



T.C.
SELÇUK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

SINIFLANDIRMA PROBLEMLERİNDE YAPAY SİNİR AĞI METOTLARI KULLANILARAK PERFORMANSLARININ DEĞERLENDİRİLMESİ

ALİ YAŞAR

YÜKSEK LİSANS TEZİ

BİLGİSAYAR MÜHENDİSLİĞİ

2021
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Ali YAŞAR tarafından hazırlanan "Sınıflandırma Problemlerinde Yapay Sinir Ağı Metotları Kullanılarak Performanslarının Değerlendirilmesi" adlı tez çalışması 23/02/2021 tarihinde aşağıdaki jüri tarafından oy birliği ile Selçuk Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı'nda YÜKSEK LİSANS tezi olarak kabul edilmiştir.

Jüri Üyeleri	**İmza**
Başkan Dr. Öğr. Üyesi Onur İNAN	……..
Danışman Prof. Dr. İsmail SARITAŞ	……..
Üye Dr. Öğr. Üyesi İlker Ali ÖZKAN	……..

Yukarıdaki sonucu onaylarım.

Prof. Dr. Sait GEZGİN
FBE Müdürü

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

Ali YAŞAR

Tarih:

ÖZET

YÜKSEK LİSANS

SINIFLANDIRMA PROBLEMLERİNDE YAPAY SİNİR AĞI METOTLARI KULLANILARAK PERFORMANSLARININ DEĞERLENDİRİLMESİ

Ali YAŞAR

Selçuk Üniversitesi Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. İsmail SARITAŞ

Yıl, 58 Sayfa

Jüri
Prof. Dr. İsmail SARITAŞ
Dr. Öğr. Üyesi Onur İNAN
Dr. Öğr. Üyesi İlker Ali ÖZKAN

Yapay zekâ insanlara has özelliklerden olan akıl yürütme, mevcut bilgilerden çıkarım yapma, bilgileri kullanarak genelleme yapabilmesi ve geçmiş tecrübelerimizden yararlanarak yaşantımızda kalıcı etki bırakması (öğrenme) gibi zihinsel süreçlerimize ait yeteneklerin bir bilgisayar ya da makineye sezgisel ve meta-sezgisel yöntemlerle geliştirilen programlar yardımıyla kazandırılmasını sağlayan geniş ve kapsamlı bir çalışma alanıdır. Yapay sinir ağı karşımıza en çok çıkan Yapay Zekâ yöntemlerinden bir tanesidir. Sınıflandırma ve Tahmin problemlerinde sıkça kullanılan Yapay Sinir Ağlarının eğitilmesinde kullanılan ve geliştirilen sezgisel ve meta-sezgisel çok sayıda algoritma bulunmaktadır. Gün geçtikçe de bu algoritmaların sayısı artmaya devam etmektedir.

Bu tez çalışmasında YSA'ların eğitiminde kullanılan metotlardan İleri Beslemeli Sinir Ağı, Kademeli İleri Sinir Ağı, Genelleştirilmiş Regresyon Sinir Ağı, Olasılıksak Sinir Ağı ve Tekrarlayan Sinir Ağı kullanılarak YSA ağları eğitilmiş sonuçlar tek ara katmanlı sinir ağı ve çok ara katmanlı 10 kat çapraz doğrulamalı sinir ağları ile YSA'ların performans değerleri belirlenmiştir.

Tez çalışmamızın performanslarını kontrol etmek adına UCI Machine Learning Repository'de yer alan Ionosphere, Iris ve Wine olmak üzere 3 veri kümesi deneysel sonuçlarda kullanılmıştır. Deney sonuçlarında Karışıklık matrisleri bulunmuş ve bu karışıklık matrisinden yaralanarak sınıflandırma doğrulukları, hassasiyetleri, duyarlılık ve F1-Skorları dinamik olarak yapılan kodlama ile parametreler istenildiği zaman güncellenebilmektedir. Belirlenen parametreler ile hem tek ara katman için hem çok ara katmanlı 10 kat çapraz doğrulama teknikleri kullanılarak hedeflenen değerler hesaplanmıştır.

Ionosphere veri kümesi üzerinde Tek Ara Katmanlı metotlardan %88,57 ile en yüksek doğruluk derecesi İleri Beslemeli Sinir Ağı metodu ile sağlanırken, Çok Ara Katmanlı ve 10 Kat Çapraz Doğrulama kullanan metotlardan %96,58 ile en yüksek doğruluk derecesine Kademeli İleri Sinir Ağı metodu ulaşmıştır.

Iris veri kümesi üzerinde Tek Ara Katmanlı metotlardan %98,67 ile en yüksek doğruluk derecesi Tekrarlayan Sinir Ağı metodu ile sağlanırken, Çok Ara Katmanlı ve 10 Kat Çapraz Doğrulama kullanan metotlardan %100 ile en yüksek doğruluk derecesine yine Tekrarlayan Sinir Ağı metodu ulaşmıştır.

Şarap veri kümesi üzerinde Tek Ara Katmanlı metotlardan %96,63 ile en yüksek doğruluk derecesine İleri Beslemeli Sinir Ağı ve Kademeli İleri Sinir Ağı metotları ile sağlanırken, Çok Ara Katmanlı ve 10 Kat Çapraz Doğrulama kullanan metotlardan %100 ile en yüksek doğruluk derecesine Tekrarlayan Sinir Ağı metodu ulaşmıştır.

Anahtar Kelimeler: Çapraz Doğrulama, Duyarlılık, F1-Skor, Hassasiyet, Makine Öğrenmesi, Sınıflandırma, Yapay Sinir Ağı

ABSTRACT

MS THESIS

EVALUATION OF PERFORMANCE USING ARTIFICIAL NEURAL NETWORK METHODS IN CLASSIFICATION PROBLEMS

Ali YAŞAR

THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCE OF SELCUK UNIVERSITY
THE DEGREE OF MASTER OF SCIENCE
IN COMPUTER ENGINEERING

Advisor: Prof. Dr. İsmail SARITAŞ

2021, 58 Pages

Jury
Prof. Dr. İsmail SARITAŞ
Asst. Prof. Dr. Onur İNAN
Asst. Prof. Dr. İlker Ali ÖZKAN

Artificial intelligence is a wide and comprehensive field of study which is about the acquisition of the abilities of our mental processes such as reasoning, making inferences from existing information, making generalizations using information, and making a permanent effect in our lives (learning) by making use of our past experiences to a computer or machine with the help of programs developed with intuitive and meta-intuitive methods. Artificial neural network is one of the most common Artificial Intelligence methods. There are many heuristic and meta-heuristic algorithms that are used and developed in training Artificial Neural Networks, which are frequently used in Classification and Prediction problems. The number of these algorithms continues to increase day by day.

In this thesis study, ANN networks were trained using the methods used in the training of ANNs: Feed Forward Neural Network, Graded Advanced Neural Network, Generalized Regression Neural Network, Probability Neural Network and Recurrent Neural Network. Performance values of ANNs were determined with the results of single interlayer neural network and multi-interlayer 10-fold cross verification neural networks.

In order to evaluate the performances of our thesis, 3 data sets, Ionosphere, Iris and Wine, which are in the UCI Machine Learning Repository, were used in the experimental results. Confusion matrices were found in the experimental results and by using this confusion matrix, the classification accuracies, sensitivity, specificity and F1-Scores can be updated at any time by dynamically coding. Target values were calculated by using the determined parameters for both single interlayer and multi-interlayer 10-fold cross validation techniques.

On the Ionosphere dataset, the highest accuracy value with 88.57% of the Single Interlayer methods was provided by the Feed Forward Neural Network method, while the Stepped Advanced Neural Network method reached the highest accuracy with 96.58% among the methods using Multi-Interlayer and 10-Fold Cross Validation.

On the Iris dataset, the highest accuracy value of 98.67% and 100% was achieved with both Single Interlayer and Multi-Interlayer and 10-fold Cross Verification methods by using Recurrent Neural Network method.

On the wine data set, the highest accuracy value with 96.63% from Single Interlayer methods is provided by the Feed Forward Neural Network and Progressive Neural Network methods, while the Recurrent Neural Network method reached the highest accuracy with 100% among the methods using Multi-Interlayer and 10-Fold Cross Validation.

