, Best Test Performance is 0.10638!



(b)

Best Train Performance is 0.0885609, Best Test Performance is 0.10638!





(c)

Şekil 4.18. YSA eğitim ve test performansları (Model-III-A) (a) LVQNN, (b) PNN, (c) PRNN.

En başarılı LVQNN, PNN ve PRNN karşılaştırma matrisi grafikleri Şekil 4.19’da verilmiştir.



Training Confusion Matrix			Test Confusion Matrix			All Confusion Matrix					
Output Class	1	187 69.0%	21 7.7%	89.9%	10.1%	Output Class	1	286 69.4%	32 7.8%	89.9%	10.1%
	2	18 6.6%	45 16.6%	71.4%	28.6%		23 5.6%	71 17.2%	75.5%	24.5%	
		91.2% 8.8%	68.2% 31.8%	85.6% 14.4%			92.6% 7.4%	68.9% 31.1%	86.7% 13.3%		
		↖ ↘		↖ ↘			↖ ↘		↖ ↘		
		Target Class		Target Class			Target Class		Target Class		


(a)



Şekil 4.19. YSA karşılaştırma matrisi sonuçları (Model-III-A) (a) LVQNN, (b) PNN, (c) PRNN.

Şekil 4.20’de FCM B kümesine göre en iyi sonuç üreten YSA’lar olan; gizli katmanı 95 nöronlu ve learnlv1 öğrenme fonksiyonuna sahip LVQNN, yayılma faktörü = 0,39 olan PNN, ve gizli katmanı 9 nöronlu ve Levenberg–Marquardt öğrenme algoritması ile eğitilmiş PRNN ağlarının eğitim ve test performansları gösterilmiştir.







(c)

Şekil 4.20. YSA eğitim ve test performansları (Model-III-B) (a) LVQNN, (b) PNN, (c) PRNN.


En başarılı LVQNN, PNN ve PRNN karşılaştırma matrisi grafikleri Şekil 4.21’de verilmiştir.



(a)



(b)



Şekil 4.21. YSA karşılaştırma matrisi sonuçları (Model-III-B) (a) LVQNN, (b) PNN, (c) PRNN.


Sonuç olarak, Model-III A kümesi için 0,106383 MSE ile gizli katmanı 5 nöronlu ve Levenberg–Marquardt öğrenme algoritması ile eğitilmiş PRNN (Şekil 4.18), Model-III B kümesi için ise 0,145251 MSE ile gizli katmanı 95 nöronlu ve learnlv1 öğrenme fonksiyonuna sahip LVQNN (Şekil 4.20) daha az hata yaparak daha başarılı test sonuçları vermiştir. Şekil 4.19 ve Şekil 4.21’deki karşılaştırma matrislerinden bu iki ağın toplam doğruluk oranı, yani Model-III’ün doğruluk oranı, eğitim seti için $(247+296)/641 = \%84,71$, test seti için $(126+153)/320 = \%87,19$ olarak bulunmuştur.

4.7.4. Model-IV

Bu modelde, SOM ve FCM ağlarının ürettiği değerler de YSA’lara girdi olarak verilip LVQNN, PNN ve PRNN ile sınıflandırma yapılmıştır. A modelinde SOM değeri, B modelinde FCM değeri, C modelinde ise hem SOM hem de FCM değerleri YSA’ların girdilerine eklenmiştir.


Şekil 4.22’de Model-IV-A’ya göre en iyi sonuç üreten YSA’lar olan; gizli katmanı 73 nöronlu ve learnlv2 öğrenme fonksiyonuna sahip LVQNN, yayılma faktörü = 0,23 olan PNN, ve gizli katmanı 51 nöronlu ve Levenberg–Marquardt öğrenme algoritması ile eğitilmiş PRNN ağlarının eğitim ve test performansları gösterilmiştir. Bu YSA’ların karşılaştırma matrisleri ise Şekil 4.23’te verilmiştir.

Best Train Performance is 0.179407, Best Test Performance is 0.14375




(a)

Best Train Performance is 0.199688, Best Test Performance is 0.140625



(b)

Best Train Performance is 0.199688, Best Test Performance is 0.153125





(c)

Şekil 4.22. YSA eğitim ve test performansları (Model-IV-A) (a) LVQNN, (b) PNN, (c) PRNN.

Şekil 4.22'ye bakıldığında, Model-IV-A için en iyi sonuç üreten YSA'nın, test verileri için 0,140625 MSE değeri hesaplanan yayılma faktörü = 0,23 olan PNN olduğu görülmektedir.


Training Confusion Matrix			Test Confusion Matrix			All Confusion Matrix					
Output Class	Target Class			Output Class	Target Class			Output Class	Target Class		
	1	2	3		1	2	3		1	2	3
	1	290 45.2%	50 7.8%		85.3% 14.7%	138 43.1%	23 7.2%		85.7% 14.3%	428 44.5%	73 7.6%
2	65 10.1%	236 36.8%	78.4% 21.6%	23 7.2%	136 42.5%	85.5% 14.5%	88 9.2%	372 38.7%	80.9% 19.1%		
3	81.7% 18.3%	82.5% 17.5%	82.1% 17.9%	85.7% 14.3%	85.5% 14.5%	85.6% 14.4%	82.9% 17.1%	83.6% 16.4%	83.2% 16.8%		

(a)




Şekil 4.23. YSA karşılaştırma matrisi sonuçları (Model-IV-A) (a) LVQNN, (b) PNN, (c) PRNN.


Şekil 4.24'te Model-IV-B'ye göre en iyi sonuç üreten YSA'lar olan; gizli katmanı 98 nöronlu ve learnlv2 öğrenme fonksiyonuna sahip LVQNN, yayılma faktörü = 0,23 olan PNN, ve gizli katmanı 13 nöronlu ve Levenberg–Marquardt öğrenme algoritması ile eğitilmiş PRNN ağlarının eğitim ve test performansları gösterilmiştir. Bu YSA'ların karşılaştırma matrisleri ise Şekil 4.25'te verilmiştir.



(a)




(b)



(c)

Şekil 4.24. YSA eğitim ve test performansları (Model-IV-B) (a) LVQNN, (b) PNN, (c) PRNN.


Şekil 4.24'e bakıldığında, Model-IV-B için en iyi sonuç üreten YSA'nın, yine test verileri için 0,140625 MSE değeri hesaplanan yayılma faktörü = 0,23 olan PNN olduğu görülmektedir.





Şekil 4.25. YSA karşılaştırma matrisi sonuçları (Model-IV-B) (a) LVQNN, (b) PNN, (c) PRNN.

Şekil 4.26’da Model-IV-C’ye göre en iyi sonuç üreten YSA’lar olan; gizli katmanı 66 nöronlu ve learnlv2 öğrenme fonksiyonuna sahip LVQNN, yayılma faktörü = 0,23 olan PNN, ve gizli katmanı 88 nöronlu ve Levenberg–Marquardt öğrenme algoritması ile eğitilmiş PRNN ağlarının eğitim ve test performansları gösterilmiştir. Bu YSA’ların karşılaştırma matrisleri ise Şekil 4.27’de verilmiştir.



Şekil 4.26. YSA eğitim ve test performansları (Model-IV-C) (a) LVQNN, (b) PNN, (c) PRNN.

Şekil 4.26'ya bakıldığında, Model-IV-C için en iyi sonuç üreten YSA'nın, test verileri için 0,140625 MSE değeri hesaplanan gizli katmanı 66 nöronlu ve learnlv2 öğrenme fonksiyonuna sahip LVQNN olduğu görülmektedir.



Şekil 4.27. YSA karşılaştırma matrisi sonuçları (Model-IV-C) (a) LVQNN, (b) PNN, (c) PRNN.

Şekil 4.23, Şekil 4.25 ve Şekil 4.27'deki karşılaştırma matrislerinden görüldüğü üzere, hem Model-IV-A'da, hem Model-IV-B'de, hem de Model-IV-C'de test seti için $275/320 = \%85,94$ doğruluk oranı elde edilmiştir. Eğitim seti için ise, doğruluk

oranları Model-IV-A’da $513/641 = \%80,03$, Model-IV-B’de $516/641 = \%80,5$ ve Model-IV-C’de $523/641 = \%81,59$ ’dur. Dolayısıyla, Model-IV’te en başarılı sonucu hem SOM hem de FCM değerlerinin girdi olarak verildiği C modeli vermiştir.

Tablo 4.5’de Erlangen–Nuremberg meme kanseri veri seti için bu doktora tezinde geliştirilen modellerin sonuçları karşılaştırılmalı biçimde özetlenmiştir.

Tablo 4.5. Geliştirilen modellerin (kanser sınıflandırma) doğruluk yüzdeleri.

Model	Kullanılan Yöntemler	Doğruluk Oranı	
		Eğitim	Test
Model-I	LVQNN	%81,12	%85,63
	PNN	%81,90	%85,63
	PRNN	%82,22	%84,69
Model-II	SOM ve LVQNN, PNN, PRNN	%82,06	%87,19
Model-III	FCM ve LVQNN, PNN, PRNN	%84,71	%87,19
Model-IV	SOM ve LVQNN, PNN, PRNN	%80,03	%85,94
	FCM ve LVQNN, PNN, PRNN	%80,50	%85,94
	SOM, FCM ve LVQNN, PNN, PRNN	%81,59	%85,94

Tablo 4.5’teki sonuçlarda, en başarılı kanser teşhisinin %87,19’luk test ve %84,71’lik eğitim doğruluk oranı ile önce FCM algoritması ile kümeleme yapıldığı, sonra her bir küme için LVQNN, PNN ve PRNN algoritmaları ile sınıflandırma yapıldığı Model-III ile elde edildiğini görülmektedir. Kümeleme algoritması kullanılan tüm modeller, test verilerinde daha başarılı sonuçlar üretmişlerdir. Bu da, sınıflandırma işlemlerine, kümeleme algoritmalarının dâhil edilmesinin olumlu katkı sağladığını göstermektedir.

Tablo 4.6’da bu doktora tezinde yapılan en başarılı modelin sonuçları ile literatürdeki UCI makine öğrenmesi veritabanında bulunan Erlangen–Nuremberg Üniversitesi Hastanesi’ne ait hasta kayıtlarından oluşan “Mammography Mass” meme kanseri veri seti ile yapılmış çalışmaların sonuçları karşılaştırmıştır.

Tablo 4.6. Kanser sınıflandırma sonuçları.

Çalışma	Kullanılan Yöntemler	En İyi Sonuç Veren Yöntem	Doğruluk Oranı
Luo ve Cheng (2012)	Karar Ağacı, Bagging, AdaboostM1, MultiBoosting, Destek Vektör Makinesi	Bagging Karar Ağacı	%83,4
Güzel ve ark. (2013)	Naive Bayes, <i>k</i> -En Yakın Komşular	Naive Bayes & <i>k</i> -En Yakın Komşular	%82,49
Hassim ve Ghazali (2016)	Çok Katmanlı Algılayıcı, YSA, Yapay Arı Kolonisi, Ateşböceği Algoritması	YSA & Yapay Arı Kolonisi & Ateşböceği Algoritması	%83,45
Kaushik ve Kaur (2016)	Çok Katmanlı Algılayıcı, Rastgele Ağaç, Rastgele Orman	Çok Katmanlı Algılayıcı & Rastgele Ağaç & Rastgele Orman	%83,5
Yan ve ark. (2017)	YSA, Çoklu-Granülasyon, Bagging	Bagging	%84
Zahriah ve ark. (2017)	Naive Bayes, C4.5, Karar Kütüğü, Rastgele Ağaç, Rastgele Orman, Destek Vektör Makinesi	Naive Bayes	%84,4
Bakırarar ve ark. (2019)	Çok Katmanlı Algılayıcı, Rastgele Orman	Çok Katmanlı Algılayıcı	%80,9
Pickens ve Sengupta (2021)	<i>k</i> -Ortalama, Sinirsel Ağılı Parçacık Sürü Optimizasyonu, FCM	Sinirsel Ağılı Parçacık Sürü Optimizasyonu	%78,83
Williamson ve ark. (2022)	<i>k</i> -En Yakın Komşular ve Rastgele Orman	<i>k</i> -En Yakın Komşular ve Rastgele Orman	%84,7
Kocamaz (2024)	SOM, FCM, LVQNN, PNN, PRNN	FCM & PRNN & LVQNN	%87,19

Tablo 4.6'daki sonuçlar incelendiğinde, Erlangen–Nuremberg meme kanseri veri seti kullanılarak yapılan çalışmaların %78 ile %87 arasında doğruluk yüzdesine sahip olduğu, çoğunun %82-85 aralığında olduğu görülmektedir. En yüksek sınıflandırma başarısı ise, %87,19'luk oran ile bu doktora tezindeki Model-III ile elde edilmiştir.



5. DİYABET RİSK SINIFLANDIRMASI

Diyabet hem ülkemizde hem de dünyada artan görülme sıklığı ve neden olduğu komplikasyonlar nedeniyle en önemli sağlık sorunlarından biri haline gelmiştir. Yaşam kalitesini düşüren, uzun dönemde farklı organlarda hasara yol açarak organ, işlev kaybı ve ölüme neden olabilen, ülke ekonomisine yük getiren bir toplum sağlığı hastalığıdır. Diyabet görülme sıklığı yaş, beslenme alışkanlıkları, kalıtım gibi faktörlere bağlı olarak toplumlarda farklılıklar gösterebilir. Beslenme ve yaşam tarzı değişiklikleri nedeniyle diyabet prevalansı hızla artmıştır.

Vücudun enerji ihtiyacı besinlerde bulunan yağ, karbonhidrat ve proteinlerden sağlanır. Karbonhidratlar sindirildiğinde basit bir şeker olan glikoz açığa çıkar. Glikoz organizma için en önemli enerji kaynağıdır. Glikozun enerji sağlayabilmesi için kandan kas, yağ, karaciğer hücreleri gibi vücut hücrelerinin içine girmesi gerekmektedir. Pankreastan salgılanan insülin hormonu kandaki glikozun hücre içine girmesini sağlar. Hücrelere alınan glikoz glikojen olarak depolanır. Pankreas her gıda alımı sonrası besinlerin enerjiye dönüşmesi için insülin üretir. Pankreas tarafından yeteri kadar insülin üretilmemesi ya da insülinin hedef hücreler tarafından kullanılamaması (insüline duyarlılık) durumunda kandaki glikoz hücrelere geçemez ve kan şekeri yükselir.

Diyabet 4 grupta sınıflandırılır, bunlar:

Tip 1 diyabet insülin üretiminin neredeyse hiç olmadığı genellikle çocuklar ve genç yetişkinlerde görülen otoimmün bir hastalıktır. Tip 1 diyabette otoimmün beta hücre yıkımına bağlı insülin eksikliği vardır. Etiyolojisinde genetik yatkınlık, çevresel ve immünolojik faktörler yer alır. Halsizlik, yorgunluk, çok su içme, fazla idrara çıkma, kilo kaybı hastalığın başlıca bulgularıdır.