Keywords: Artificial Neural Network, Classification, Cross Validation, F1-Score, Machine Learning, Precision, Recall.

ÖNSÖZ

Bu çalışmanın yürütülmesinde verdikleri destek, gösterdikleri anlayış ve ilgiden dolayı danışman hocam Prof. Dr. İsmail SARITAŞ'a; Özellikle manevi desteğini hiçbir zaman esirgemeyen her zaman ve her konuda hep yanımda olan aileme desteklerinden dolayı teşekkür ederim.

Ali YAŞAR
KONYA-2021

İÇİNDEKİLER

ÖZET ..... **iv**

ABSTRACT ..... **v**

ÖNSÖZ ..... **vi**

İÇİNDEKİLER ..... **vii**

SİMGELER VE KISALTMALAR ..... **ix**

ŞEKİLLER LİSTESİ ..... **x**

ÇİZELGELER LİSTESİ ..... **xi**

1. GİRİŞ **1**

1.1. Çalışmanın Amacı ve Yöntemi 2
1.2. Kaynak Araştırması 2
1.3. Tezin Organizasyonu 5

2. YAPAY SİNİR AĞLARI **7**

2.1. Biyolojik Sinir Sistemi 7
2.2. Yapay Sinir Ağları, Yapısı, Kullanım Alanları ve Özellikleri 9
2.3. Yapay Sinir Ağlarının Yapıları 11
2.3.1. İleri Beslemeli Sinir Ağı 11
2.3.2. Geri Beslemeli Sinir Ağı 12
2.4. Yapay Sinir Ağlarında Öğrenme 13

3. MATERYAL VE METOD **15**

3.1. Sınıflandırma 15
3.2. İleri Beslemeli Sinir Ağları 16
3.3. Kademeli İleri Sinir Ağları 18
3.4. Genelleştirilmiş Regresyon Sinir Ağları 20
3.5. Olasılıksak Sinir Ağları 23
3.6. Tekrarlayan Sinir Ağları 24
3.7. Çapraz Doğrulama 26
3.8. Levenberg-Marquardt Algoritması 27
3.9. Tahmin Testleri 28

4. DENEYSEL SONUÇLAR VE ANALİZ **30**

4.1. İki Sınıflı Veri Setleri Üzerindeki Uygulamalar 30
4.1.1. Ionosphere Veri Kümesi 30
4.2. Çok Sınıflı Veri Setleri Üzerindeki Uygulamalar 37
4.2.1. Iris Veri Kümesi 37
4.2.2. Şarap Veri Kümesi 44

5. SONUÇLAR VE ÖNERİLER 52

5.1 Sonuçlar 52
5.2 Tartışma 52
5.3 Öneriler 53

KAYNAKLAR 54

SİMGELER VE KISALTMALAR

Kısaltmalar

YZ	: Yapay Zekâ
M.Ö	: Makine Öğrenmesi
AI	: Artificial Intelligent
YSA	: Yapay Sinir Ağlarıdır
FNN	: FeedForward Neural Network
CNN	: Convulational neural network
SOM	: Kohonen Self Organizing Network
RNN	: Recurrent neural network
RBFN	: Radial basis function network
CFNN	: Cascade Forward Neural Network
GRNN	: Generalized Regression Neural Network
PNN	: Probabilistic Neural Network
LM	: Levenberg-Marquadt
GRNN	: Genelleştirilmiş Regresyon Sinir Ağı
DOCR	: Yönlü aşırı akım rölesi
VQ	: Vektör Niceleme
İBSA	: İleri Beslemeli Sinir Ağları
KİSA	: Kademeli İleri Sinir Ağı
GRSA	: Genelleştirilmiş Regresyon Sinir Ağı
OSA	: Olasılıksak Sinir Ağı
TSA	: Tekrarlayan Sinir Ağı
k-cv	: K- Cross- Validation
sn	: Saniye

ŞEKİLLER LİSTESİ

Şekil 2.1. Biyolojik Sinir Hücresinin Yapısı 7
Şekil 2.2. Temel Sinir Ağı Yapısı 8
Şekil 2.3 Tek Katmanlı İleri Beslemeli Sinir Ağ Yapısı 12
Şekil 2.4. Çok Katmanlı İleri Beslemeli Sinir Ağı 12
Şekil 2.5. Geri Beslemeli Sinir Ağı 13

Şekil 3.1 Tek Ara Katmanlı İleri Beslemeli Yapay Sinir Ağı Yapısı 17
Şekil 3.2 Tek Ara Katmanlı İleri Beslemeli Sinir Ağ Topolojisi 17
Şekil 3.3 Çok Ara Katmanlı İleri Beslemeli Sinir Ağı Topolojisi 18
Şekil 3.4 Tek Ara Katmanlı KİSA Yapısı 19
Şekil 3.5 Tek Ara Katmanlı KİSA Topolojisi 20
Şekil 3.6 Çok Ara Katmanlı KİSA Topolojisi 20
Şekil 3.7 GRSA Yapısı 22
Şekil 3.8 GRSA NNtool Ağ Yapısı 22
Şekil 3.9 OSA Mimari Yapısı 23
Şekil 3.10 TSA Ağa açılma Diyagramı 25
Şekil 3.11 Tipik bir TSA Mimari Yapısı 25
Şekil 3.12 NNtool TSA Mimarisi 25
Şekil 3.13 K-Kat Çapraz Doğrulama İşlemi 27

Şekil 4.1 Tek Ara Katmanlı İBSA Yapısı 31
Şekil 4.2 Çok Ara Katmanlı İBSA Yapısı 31
Şekil 4.3 Tek Ara Katmanlı KİSA Yapısı 32
Şekil 4.4 Çok Ara Katmanlı KİSA Yapısı 33
Şekil 4.5 Tek Ara Katmanlı TSA Yapısı 36
Şekil 4.6 Çok Ara Katmanlı TSA Yapısı 36
Şekil 4.7 Tek Ara Katmanlı İBSA Yapısı 38
Şekil 4.8 Çok Ara Katmanlı İBSA Yapısı 38
Şekil 4.9 Tek Ara Katmanlı KİSA Yapısı 39
Şekil 4.10 Çok Ara Katmanlı KİSA Yapısı 40
Şekil 4.11 Tek Ara Katmanlı TSA Yapısı 43
Şekil 4.12 Çok Ara Katmanlı TSA Yapısı 43
Şekil 4.13 Tek Ara Katmanlı İBSA Yapısı 45
Şekil 4.14 Çok Ara Katmanlı İBSA Yapısı 46
Şekil 4.15 Tek Ara Katmanlı KİSA Yapısı 47
Şekil 4.16 Çok Ara Katmanlı KİSA Yapısı 47
Şekil 4.17 Tek Ara Katmanlı TSA Yapısı 50
Şekil 4.18 Çok Ara Katmanlı TSA Yapısı 51

ÇİZELGELER LİSTESİ

Çizelge 2.1 Biyolojik Sinir Sistemine ait Elemanlar ve Yapay Sinir Ağındaki Karşılığı 7
Çizelge 2.2 Geleneksel Algoritmalar ile YSA'ların karşılaştırılması 11

Çizelge 3.1 Belirleme Katsayıları 28
Çizelge 3.2 Karışıklık matrisi ve çoklu sınıfların gösterimi. 29