Tip 2 diyabet en yaygın diyabet türüdür, dünyadaki tüm diyabetlerin yaklaşık %90'ının oluşturur. İnsülin sekresyonunda bozukluğa bağlı yeteri kadar salgılanamaması veya hedef hücrelerdeki insülinin etkisine karşı direnç sonucu kan şekerinde yükselme yani hiperglisemi ile seyreden kronik bir hastalıktır. Sıklıkla orta

ve ileri yaşlarda görülmektedir ama özellikle obezitenin artışı ile birlikte daha genç yaşlarda da görülmeye başlamıştır. Tip 2 diyabetli hastalarda başlangıçta belirtiler görülmez, hastalık sinsi ilerler. Yaygın belirtileri halsizlik, yorgunluk, fazla su içme, çok idrara çıkma, yara iyileşmesinde gecikme, el ve ayaklarda uyuşma, tekrarlayan mantar enfeksiyonları olarak sayılabilir. Uzun dönemde mikrovasküler ve makrovasküler komplikasyonlara bağlı kardiyovasküler hastalıklar, retinopati, nöropati ortaya çıkabilmektedir. Uluslararası Diyabet Federasyonu'nun 2021 verileri değerlendirildiğinde dünyada yaklaşık 483 milyon tip 2 diyabetli hasta bulunduğu görülmektedir.

Gestasyonel diyabet genellikle gebeliğin 3. trimesterinde ortaya çıkan ve doğumla beraber normale dönen glikoz intoleransıdır. Gestasyonel Diyabetes Mellitus (GDM) olarak da adlandırılmaktadır. Anne ve bebek için olumsuz etkileri olabilir, annede preeklamsi, erken doğum riskinde artış, bebekte makrozomi, neonatal hipoglisemi, solunum sıkıntılarına neden olabilir. Doğum sonrası diyabette düzelme görülse de sonraki gebeliklerde tekrarlama, ileri yaşlarda tip 2 diyabet gelişme riski artmaktadır.

Diğer spesifik diyabet tipleri, tip 1 ve tip 2 diyabet ile ilişkili olmayan, hormon bozuklukları, pankreas hastalıkları, ilaçlar, genetik sendromlar gibi farklı nedenlere bağlı ortaya çıkmaktadır. Genetik bozukluğa bağlı olarak genç yaşta başlayan diyabet, pankreatit, pankreas kanseri, kortizonlu ilaçlar, akromegali, feokromasitoma gibi endokrin hastalıklar nedeniyle oluşan diyabet bu grup içinde yer alır.

5.1. Diyabet Tanısı

Diyabet tanısında açlık kan şekeri ölçümü, Oral Glikoz Tolerans Testi (OGTT) ve HbA1C (HemoglobinA1C) testleri değerlendirilir.

Açlık kan şekeri sağlıklı insanlarda ortalama 70-100 mg/dl'dir. 126 mg/dl ve daha yüksek tespit edilen açlık kan şekeri değerleri diyabet tanısını destekler. Açlık kan şekeri 100-126 mg/dl arasında tespit edilen hastalarda OGTT uygulanarak kişinin tokluk kan şekeri ölçülür. Yemekten 2 saat ölçülen kan şekeri 200 mg/dl üzerindeyse diyabet tanısı konulur. Tokluk kan şekeri 200 mg/dl'nin altında 140 mg/dl üzerindeyse gizli şeker (prediyabetik evre) tanısı konur. HbA1C son 3 aydaki ortalama kan şekeri düzeyini göstermektedir. %6,5'in üzerinde olması diyabet tanısı koydurur. Bu tanı kriterleri Tablo 5.1'de gösterilmiştir.

Tablo 5.1. Diyabet tanı kriterleri.

	Kan Şekeri (mg/dl)		HbA1C
	Açlık	Tokluk	%
Normal	< 100	< 140	< 5,7
Bozulmuş glukoz toleransı (prediyabet)	[100 – 125]	[140 – 199]	[5,7 – 6,4]
Diyabet	≥ 126	≥ 200	≥ 6,5

5.2. Diyabet Tedavisi

Diyabet tedavisinde amaç kan glikoz düzeyini ve insülin aktivitesini kontrol altında tutarak hipoglisemi ve hiperglisemi ile ilişkili morbidite ve mortaliteyi en aza indirmek, uzun vadeli vasküler ve nöropatik komplikasyonları azaltmaktır. Kan glikozunun yanı sıra, kan basıncı ve kan lipidlerinin de hedeflenen düzeylerde olması diyabetin komplikasyonlarını önlemek için gereklidir. Beslenme, fiziksel aktivite, ilaç tedavisi, kendine kendine izlem (kan şekeri kontrolü) ve diyabet eğitimi tedavinin önemli unsurlarıdır.

Hastalığın olumsuz etkilerini azaltmak için kan şekeri normal sınırlar içinde tutulmalıdır. Tedavi yöntem ve ilaçlardaki gelişmelere rağmen bazı hastalarda hedef glikoz değerlerine ulaşılamamaktır. Hastanın ilaç tedavisine uyum göstermesi dışında hastalığı hakkında bilgi sahibi olması, beslenme ve yaşam tarzı değişiklikleri yapması, evde ölçümler yaparak hastalığın takip sürecine dâhil olması da önemlidir. Diyabet eğitimi, beslenme ve egzersiz programı, tıbbi tedavinin bir arada verilmesi diyabetli hastaların tedaviye uyumunu, yaşam kalitesini artırır, tedavi maliyetlerini düşürür. Diyabetli hastalarda diyet programı hastanın yeme alışkanlıkları, öğün saatleri, kilosu, eşlik eden diğer hastalıkları dikkate alınarak yapılır. Egzersizin kan şekeri kontrolünde olumlu katkı yaptığı, dokuların insülin duyarlılığını arttırdığı, hipertansiyonda iyileşme, kilo vermede kolaylaşma sağladığı, yüksek kan yağlarını düşürdüğü bilinmektedir. Haftada en az 3 gün tempolu yürüyüş, bisiklet, yüzme gibi aerobik egzersiz programları diyabetli hastalara önerilmelidir.

Diyet ve egzersiz gibi yaşam tarzı değişiklikleriyle hedef glisemik değerlere ulaşamadığında medikal tedaviye ihtiyaç duyulur. Oral antidiyabetikler ilk tercih olarak kullanılır. Bu ilaçlar pankreas hücrelerinden insülin salınımını, hücrelerinin glukoza hassasiyetini artırır, insülin direncine karşı koyar ya da bağırsaklardan glikoz emilimini azaltır. Tekli ilaç kullanımının yeterli olmadığı durumlarda diğer oral antidiyabetiklerle veya insülinle kombine edilerek kullanılabilirler. Oral antidiyabetiklerle kontrol sağlanamadığında, alerji veya yan etki gelişmesi durumunda, Tip 1 diyabetli hastalarda, böbrek ve karaciğer yetmezliği olanlarda, ketotik komaya giren, majör cerrahi operasyon geçiren hastalarda, gebelik ve emzirme döneminde insülin tedavisi kullanılmalıdır.

Diyabet iyi tedavi edilmediğinde yıllar içinde çeşitli komplikasyonlar ortaya çıkar, diyabetin akut ve kronik komplikasyonları vardır. Akut komplikasyonlar; diyabetik ketoasidoz, hiperglisemik hiperosmolar nonketotik koma, laktik asidoz ve hipoglisemidir. Hipoglisemi en sık karşılaşılan akut komplikasyondur. Kronik komplikasyonlar mikrovasküler ve makrovasküler komplikasyonlar olmak üzere ikiye ayrılırlar. Mikrovasküler komplikasyonlar; retinopati, nefropati, nöropati'dir. Makrovasküler komplikasyonlar; kalp damar hastalıkları, serebrovasküler hastalıklar ve periferik damar hastalıklarıdır.

5.3. Diyabet Riski

Yapılan tarama çalışmaları ile ülkemizde diyabetik ve prediyabetik hastaların yaklaşık %50'sinin henüz tanı almamış olduğu bulunmuştur. Tanısal tarama testlerinin riskli bireyler belirlenerek, bu bireylere belli aralıklarla yapılması bu nedenle çok önemlidir. Tip 1 diyabette rutin tarama endikasyonu yoktur. Ancak aile taramaları yapılabilir. Yani, tip 1 diyabetli hastaların birinci dereceden yakınlarında otoantikörler bakılabilir. Tip 2 diyabet risk faktörleri ise tüm yetişkinlerde değerlendirilmelidir. Ailesinde diyabet bulunan kişiler, fazla kilolu veya obez kişiler, doğum tartısı 4 kg ve üzeri bebek doğuran, daha önce gestasyonel diyabet tanısı alan, hipertansiyonu, kolesterol ve trigliserid yüksekliği olan, koroner arter, periferik ya da serebrovasküler hastalığı olan, fiziksel aktivitesi düşük olan, uzun süreli kortikosteroid kullanan kişiler tip 2 diyabet açısından yüksek risk grubundadırlar. 35 yaşından büyük tüm bireylerde, vücut kitle indeksi $VKİ \geq 25 \text{ kg/m}^2$ olan ve diyabet risk faktörü bulunan kişilerde açlık kan glikoz düzeyleri ölçülmelidir. Ek risk faktörü bulunan kişilerde

daha erken yaşlarda ve daha sık açlık kan şekeri ölçümü yapılmalıdır. Daha önce prediyabet tanısı olan veya GDM olan kişilerin OGTT ile değerlendirilmesi önerilir.

5.4. Yapay Zeka Yöntemleri ile Diyabet Sınıflandırma Çalışmaları

Diyabet tanısı üzerine birçok bilimsel araştırma yapılmıştır. Kaggle veritabanındaki içinde 768 veri bulunan 9 özniteliğe sahip PIMA Yerlileri veri seti en çok çalışılanlardan biridir. Temurtas ve ark. (2009) tarafından diyabet tanısı üzerine yapılan karşılaştırılmalı çalışmada Levenberg–Marquardt algoritması ile eğitilen çok katmanlı YSA ve PNN kullanılmıştır. Yaptıkları çalışmanın daha önce yapılmış çalışmalarla kıyaslandığında daha iyi sonuçlar verdiğini ve YSA yapılarının diyabet tanısına yardımcı olmak için etkili şekilde kullanılabileceğini belirtmişlerdir. Akyol ve Şen (2018) çalışmalarında önce, öznitelik seçimi ve ağırlıklandırma yöntemleri ile en önemli öznitelikleri tespit etmiş, sonra AdaBoost, gradyan artırımı karar ağaçları ve rastgele orman algoritmalarını kullanmış, en iyi sonuca %73,88 doğruluk oranı ile AdaBoost algoritması ile ulaşmışlardır. Sisodia ve Sisodia (2018), Gaussian Naive Bayes, destek vektör makinesi ve karar ağacı makine öğrenmesi algoritmalarını kullanmışlar, en iyi tahmin performansını %76,30 değeriyle Gaussian Naive Bayes algoritmasıyla elde etmişlerdir. Birjais ve ark. (2019) üç farklı makine öğrenmesi tekniğini kullanmış, gradyan artırma ile %86, lojistik regresyon ile %79, Naive Bayes ile %77 doğruluk oranı elde etmişlerdir. Jakka ve Rani (2019), *k*-en yakın komşular, karar ağacı, Naive Bayes, destek vektör makinesi, lojistik regresyon ve rastgele orman algoritmalarının performansını karşılaştırmış, en başarılı doğru sınıflandırma oranını %77,6 olarak lojistik regresyon yöntemiyle bulmuşlardır. Naz ve Ahuja (2020), Naive Bayes, karar ağacı, YSA ve derin öğrenme yöntemlerinin performansını analiz etmişlerdir. En başarılı sınıflandırmayı derin öğrenme yöntemi %98,07 ile vermiştir. Kumari ve ark. (2021), lojistik regresyon, Naive Bayes ve rastgele orman algoritmalarının birlikte karar vermesini sağlayan bir topluluk öğrenmesi yöntemi önermişler, %79,04 doğruluk oranı elde etmişlerdir. Cihan ve Coşkun (2021) çalışmalarında, lojistik regresyon, *k*-en yakın komşular, destek vektör makinesi, Gaussian Naive Bayes, karar ağacı, rastgele orman ve YSA makine öğrenmesi algoritmalarını kullanmışlardır. En iyi sonucu lojistik regresyon yöntemi vermiştir. Ram ve Vishwakarma (2021) ise, çalışmalarında en iyi 5 özniteliği seçerek, *k*-en yakın komşular, destek vektör makinesi, lojistik regresyon, Gaussian Naive Bayes ve

rastgele orman algoritmalarını kullanmışlar, en başarılı doğruluk değerini %85 ile lojistik regresyon yönteminden elde etmişlerdir.

Zou ve ark. (2018) diyabet hastalığı teşhisi için hem Kaggle veritabanından aldıkları PIMA Yerlileri veri seti hem de UCI veritabanından aldıkları Sylhet Hastanesi veri seti ile çalışmışlardır. Her iki veri seti için de rastgele orman, J48 ve YSA yöntemlerini kullanmışlar, en iyi sonucu rastgele orman algoritması ile PIMA Yerlileri veri seti için %77,2 ve Sylhet Hastanesi veri seti için %80,8 olarak elde etmişlerdir.

Alehegn ve ark. (2019), diyabet hastalığını sınıflandırmak için, PIMA Yerlileri veri seti ve ABD'deki 130 hastanenin 48 nitelikli 70 bin civarındaki veri seti ile çalışmışlardır. Rastgele orman, *k*-en yakın komşular, Naive Bayes, J48 ve bu 4 yöntemi birleştiren bir topluluk öğrenmesi yöntemi kullanmışlardır. En doğru sınıflandırma oranlarını PIMA Yerlileri veri seti için %93,6, ABD veri seti için ise %88,56 olarak kullandıkları topluluk öğrenmesi yöntemi vermiştir.

Chen ve Pan (2018), diyabet hastalığının teşhisinde Çin'deki bir üniversitenin endokrin bölümündeki 2004-2014 yılları arasındaki 30 öznitelikli 35669 hasta kaydını içeren veri setini kullanmışlardır. Lojistik regresyon, rastgele orman, AdaBoost.M1 ve LogitBoost yöntemlerini uygulamışlardır. LogitBoost algoritması %93,93 doğruluk oranı ile en iyi sonucu üretmiştir.

Kowsher ve ark. (2019) çalışmalarında tip 2 diyabet hastalığını önceden tespit edebilmek için, 9483 diyabetli hasta kaydından oluşan bir veri seti üzerinde lojistik regresyon, lineer diskriminant analizi, *k*-en yakın komşular, destek vektör makinesi, Naive Bayes, rastgele orman ve YSA algoritmalarını kullanmışlardır. YSA, %94,7 doğruluk oranı ile en iyi sonucu vermiştir.