Çizelge 4.1. Tek Ara Katmanlı İBSA Karışıklık Matrisi, Sınıflar, Gerçek Sınıf Sayıları, Tahmin Edilen Sınıf Sayıları, Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, Değerleri 31
Çizelge 4.2 Çok Ara Katmanlı ve 10 Kat Çapraz Doğrulamalı İBSA Karışıklık Matrisi, Sınıflar, Gerçek Sınıf Sayıları, Tahmin Edilen Sınıf Sayıları, Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, Değerleri 32
Çizelge 4.3. Tek Ara Katmanlı KİSA Karışıklık Matrisi, Sınıflar, Gerçek Sınıf Sayıları, Tahmin Edilen Sınıf Sayıları, Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, Değerleri 33
Çizelge 4.4 Çok Ara Katmanlı ve 10 Kat Çapraz Doğrulamalı KİSA Karışıklık Matrisi, Sınıflar, Gerçek Sınıf Sayıları, Tahmin Edilen Sınıf Sayıları, Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, Değerleri 33
Çizelge 4.5 Tek Ara Katmanlı GRSA Karışıklık Matrisi, Sınıflar, Gerçek Sınıf Sayıları, Tahmin Edilen Sınıf Sayıları, Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, Değerleri 34
Çizelge 4.6 Çok Ara Katmanlı ve 10 Kat Çapraz Doğrulamalı GRSA Karışıklık Matrisi, Sınıflar, Gerçek Sınıf Sayıları, Tahmin Edilen Sınıf Sayıları, Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, Değerleri 34
Çizelge 4.7 Tek Ara Katmanlı OSA Karışıklık Matrisi, Sınıflar, Gerçek Sınıf Sayıları, Tahmin Edilen Sınıf Sayıları, Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, Değerleri 35
Çizelge 4.8 Çok Ara Katmanlı ve 10 Kat Çapraz Doğrulamalı OSA Karışıklık Matrisi, Sınıflar, Gerçek Sınıf Sayıları, Tahmin Edilen Sınıf Sayıları, Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, Değerleri 35
Çizelge 4.9 Tek Ara Katmanlı TSA Karışıklık Matrisi, Sınıflar, Gerçek Sınıf Sayıları, Tahmin Edilen Sınıf Sayıları, Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, Değerleri 36
Çizelge 4.10 Çok Ara Katmanlı ve 10 Kat Çapraz Doğrulamalı TSA Karışıklık Matrisi, Sınıflar, Gerçek Sınıf Sayıları, Tahmin Edilen Sınıf Sayıları, Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, Değerleri 37
Çizelge 4.11 Tek Ara Katmanlı İBSA Karışıklık Matrisi, Sınıflar, Gerçek Sınıf Sayıları, Tahmin Edilen Sınıf Sayıları, Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, Değerleri 39
Çizelge 4.12 Çok Ara Katmanlı ve 10 Kat Çapraz Doğrulamalı İBSA Karışıklık Matrisi, Sınıflar, Gerçek Sınıf Sayıları, Tahmin Edilen Sınıf Sayıları, Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, Değerleri 39
Çizelge 4.13 Tek Ara Katmanlı KİSA Karışıklık Matrisi, Sınıflar, Gerçek Sınıf Sayıları, Tahmin Edilen Sınıf Sayıları, Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, Değerleri 40
Çizelge 4.14 Çok Ara Katmanlı ve 10 Kat Çapraz Doğrulamalı KİSA Karışıklık Matrisi, Sınıflar, Gerçek Sınıf Sayıları, Tahmin Edilen Sınıf Sayıları, Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, Değerleri 41

Çizelge 4.15. Tek Ara Katmanlı GRSA Karışıklık Matrisi, Sınıflar, Gerçek Sınıf Sayıları, Tahmin Edilen Sınıf Sayıları, Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, Değerleri 41
Çizelge 4.16 Çok Ara Katmanlı ve 10 Kat Çapraz Doğrulamalı GRSA Karışıklık Matrisi, Sınıflar, Gerçek Sınıf Sayıları, Tahmin Edilen Sınıf Sayıları, Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, Değerleri 42
Çizelge 4.17 Tek Ara Katmanlı OSA Karışıklık Matrisi, Sınıflar, Gerçek Sınıf Sayıları, Tahmin Edilen Sınıf Sayıları, Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, Değerleri 42
Çizelge 4.18 Çok Ara Katmanlı ve 10 Kat Çapraz Doğrulamalı OSA Karışıklık Matrisi, Sınıflar, Gerçek Sınıf Sayıları, Tahmin Edilen Sınıf Sayıları, Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, Değerleri 43
Çizelge 4.19 Tek Ara Katmanlı TSA Karışıklık Matrisi, Sınıflar, Gerçek Sınıf Sayıları, Tahmin Edilen Sınıf Sayıları, Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, Değerleri 44
Çizelge 4.20 Çok Ara Katmanlı ve 10 Kat Çapraz Doğrulamalı TSA Karışıklık Matrisi, Sınıflar, Gerçek Sınıf Sayıları, Tahmin Edilen Sınıf Sayıları, Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, Değerleri 44
Çizelge 4.21 Tek Ara Katmanlı İBSA Karışıklık Matrisi, Sınıflar, Gerçek Sınıf Sayıları, Tahmin Edilen Sınıf Sayıları, Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, Değerleri 46
Çizelge 4.22 Çok Ara Katmanlı ve 10 Kat Çapraz Doğrulamalı İBSA Karışıklık Matrisi, Sınıflar, Gerçek Sınıf Sayıları, Tahmin Edilen Sınıf Sayıları, Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, Değerleri 47
Çizelge 4.23 Tek Ara Katmanlı KİSA Karışıklık Matrisi, Sınıflar, Gerçek Sınıf Sayıları, Tahmin Edilen Sınıf Sayıları, Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, Değerleri 48
Çizelge 4.24 Çok Ara Katmanlı ve 10 Kat Çapraz Doğrulamalı KİSA Karışıklık Matrisi, Sınıflar, Gerçek Sınıf Sayıları, Tahmin Edilen Sınıf Sayıları, Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, Değerleri 48
Çizelge 4.25 Tek Ara Katmanlı GRSA Karışıklık Matrisi, Sınıflar, Gerçek Sınıf Sayıları, Tahmin Edilen Sınıf Sayıları, Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, Değerleri 49
Çizelge 4.26 Çok Ara Katmanlı ve 10 Kat Çapraz Doğrulamalı GRSA Karışıklık Matrisi, Sınıflar, Gerçek Sınıf Sayıları, Tahmin Edilen Sınıf Sayıları, Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, Değerleri 49
Çizelge 4.27 Tek Ara Katmanlı OSA Karışıklık Matrisi, Sınıflar, Gerçek Sınıf Sayıları, Tahmin Edilen Sınıf Sayıları, Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, Değerleri 50
Çizelge 4.28 Çok Ara Katmanlı ve 10 Kat Çapraz Doğrulamalı OSA Karışıklık Matrisi, Sınıflar, Gerçek Sınıf Sayıları, Tahmin Edilen Sınıf Sayıları, Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, Değerleri 50
Çizelge 4.29 Tek Ara Katmanlı TSA Karışıklık Matrisi, Sınıflar, Gerçek Sınıf Sayıları, Tahmin Edilen Sınıf Sayıları, Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, Değerleri 51
Çizelge 4.30 Çok Ara Katmanlı ve 10 Kat Çapraz Doğrulamalı TSA Karışıklık Matrisi, Sınıflar, Gerçek Sınıf Sayıları, Tahmin Edilen Sınıf Sayıları, Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, Değerleri 51

1. GİRİŞ

Yapay zekâ (YZ) insanlara özgü akıl yürütme, çıkarım yapma, bilgi genellemesi ve geçmiş tecrübelerimizin yaşamımızda kalıcı etki bırakması (öğrenme) gibi zihinsel süreçlerimize ait yeteneklerin bir bilgisayar ya da makineye sezgisel ve meta-sezgisel yöntemlerle geliştirilen programlar yardımıyla kazandırılmasını sağlayan geniş ve kapsamlı bir çalışma alanıdır. Öğrenme, çok yönlü ve kapsamlı bir olgudur. Öğrenme süreçleri, yeni beyan edilen bilginin kazanılmasını, yeni bilginin genel olarak organize edilmesini, eğitim veya uygulama yoluyla motor ve bilişsel becerilerin kazandırılmasını, gözlem ve deney yoluyla yeni gerçeklerin ve teorilerin keşfini içerir.

Günlük hayatımızın vazgeçilmezi haline gelen bilgisayarın, artık insanların yaptığı gibi karar verme ve öğrenme işlemlerini gerçekleştirme yeteneklerini kazanması ile kullanım alanları bir hayli artmıştır. Problemlerin Matematiksel olarak ifade edilemediği ve insanların çözüm üretmekte bir hayli zorlandığı problemlerin çözümünde yapay zekâ yöntemleri kullanılabilmektedir. YZ yöntemlerinin en temel özelliği, olaylara ve problemlere çözümler üretirken örneklerden, benzetimden, tecrübeden öğrenme işlemi gerçekleştirebilme ve karar verebilme kabiliyetlerinin olmasıdır (Arı ve Berberler, 2017).