Daghistani ve Alshammari (2020), diyabet hastalığı teşhisi için, 2013-2015 yılları arasındaki 18 öznitelik ve 66325 hasta kaydını içeren Suudi Arabistan'daki bir sağlık kuruluşundan elde ettikleri veriler üzerinde lojistik regresyon ve rastgele orman algoritmalarının performanslarını analiz etmiş, en iyi doğruluk değerini rastgele orman algoritması ile %88 olarak bulmuşlardır.

Veranyurt ve ark. (2020) diyabet hastalığının erken teşhisi için yaptıkları çalışmada, Vanderbilt Üniversitesi biyoistatistik bölümü tarafından açık erişime sunulan 15 değişkenden oluşan 390 kişiye ait diyabet veri setini AdaBoost, rastgele orman ve *k*-en yakın komşular algoritmalarını kullanarak sınıflandırmışlardır. Diyabet

hastalığının teşhisinde rastgele orman ve k -en yakın komşular algoritmaları ile %92,30'lık başarı oranı elde etmişlerdir.

Alcala-Rmz ve ark. (2021) çalışmalarında Medical Research Unit in Biochemistry tarafından tahsis edilen yaş, cinsiyet, kolesterol, yüksek kolesterol, düşük kolesterol, trigliserit niteliklerinden oluşan diyabet veri setinde, lojistik regresyon, YSA, k -en yakın komşular, rastgele orman ve karar ağacı makine öğrenmesi algoritmalarını kullanmışlardır. En iyi doğruluk oranı %79,5 ile lojistik regresyon algoritmasından, en kötü performans ise %66,9 doğruluk oranıyla k -en yakın komşular algoritmasından alınmıştır.

Mujawar ve ark. (2021) çalışmalarında Swad Diabetic Care Centre'deki 461 hasta kaydı üzerinden YSA kullanarak diyabetli hastaların teşhisini %94,2 doğruluk oranı ile bulmuşlardır. Diyabet teşhisi için, online (çevrimiçi) bir sistem geliştirmişlerdir.

Diyabet hastalığının daha başarılı teşhisi üzerine yapılan çalışmalarda, UCI veritabanında bulunan Bangladeş'teki Sylhet Hastanesi'ne ait her biri 17 niteliğe sahip 520 örnek içeren veri seti de yaygın kullanılmaktadır. Alpan ve İlgi (2020), çalışmalarında Bayes ağı, Naive Bayes, J48, rastgele ağaç, rastgele orman, k -en yakın komşular ve destek vektör makinesi algoritmalarını kullanmış, bunlardan daha iyi sonuç vereni %98,07 doğru sınıflandırma oranı ile k -en yakın komşular algoritması olmuştur. Islam ve ark. (2020), yaptıkları çalışmada Naive Bayes, lojistik regresyon, J48 ve rastgele orman sınıflandırma algoritmalarını karşılaştırmışlar, en başarılı algoritmayı %97,4 doğru sınıflandırma oranı ile rastgele orman olarak tespit etmişlerdir. Xue ve ark. (2020) çalışmalarında, destek vektör makinesi, Naive Bayes ve LightGBM makine öğrenmesi algoritmalarını kullanmışlar, en yüksek doğruluk oranını %98,07 ile destek vektör makinesi ile elde etmişlerdir. Chaves ve Marques (2021), YSA, k -en yakın komşu, Naive Bayes, rastgele orman, destek vektör makinesi ve AdaBoost makine öğrenmesi yöntemlerinin performansını karşılaştırmış, önerdikleri YSA modeli %98,1 ile en yüksek doğru sınıflandırma oranını vermiştir. Doğru (2021) çalışmasında lojistik regresyon, gradyan arttırma, karar ağacı, rastgele orman algoritmaları ve bu algoritmaları bir araya getiren bir topluluk makine öğrenmesi yöntemi ile diyabet hastalığının erken teşhis edilmesini gerçekleştirmiştir, en yüksek doğruluk tahmini %99,4 ile topluluk öğrenme algoritmasıyla elde etmiştir. Sadhu ve Jadli (2021) çalışmalarında, lojistik regresyon, Naive Bayes, rastgele orman, çok katmanlı algılayıcı, karar ağacı, k -en yakın komşular ve destek vektör makinesi

algoritmalarını kullanmışlar, en iyi performansı %98,07 doğruluk ile rastgele orman algoritması üretmiştir. Yurttakal ve Baş (2021) çalışmalarında, yığınlanmış derin öğrenme sinir ağını kullanmışlar, modelleri %98,71 ve %99,36 doğruluk oranları vermiştir. Saxena ve ark. (2023) lojistik regresyon, lineer diskriminant analizi, k -en yakın komşular, karar ağacı, Naive Bayes, destek vektör makinesi, AdaBoost, gradyan arttırma, rastgele orman, ekstra ağaç sınıflandırıcı ve bunların birleşimi bir topluluk öğrenmesi modeli kullanmışlar, %97’lik doğruluk performansı elde etmişlerdir.

5.5. Diyabet Veri Seti

Bu çalışmada 520 kişinin çeşitli özelliklerini içeren UCI veritabanından edinilen Sylhet, Bangladeş erken diyabet riski veri seti kullanılmıştır (Islam ve ark., 2020). Bu veri setinde toplam 17 öznitelik bulunmaktadır. Bunlardan ilki yaş’tır. Diğerleri cinsiyet, ani ağırlık kaybı, bulanık görme, obezite gibi ikili (binary) bilgilerden oluşmaktadır. Son öznitelik ise sonuç değeridir: diyabet hastası olup olmadığını temsil etmektedir. Diyabetli olan 320, olmayan 200 hasta vardır.


Tablo 5.2. Diyabet riski sınıflandırma nitelikleri.

Öznitelik	Veri Tipi	Değer Aralığı
Yaş	Tamsayı	[16 – 90]
Cinsiyet	İkili sayı	{Kadın, Erkek}
Poliüri (sık idrara çıkma), polidipsi (çok susama), ani kilo kaybı, halsizlik, polifaji (iştah artışı), genital mantar, bulanık görme, kaşıntı, sinirlilik, yara iyileşmesinde gecikme, kısmi parezi, kas sertliği, alopesi (saç dökülmesi), obezite	İkili sayı	{Evet, Hayır}
Sınıf	İkili sayı	{Negatif, Pozitif}

LVQNN, PNN ve PRNN yöntemleri kullanılarak sınıflandırma işlemi yapılmıştır. Erken diyabet riskinin tespiti amaçlanmaktadır. 520 veriden 2/3’ü, yani 347 tanesi eğitim için girilmiştir ve geri kalan 1/3 veri, yani 173 veri test için kullanılmıştır. Girdi verileri [0,1 – 0,9] aralığına normalize edilmiştir.


5.6. Diyabet Sınıflandırması

Uygulamada, diyabet risk grubunun belirlenmesinde LVQNN, PNN ve PRNN yöntemlerinden faydalanılmıştır. MATLAB™ programı kullanılmıştır. Şekil 5.1’de gizli katmandaki nöron sayılarına göre LVQNN’nin eğitim ve test performansları, learnlv1 ve learnlv2 LVQ öğrenme fonksiyonları ile gösterilmiştir.




Şekil 5.1. Gizli katmandaki nöron sayılarına göre LVQNN’nin eğitim ve test performansları (a) learnlv1, (b) learnlv2 LVQ öğrenme fonksiyonları ile.

Şekil 5.1 incelendiğinde, en iyi test sonucunun 0,034682 MSE ile gizli katmanında 72 nöron bulunan learnlv1 LVQ öğrenme fonksiyonuna sahip LVQNN ağı ile elde edildiği görülmektedir. Bu LVQNN mimarisi Şekil 5.2’de verilmiştir.




Şekil 5.2. Diyabet veri seti için kullanılan LVQNN mimarisi.

Şekil 5.3'te yayılma faktörüne (spread factor) göre PNN'nin eğitim ve test performansları gösterilmiştir.




Şekil 5.3. Yayılma faktörüne göre PNN'nin eğitim ve test performansları.

Şekil 5.3 incelendiğinde, en iyi test sonucunun 0,040462 MSE ile 0,05 yayılma faktörlü PNN ağı ile elde edildiği görülmektedir. Bu PNN mimarisi Şekil 5.4'te verilmiştir.




Şekil 5.4. Diyabet veri seti için kullanılan PNN mimarisi.

Şekil 5.5'te gizli katmandaki nöron sayılarına göre PRNN'nin eğitim ve test performansları, Levenberg–Marquardt ve Bayesian öğrenme algoritmaları ile gösterilmiştir.




(a)



(b)

Şekil 5.5. Gizli katmandaki nöron sayılarına göre PRNN'nin eğitim ve test performansları (a) Levenberg–Marquardt, (b) Bayesian öğrenme algoritmaları ile.


Şekil 5.5 incelendiğinde, en iyi test sonucunun 0,023121 MSE ile gizli katmanında 49 nöron bulunan Levenberg–Marquardt öğrenme algoritması ile eğitilmiş PRNN ağı ile elde edildiği görülmektedir. Bu PRNN mimarisi Şekil 5.6'da verilmiştir.



Şekil 5.6. Diyabet veri seti için kullanılan PRNN mimarisi.


Şekil 5.7'de YSA eğitim ve test performansları, gizli katmanı 72 nöronlu ve learnlv1 öğrenme fonksiyonuna sahip LVQNN, yayılma faktörü = 0,05 olan PNN, ve gizli katmanı 49 nöronlu ve Levenberg–Marquardt öğrenme algoritması ile eğitilmiş PRNN için gösterilmiştir.

Best Train Performance is 0.037464, Best Test Performance is 0.034682




(a)

Best Train Performance is 0, Best Test Performance is 0.0404624



(b)


Best Train Performance is 0.00864553, Best Test Performance is 0.02312'




(c)

Şekil 5.7. YSA eğitim ve test performansları (a) LVQNN, (b) PNN, (c) PRNN.


En başarılı LVQNN, PNN ve PRNN ağlarının histogram grafikleri Şekil 5.8'de verilmiştir.



(a)






(b)




(c)

Şekil 5.8. YSA histogram grafikleri (a) LVQNN, (b) PNN, (c) PRNN.


En başarılı LVQNN, PNN ve PRNN ağlarının ROC eğrisi grafikleri Şekil 5.9’da ve karşılaştırma matrisi grafikleri Şekil 5.10’da verilmiştir.




Şekil 5.9. YSA ROC eğrileri (a) LVQNN, (b) PNN, (c) PRNN.



(a)



(b)



(c)

Şekil 5.10. YSA karşılaştırma matrisi sonuçları (a) LVQNN, (b) PNN, (c) PRNN.

Karşılaştırma matrisi Şekil 5.10 sonuçlarına göre 173 test diyabet riski tahmininde PRNN modeli 4 hata (%97,69 doğruluk), LVQNN modeli 6 hata (%96,53 doğruluk) ve PNN modeli 7 hata (%95,95 doğruluk) ile sınıflandırma işlemini başarmıştır. 347 eğitim seti verisinde ise, PRNN modeli 3 hatalı (%99,14 doğru), LVQNN modeli 13 hatalı (%96,25 doğru), ve PNN modeli 0 hatalı (%100 doğru) sonuç üretmiştir. Dolayısıyla, PRNN modeli, PNN ve LVQNN modellerine kıyasla diyabet sınıflandırma işlemi için daha iyi doğruluk oranları vermiştir.

Tablo 5.3'te literatürdeki Bangladeş, Sylhet Hastanesi diyabet veri seti ile yapılmış çalışmalar ile bu tezde yapılan çalışmaların sonuçları karşılaştırmalı sunulmuştur.

Tablo 5.3. Diyabet riski sınıflandırma sonuçları.

Çalışma	Kullanılan Yöntemler	En İyi Sonuç Veren Yöntem	Doğruluk Oranı
Zou ve ark. (2018)	Rastgele Orman, J48, YSA	Rastgele Orman	%80,8
Alpan ve İlgi (2020)	Bayes Ağı, Naive Bayes, J48, Rastgele Ağaç, Rastgele Orman, <i>k</i> -En Yakın Komşular, Destek Vektör Makinesi	<i>k</i> -En Yakın Komşular	%98,07
Islam ve ark. (2020)	Naive Bayes, Lojistik Regresyon, J48, Rastgele Orman	Rastgele Orman	%97,4
Xue ve ark. (2020)	Destek Vektör Makinesi, Naive Bayes, LightGBM	Destek Vektör Makinesi	%98,00
Chaves ve Marques (2021)	YSA, <i>k</i> -En Yakın Komşu, Naive Bayes, Rastgele Orman, Destek Vektör Makinesi, Adaboost	YSA	%98,1
Doğru (2021)	Lojistik Regresyon, Gradyan Arttırma, Karar Ağacı, Rastgele Orman, Topluluk Öğrenmesi	Topluluk Öğrenmesi	%99,4
Sadhu ve Jadli (2021)	Lojistik Regresyon, Naive Bayes, Rastgele Orman, Çok Katmanlı Algılayıcı, Karar Ağacı, <i>k</i> -En Yakın Komşular, Destek Vektör Makinesi	Rastgele Orman	%98,07
Yurttakal ve Baş (2021)	Yığınlanmış Derin Öğrenme Sinir Ağı	Derin Öğrenme	%99,36
Saxena ve ark. (2023)	Lojistik Regresyon, Lineer Diskriminant Analizi, <i>k</i> -En Yakın Komşular, Karar Ağacı, Naive Bayes, Destek Vektör Makinesi, Adaboost, Gradyan Arttırma, Rastgele Orman, Ekstra Ağaç Sınıflandırıcı, Topluluk Öğrenmesi	Topluluk Öğrenmesi	%97
Kocamaz (2024)	LVQNN, PNN, PRNN	PRNN	%97,69

Tablo 5.3'te verilen sonuçlara göre, UCI veritabanında bulunan Bangladeş'teki Sylhet Hastanesi'ne ait verilerin erken diyabet teşhisi açısından sınıflandırma başarısının %80,8 ile %99,4 arasında değiştiği görülmektedir. Mevcut çalışmada %97,69'luk PRNN sınıflandırma başarısı elde edilmiştir. En yüksek doğruluk oranı %99,4 olarak, Doğru'nun (2021) çalışmasında topluluk öğrenmesi yöntemi ile elde edilmiştir. Çoğu çalışma %97 ile %99 arasında oldukça başarılı doğruluk performansına sahiptir. Aynı veri seti kullanılsa da, çalışmalarda kullanılan eğitim-test veri miktarları ve eğitim-test verileri değişkenlik göstermektedir. Bunun da sonuç yüzdelerini etkileyen bir unsur olduğu göz ardı edilmemelidir.



6. TİROİD FONKSİYON SINIFLANDIRMASI

Tiroid bezi boyunun orta hattında, soluk borusunun önünde bulunan kelebek şeklinde, ortalama 20-30 gr ağırlığında, foliküllerden oluşan, damarsal yapıdan zengin, hormon salgılayan endokrin bir bezdir. Tiroid bezinin istmus denen bölümle birleşen sağ ve sol iki lobu mevcuttur. Salgıladığı hormonlar ile bazal metabolizma hızını, vücut ısını dengeler, büyüme ve gelişmede rol oynar.