Bilgisayar çağının başlangıcından günümüze kadar araştırmacılar bu tür yetenekleri bilgisayarlara ve makinelere yerleştirmeye çalışıyorlar. Bu sorunu çözmek, YZ (*Artificial Intelligent AI*) için en zorlu ve büyüleyici uzun vadeli bir hedef olmuştur ve olmaya devam etmektedir. Öğrenme süreçlerinin çoklu tezahürlerinde incelenmesi ve bilgisayar modellemesi, makine öğreniminin (MÖ) konusunu oluşturur (Mitchell ve ark., 2013). Yapay zekâ ve Makine öğrenmesi çalışmaları incelendiğinde literatürdeki en yaygın çalışma konularından birisi Yapay Sinir Ağlarıdır (YSA) (Turkoglu ve Kaya, 2020).

YSA insan beyninin çalışma şeklini basit bir şekilde taklit eden Yapay Zekâ Teknolojileri içinde önemli bir kullanım alanına sahiptir. YSA çalışma yöntemlerine bakıldığında veri setinden öğrenebilme, çıkarım ve genelleme yapabilme, eksik veri ve çok sayıda değişkenle çalışabilme gibi oldukça önemli özelliklere sahiptir. Bu önemli özellikler sayesinde avantaj sağlayan YSA diğer alanlarda olduğu gibi öngörü modellemesi alanında da yaygın bir şekilde kullanılmaktadır (Ataseven, 2013).

Son zamanlarda YSA, birçok disiplinde sınıflandırma, kümeleme, örüntü tanıma ve tahmin için popüler ve yararlı bir model haline geldi. Bu nedenle mühendislik

problemleri, tıp, jeoloji, kimya, biyoloji ve fizik gibi farklı alanlarda başarıyla uygulanmaktadır. YSA'lar, MÖ için bir model türüdür ve kullanışlılıkla ilgili geleneksel regresyon ve istatistiksel modellere göre nispeten rekabetçi hale gelmiştir (Dave ve Dutta, 2014; Abiodun ve ark., 2018) . Şu anda, yapay zekâ (makine öğrenimi, sinir ağı, derin öğrenme, robotik), bilgi güvenliği, büyük veri, bulut bilişim, internet ve adli bilim, bilgi ve iletişim teknolojisinin ilgi çekici noktaları ve heyecan verici konularıdır. YSA uygulamaları, doğruluk, işlem hızı, gecikme, performans, hata toleransı, hacim, ölçeklenebilirlik ve yakınsama gibi veri analizi faktörlerine göre değerlendirilebilir (He ve Garcia, 2009; Mozaffari ve ark., 2019).

Literatürde birçok YSA modeli önerilmiştir. İleri Beslemeli Sinir Ağları (*FeedForward Neural Network, FNN*), Evrişimsel Sinir Ağları (*Convulational Neural Network, CNN*), Kohonen Ağları (*Kohonen Self Organizing Network, SOM*), Tekrarlayan Sinir Ağları (*Recurrent Neural Network, RNN*), Radyan Temelli Fonksiyon Ağları (*Radial Basis Function Network, RBFN*) vb. popüler sinir ağı modelleridir (Kohonen, 1990; Türkoğlu, 2018).

1.1.Çalışmanın Amacı ve Yöntemi

Bu tez çalışmasının temel amacı YSA'nın eğitilmesinde geliştirilen modellerden İleri Beslemeli Sinir Ağları (*Feedforward Neural Network, FNN*), Kademeli İleri Sinir Ağı (*Cascade Forward Neural Network, CFNN*), Genelleştirilmiş Regresyon Sinir Ağı (*Generalized Regression Neural Network, GRNN*), Olasılıksak Sinir Ağı (*Probabilistic Neural Network, PNN*) ve Tekrarlayan Sinir Ağları (*Recurrent neural network, RNN*) kullanılarak veri setlerinin öğrenme ve Çapraz Doğrulama (*Cross-Validation*) sonuçları karşılaştırılmıştır. Algoritmaların performansı UCI makine öğrenme deposundan (https://archive.ics.uci.edu/ml/index.php) alınan 3 veri kümesi ile değerlendirilmiştir.

1.2.Kaynak Araştırması

YSA'nın eğitilmesi bilgisayar ve makine öğrenmesindeki en zor problemlerden birisidir (Aljarah ve ark., 2018). YSA'lar örnek olaylardan öğrenebilme ve dış etmenlerden gelen olaylara karşı tepki verebilme yetenekleriyle esnek ve güçlü yapılarından dolayı makina öğrenme, sınıflandırma, tahmin yapma, kümeleme, genelleme ve optimizasyon alanlarında kullanılmak için tercih edilmesinde etken

olmuşlardır. Bunların neticesinde, çok çeşitli YSA mimarileri geliştirilmiş ve bu mimariler çeşitli alanlarda kullanılmışlardır.

İleri beslemeli Sinir Ağları (FNN), nöronların katmanlar halinde gruplandırıldığı ve yalnızca ileriye doğru bağlantıların bulunduğu en popüler YSA mimarilerinden biridir. Bu şekilde ağ yapısı arasında güçlü bir bağlantı modeli sağlar. Sınıflandırma Problemleri, Zaman Serilerinin Tahmin edilmesi, Tıbbi Teşhis veya El Yazısı Tanıma gibi doğrusal olmayan problemlerin çözümünde başarılı uygulamalarla karşımıza çıkmaktadır (Mendes ve ark., 2002).

Asteris ve ark. 2017 yaptıkları çalışmada kum beton malzemelerinin kritik mekanik özelliklerini tahmin etmek için yumuşak sensör yaklaşımı sunarak İleri beslemeli sinir ağı (FNN) modeli ile 28 günlük basınç dayanımını ve kum beton malzemelerin esneklik modülünü tahmin edebilen yumuşak sensörler oluşturmak için kullanmışlardır. Elde edilen sonuçların mevcut deneysel verilerle karşılaştırılması, FNN'lerin kum beton malzemelerinin mekanik özelliklerini kesin doğrulukla tahmin etme kapasitesi gösterdiğini ifade etmişlerdir (Asteris ve ark., 2017).

YSA algoritmaları ileri beslemeli sinir ağları eğitimde kullanılan ağırlıkları optimize etmek için yerel veya global doğrusal olmayan optimizasyon yöntemlerini kullanır. Yerel aramalar yerel çözümlerle sınırlıdır, oysa küresel aramalar bu sınırlamadan kaçınır (Ilonen ve ark., 2003).

YSA'nın eğitim performansı, optimizasyon sürecinin amaç işlevine ve belirli bir problemin altında yatan hata yüzeyine ve ağ yapısına bağlı olarak değişir. En popüler optimizasyon yöntemleri, gradyan tabanlı geri yayılım algoritmalarının varyantlarıdır. Bunun nedeni, hata yüzeyinin gradyan bilgisinin bu algoritmalarda mevcut olmasıdır. Yaygın olarak kullanılan yöntemler şunlardır: *Levenberg-Marquadt (LM), BFGS Quasi Newton, Resilient BackPropagation, Scaled conjugate gradient, Conjugate gradient with Powell-Beale restarts, Fletcher-Powell conjugate gradient, Polak-Ribiere conjugate gradient, One step secant*'tır. Bir YSA'da eğitim sürecinin amacı global hatayı (E) azaltmaktır (Perera ve ark., 2020).

Çiğizoğlu ve ark yapmış olukları çalışmada başka bir YSA algoritması olan Genelleştirilmiş Regresyon Sinir Ağı (GRNN), kullanarak nehirde askıya alınmış tortu tahmini yapmıştır. Genelleştirilmiş Regresyon Sinir Ağı, geri yayılma yönteminde olduğu gibi yinelemeli bir eğitim prosedürü gerektirmez. GRNN simülasyonları, *FeedForward Back Propagation* uygulamalarında sıklıkla karşılaşılan yerel minimum

problemle karşılaşmaz ve GRNN, fiziksel olarak makul olmayan tahminler üretmez (Cigizoglu ve Alp, 2006).

Li ve ark. 2013 yılında yaptıkları çalışmada yıllık güç miktarı tahmini doğrusal olmayan bir sorun olduğunu çünkü yük eğrisinin doğrusal olmayan bir özellik gösterdiğini ifade etmişlerdir. Bunun için Genelleştirilmiş regresyon sinir ağının (GRNN) doğrusal olmayan problemlerle başa çıkmada etkili olduğu kanıtlanmış olduğunu ifade edip çalışmalarında yıllık güç yükü tahmini için GRNN'yi kullanılmıştır (Li ve ark., 2013).

Sahrin ve ark. 2017. Yılında yaptıkları çalışmada Döngü elektrik ağı sisteminde ortaya çıkan sorunlar, güç kaynağı çalışması, düzenli bakım ve güç kaynağında hasar gibi sistemdeki değişiklikleri takip eden bir röle ayarıdır. Ağ sistemindeki değişiklikleri takip edebilen uyarlanabilir bir röle elde etmek için, üç güç kaynağı, on beş koruma rölesi, altı veri yolu ve üç yükü simüle ederek güç sistemi ağının kademeli ileri sinir ağı (CFNN) ile koordinasyonunun modellenmesini önermişlerdir. Yönlü aşırı akım rölesi (DOCR) eğri modelinde uygulanan CFNN, döngü elektrik şebekesi sistemindeki koruma koordinasyonundan örnek verileri kullanarak Dört kombinasyonlu giriş ve iki çıkış ile en iyi doğruluğu ve zaman hızını elde etmek için birkaç nöronu ve öğrenme oranını karşılaştırarak modelleme sürecinde CFNN yöntemini kullanan modelleme rölesinin sonuçları, %95 akım katkısı ile ortalama 3,24'e-06 kare hatası ve % 105 akım katkısı ile 2,10e-03 ortalama kare hatası bulmuşlardır. Yapılan modelleme sonuçlarının çok doğru ve dijital aşırı akım rölesine uygulanabilir olduğunu ifade etmişlerdir. (Sahrin ve ark., 2017).

Mohonty ve ark 2020 yılında yaptıkları çalışmada Duygu tanıma için etkili özelliklerin kullanılması, daha iyi doğruluğa ulaşmak için atılan doğru bir adımdır. İfadelerden çıkarılan *segmental* özellikler hem fazlalık hem de yüksek bir boyuta sahiptir. Sinir ağı tabanlı model için düşük boyutlu özellik seti esastır ve eşit derecede önemlidir. Ancak veri indirgeme tekniği uygun şekilde seçilmelidir. Çalışmada, etkili özellik kullanımı için Vektör Niceleme (VQ) ve öz değer ayrışımının kombinasyonunu kullanan bir özellik azaltma mekanizması önermektedir. Alt sıradaki Eigen bileşenleri, Temel Bileşenler ile karşılaştırıldığında daha bilgilendiricidir ve bu çalışmada çocukların konuşma duygularını analiz etmek için ele alınmıştır. Sınıflandırma için Olasılıklı Sinir Ağı (PNN) modeli, istatistiksel özelliklerle doğruluk seviyesi nedeniyle dikkate alındığını ifade etmişlerdir (Mohanty ve Palo, 2020).

Hibat ve ark. 2020 de yaptığı çalışmada Yapay zekâ devriminden ortaya çıkan temel bir teknoloji, tekrarlayan sinir ağıdır (RNN) olduğunu ifade etmişlerdir. Eşsiz sıra tabanlı mimarisi, doğal dil işleme ve sinir makinesi çevirisinde birçok muhteşem ilerlemeyi hızlandıran bir kombinasyon olan kararlı eğitim paradigmalarıyla izlenebilir bir olasılık tahmini sağlar. Bu mimari aynı zamanda, bir kuantum Hamiltoniyeninin yaklaşık temel durumunu öğrenmek için RNN parametrelerinin ayarlandığı bir varyasyonel dalga fonksiyonu için iyi bir adaydır. Çalışmalarında, RNN'lerin birkaç çok cisimli dalga fonksiyonunu temsil etme yeteneğini göstererek, varyasyonel parametreleri stokastik bir yaklaşım kullanarak optimize ettiklerini ifade etmişlerdir. (Hibat-Allah ve ark., 2020)

Zhang ve ark. 2017 yılında yaptıkları çalışma ile tekrarlanan sinir ağını (RNN) hem Çince karakterleri tanımak için ayırt edici bir model hem de Çince karakterleri çizmek (üretmek) için üretken bir model olarak kullanarak bir çerçeve önermişlerdir. Çince karakterleri tanımak için, yapılan çalışmalarda yöntemler genellikle çevrimiçi el yazısı yörüngesinin görüntü benzeri temsillere dönüştürülmesini gerektiren evrişimli sinir ağı (CNN) modellerini kullanıldığını ifade etmişlerdir. Yaptıkları çalışma ile bunun yerine, RNN tabanlı, doğrudan sıralı yapı ile ilgilenen ve herhangi bir alana özgü bilgi gerektirmeyen uçtan uca bir sistemi sunmuşlardır (Zhang ve ark., 2017).

1.3.Tezin Organizasyonu

Bu tez çalışmasında YSA'nın eğitilmesinde kullanılan modeller kullanılarak sınıflandırma problemleri çözümlenmiş ve karşılaştırılması yapılmıştır. Çalışma toplam beş bölüm oluşmaktadır.

Birinci bölüm giriş bölümü olup konunun genel tanımı yapılmış, çalışmanın amacı ve önemi üzerinde durulmuştur. Konu ile ilgili önceden yapılmış olan benzer çalışmalar hakkında araştırmalar yapılmış, bilgiler verilmiş ve kısa bir analiz yapılmıştır.

İkinci bölümde; çalışmanın çıkış noktası olan yapay sinir ağlarının ortaya çıkışı, bu ağların yapıları ve modelleri ile eğitilmesi, eğitimde kullanılan metotlar üzerinde durulmuştur.

Üçüncü bölümde; sınıflandırma işlemleri ve sınıflandırma işlemlerinde kullanılan ve tez çalışmasının üzerinde odaklanılan yapay sinir ağı modelleri tek tek incelenmiştir. Yapılan sınıflandırma işlemlerinin performanslarının değerlendirilmesi için yapılacak işlemlerden bahsedilmiştir.

Dördüncü bölümde; yapay sinir ağı metotlarının sınıflandırma test problemleri için algoritmalar ile eğitilmesi ve literatürde karşımıza çıkan sınıflandırma problemleri üzerinde uygulanmıştır.

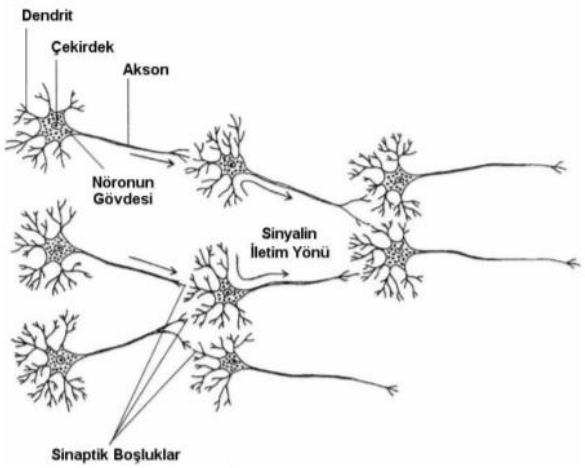
Elde edilen deneysel sonuçlar ve bu sonuçlara ait gösterge değerleri bu bölümde sunulmuştur ve son olarak bölüm değerlendirmesi yapılmıştır.

Beşinci bölüm, tez çalışmasında elde edilen sonuçlar tartışılmış ve bu konu üzerinde çalışma yapmak isteyen araştırmacılara önerilerde bulunulmuştur.