Tiroid uyarıcı hormon (Tiroid Stimulan Hormon – TSH) hipofiz bezinden salgılanır, tiroid bezini triiyodotironin (T3) ve tiroksin (T4) üretmesi için uyarır. Tiroid bezinin yeterli çalışmadığı T3 ve T4 değerlerinin düşük olduğu durumlarda TSH yükselir, hipofiz bezi daha fazla tiroid hormonunun salgılanması için tiroid bezini uyarır. Tiroid bezinin fazla çalıştığı T3 ve T4 değerlerinin yükseldiği durumlarda ise TSH değeri düşer (Ofloğlu, 2009).

Tiroid bezinin en önemli görevi vücudun metabolizmasını düzenlemek ve metabolizma hızını kontrol etmektir. Tiroid hormonu birçok organ ve dokuyu etkilemektedir. Kalp hızı, vücut ısı, iştah, kan yağları, kolesterol düzeyi, kilo dengesi, beyin, sinir sistemi, iskelet sisteminin gelişimi, zeka fonksiyonlarının gelişimi üzerinde etkileri mevcuttur.

Tiroid bezi hastalıkları hormon salınımını etkileyerek vücudun farklı fonksiyonlarının bozulmasına ve buna bağlı ciddi sağlık sorunlarına neden olabilir. Tiroid bezi normal çalışmadığında kalp hızında değişimler, yüksek tansiyon, halsizlik, yorgunluk, uyku bozukluğu, depresyon, boyun bölgesinde şişlik, sekte değişiklik, ishal, kabızlık, kilo kaybı, kilo alma, saç dökülmesi gibi belirtiler ortaya çıkabilir.

6.1. Tiroid Bezi Hastalıkları

Guatr: Tiroid bezinin anormal ve düzensiz şekilde büyümesidir. En sık nedeni iyot eksikliğidir. Tiroid bezinin tiroid hormonu üretebilmesi için iyota ihtiyacı vardır. İyot eksikliğinde daha fazla tiroid hormonu üretebilmek için tiroid bezi daha fazla çalışır bu da bezin büyümesine neden olur. İyot eksikliği dışında bazı enfeksiyonlar, sigara, radyasyon ve gebelik de guatra neden olabilmektedir. Kadınlarda erkeklere göre daha

fazla görülür. Tiroid bezinin büyümesi genellikle ağrıya neden olmaz, öksürük, yutma güçlüğü ve nefes darlığına neden olabilir.

Nodül: Tiroid bezi içinde farklı büyüklüklerde oluşan kitlelerdir. Çoğunluğu iyi huyludur ama %5-10 oranında kansere dönüşme riski taşırlar. Nodül sayısı tek ise uninodüler, birden fazla ise multinodüler guatr olarak adlandırılır. Ultrason ile değerlendirildiğinde nodül kistik, solid veya karışık yapıda tespit edilebilir. Sintigrafi ile değerlendirildiğinde ise verilen radyoizotop madde nodül tarafından tutulursa sıcak, tutulmazsa soğuk nodül olarak isimlendirilir. Soğuk nodüllerde kanserleşme riski daha fazladır.

Tiroid kanseri: Tiroid bezi hücrelerinin kontrolsüz şekilde büyümesiyle oluşur. Kontrolsüz çoğalan hücreler tiroid bezinde kitle oluşturur. Papiller, foliküler, medüller ve anaplastik kanser olarak 4 ana gruba ayrılır.

Tiroidit: Tiroid bezinin otoimmün nedenler veya enfeksiyonlar sonucu oluşan inflamasyonu ve iltihabı ile karakterize bir hastalıktır.

Hipertiroidi: Tiroid bezinin fazla çalışması sonucu tiroid hormonlarının çok fazla salgılanmasıyla ortaya çıkar. Graves hastalığı, multinodüler guatr, tiroid kanseri, hipofiz adenomu, tiroidit ve bazı ilaçlar hipertiroidiye neden olabilir. Graves hastalığı hipertiroidinin en yaygın nedenidir. Graves hastalığında bağışıklık sistemi kişinin kendi tiroid bezlerine saldırarak fazla tiroid hormonunun salgılanmasına neden olur. Belirtileri kalp hızında artış, çarpıntı, gerginlik, sinirlilik, uykusuzluk, ellerde titreme, iştahın açılması, bağırsak hareketlerinde hızlanma, kilo kaybı, saçlarda incelme, dökülme, sıcağa tahammülsüzlük, aşırı terleme, adet düzensizliği olarak sayılabilir.

Hipotiroidi: Tiroid bezinin tiroid hormonlarını yeterli düzeyde üretememesi, T3 ve T4 hormonlarının az salgılanmasıyla ortaya çıkar. Hipotiroidide vücut fonksiyonlarının birçoğu yavaşlar. Tiroid bezinin otoimmün hastalığı (Hashimoto tiroiditi), tiroid operasyonu, radyasyon, bazı ilaçlar, gebelik, iyot eksikliği, hipofiz bezinde bozukluğa neden olan kitleler hipotiroidinin nedenlerindendir. Belirtileri kalp hızında azalma, nabız düşüklüğü, soğuğa karşı hassasiyet, üşüme, ses kısıklığı, bağırsak hareketlerinde yavaşlama, kabızlık, kilo alımı, yorgunluk, halsizlik, hareketlerde yavaşlama, cilt kuruluğu, depresyon, adet düzensizliği olarak sayılabilir (Ofluoğlu, 2009).

6.2. Tiroid Hastalıkları Tanısı

Tanısı için hastanın şikayetleri, muayene bulguları, kan testleri ve radyolojik görüntülemeler birlikte değerlendirilmelidir. Tiroid muayenesinde tiroidin büyüklüğü, kıvamı, ağrı ve hassasiyet, kitle, yapışıklık değerlendirilir. Tiroid fonksiyonlarının değerlendirilmesinde kandaki T3, T4 ve TSH değerlerinin ölçümü yapılır. Otoimmün tiroid hastalıkları düşünüldüğünde tiroid otoantikörlerine özellikle anti-TPO'ya (anti-Tiroid PerOksidaz'a) bakılmalıdır. Tiroid ultrasonografisi ile tiroid bezinin boyutları, nodül varlığı, varsa nodülün özellikleri, yeri, sayısı, büyüklükleri belirlenir. Kanser şüphesinde ultrason eşliğinde ince iğne aspirasyon biyopsisi yapılmalıdır. Tiroid sintigrafisi ile tiroid ve varsa tiroid nodüllerinin fonksiyonu değerlendirilir. Vücuda radyoaktif iyodun verilmesi, tiroide toplanması ve bunun görüntülenmesi esasına dayanır. Soğuk nodüller çevre dokulardan daha düşük oranda, sıcak nodüller daha yüksek oranda, ılık nodüller çevre tiroid dokusu ile benzer oranda radyoaktif madde tutarlar.

6.3. Tiroid Hastalıkları Tedavisi

Guatrda tiroid boyutu çok büyük değilse, hormon düzeyleri normale tedavi başlanmayabilir, hasta takibe alınır. Tiroid boyutu büyükse, hastanın hipotiroidi veya hipertiroideye bağlı semptomları varsa, tiroidi küçültmek, hastanın şikayetlerini azaltmak, hormon seviyesini normale getirmek amacıyla tedavi başlanır. İyot bakımından zengin gıdalar iyot eksikliğine bağlı hipotiroidide diyetle eklenmelidir. Hipertiroidide hormon üretimini baskılayan ilaçlar, hipotiroidi durumunda ise tiroid hormonu ilaç olarak kullanılır. Tiroid hormonu başlanan hastalarda doz ayarlaması için aralıklarla kan testleri yapılmalıdır. Hipertiroidide radyoaktif iyot kullanılarak guatrın küçülmesi hedeflenir. Diğer tedavi yöntemlerine yanıt alınamadığında cerrahi tedavi tercih edilir, tiroid bezinin bir kısmı veya tamamı ameliyatla çıkarılır. Nodüler guatrda nodülün özellikleri önemlidir, kanser riski olan nodüller için operasyon önerilir. Küçük ve tek nodüllerde ilaçsız veya ilaçlı takip yapılabilir (Ofloğlu, 2009).

6.4. Yapay Zeka Yöntemleri ile Tiroid Fonksiyon Sınıflandırma Çalışmaları

Keleş ve Keleş (2008) yaptıkları çalışmalarında UCI makine öğrenmesi veritabanından elde ettikleri 215 kişiye ait tiroid verilerini kullanarak NEFCLASS-J ile %95,33'lük doğruluk oranı başarıyla sağladıklarını belirtmişlerdir. Bu UCI

veritabanındaki tiroid verileri başka çalışmalarda da kullanılmıştır: Şenol ve Yıldırım (2008, 2009) YSA ile bulanık mantığın bir arada kullanıldığı hibrit bir yapı tasarlayarak yaptıkları çalışmalarda bulanık-YSA karma yapısının YSA tekniğinden daha başarılı olduğunu göstermişlerdir. Temurtas (2009) yaptığı çalışmada çok katmanlı YSA ile %89,79, PNN ile %94,81 başarı oranı sonuçları elde etmiştir. Doğantekin ve ark. (2011) çalışmalarında genelleştirilmiş diskriminant analizi ve dalgacık destek vektör makinesi yöntemini uygulamışlar ve %91,86 doğruluk oranıyla başarı sağlamışlardır. Liu ve ark. (2012) çalışmalarında bilgisayar destekli tiroid tanı sistemi geliştirilmiş, bulanık *k*-en yakın komşu sınıflandırıcı metoduyla %98,82 ortalama ve %99,09 maksimum başarı oranlarına ulaşmışlardır. Kousarrizi ve ark. (2012) çalışmalarında sınıflandırma yöntemlerinden destek vektör makinelerini kullanmışlardır. Solmaz ve ark. (2013) çalışmalarında sınıflama yöntemi ile %96,57, kümeleme yöntemi ile %90,68 doğruluk oranları elde etmişlerdir.

Banu (2017) çalışmasında UCI makine öğrenmesi veritabanından aldığı hipotiroidi veri kümesini hastalığı teşhis etmek amacıyla kullanmıştır. Karar ağacı ve veri madenciliği tekniklerinden faydalanmıştır. Önce, toplam 30 nitelikten oluşan veri setini, sınıflandırmak için 12 niteliğe düşürmüş, sonra, sınıflandırma işleminde *k*-en yakın komşular ile %96,35, destek vektör makinesi ile %94,44, C4.5 ile %99,47 ve rastgele orman ile %99,47 doğruluk oranlarına ulaşmıştır.

Begum ve Parkavi (2019) çalışmalarında UCI makine öğrenmesi veritabanından çekilmiş 15 nitelikten oluşan tiroid veri setini sınıflandırmak için ID3 ve C4.5 karar ağacı yöntemlerini kullanmışlardır.

Sidiq ve ark. (2019) çalışmalarında Keşmir'deki teşhis laboratuvarlarında 553'ü normal, 218'i hipotiroidi, 36'sı hipertiroidi olan 807 hastadan alınan veri kümesi üzerinde destek vektör makinesi, Naive Bayes, en yakın komşular ve karar ağaçları sınıflandırma tekniklerini uygulamış, en yüksek doğruluğu karar ağaçları ile %98,89 oranı ile elde etmişlerdir.

Bao ve ark. (2019) çalışmalarında tiroit nodüllerini sınıflandırılmak için rastgele orman, *k*-en yakın komşular, YSA, *k*-destek vektör makinesi, Naive Bayes ve glmnet algoritmalarını kullanmışlardır.

Akgül ve ark. (2020) çalışmalarında UCI makine öğrenmesi veritabanındaki toplam 3163 örnekten oluşan 151 tanesi hipotiroidi geri kalanı hipotiroidi olmayan veri setini

ve k -en yakın komşu, destek vektör makinesi, lojistik regresyon yöntemlerini kullanarak yeni örneklerin hipotiroidi olup olmadığını tahmin etmişlerdir.

Asif ve ark. (2020) tiroid hastalıklarının teşhisinde k -en yakın komşular, destek vektör makinesi, gaussian process sınıflandırıcı, gradient boosting sınıflandırıcı, AdaBoost, XGBoost, çok katmanlı algılayıcı gibi farklı makine öğrenmesi algoritmalarının performanslarını karşılaştıran kapsamlı bir çalışma yapmışlardır ve %99,70 ile en yüksek doğruluğu veren çok katmanlı algılayıcının kullanımını önermişlerdir. Ayrıca, tiroid hastalığının erken teşhisinde tıp uzmanlarına yardımcı olacağını belirtmişlerdir.

Hamid ve ark. (2012) çalışmalarında UCI makine öğrenmesi veritabanında bulunan 7200 kişiye ait 21 adet tiroid hastalığını belirleyen öznelik içeren, 3 sınıftan oluşan veri setini çok katmanlı algılayıcılar kullanarak sınıflandırmış, %95,0 oranında doğruluk elde etmişlerdir. Margret ve ark. (2012) çalışmalarında bu veri setini karar ağacı algoritması kullanarak çeşitli bölme kuralları ile analiz etmiş ve karşılaştırmıştır. Hayashi ve ark. (2015) tiroid veri setini geliştirdikleri sürekli rekürsif kural çıkarma algoritması üzerine uygulamış, %96,7 sınıflandırma başarısı elde etmişlerdir. Gorunescu ve Belciug (2016) çok katmanlı algılayıcılar ile %95,72 doğruluk oranına ulaşmışlardır. Ionita ve Ionita (2016) karar ağacı, çok katmanlı algılayıcı, Naive Bayes ve radyal tabanlı sinir ağları yöntemlerini karşılaştırdıkları çalışmalarında, sırasıyla %97,35, %95,34, %94,71 ve %94,27 tiroid fonksiyonu sınıflandırma başarı oranlarını bulmuşlardır. Yine bu veri seti ile Razia ve ark. (2018) tarafından yapılan çalışmada karar ağacı, destek vektör makinesi ve çoklu lojistik regresyon yöntemleri kullanılmış, sırasıyla %99,23, %96,04 ve %91,59 sınıflandırma başarısı elde edilmiştir. Kolbusz ve ark. (2019) ise çalışmalarında Elman ve ileri beslemeli sinir ağları ile %97,8'lik ve %95,8'lik doğruluk elde etmişlerdir. Hosseinzadeh ve ark. (2021) geliştirdikleri çok katmanlı YSA ile %98,8 oranında doğruluk ile tiroid hastalığını sınıflandırmışlardır.