2. YAPAY SİNİR AĞLARI

2.1. Biyolojik Sinir Sistemi

Biyolojik Sinir Sistemi; beynin kontrol ettiği ve sinir hücrelerinden gelen verileri yorumlayarak gerekli kararı alıp üzerinde işlem yürüten sistemdir. Biyolojik Sinir sisteminin ana elemanı Nöron ismiyle anılan sinir hücreleridir. Biyolojik sinir hücresi Dentrit'ler, Hücre Gövdesi, Akson'lar ve Sinaps'lardan oluşmaktadır. Her birinin farklı görevleri bulunmaktadır. Şekil 2.1'de nöronun yapısı gösterilmektedir (Köprü, 2020).



Şekil 2.1. Biyolojik Sinir Hücresinin Yapısı

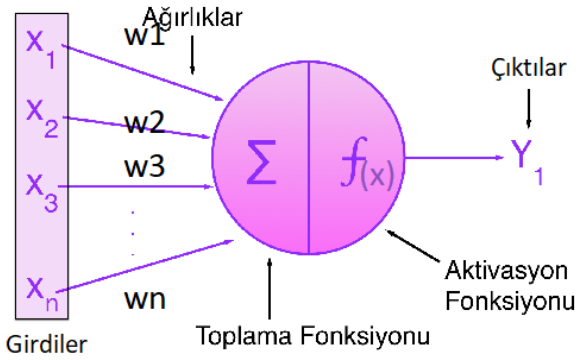
YSA'nın ana bileşenleri, biyolojik sinir sisteminde bulunan nöronların çalışma şekillerini gerçekleştiren Yapay Nöronlardır. Bunlar, birbirleri ile aralarında bağlantılar kurarak ve katman şeklinde birleşerek YSA'yı meydana getirirler.

Biyolojik Sinir sistemi yer alan elemanlar ve bunların yapay sinir ağlarına uyarlanması Çizelge 2.1'de verilmiştir. Biyolojik sinir sistemi parçalara ayrılmış ve yapay sinir ağında denk geldiği karşılıkları verilmiştir (Karakaş, 2020)

Çizelge 2.1. Biyolojik Sinir Sistemine ait Elemanlar ve Yapay Sinir Ağındaki Karşılığı

Sinir Sistemi	Yapay Sinir Ağı
Nöron	İşlem Elemanı
Dentrit	Toplama Fonksiyonu
Hücre Gövdesi	Aktivasyon Fonksiyonu
Akson	Eleman Çıkışı
Sinaps	Ağırlıklar

Şekil 2.2.'de n tane giriş verisine sahip basit bir sinir ağı yapısı gösterilmiştir. Şekilde verilen x 1'den *n*'e kadar olan sinir girişlerini, w 1'den *n*'e kadar olan giriş verilerine ait ağırlık değerlerini, f (x) fonksiyonu ile kullanılan aktivasyon fonksiyonunu ifade etmektedir.



Şekil 2.2. Temel Sinir Ağı Yapısı

Temel yapay sinir ağlarının 5 temel elemanı vardır. Bunlar:

1. Girdiler: Dış ortamdan yapay sinir hücresine gelen verilere denir. Veriler dış ortamdan sisteme gelen veriler olabileceği gibi farklı bir yapay sinir ağına ait hücrelerinin çıktı değerleri de olabilir. Bazı durumlarda işlem yapılan elemanların geri besleme yöntemi ile kendileri de girdi oluşturabilir.

2. Ağırlıklar: Bir sinir ağı hücresine çok miktarda girdi verisi ulaşır. Her bir girdinin kendine ait bir ağırlık değeri bulunmaktadır. Kullanılan her bir ağırlığın birbirinden farklı sabit değerleri bulunmaktadır. Başlangıç ağırlıkları değerleri çoğunlukla rastgele değerler atanmaktadır. Bu değerler pozitif veya negatif değerler olabilmektedir. Hücreye giren verinin etki ve önem dereceleri ağırlıklarla belirlenir. Bunun sonucunda bazı girdiler diğer girdilerden daha fazla önem kazanabilir. Bu durum bu girdilerin sinir hücresi üzerinde daha fazla etkili olduğunu ifade edebilir. Ağ yapısı ve kullanılan öğrenme algoritmalarına göre ağırlık değerlerinin güncellenmesinde farklılık olabilmektedir.

3. Toplama Fonksiyonu: Bir sinir hücresine gelen net girdinin hesaplanmasını sağlayan fonksiyondur. Literatürde en sık kullanılan ve karşımıza çıkan toplam fonksiyonu girdi değerlerinin kendisi ile ilgili ağırlık değerleri ile çarpılıp toplandığı ağırlıklı toplam fonksiyonudur ve denklem 2.1 'deki gibi formül ile ifade edilir.

$$netf = \sum_{i=1}^{n} xi * wi \qquad (2.1)$$

YSA'da çözülmesi gereken problemlerde hangi toplam fonksiyonunun kullanılacağına dair bir standart yoktur. İşleme dahil olan tüm elemanlar aynı toplam fonksiyonunu kullanabilecekleri gibi her işlem elemanı kendi başına bağımsız olarak ayrı bir toplama fonksiyonunu da kullanabilmektedir.

4. Aktivasyon Fonksiyonu: Her bir nörona gelen net girdinin işleme tabi tutulup girdi değerlerime karşılık gelen çıktı değerinin elde edilmesini gerçekleştiren fonksiyondur. Aktivasyon fonksiyonları probleme, problemin çözümü için tasarlanan ağın topolojisine ya da seçilen öğrenme algoritmasına göre değişkenlik gösterebilir. Örnek verecek olursak geri yayılım (*backpropagation*) algoritması uygulanacak ağlar için, çıktının hesaplanacağı aktivasyon fonksiyonunun türevi alınabilir bir fonksiyon olması gerekir

Literatür çalışmalarına bakıldığında çok fazla sayıda aktivasyon fonksiyonu bulunduğu görülmekte ve bilinmektedir. Yapay Sinir Ağlarında karşımıza sıkça çıkan aktivasyon fonksiyonlarından bazıları şunlardır:

- Eşik Değer Fonksiyonu
- Sigmoid Aktivasyon Fonksiyonu
- Adım (*Step*) Aktivasyon Fonksiyonu
- Doğrusal (*Lineer*) Aktivasyon Fonksiyonu
- Tanjant Hiperbolik Aktivasyon Fonksiyonu
- Sinüs Aktivasyon Fonksiyonu

5. Çıktılar: Aktivasyon fonksiyonundan elde edilen sonuç hücre çıktısı olarak kabul edilir. Bu çıktı hücrenin ağda bulunduğu konumuna göre ya bağlandığı diğer hücrelere girdi olarak verilir ya da ağın çıktısı olarak ürettiği sonuç olarak ifade edilir.

2.2. Yapay Sinir Ağları, Yapısı, Kullanım Alanları ve Özellikleri

Yapay sinir ağları (YSA), insan beyninden esinlenerek insanların öğrenme şeklini taklit ederek beynin öğrenme, hatırlama, genelleme yapabilme şeklinde elde ettiği verilerden yeni veri üretebilme yeteneğine sahip bilgisayar yazılımlarıdır.

Hızla ilerleyen teknolojik gelişmelere paralel olarak ortaya çıkan işleme sayısı ve hesaplama gücüyle beraber, karmaşık problemlerin çözülmesi ve gelişen yapay zekâ

teknolojilerinin kullanışlılığının artması ile geleceğe dönük öngörü modellemelerinin gerçekleştirmesi imkan dahiline girmiştir (Karaca, 2020).