6.5. Tiroid Veri Seti

Bu bölümdeki uygulama, UCI veritabanından edinilen Garavan Enstitüsü Sidney, Avustralya'dan alınan 7200 kişiye ait tiroid verilerini içermektedir (Quinlan ve ark., 1986). Bu veri seti Tablo 6.1'de gösterilen toplam 22 öznelikten oluşmaktadır. Bunlardan 21 tanesi tiroid hastalığını belirleyen niteliklerdir. Son öznelik ise, tiroid bezinin normal çalıştığı insanları gösteren "normal", tiroid bezinin fazla çalıştığı hastaları gösteren "hipertiroidi" ve tiroid bezinin az çalıştığı hastaları gösteren

“hipotiroidi” olacak şekilde, 3 farklı sınıftan biridir. Örneklerin 166’sı normal, 368’i hipertiroidi ve 6666’sı hipotiroidi sınıfına aittir.


Tablo 6.1. Tiroid fonksiyonu sınıflandırma nitelikleri.

Öznitelik	Veri Tipi	Değer Aralığı
Yaş	Gerçek sayı	[0,00 – 0,93]
Cinsiyet, Tiroksin kullanan, Tiroksin kullandığı şüphesi, Antitiroid tedavi, Hasta, Hamile, Tiroid operasyonu, I131 tedavisi, Hipotiroidi şüphesi, Hipertiroidi şüphesi, Lityum, Guatr, Tümör, Hipopitüitarizm, Psikoloji	Tamsayı (ikili sayı)	{0, 1}
TSH	Gerçek sayı	[0,00 – 0,53]
T3	Gerçek sayı	[0,0005 – 0,18]
TT4	Gerçek sayı	[0,002 – 0,6]
T4U	Gerçek sayı	[0,017 – 0,233]
FTI	Gerçek sayı	[0,002 – 0,642]
Sınıf	Tamsayı	{1, 2, 3}


LVQNN, PNN ve PRNN yöntemleri kullanılarak sınıflandırma işlemi yapılmıştır. Tiroid hastalığının tespiti amaçlanmaktadır. 7200 veriden 2/3’ü, yani 4800 tanesi eğitim için girilmiştir ve geri kalan 1/3 veri, yani 2400 veri test için kullanılmıştır. Girdi verileri [0,1 – 0,9] aralığına normalize edilmiştir.

6.6. Tiroid Sınıflandırması

Bu doktora tezinde, tiroid fonksiyon sınıflandırmasında MATLAB™ programında LVQNN, PNN ve PRNN yöntemleri kullanılmıştır. Şekil 6.1’de gizli katmandaki nöron sayılarına göre LVQNN’nin eğitim ve test performansları, learnlv1 ve learnlv2 LVQ öğrenme fonksiyonları ile gösterilmiştir.




(a)




(b)

Şekil 6.1. Gizli katmandaki nöron sayılarına göre LVQNN'nin eğitim ve test performansları (a) learnlv1, (b) learnlv2 LVQ öğrenme fonksiyonları ile.

Şekil 6.1 incelendiğinde, en iyi test sonucunun 0,154583 MSE ile hem gizli katmanında 94 nöron bulunan learnlv1 LVQ öğrenme fonksiyonuna sahip LVQNN ağı ile hem de gizli katmanında 91 nöron bulunan learnlv2 LVQ öğrenme fonksiyonuna sahip LVQNN ağı ile elde edildiği görülmektedir. Bu LVQNN'lerin mimarisi Şekil 6.2'de verilmiştir.




(a)



(b)


Şekil 6.2. Tiroid veri seti için kullanılan LVQNN mimarisi (a) learnlv1, (b) learnlv2 LVQ öğrenme fonksiyonları ile.

Şekil 6.3'te yayılma faktörüne (spread factor) göre PNN'nin eğitim ve test performansları gösterilmiştir.




Şekil 6.3. Yayılma faktörüne göre PNN'nin eğitim ve test performansları.

Şekil 6.3 incelendiğinde, en iyi test sonucunun 0,095417 MSE ile 0,03 yayılma faktörlü PNN ağı ile elde edildiği görülmektedir. Bu PNN mimarisi Şekil 6.4'te verilmiştir.




Şekil 6.4. Tiroid veri seti için kullanılan PNN mimarisi.

Şekil 6.5'te gizli katmandaki nöron sayılarına göre PRNN'nin eğitim ve test performansları, Levenberg–Marquardt ve Bayesian öğrenme algoritmaları ile gösterilmiştir.




(a)



(b)

Şekil 6.5. Gizli katmandaki nöron sayılarına göre PRNN'nin eğitim ve test performansları (a) Levenberg–Marquardt, (b) Bayesian öğrenme algoritmaları ile.


Şekil 6.5 incelendiğinde, en iyi test sonucunun 0,015833 MSE ile gizli katmanında 3 nöron bulunan Bayesian öğrenme algoritması ile eğitilmiş PRNN ağı ile elde edildiği görülmektedir. Bu PRNN mimarisi Şekil 6.6'da verilmiştir.



Şekil 6.6. Tiroid veri seti için kullanılan PRNN mimarisi.


Şekil 6.7'de YSA eğitim ve test performansları, gizli katmanı 94 nöronlu ve learnlv1 öğrenme fonksiyonuna sahip LVQNN, yayılma faktörü = 0,03 olan PNN, ve gizli katmanı 3 nöronlu ve Bayesian öğrenme algoritması ile eğitilmiş PRNN için gösterilmiştir.

Best Train Performance is 0.137708, Best Test Performance is 0.154581




(a)

Best Train Performance is 0.0325, Best Test Performance is 0.0954167



(b)


Best Train Performance is 0.00916667, Best Test Performance is 0.015831




(c)

Şekil 6.7. YSA eğitim ve test performansları (a) LVQNN, (b) PNN, (c) PRNN.


En başarılı LVQNN, PNN ve PRNN ağlarının histogram grafikleri Şekil 6.8'de verilmiştir.



(a)






(b)




(c)

Şekil 6.8. YSA histogram grafikleri (a) LVQNN, (b) PNN, (c) PRNN.


En başarılı LVQNN, PNN ve PRNN ağlarının ROC eğrisi grafikleri Şekil 6.9’da ve karşılaştırma matrisi grafikleri Şekil 6.10’da verilmiştir.




Şekil 6.9. YSA ROC eğrileri (a) LVQNN, (b) PNN, (c) PRNN.



(a)



(b)



(c)

Şekil 6.10. YSA karşılaştırma matrisi sonuçları (a) LVQNN, (b) PNN, (c) PRNN.

Karşılaştırma matrisi Şekil 6.10 sonuçlarına göre 2400 test tiroid fonksiyon tahmininde PRNN modeli 23 hata (%99,04 doğruluk), LVQNN modeli 197 hata (%91,79 doğruluk) ve PNN modeli 172 hata (%92,83 doğruluk) ile sınıflandırma işlemini başarmıştır. 4800 eğitim seti verisinde ise, PRNN modeli 20 hatalı (%99,58 doğru), LVQNN modeli 337 hatalı (%92,98 doğru) ve PNN modeli 144 hatalı (%97,00 doğru) sonuç üretmiştir. Dolayısıyla, PRNN modeli, LVQNN ve PNN modellerine kıyasla tiroid fonksiyonu sınıflandırma işlemi için daha iyi doğruluk oranları vermiştir.

Tablo 6.2’de mevcut çalışmanın sonuçları ile aynı tiroid veri seti üzerine yapılan literatürdeki önceki çalışmalar karşılaştırılmıştır. Bu çalışmalarda, başarıyı yüksek sınıflandırmalar yapıldığı görülmektedir.

Tablo 6.2. Tiroid fonksiyonu sınıflandırma sonuçları.

Çalışma	Yöntem	Doğruluk Oranı
Hamid ve ark. (2012)	Çok Katmanlı Algılayıcı	%95,00
Hayashi ve ark. (2015)	Sürekli Re-RX	%96,70
Gorunescu ve Belciug (2016)	Çok Katmanlı Algılayıcı	%95,72
Ionita ve Ionita (2016)	Karar Ağacı	%97,35
	Çok Katmanlı Algılayıcı	%95,34
	Naive Bayes	%94,71
	Radyal Tabanlı YSA	%94,27
Razia ve ark. (2018)	Karar Ağacı	%99,23
	Destek Vektör Makinesi	%96,04
	Çoklu Lojistik Regresyon	%91,59
Kolbusz ve ark. (2019)	Elman YSA	%97,80
	İleri Beslemeli YSA	%95,80
Hosseinzadeh ve ark. (2021)	Çok Katmanlı YSA	%98,80
Kocamaz (2024)	LVQNN	%91,79
	PNN	%92,83
	PRNN	%99,04

Tablo 6.2’de verilen sonuçlara göre, en başarılı tiroid fonksiyon sınıflandırma sonucu %99,23’lük başarı oranı ile karar ağacı algoritmasıyla Razia ve ark. (2018)’nin çalışmasında elde edilmiştir. Bu sonucun mevcut çalışmada elde edilen %99,04’lük PRNN sınıflandırma başarısına oldukça yakın olduğu görülmektedir.



7. SONUÇ VE ÖNERİLER

YSA tekniklerinin tıbbi alanlarda kullanımı büyük bir potansiyele sahiptir. TKDS ile veritabanındaki bilgilere kolay erişim sağlanmakta, hastaya ait verilerin doğru ve hızlı analizi ile önlenabilir hastalıkların tarama testleri, hastalıkların doğru teşhisi ve tedavi takibi etkili şekilde yapılabilmektedir. Mevcut araştırma, farklı makine öğrenmesi sınıflandırma yöntemleri kullanarak en uygun yöntem sayesinde tahminlerdeki doğruluğu iyileştirmeyi amaçlamaktadır.

Gebelik, doğum ve doğum sonrası dönemde bebek ve anne birçok riskle karşı karşıya kalabilmektedir, bu süreçlerin düzenli takibi sonrası doğum şekline karar verilmelidir. Sezaryen, bebek veya anne için normal doğumun morbidite veya mortalite riski oluşturduğu durumlarda tercih edilmektedir. Sezaryen, dünya genelinde en çok yapılan cerrahi operasyonlardan biridir. Erken ve doğru sezaryen kararı anne ve bebekte oluşabilecek sıkıntıları azaltmaya yardımcı olacaktır. Yapay zeka tekniklerinden faydalanılarak uygun doğum yöntemi tespit edilebilir. Bu amaç doğrultusunda, bu doktora tezinde LVQNN, PNN ve PRNN olmak üzere 3 farklı sınıflandırma YSA tekniği kullanılmıştır. Her bir YSA tekniği, 80 gebenin doğum yöntemi sonuçları ile yaş, doğum sayısı, doğum zamanı, tansiyon ve kalp durumu bilgilerinin yer aldığı Tebriz Sağlık Merkezi veri seti ile önce eğitilmiş, ardından test edilmiştir. Bu YSA'lar verileri iki kategoride sınıflandırmaktadır: normal doğum ya da sezaryen. Şekiller ve tablolar, tüm YSA tekniklerinin doğum yöntemini sınıflandırma işleminde başarılı sonuçlar sağladığını göstermektedir. LVQNN modeli, 20 test verisinde sadece 2 hata, 60 eğitim verisinde ise 10 hata ile doğum yöntemini sınıflandırma işlemini gerçekleştirmiştir. Öte yandan, PNN ve PRNN ile aynı başarımda sonuçlar üretmiştir: test setinde 3, eğitim setinde 11 hata ile, toplamda 66 (%82,5) doğru sonuçla sınıflandırma yapılmıştır. Dolayısıyla, LVQNN modeli, PNN ve PRNN modellerine kıyasla daha iyi doğruluk oranları vermiştir. Sonuçlar, LVQNN'nin eğitim ve test aşamalarında sırasıyla %83,33 ve %90 doğruluk oranlarına ulaşarak daha iyi bir doğum yöntemi sınıflandırıcısı olduğunu göstermiştir. PNN ve PRNN ile, eğitim ve test aşamaları için sırasıyla %81,67 ve %85 doğum yöntemi sınıflandırma doğruluğu elde edilmiştir.

Çağımızın önemli hastalıklarından olan kanser, çevresel ve genetik faktörlerin etkisi ile hücre DNA'sında hasar oluşmasından dolayı vücuttaki bazı hücrelerin kontrolsüz biçimde sürekli çoğalmasındır. Kanser, kardiyovasküler hastalıklardan sonra en sık ölüme neden olan hastalıktır. Son yıllarda kanser taramaları ile erken dönemde teşhisi sağlanabilmektedir. Cerrahi ve medikal tedavilerdeki gelişmeler sayesinde kanser daha tedavi edilebilir bir hastalık haline gelmiş ve sağ kalım oranları artmıştır. Bu doktora tezinde, UCI makine öğrenmesi veritabanından edinilen Erlangen–Nuremberg Üniversitesi Hastanesi'ne ait hasta kayıtlarından oluşan “Mammography Mass Breast Cancer” veri seti kullanılarak YSA'lar ile kadınlarda en sık görülen kanser türü olan meme kanserinin teşhisine yönelik bir tahmin mekanizması oluşturulmuştur. Farklı YSA modelleri geliştirilmiş, eğitilmiş ve test edilmiştir. Eğitim esnasında 961 örneğin 2/3'ü, yani 641 adeti kullanılmıştır. Kalan 320 örnek ise test aşamasında kullanılmıştır. Eğitimde kullanılan örneklerin 355'i iyi huylu (benign), 286'sı kötü huylu (malignant) ve test setinde kullanılan örneklerin 161'i iyi huylu, 159'u kötü huylu sınıfına aittir. Model-I'de LVQNN, PNN ve PRNN ile tümörün iyi-kötü huylu olduğu sınıflandırması yapılmıştır. Yayılma faktörü 0,17 değerine sahip PNN en iyi sonuçları üretmiştir. Bu ağın doğruluk oranı, eğitim seti için $525/641 = \%81,9$ ve test seti için $274/320 = \%85,63$ 'tür. Model-II ve Model-III'te ise, önce SOM ve FCM ağları ile meme kanseri veri seti, Davies–Bouldin ve Silhouette yöntemlerine göre optimum küme sayısı 2 olarak tespit edildiği için, 2 kümeye (A ve B kümeleri) ayrılmış, sonrasında her bir küme LVQNN, PNN ve PRNN ile eğitilmiş ve test edilmiştir. Model-II'de A kümesinde PRNN, B kümesinde LVQNN daha başarılı sonuçlar üretmiştir. A kümesi için gizli katmanı 46 nöronlu ve Levenberg–Marquardt öğrenme algoritması ile eğitilmiş PRNN, B kümesi için gizli katmanı 34 nöronlu ve learnlv2 öğrenme fonksiyonuna sahip LVQNN ile en iyi sonuçlar elde edilmiştir. Bu iki ağın toplamdaki doğruluk oranı, eğitim seti için $526/641 = \%82,06$ ve test seti için $279/320 = \%87,19$ 'dur. FCM'nin kullanıldığı Model-III'te ise yine A kümesinde PRNN, B kümesinde LVQNN daha başarılı sonuçlar üretmiştir. Bu ağlarının toplam doğruluk oranı ise eğitim seti için $543/641 = \%84,71$ ve test seti için $279/320 = \%87,19$ 'dur. SOM ve FCM değerlerinin girdi olarak ilave edildiği Model-IV'te ise LVQNN, PNN ve PRNN'in tümünde test seti için $275/320 = \%85,94$ doğruluk oranı elde edilmiştir. Eğitim setinde $523/641 = \%81,59$ ile en başarılı sonucu Model-IV-C (hem SOM hem de FCM değeri girdi) vermiştir. Sonuç olarak, Model-III tümörün iyi-kötü huylu sınıflandırılması doğruluk oranını en çok yükselten model olmuştur.