YSA genel olarak 3 katmandan oluşmaktadır. Bu katmanlar ve bu katmanlara ait özellikler şu şekilde sıralanabilir;

- **Giriş Katmanı *(Input Layer):*** YSA'ya dış ortamdaki verilerin girdi olarak sunulduğu katmandır. Bu katmanda dış dünyadan gelecek giriş sayısı kadar nöron olmasına rağmen genel olarak girdiler bir işlem yapılmaksızın alt katmanlara iletilmektedir. Ağa bilgi girilmesinin sağlandığı katmandır.
- **Ara Katman *(Hidden Layers):*** Giriş katmanından çıkan bilgiler bu katmana gelir. Ara katman sayısında bir standart olamayıp belirlenen ağ ağısına göre ağdan ağa değişkenlik göstermektedir. Bazı YSA'larda ara katman bulunmayıp bazı YSA'larda ise birden çok sayıda ara katman bulunabilmektedir. Benzer şekilde ara katmanlarda bulunan nöron sayıları da girdi ve çıktı sayısından bağımsız olarak farklılıklar gösterebilir. Hatta tasarlanan ağ topolojisinde birden fazla ara katman bulunmakta ise böyle topolojilerdeki ağlarda ara katmanlar arasında ve kendi aralarındaki nöron sayılarında da farklılıklar olabilir. Ara katman sayılarının ve bu katmanlarda belirlenen nöron sayılarının artması ağdaki hesaplama karmaşıklığını ve işlem süresini arttırmasına neden olmaktadır. Ancak bu durum YSA'nın daha karmaşık problemlerin çözümünde de kullanılabilmesine imkan sağlayabilir.
- **Çıkış Katmanı (*Output Layer):*** Ara katman ya da ara katmalardan gelen değerleri işleyerek ağın girdi katmanına gelen verilere yanıt olarak üretilen çıktıların olduğu katmandır. Bu katmanda elde edilen ya da üretilen çıktı değerleri ya dış ortama ya da geri beslemeli ağlarda üretilen çıktı değerleri kullanılarak ağın yeni ağırlık değerlerinin hesaplanmasında kullanılır. Girdilere karşılık çıktıların elde edileceği ve matematiksel işlemlerin gerçekleştirildiği katmandır.

YSA sağlık, fen ve mühendislik bilimleri ve soysal bilimler alanında olmak üzere birçok alanda kullanılmaktadır. YSA'nın gerçek hayatta karşımıza çıktığı alanları şu şekilde sıralayabiliriz (Ağyar, 2015)

- Finansal Öngörü, Kalite Kontrol, Kredi Derecelendirme, Ekonomik Öngörü.
- Tahmin yapma, Optimizasyon, Kümeleme, Sınıflandırma, Örüntü Tanımlama,
- Filtreleme, Sinyal İşleme, Derecelendirme, Fiziksel Sistem Modelleme ve Yönetimi
- Konuşmak ve Yapı Tanımlama, İşlem Modelleme ve Yönetimi
- Hastalık Teşhisi, Doku Analizi, Koku Analizi ve Tanımı
- Veri Madenciliği, Veri ilişkilendirme ve yorumlama

Geleneksel algoritmaların özellikleri ile YSA'nın özelliklerinin karşılaştırılması Çizelge 2.2'de verilmiştir (Karakaş, 2020).

Çizelge 2.2. Geleneksel Algoritmalar ile YSA'ların karşılaştırılması

Geleneksel Algoritmalar	Yapay Sinir Ağları
Çıkışlar, koyulan kurallara girişlerin uygulanması ile elde edilir.	Öğrenme esnasında giriş çıkış bilgileri verilerek, kurallar koyulur.
Bilgiler ve algoritmalar kesindir.	Deneyimden yararlanır.
Hesaplama; merkezi, eş zamanlı ve ardışıktır	Hesaplama; toplu, eş zamansız ve öğrenmeden sonra paraleldir.
Bellek paketlenmiş ve hazır bilgi depolanmıştır.	Bellek ayrılmış ve ağa yayılmıştır.
Hata toleransı yoktur	Hata toleransı vardır.
Nispeten hızlıdır.	Yavaş ve donanıma bağımlıdır.

2.3. Yapay Sinir Ağlarının Yapıları

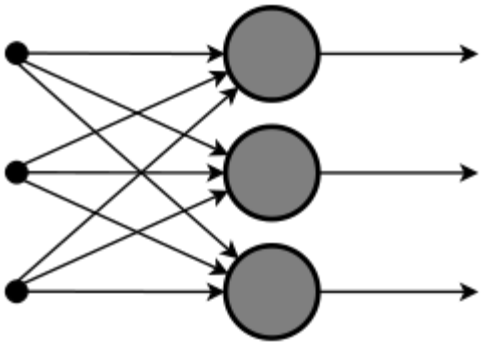
Yapılarına göre YSA'yı, ileri beslemeli ve geri beslemeli sinir ağı olmak üzere iki sınıfta incelenir.

2.3.1. İleri Beslemeli Sinir Ağı

YSA işlem elemanlarının bulunduğu her bir gruba katman denilir. İleri beslemeli YSA, veri akış yönünün sadece giriş katmanından çıkış katmanına doğru tek yönlü olduğu ağlardır. Bu modelde bir katmana ancak önceki katmandan bağlantı olabilir. Yani bir nöronun çıktısı kendinden sonraki nöronun girdisi olarak kullanılabilir. İleri beslemeli YSA tek ve çok katmanlı olmak üzere iki gruba ayrılır (Arı, 2019).

2.3.1.1. Tek katmanlı ileri beslemeli sinir ağı

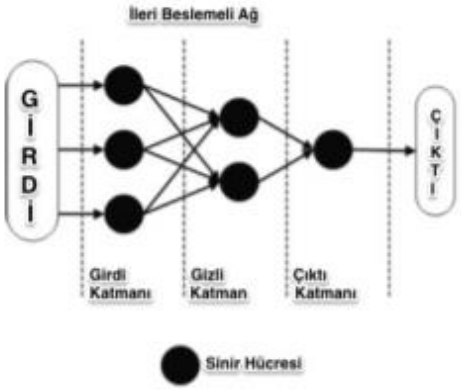
YSA'nın en temel ağ yapısıdır. Tek bir giriş katmanı bulunmaktadır ve direkt olarak çıkış katmanına bağlıdır. Çıktı katmanındaki her bir nöron, giriş katmanındaki tüm nöronlarla bağlıdır. Giriş katmanında herhangi bir hesaplama işlemi yapılmadığı için sadece çıkış katmanında hesaplama yapıldığından bu ağlara tek katmanlı ağ denir. Şekil2.3'te tek katmanlı ileri beslemeli sinir ağ yapısı gösterilmiştir (URL1, 2021).



Şekil 2.3 Tek Katmanlı İleri Beslemeli Sinir Ağ Yapısı

2.3.1.2. Çok katmanlı ileri beslemeli sinir ağı

YSA'da bilgi akışı giriş katmanı, ara katman/ (lar) ve çıktı katmanı olacak şekildedir. Geri yönlü bir besleme söz konusu değildir. Çıktı değerleri sadece giriş değerlerinin ara katman/ (lar)da işlenmesi sonucunda elde edilir (Karakaş, 2020). Genel olarak bir katmanda bulunan yapay sinir hücreleri bir önceki katmandaki yapay sinir hücreleri tarafından beslenmektedir (İçel, 2019). Şekil2.4'de yaygın kullanılan ileri beslemeli ağ modeli gösterilmektedir (Saatçioğlu ve Özçakar).

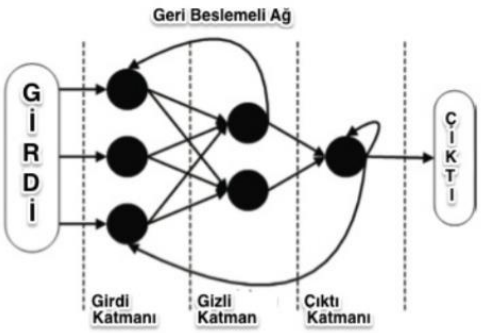


Şekil 2.4. Çok Katmanlı İleri Beslemeli Sinir Ağı

2.3.2. Geri Beslemeli Sinir Ağı

YSA'da çıkış ve ara katmanlara ait çıkışlar, giriş veya daha önceki ara katmanlara geri beslenmektedir. Yani nöronlar bulunduğu katmandaki herhangi bir başka nörona veya kendi bulunduğu katmandan önceki bir katmandaki başka bir nörona

bağlanabilirler. Böylece girişler, ileri ve geri yönde aktarılırlar (Çelebi, 2020). Geri beslemeli sinir ağının yapısı Şekil2.5'te verilmiştir (Saatçioğlu ve Özçakar).