Diyabet tüm dünyada görülme sıklığı giderek artan, erişkinlerde daha sık olmakla birlikte her yaşta görülebilen, farklı sistemlerde neden olduğu komplikasyonlar sonucu organ, işlev kayıplarına hatta ölüme neden olabilen çağımızın ciddi kronik hastalıklarından biridir. Dünyada yaklaşık 400 milyon kişinin diyabet hastası olduğu, bu sayının her yıl hızlı şekilde arttığı bilinmekte, milyonlarca kişinin de diyabet gelişimi açısından risk grubunda olduğu tahmin edilmektedir. Diyabet risk grubunda bulunan kişilerin belirlenip tedaviye erken başlanması ile farklı organlarda oluşan hasarlarda azalma sağlanabilmektedir. Bu doktora tezinde, UCI makine öğrenmesi veritabanından edinilen Sylhet, Bangladeş erken diyabet riski veri seti kullanılmıştır. Bu veri seti 520 hastanın toplam 17 niteliğini barındırmaktadır. Diyabetli olan 320, olmayan 200 kişi bulunmaktadır. Verilerin 2/3'ü eğitim esnasında, kalan 1/3'ü test aşamasında kullanılmıştır. LVQNN, PNN ve PRNN ile erken diyabet riski teşhisine yönelik sınıflandırma yapılmıştır. Gizli katmanı 49 nöronlu, Levenberg–Marquardt öğrenme algoritması ile eğitilmiş PRNN en başarılı test sonuçlarını üretmiştir. Bu ağın doğruluk oranı, eğitim seti için $344/347 = \%99,14$, test seti için $169/173 = \%97,69$ 'dur. LVQNN ve PNN ise test setinde sırasıyla $167/173 = \%96,53$ ve $166/173 = \%95,95$ doğruluk oranları ile sınıflandırma işlemini gerçekleştirmişlerdir.

Tiroid bezinden salgılanan tiroid hormonları metabolizma hızını düzenler. Kalp hızı, tansiyon, kan yağları, iştah, sindirim sistemi, kas iskelet sistemi ve sinir sistemi üzerinde etkileri mevcuttur. Tiroid hormonu sağlıklı bir yaşam için normal seviyede olmalıdır. Tiroid bezinin az ya da çok çalışması istenilmeyen bir durumdur. Tiroid bezinin fonksiyonundaki bozukluğa bağlı olarak birçok doku ve sistemin çalışması olumsuz yönde etkilenmekte, tedavi edilmediği takdirde ciddi sağlık sorunlarına neden olabilmektedir. Bu doktora tezinde, UCI veritabanından edinilen Garavan Enstitüsü, Sidney, Avustralya'daki 7200 kişiye ait 22 öznelikten oluşan tiroid fonksiyonu veri seti kullanılmıştır. Bu veri setindeki örneklerin 166'sı normal, 368'i hipertiroidi ve 6666'sı hipotiroidi sınıfına aittir. Verilerin 2/3'ü eğitim esnasında, kalan 1/3'ü test aşamasında kullanılmıştır. LVQNN, PNN ve PRNN ile tiroid fonksiyonu teşhisine yönelik sınıflandırma yapılmıştır. Gizli katmanında 3 nöron bulunan, Bayesian öğrenme algoritması ile eğitilmiş PRNN en başarılı test sonuçlarını üretmiştir. Bu ağın doğruluk oranı, eğitim seti için $4780/4800 = \%99,58$ ve test seti için $2377/2400 = \%99,04$ 'tür. LVQNN ve PNN ise test setinde sırasıyla $2228/2400 = \%92,83$ ve $2203/2400 = \%91,79$ doğruluk oranları ile sınıflandırma işlemini gerçekleştirmişlerdir.

Bu doktora çalışması, sınıflandırma işlemi için özelleştirilmiş YSA teknikleri olan LVQNN, PNN, PRNN algoritmaları kullanılarak doğum yönteminin belirlemesinin (normal doğum ya da sezaryen), meme kanserindeki tümörün iyi-kötü huylu olduğunun teşhisinin, erken diyabet riski tanısının ve tiroid fonksiyon hastalıklarının başarı ile bulunabileceğini göstermiştir. Bu doktora çalışmasında, ayrıca, sınıflandırma başarısının nispeten daha düşük olduğu durumlarda, başarı miktarını arttırmak için SOM ve FCM kümeleme algoritmalarından faydalanılması önerilmiş, farklı modeller geliştirilmiştir. Böl ve yönet yaklaşımı kullanılan, önce kümeleme algoritmaları ile verileri bölen sonra sınıflandırma algoritmaları ile teşhis koyma işlemini tamamlayan model en iyi sonucu vermiştir. Teknolojideki gelişmelerle beraber geliştirilen, başarısı daha yüksek olan yapay zeka yöntemlerinin tıp alanında kullanılması uygun ve yeterli tetkiklerle riskli bireylerin belirlenmesini, erken tanı ve tedavi ile de hastalık sürelerinin kısalmasını, yaşam kalitesinin artmasını ve tedavi maliyetlerinin düşmesini sağlamaktadır. Daha zeki tıbbi karar destek sistemleri hasta ve hastalıklara ait verileri, güncel bilimsel bilgileri, tanı, takip ve tedavi için alternatif seçenekleri analiz ederek doktorlara hastayı daha hızlı ve daha doğru şekilde değerlendirme ve tedavi edebilme olanağı kazandırmaktadır.

KAYNAKLAR

- Abbas, S. A., Riaz, R., Kazmi, S. Z. H., Rizvi, S. S., ve Kwon, S. J. (2018). Cause analysis of caesarian sections and application of machine learning methods for classification of birth data. *IEEE Access*, 6, 67555–67561. <https://doi.org/10.1109/ACCESS.2018.2879115>
- Akgül, G., Çelik, A. A., Aydın, Z. E., ve Öztürk, Z. K. (2020). Hipotiroidi hastalığı teşhisinde sınıflandırma algoritmalarının kullanımı. *Bilişim Teknolojileri Dergisi*, 13(3), 255–268. <https://doi.org/10.17671/gazibtd.710728>
- Akyol, K. ve Şen, B. (2018). Diabetes mellitus data classification by cascading of feature selection methods and ensemble learning algorithms. *International Journal of Modern Education and Computer Science*, 10(6), 10–16. <https://doi.org/10.5815/ijmecs.2018.06.02>
- Al-Azzam, N. ve Shatnawi, I. (2021). Comparing supervised and semi-supervised machine learning models on diagnosing breast cancer. *Annals of Medicine and Surgery*, 62, 53–64. <https://doi.org/10.1016/j.amsu.2020.12.043>
- Alcala-Rmz, V., Galvan-Tejada, C. E., Garcia-Hernandez, A., Valladares-Salgado, A., Cruz, M., Galvan-Tejada, J. I., Celaya-Padilla, J. M., Luna-Garcia, H., ve Gamboa-Rosales, H. (2021). Identification of people with diabetes treatment through lipids profile using machine learning algorithms. *Healthcare*, 9(4), 422. <https://doi.org/10.3390/healthcare9040422>
- Alehegn, M., Raghvendra Joshi, R., ve Mulay, P. (2019). Diabetes analysis and prediction using random forest, KNN, Naive Bayes, and J48: An ensemble approach. *International Journal of Scientific & Technology Research*, 8(9), 1346–1354.
- Alpan, K. ve İlgi, G. S. (2020, 22-24 Ekim). Classification of diabetes dataset with data mining techniques by using WEKA approach. *4th International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT)*, İstanbul, Türkiye, 1–7. <https://doi.org/10.1109/ISMSIT50672.2020.9254720>
- Alzu'bi, A., Najadat, H., Doulat, W., Al-Shari, O., ve Zhou, L. M. (2021). Predicting the recurrence of breast cancer using machine learning algorithms. *Multimedia Tools and Applications*, 80(9), 13787–13800. <https://doi.org/10.1007/s11042-020-10448-w>
- Americanpregnancy (2021, 10 Nisan). Fetal distress. <https://americanpregnancy.org/healthy-pregnancy/labor-and-birth/fetal-distress-9221/>
- Amin, M. Z. ve Ali, A. (2017, 8-9 Şubat). Application of multilayer perceptron (MLP) for data mining in healthcare operations, *3rd International Conference on Biotechnology*, Lahore, Pakistan, 2–11.

- Amrane, M., Oukid, S., Gagaoua, I., ve Ensari, T. (2018, 18-19 Nisan). Breast cancer classification using machine learning. *2018 Electric Electronics, Computer Science, Biomedical Engineerings' Meeting (EBBT)*, İstanbul, Türkiye, 1–4. <https://doi.org/10.1109/EBBT.2018.8391453>
- Asif, M. A. A. R., Nishat, M. M., Faisal, F., Shikder, M. F., Udoy, M. H., Dip, R. R., ve Ahsan, R. (2020, 17-19 Aralık). Computer aided diagnosis of thyroid disease using machine learning algorithms. *11th International Conference on Electrical and Computer Engineering (ICECE)*, Dakka, Bangladeş, 222–225. <https://doi.org/10.1109/ICECE51571.2020.9393054>
- Asri, H., Mousannif, H., Al Moatassime, H., ve Noel, T. (2016, 23-26 Mayıs). Using machine learning algorithms for breast cancer risk prediction and diagnosis. *7th International Conference on Ambient Systems, Networks and Technologies (ANT) / 6th International Conference on Sustainable Energy Information Technology (SEIT)*, Madrid, İspanya, 83, 1064–1069. <https://doi.org/10.1016/j.procs.2016.04.224>
- Aydındağ Bayrak, E., Kırıcı, P., Ensari, T., Seven, E., ve Dağtekin, M. (2022). Göğüs kanseri verileri üzerinde makine öğrenmesi yöntemlerinin uygulanması. *Zeki Sistemler Teori ve Uygulamaları Dergisi*, 5(1), 35–41. <https://doi.org/10.38016/jista.966517>
- Avcı, U. (2006). *Bulanık kümeleme algoritmalarının karşılaştırmalı analizi ve bilgisayar uygulamaları* [Yüksek lisans tezi] Ege Üniversitesi.
- Bakırarar, B., Kar, İ., Gökmen, D., Elhan, A. H., ve Genç, V. (2019). The prediction of breast biopsy outcomes using two data mining algorithms based on parameter variations. *Türkiye Klinikleri Biyoistatistik Dergisi*, 11(2), 133–142. <https://doi.org/10.5336/biostatic.2019-64754>
- Banu, G. R. (2016). A role of decision tree classification data mining technique in diagnosing thyroid disease. *International Journal of Computer Sciences and Engineering*, 4(11), 64–70.
- Bao, W., Lianju, N., ve Yue, K. (2019). Integration of unsupervised and supervised machine learning algorithms for credit risk assessment. *Expert Systems with Applications*, 128, 301–315. <https://doi.org/10.1016/j.eswa.2019.02.033>
- Bayır, F. (2006). *Yapay sinir ağları ve tahmin modellemesi üzerine bir uygulama* [Yüksek lisans tezi] İstanbul Üniversitesi.
- BBC News (2010, 30 Haziran). World Health Organization (WHO) statement "Should there be a limit on caesareans?"
- Begum, B. A. ve Parkavi, A. (2019, 15-16 Mart). Prediction of thyroid disease using data mining techniques. *5th International Conference on Advanced Computing and Communication Systems (ICACCS)*, Coimbatore, Hindistan, 342–345. <https://doi.org/10.1109/icaccs.2019.8728320>
- Bezdek, J. C. (1981). *Fuzzy mathematics in pattern classification* [Doktora tezi] Cornell University.
- Birjais, R., Mourya, A. K., Chauhan, R., ve Kaur, H. (2019). Prediction and diagnosis of future diabetes risk: A machine learning approach. *SN Applied Sciences*, 1(9), 1112. <https://doi.org/10.1007/s42452-019-1117-9>

- Bunjaku, T. R. (2014). *PNN ve SVM kullanarak DWT tabanlı yüz tanıma* [Yüksek lisans tezi] Sakarya Üniversitesi.
- Chaves, L. ve Marques, G. (2021). Data mining techniques for early diagnosis of diabetes: A comparative study. *Applied Sciences-Basel*, 11(5), 2218. <https://doi.org/10.3390/app11052218>
- Chen, P. H. ve Pan, C. D. (2018). Diabetes classification model based on boosting algorithms. *BMC Bioinformatics*, 19(1), 109. <https://doi.org/10.1186/s12859-018-2090-9>
- Cihan, P. ve Coşkun, H. (2021, 9-11 Haziran). Performance comparison of machine learning models for diabetes prediction. *29th Signal Processing and Communications Applications Conference (SIU)*, İstanbul, Türkiye, 1–4. <https://doi.org/10.1109/SIU53274.2021.9477824>
- Çalışkan, A., Koçak, D., ve Ertürk, Y. (2021). Ülkelerin yükseköğretim performanslarının bulanık C-ortalamalar kümeleme algoritması ile değerlendirilmesi. *Üniversite Araştırmaları Dergisi*, 4(1), 1–5. <https://doi.org/10.26701/uad.898187>
- Çekli, S. ve Uzunoğlu, C. P. (2011, 22-22 Nisan). Classification of chaotic circuit output patterns with probabilistic neural networks. *19th Signal Processing and Communications Applications Conference (SIU)*, Antalya, Türkiye, 170–173. <https://doi.org/10.1109/SIU.2011.5929614>
- Çevik, K. K. ve Koçer, H. E. (2013). Parçacık sürü optimizasyonu ile yapay sinir ağları eğitime dayalı bir esnek hesaplama uygulaması. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 17(2), 39–45.
- Daghistani, T. ve Alshammari, R. (2020). Comparison of statistical logistic regression and randomforest machine learning techniques in predicting diabetes. *Journal of Advances in Information Technology*, 11(2), 78–83. <https://doi.org/10.12720/jait.11.2.78-83>
- Dieste-Velasco, M. I. (2021). Application of a pattern-recognition neural network for detecting analog electronic circuit faults. *Mathematics*, 9(24), 3247. <https://doi.org/10.3390/math9243247>
- Doğantekin, E., Doğantekin, A., ve Avcı, D. (2011). An expert system based on generalized discriminant analysis and wavelet support vector machine for diagnosis of thyroid diseases. *Expert Systems with Applications*, 38(1), 146–150, 2011. <https://doi.org/10.1016/j.eswa.2010.06.029>
- Doğru, A. (2021). *Diyabet tespitiinde makine öğrenmesi algoritmaları yaklaşımını kullanarak yapılmış bir çalışma* [Yüksek lisans tezi] Çankırı Karatekin Üniversitesi.
- Dunn, J. C. (1973). A fuzzy relative of the ISODATA process and its use in detecting compact well-separated clusters. *Journal of Cybernetics*, 3(3), 32–57. <https://doi.org/10.1080/01969727308546046>
- Elmannai, H., Hamdi, M., ve AlGarni, A. (2021). Deep learning models combining for breast cancer histopathology image classification. *International Journal of Computational Intelligence Systems*, 14(1), 1003–1013. <https://doi.org/10.2991/ijcis.d.210301.002>

- Elter, M., Schulz-Wendtland, R., ve Wittenberg, T. (2007). The prediction of breast cancer biopsy outcomes using two CAD approaches that both emphasize an intelligible decision process. *Medical Physics*, 34(11), 4164–4172. <https://doi.org/10.1118/1.2786864>
- Erilli, N. A. ve Karaköy, Ç. (2015, 9-11 Eylül). Classification of Turkish Republics with specific economic indicators in fuzzy clustering analysis. *International Conference of Eurasian Economies*, Kazan, Rusya, 305–310. <https://doi.org/10.36880/C06.01253>
- Eriş Hasırcı, H. M. (2019). *Öz düzenlemeli haritalar yöntemi ile elde edilen yapı geçerliği kanıtlarının faktör analizi ve kümeleme analizi ile karşılaştırılması* [Doktora tezi] Ankara Üniversitesi.
- Eşmen, S. (2020). *Özdüzenleyici haritalar ile portföy seçimi: Bist-100’de bir uygulama* [Doktora tezi] Aydın Adnan Menderes Üniversitesi.
- Fergus, P., Hussain, A., Al-Jumeily, D., Huang, D. S., ve Bouguila, N. (2017). Classification of caesarean section and normal vaginal deliveries using foetal heart rate signals and advanced machine learning algorithms. *Biomedical Engineering Online*, 16, 89. <https://doi.org/10.1186/s12938-017-0378-z>
- Fergus, P., Selvaraj, M., ve Chalmers, C. (2018). Machine learning ensemble modelling to classify caesarean section and vaginal delivery types using cardiotocography traces. *Computers in Biology and Medicine*, 93, 7–16. <https://doi.org/10.1016/j.compbiomed.2017.12.002>
- Fogel, D. B., Wasson, E. C., Boughton, E. M., ve Porto, V. W. (1997). A step toward computer-assisted mammography using evolutionary programming and neural networks. *Cancer Letters*, 119(1), 93–97. [https://doi.org/10.1016/S0304-3835\(97\)00259-0](https://doi.org/10.1016/S0304-3835(97)00259-0)
- Frize, M., Ibrahim, D., Seker, H., Walker, R. C., Odetayo, M. O., Petrovic, D., ve Naguib, R. N. G. (2004, 1-5 Eylül). Predicting clinical outcomes for newborns using two artificial intelligence approaches. *26th Annual International Conference of the IEEE-Engineering-in-Medicine-and-Biology-Society*, San Francisco, Kaliforniya, Amerika Birleşik Devletleri, 3202–3205. <https://doi.org/10.1109/IEMBS.2004.1403902>
- Gao, K., Chen, Z. D., Weng, S., Zhu, H. P., ve Wu, L. Y. (2022). Detection of multi-type data anomaly for structural health monitoring using pattern recognition neural network. *Smart Structures and Systems*, 29(1), 129–140. <https://doi.org/10.12989/sss.2022.29.1.129>
- Gauri, S. K. (2010). Control chart pattern recognition using feature-based learning vector quantization. *International Journal of Advanced Manufacturing Technology*, 48(9-12), 1061-1073. <https://doi.org/10.1007/s00170-009-2354-7>
- Gharehchopogh, F. S., Mohammadi, P., ve Hakimi, P. (2012). Application of decision tree algorithm for data mining in healthcare operations: A case study. *International Journal of Computer Applications*, 52(6), 21–26. <https://doi.org/10.5120/8206-1613>
- Ghosh, S. ve Dubey, S. K. (2013). Comparative analysis of k-means and fuzzy c-means algorithms. *International Journal of Advanced Computer Science and Applications*, 4(4), 35–39.

- Gopal, V. N., Al-Turjman, F., Kumar, R., Anand, L., ve Rajesh, M. (2021). Feature selection and classification in breast cancer prediction using IoT and machine learning. *Measurement*, 178, 109442. <https://doi.org/10.1016/j.measurement.2021.109442>
- Gorunescu, F. ve Belciug, S. (2016). Boosting backpropagation algorithm by stimulus-sampling: Application in computer-aided medical diagnosis. *Journal of Biomedical Informatics*, 63, 74–81. <https://doi.org/10.1016/j.jbi.2016.08.004>
- Gorunescu, M., Gorunescu, F., ve Revett, K. (2007, 15-18 Mart). Investigating a breast cancer dataset using a combined approach: Probabilistic neural networks and Rough sets. *3rd ACM International Conference on Intelligent Computing and Information Systems (ICICIS07)*, Kahire, Mısır, 246–249.
- Gupta, P. ve Garg, S. (2020). Breast cancer prediction using varying parameters of machine learning models. *Procedia Computer Science*, 171, 593–601. <https://doi.org/10.1016/j.procs.2020.04.064>
- Güzel, C., Kaya, M., Yıldız, O., ve Bilge, H. Ş. (2013). Breast cancer diagnosis based on Naive Bayes machine learning classifier with KNN missing data imputation. *AWERProcedia Information Technology & Computer Science*, 4, 401–407.
- Hamid, N. A., Nawı, N. M., Ghazali, R., ve Salleh, M. N. M. (2012). Solving local minima problem in back propagation algorithm using adaptive gain, adaptive momentum and adaptive learning rate on classification problems. *International Journal of Modern Physics: Conference Series*, 9, 448–455. <https://doi.org/10.1142/S2010194512005533>
- Hamilton, B. E., Martin, J. A., ve Ventura S. J. (2007). Division of vital statistics, births: Preliminary data for 2007. *National Vital Statistics Report*.
- Hamilton, B. E., Martin, J. A., Osterman, M. J. K., Driscoll, A. K., ve Rossen, L. M. (2018). Births: Provisional Data for 2017. *Vital Statistics Rapid Release*, Report No. 004, 1–23.
- Hawrami, Z. S. M. (2022). *Derin öğrenme ile sınıflandırma: Meme kanseri teşhisi* [Yüksek lisans tezi] Gazi Üniversitesi.
- Hayashi, Y., Nakano, S., ve Fujisawa, S. (2015). Use of the recursive-rule extraction algorithm with continuous attributes to improve diagnostic accuracy in thyroid disease. *Informatics in Medicine Unlocked*, 1, 1–8. <https://doi.org/10.1016/j.imu.2015.12.003>
- Haykin, S. (1994). *Neural Networks*. Prantice Hall, Amerika Birleşik Devletleri.
- Hassim, Y. M. M. ve Ghazali, R. (2016). Improving functional link neural network learning scheme for mammographic classification. In: Bassis, S., Esposito, A., Morabito, F., Pasero, E. (Ed.), *Advances in Neural Networks, WIRN 2015, Smart Innovation, Systems and Technologies*, 54, 213–221, Springer, Cham. https://doi.org/10.1007/978-3-319-33747-0_21
- Hosseinzadeh, M., Ahmed, O. H., Ghafour, M. Y., Safara, F., Hama, H., Ali, S., Vo, B., ve Chiang, H. S. (2021). A multiple multilayer perceptron neural network with an adaptive learning algorithm for thyroid disease diagnosis in the internet of medical things. *Journal of Supercomputing*, 77(4), 3616–3637. <https://doi.org/10.1007/s11227-020-03404-w>

- Hsiao, Y. H., Huang, Y. L., Liang, W. M., Lin, C., Kuo, S. J., ve Chen, D. R. (2009). Characterization of benign and malignant solid breast masses: Harmonic versus nonharmonic 3D power Doppler imaging. *Ultrasound Medicine and Biology*, 35(3), 353–359. <https://doi.org/10.1016/j.ultrasmedbio.2008.09.010>
- Ionita, I. ve Ionita, L. (2016). Prediction of thyroid disease using data mining techniques. *BRAIN-Broad Research in Artificial Intelligence and Neuroscience*, 7(3), 115–124.
- Islam, M. M. F., Ferdousi, R., Rahman, S., ve Bushra, H. Y. (2020). Likelihood prediction of diabetes at early stage using data mining techniques. In: Gupta, M., Konar, D., Bhattacharyya, S., Biswas, S. (Ed.), *Computer Vision and Machine Intelligence in Medical Image Analysis*. Springer, Singapur, 992, 113–125. https://doi.org/10.1007/978-981-13-8798-2_12
- Izakian, H. ve Abraham, A. (2011). Fuzzy c-means and fuzzy swarm for fuzzy clustering problem. *Expert Systems with Applications*, 38(3), 1835–1838. <https://doi.org/10.1016/j.eswa.2010.07.112>
- Karapınar Şentürk, Z. ve Şentürk A. (2016). Yapay sinir ağları ile göğüs kanseri tahmini. *El-Cezeri Fen ve Mühendislik Dergisi*, 3(2), 345–350. <https://doi.org/10.31202/ecjse.264199>
- Kaushik, D. ve Kaur, K. (2016, 6-8 Temmuz). Application of data mining for high accuracy prediction of breast tissue biopsy results. *3rd International Conference on Digital Information Processing, Data Mining, and Wireless Communications (DIPDMWC)*, Moskova, Rusya, 40–45. <https://doi.org/10.1109/DIPDMWC.2016.7529361>
- Kaya, A. (2018). *Bulanık kümeleme analizinde bulanık kümeleme algoritmalarının karşılaştırılması* [Yüksek lisans tezi] Anadolu Üniversitesi.
- Keleş A. ve Keleş A. (2008). ESTDD: Expert system for thyroid diseases diagnosis. *Expert Systems with Applications*, 34(1), 242–246. <https://doi.org/10.1016/j.eswa.2006.09.028>
- Khan, M. M., Islam, S., Sarkar, S., Ayaz, F. I., Ananda, M. K., Tazin, T., Albraikan, A. A., ve Almalki, F. A. (2022). Machine learning based comparative analysis for breast cancer prediction. *Journal of Healthcare Engineering*, 2022, 4365855. <https://doi.org/10.1155/2022/4365855>
- Kiknadze, M. ve Gürhanlı, A. (2020). Yapay sinir ağı kullanarak meme kanseri hastalığının tahmini. *AURUM Mühendislik Sistemleri ve Mimarlık Dergisi*, 4(2), 255–272.
- Koçak, E. (2010). *Olasılık sinir ağı kullanarak alternatör arızalarının tespiti* [Yüksek lisans tezi] Karabük Üniversitesi.
- Kohonen T. (1981). Automatic formation of topological maps of patterns in a self-organizing system. *Proceedings of Second Scandinavian Conference on Image Analysis*, Espoo, Finlandiya, 214–220.
- Kolbusz, J., Rozycki, P., Lysenko, O., ve Wilamowski, B. M. (2019, 25-27 Haziran). Error back propagation algorithm with adaptive learning rate. *International Conference on Information and Digital Technologies (IDT)*, Zilina, Slovakya, 216–222. <https://doi.org/10.1109/DT.2019.8813440>.

- Koltan Yılmaz, Ş. (2014). *Doğrusal vektör kuantizasyon modeli kullanılarak yapay sinir ağlarıyla kontrol şemalarında örüntü tanıma: Hazır beton üreten bir işletmede uygulama* [Doktora tezi] İnönü Üniversitesi.
- Korkmaz, M. (2023). *Makine öğrenmesi ve derin öğrenme teknikleri ile meme kanserinin karşılaştırmalı sınıflandırılması* [Yüksek lisans tezi] Kocaeli Üniversitesi.
- Kousarrizi, M. N., Seiti, F., ve Teshnehlav, M. (2012). An experimental comparative study on thyroid disease diagnosis based on feature subset selection and classification. *International Journal of Electrical & Computer Sciences*, 12(01), 13–20.
- Kowsher, M., Turaba, M. Y., Sajed, T., ve Mahabubur Rahman, M. M. (2019, 18-20 Aralık). Prognosis and treatment prediction of type-2 diabetes using deep neural network and machine learning classifiers. *22nd International Conference on Computer and Information Technology (ICCIT)*, Dakka, Bangladeş, 1–6. <https://doi.org/10.1109/ICCIT48885.2019.9038574>
- Kumari, L. K. ve Jagadesh B. N. (2022). A robust feature extraction technique for breast cancer detection using digital mammograms based on advanced GLCM approach. *EAI Endorsed Transactions on Pervasive Health and Technology*, 8(30), e3. <https://doi.org/10.4108/eai.11-1-2022.172813>
- Kumari, S., Kumar, D., ve Mittal, M. (2021). An ensemble approach for classification and prediction of diabetes mellitus using soft voting classifier. *International Journal of Cognitive Computing in Engineering*, 2, 40–46. <https://doi.org/10.1016/j.ijcce.2021.01.001>
- Liu, D. Y., Chen, H. L., Yang, B., Lv, X. E., Li, L. N., ve Liu, J. (2012). Design of an enhanced fuzzy k-nearest neighbor classifier based computer aided diagnostic system for thyroid disease. *Journal of Medical Systems*, 36(5), 3243–3254, <https://doi.org/10.1007/s10916-011-9815-x>
- Liu, L., Johnson, H. L., Cousens, S., Perin, J., Scott, S., Lawn, J. E., Rudan, I., Campbell, H., Cibulskis, R., Li, M. Y., Mathers, C., ve Black, R. E. (2012). Global, regional, and national causes of child mortality: An updated systematic analysis for 2010 with time trends since 2000. *Lancet*, 379(9832), 2151–2161. [https://doi.org/10.1016/S0140-6736\(12\)60560-1](https://doi.org/10.1016/S0140-6736(12)60560-1)
- Lopez-Cabrera, J. D., Rodriguez, L. A. L., ve Perez-Diaz, M. (2020). Classification of breast cancer from digital mammography using deep learning. *Inteligencia Artificial-Iberoamerical Journal of Artificial Intelligence*, 23(65), 56–66. <https://doi.org/10.4114/intartif.vol23iss65pp56-66>
- Luo, S. T. ve Cheng, B. W. (2012). Diagnosing breast masses in digital mammography using feature selection and ensemble methods. *Journal of Medical Systems*, 36(2), 569–577. <https://doi.org/10.1007/s10916-010-9518-8>
- Margret, J. J., Lakshmipathi, B., ve Kumar, S. A. (2012). Diagnosis of thyroid disorders using decision tree splitting rules. *International Journal of Computer Applications*, 44(8), 43–46. <https://doi.org/10.5120/6287-8474>
- Mihaylov, I., Nisheva, M., ve Vassilev, D. (2019). Application of machine learning models for survival prognosis in breast cancer studies. *Information*, 10(3), 93. <https://doi.org/10.3390/info10030093>

- Mujawar, I. K., Jadhav, B. T., Waghmare, V. B., ve Patil, R. Y. (2021, 5-7 Mart). Development of diabetes diagnosis system with artificial neural network and open source environment. *International Conference on Emerging Smart Computing and Informatics*, Pune, Hindistan, 477–482.
- Nawaz, M., Sewissy, A. A., ve Soliman, T. H. A. (2018). Multi-class breast cancer classification using deep learning convolutional neural network. *International Journal of Advanced Computer Science and Applications*, 9(6), 316–332. <https://doi.org/10.14569/IJACSA.2018.090645>
- Naz, H. ve Ahuja, S. (2020). Deep learning approach for diabetes prediction using PIMA Indian dataset. *Journal of Diabetes and Metabolic Disorders*, 19(1), 391–403. <https://doi.org/10.1007/s40200-020-00520-5>
- Nilashi, M., Ibrahim, O., Ahmadi, H., ve Shahmoradi, L. (2017). A knowledge-based system for breast cancer classification using fuzzy logic method. *Telematics and Informatics*, 34(4), 133–144. <https://doi.org/10.1016/j.tele.2017.01.007>
- Nyoni, S. P. ve Nyoni, T. (2020). Using artificial neural networks for predicting new Caesarian Section (CS) cases at Kwekwe General Hospital in Zimbabwe. *International Journal of Innovations in Engineering Research and Technology*, 7(5), 387–392.
- Ofluoğlu, C. (2009). Tiroit bezi ve hastalıkları. *Özlenen Rehber Dergisi*, 70, 1173.
- Ömürbek, N., Demirgubuz, M. Ö., ve Tunca, M. Z. (2013). Hastanelerdeki bilişim sistemlerinden klinik bilgi sistemlerinin kullanımına yönelik bir araştırma: Denizli ve Isparta örneği. *Sosyal ve Ekonomik Araştırmalar Dergisi*, 25, 301–328.
- Öztemel, E. (2012). *Yapay Sinir Ağları* (3. Baskı). Papatya Yayıncılık, İstanbul.
- Pala, T. (2013). *Tıbbi karar destek sisteminin veri madenciliği yöntemleriyle gerçekleştirilmesi* [Yüksek lisans tezi] Marmara Üniversitesi.
- Petriçli, G. (2020). *Öz-örgütlemeli haritalar ile kent markalaşmasında kent sakinlerinin yeşil kimlik profillerinin belirlenmesi: “Yeşil Bursa” örneği* [Doktora tezi] Bursa Uludağ Üniversitesi.
- Pickens, A. ve Sengupta, S. (2021). Benchmarking studies aimed at clustering and classification tasks using k-means, fuzzy c-means and evolutionary neural networks. *Machine Learning and Knowledge Extraction*, 3(3), 695–719. <https://doi.org/10.3390/make3030035>
- Quinlan, J. R., Compton, P. J., Horn, K. A., ve Lazurus, L. (1986). Inductive knowledge acquisition: A case study. *Second Australian Conference on Applications of Expert Systems*, Sidney, Avustralya, 137–156.
- Ram, A. ve Vishwakarma, H. (2021, 18-19 Aralık). Diabetes prediction using machine learning and data mining methods. *International Conference on Futuristic and Sustainable Aspects in Engineering and Technology (FSAET 2020)*, IOP Conference Series: Materials Science and Engineering, 1116, Mathura, Hindistan, 012135. <https://doi.org/10.1088/1757-899X/1116/1/012135>
- Razia, S., Prathyusha, P. S., Krishna, N. V., ve Sumana, N. S. (2018). A comparative study of machine learning algorithms on thyroid disease prediction. *International Journal of Engineering & Technology*, 7(2.8), 315–319. <https://doi.org/10.14419/ijet.v7i2.8.10432>

- Revett, K., Gorunescu, F., Gorunescu, M., El-Darzi, E., ve Ene, M. (2005, 21-24 Kasım). A breast cancer diagnosis system: A combined approach using Rough sets and probabilistic neural networks. *International Conference on Computer as a Tool (EUROCON 2005)*, Belgrad, Sırbistan, 1124–1127.
- Robu, R. ve Holban Ş. (2015). The analysis and classification of birth data. *Acta Polytechnica Hungarica*, 12(4), 77–96.
- Ross, T. J. (2010). *Fuzzy Logic with Engineering Applications* (3rd ed). John Wiley & Sons, Ltd., Birleşik Krallık.
- Sadhu, A. ve Jadli, A. (2021). Early-stage diabetes risk prediction: A comparative analysis of classification algorithms. *International Advanced Research Journal in Science, Engineering and Technology*, 8(2), 193–201. <https://doi.org/10.17148/IARJSET.2021.8228>
- Saxena, S., Mohapatra, D., Padhee, S., ve Sahoo, G. K. (2023). Machine learning algorithms for diabetes detection: A comparative evaluation of performance of algorithms. *Evolutionary Intelligence*, 16(2), 587–603. <https://doi.org/10.1007/s12065-021-00685-9>
- Senyefia, B. A., Joseph, O., ve Francis, E. B. (2019). Time series analysis and forecasting of caesarian section births in Ghana. *Biomedical Statistics and Informatics*, 4(1), 1–9, 2019. <https://doi.org/10.11648/j.bsi.20190401.11>
- Sidiq, U. D., Aaqib, S. M., ve Khan, R. A. (2019). Diagnosis of various thyroid ailments using data mining classification techniques. *International Journal of Scientific Research in Computer Science, Engineering and Information Technology*, 5(1), 131–136. <https://doi.org/10.32628/CSEIT195119>
- Sisodia, D. ve Sisodia, D. S. (2018). Prediction of diabetes using classification algorithms. *Procedia Computer Science*, 132, 1578–1585. <https://doi.org/10.1016/j.procs.2018.05.122>
- Sodsee, S. (2014). Predicting caesarian section by applying nearest neighbor analysis. *Procedia Computer Science*, 31, 5–14. <https://doi.org/10.1016/j.procs.2014.05.239>
- Solmaz, R., Günay, M., ve Alkan, A. (2013, 23-25 Ocak). Uzman sistemlerin tiroit teşhisinde kullanılması. *Akademik Bilişim 2013 – XV. Akademik Bilişim Konferansı Bildirileri*, Akdeniz Üniversitesi, Antalya, Türkiye, 919–922.
- Suwarno, S. ve Santo, P. A. (2019). Performance evaluation of artificial neural network classifiers for predicting cesarean sections. *International Journal of Scientific & Technology Research*, 8(9), 1843–1846.
- Şahin, F. (2016). *Ayaklardaki yüzeysel mantar enfeksiyonlarının potansiyel risk faktörlerinin kendini örgütleyen haritalar (SOM) ile analizi* [Yüksek lisans Tezi] Çukurova Üniversitesi.
- Şenol, C. ve Yıldırım, T. (2008, 26-30 Kasım). Bulanık-sinir ağı yapısı için yeni bir karma yaklaşım. *Elektrik – Elektronik ve Bilgisayar Mühendisliği Sempozyumu (ELECO'2008)*, Bursa, Türkiye.
- Şenol, C. ve Yıldırım, T. (2009, 5-8 Aralık). Thyroid and breast cancer disease diagnosis using fuzzy-neural networks. *6th International Conference on Electrical and Electronics Engineering (ELECO'2009)*, Bursa, Türkiye, 390–393. <https://doi.org/10.1109/ELECO.2009.5355297>

- Taylor, M. J. O. (2006). The management of multiple pregnancy. *Early Human Development*, 82(6), 365–370. <https://doi.org/10.1016/j.earlhumdev.2006.03.008>
- Temurtas, F. (2009). A comparative study on thyroid disease diagnosis using neural networks. *Expert System with Applications*, 36(1), 944–949. <https://doi.org/10.1016/j.eswa.2007.10.010>
- Temurtas, H., Yumusak, N., ve Temurtas, F. (2009). A comparative study on diabetes disease diagnosis using neural networks. *Expert Systems with Applications*, 36(4), 8610–8615. <https://doi.org/10.1016/j.eswa.2008.10.032>
- Tuskan, Y. (2012). *Yapay sinir ağlarının geoteknik alanında kullanımı* [Yüksek lisans tezi] Celal Bayar Üniversitesi.
- Vadivel, A. ve Surendiran, B. (2013). A fuzzy rule-based approach for characterization of mammogram masses into BI-RADS shape categories. *Computers in Biology and Medicine*, 43(4), 259–267. <https://doi.org/10.1016/j.combiomed.2013.01.004>
- Van Dyne, M. M., Woolery, L. K., Gryzmala-Busse, J., ve Tsatsoulis, C. (1994, 1-4 Mart). Using machine learning and expert systems to predict preterm delivery in pregnant women. *Tenth Conference on Artificial Intelligence for Applications*, San Antonio, Teksas, Amerika Birleşik Devletleri, 344–350. <https://doi.org/10.1109/CAIA.1994.323655>
- Veranyurt, Ü., Deveci, A., Esen, M. F., ve Veranyurt, O. (2020). Makine öğrenmesi teknikleriyle hastalık sınıflandırması: Random forest, k-nearest neighbour ve Adaboost algoritmaları uygulaması. *Uluslararası Sağlık Yönetimi ve Stratejileri Araştırma Dergisi*, 6(2), 275–286.
- Vijayarajeswari, R., Parthasarathy, P., Vivekanandan, S., ve Basha, A. A. (2019). Classification of mammogram for early detection of breast cancer using SVM classifier and Hough transform. *Measurement*, 146, 800–805. <https://doi.org/10.1016/j.measurement.2019.05.083>
- Wang, G. S., Shi, D. F., Guo, Q., Zhang, H. R., Wang, S. Y., ve Ren, K. (2022). Radiomics based on digital mammography helps to identify mammographic masses suspicious for cancer. *Frontiers in Oncology*, 12, 8438436. <https://doi.org/10.3389/fonc.2022.843436>
- Whelton, P. K., Carey, R. M., Aronow, W. S., Casey, D. E., Collins, K. J., Himmelfarb, C. D., DePalma, S. M., Gidding, S., Jamerson, K. A., Jones, D. W., MacLaughlin, E. J., Muntner, P., Ovbigele, B., Smith, S. C., Spencer, C. C., Stafford, R. S., Taler, S. J., Thomas, R. J., Williams, K. A., Williamson, J. D., ve Wright, J. T. (2018). 2017 ACC/AHA/AAPA/ABC/ACPM/AGS/APhA/ASH/ASPC/NMA/PCNA Guideline for the prevention, detection, evaluation, and management of high blood pressure in adults: A report of the American college of cardiology/American heart association task force on clinical practice guidelines. *Circulation*, 138(17), E484–E594. <https://doi.org/10.1161/CIR.0000000000000596>
- Wikipedia (2021, 10 Nisan). Vajinal doğum. https://tr.wikipedia.org/wiki/Vajinal_dogum

- Williamson, S., Vijayakumar, K., ve Kadam, V. J. (2022). Predicting breast cancer biopsy outcomes from BI-RADS findings using random forests with chi-square and MI features. *Multimedia Tools and Applications*, 81(26), 36869–36889. <https://doi.org/10.1007/s11042-021-11114-5>
- Wu, J. D. ve Hicks, C. (2021). Breast cancer type classification using machine learning. *Journal of Personalized Medicine*, 11(2), 61. <https://doi.org/10.3390/jpm11020061>
- Xue, J., Min, F., ve Ma, F. (2020, 18-20 Eylül). Research on diabetes prediction method based on machine learning. *The 2020 International Seminar on Artificial Intelligence, Networking and Information Technology*, Shanghai, Çin, *Journal of Physics: Conference Series*, 1684, 012062. <https://doi.org/10.1088/1742-6596/1684/1/012062>
- Yan, Y. T., Zhang, Y. P., Zhang, Y. W., ve Du, X. Q. (2017). A selective neural network ensemble classification for incomplete data. *International Journal of Machine Learning and Cybernetics*, 8(5), 1513–1524. <https://doi.org/10.1007/s13042-016-0524-0>
- Yıldırım, O. (2022). *OECD ülkelerinin dış ticaret verilerinin SOM algoritması ile kümelenmesi* [Yüksek lisans tezi] Burdur Mehmet Akif Ersoy Üniversitesi.
- Yurttakal, A. H. ve Baş, H. (2021). Possibility prediction of diabetes mellitus at early stage via stacked ensemble deep neural network. *Afyon Kocatepe University Journal of Science and Engineering*, 21(4), 812–819. <https://doi.org/10.35414/akufemubid.946264>
- Zahriah, S., Fahmi, A., Sharifah, S. S. A., Rabiah, A., ve Rubiyah, Y. (2017, 11-12 Ekim). Imputing missing values in mammography mass dataset: Will it increase classification performance of machine learning algorithms? *8th International Conference on Agricultural, Biological, Environmental and Medical Sciences (ABEMS-2017)*, Bali, Endonezya, 36-40. <https://doi.org/10.17758/EIRAI.IAE1017305>
- Zeybekoğlu, U. (2018). Bulanık C ortalamalar yöntemi ile Karadeniz bölgesi standart süreli yağış şiddetlerinin kümelenmesi. *Gümüşhane Üniversitesi Fen Bilimleri Dergisi*, 8(1), 147–154. <https://doi.org/10.17714/gumusfenbil.334693>
- Zontul, M. (2004). *SOM tipinde yapay sinir ağlarını kullanarak Türkiye ile ticareti olan ülkelerin kümelenmesi üzerine bir çalışma* [Doktora tezi] Cumhuriyet Üniversitesi.
- Zou, Q., Qu, K. Y., Luo, Y. M., Yin, D. H., Ju, Y., ve Tang, H. (2018). Predicting diabetes mellitus with machine learning techniques. *Frontiers in Genetics*, 9, 515. <https://doi.org/10.3389/fgene.2018.00515>



ÖZGEÇMİŞ

Ad-Soyad : Uğur Erkin KOCAMAZ

ÖĞRENİM DURUMU:

- **Lisans** : 2001, 9 Eylül Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği
- **Yüksek Lisans** : 2004, Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar ve Bilişim Mühendisliği
- **Doktora** : 2018, Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği, Elektronik (bilim dalı)

MESLEKİ DENEYİM:

- 2003 yılı Aralık ayında Sakarya Üniversitesi'nde Fen Bilimleri Enstitüsü kadrosu ile Araştırma Görevlisi olarak mesleki kariyerine başladı.
- 2012 yılı Aralık ayında Öğretim Görevlisi olarak Uludağ Üniversitesi, Karacabey Meslek Yüksekokulu'na geçti.
- Ağustos 2022'den bu yana Doktor Öğretim Üyesi ünvanıyla Bursa Uludağ Üniversitesi Karacabey Meslek Yüksekokulu'ndaki görevini sürdürmektedir.