Şekil 2.5. Geri Beslemeli Sinir Ağı

2.4. Yapay Sinir Ağlarında Öğrenme

YSA'da öğrenme en basit anlamda ağa dışarıdan bilgi girişi giriş katmanına aktarılır, giriş katmanına gelen veriler toplama fonksiyonunda toplanarak işlenir ve aktivasyon fonksiyonundan geçerek çıkış katmanında bir veya daha fazla çıkış üretilir. YSA sisteminden çıkan sonuç ile beklenen sonuç karşılaştırılır. Aradaki fark oransal olarak daha önceden belirlenen orandan farklı ise süreç belirlenen hata oranını yakalayana kadar devam eder. Süreç işleminde Algoritma üzerindeki değişikler çoğunlukla var olan ağın ağırlıkları üzerinden yapılır. Ağırlıklar üzerinde gerçekleşen değişiklikler aktivasyon fonksiyonun istenen çıktı değerine ya da hata oranına elde edecek şekilde daha etkili bir şekilde kullanılmasına olanak sağlar. Ulaşılan duruma göre güncellenen ağırlıklar neticesinde istediğimiz çıktıya ulaşma sürecine YSA'da öğrenme denir.

Güncellenen ağırlık değerleri bir sonraki aşamada dış ortamdan gelen giriş katmanı verileri değiştirilir bu veriler ile tekrar ağırlıkların doğruluğu hesaplanır. Belirlenen hata oranı diğer veri girişleri içinde tutuyorsa makinanın istemiş olduğumuz kuralı öğrendiği anlamına gelir.

Bir YSA'da ağın öğrenme süreci şu şekilde ilerlemektedir.

Öğrenmesi istenen problemin tasarlanacak sisteme girdi değerleri için verilerin sağlanması gerekmektedir. Giriş verileri sisteme tek tek sunularak ağın problemi

öğrenmesi sağlanır. Dış ortamdan ağa verilen gerçek verilerle ağın öğrenmesi tamamladıktan sonra öğrenmek üzere sisteme verilmemiş verilerden oluşan test verisi ile ağın öğrenme performansı hesaplanır.

Giriş sayısı, ara katman olup olmaması, ara katman sayısı, ara katman/ (lar)daki nöron sayısı ve çıkış katmanları belirlenerek ağın topolojik yapısı belirlenir.

Ağın öğrenme süreci ve başarısı, ağırlıkların, toplama ve aktivasyon fonksiyonları, momentum katsayısı ve öğrenme katsayısı değerlerinin doğru belirlenmesi gibi parametrelere bağlıdır. YSA'da öğrenmeyi gerçekleştirecek olan sistem ve kullandığımız öğrenme algoritmasına göre genel olarak üç öğrenme stratejisi bulunmaktadır. Bunlar, danışmanlı, danışmansız ve takviyeli öğrenmedir (Arı, 2019).

3. MATERYAL VE METOD

Çalışmamızda UCI Machine Learning Repository'de yar alan veri setlerinin Ionosphere, İris, ve Şarap veri setleri alınarak bu veri setleri üzerinde sınıflandırma işlemlerini yaparak doğruluk değerleri hesaplanmıştır. Çalışmamız Intel® Core ™ i7-5500U CPU @ 2.4 GHz, 8 GB Ram, 960 GB SSD özelliklerine sahip Laptop üzerinde Matlab Programlama dili kullanılarak sınıflandırılmıştır. Matlab'da yapay sinir ağı toolbox özelliklerinden faydalanılarak sınıflandırma işlemleri gerçekleştirilmiştir. YSA metotlarının eğitilmesinde bütün algoritmalarda eğitim algoritması olarak varsayılan eğitim algoritması *Levenberg-Marquardt* algoritması kullanılmıştır. Levenberg_Marquardt algoritması aktivasyonu fonksiyonu olarak sigmoid fonksiyonunu kullanmaktadır.

Burada YSA modellerinden İleri Beslemeli Sinir Ağları, Kademeli İleri Sinir Ağı, Genelleştirilmiş Regresyon Sinir Ağı, Olasılıksak Sinir Ağı (OSA) ve Tekrarlayan Sinir Ağları hakkında bilgi verilecektir.

3.1. Sınıflandırma

Verinin sınıflandırılması ve veri değerimin tahmini, gelecekte karşımıza çıkacak verilere ait veri tahmini yapmak veya bu verilere ait veri sınıflarını açıklayan modeller oluşturmak için kullanılan iki farklı veri analiz biçimidir. Sınıflandırma işleminde, kategorik tanımlamalar yaparken, tahmin işleminde, sürekli-değerli fonksiyonlar modellenmektedir (Kamber ve Pei, 2001). Örneğin bir sınıflandırma modelinde, banka kredi uygulamalarının güvenli ya da riskli olarak kategoriye ayırmak için tasarlanırken, tahmin işlemi, müşterilerin gelir düzeyi ve sahip oldukları meslek bilgilerinden faydalanarak, potansiyel sahibi müşterilerin bilgisayar malzemeleri tüketimini öngörmek için kurgulanabilir. Sınıflandırma işlemi iki kısımdan oluşmaktadır. Birinci kısımda sınıflandırma algoritması kullanılarak tecrübe edilmiş verilerden sınıflandırma kuralları oluşturulur. Sonraki kısımda ise oluşturulan sınıflandırma kuralları kullanılarak tecrübe edilmemiş farklı ve yeni veriler sınıflandırılır. Araştırmacıların yaptıkları çalışmalar neticesinde makine öğrenmesi, uzman sistemler, istatistik ve nöro-biyoloji için kullanılabilecek çok miktarda sınıflandırma ve tahmin metodu önerilmiştir. Tahmin ve sınıflandırma işlemlerini yapmak için birçok yöntem önerilmiş ve değişik alanlarda

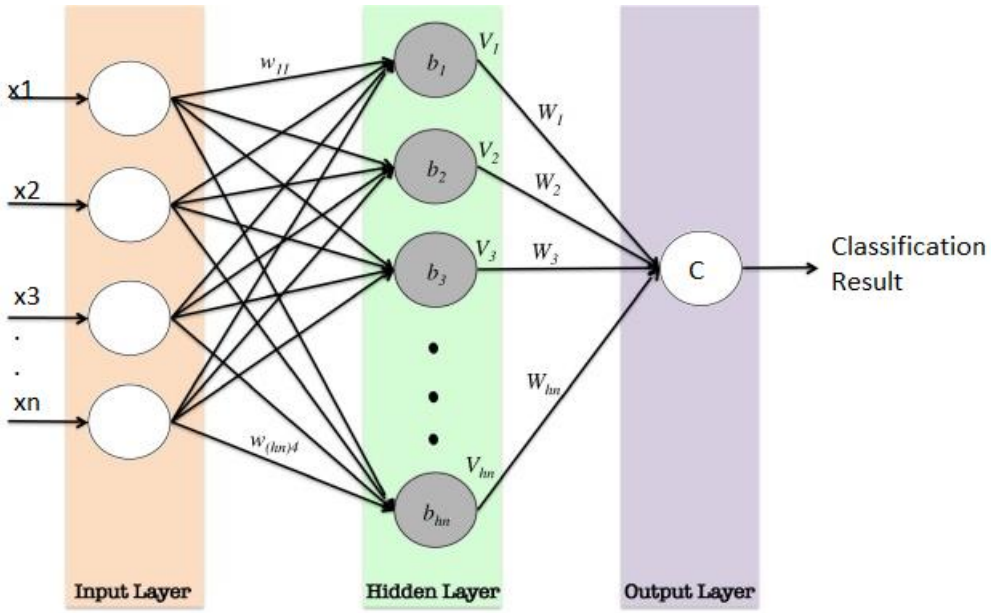
uygulamalar yapılmıştır. Bazı yöntemler belirli alanlarda başarılı olsa da her alanda başarılı olan bir yöntem henüz bulunamamıştır (Köklü, 2014).

3.2. İleri Beslemeli Sinir Ağları

İleri Beslemeli Sinir Ağları, nöronların katmanlar halinde gruplandığı ve yalnızca ileri bağlantıların bulunduğu en popüler Yapay Sinir Ağı mimarilerinden bir tanesidir. Bu, sürekli doğrusal olmayan haritalamayı öğrenebilen güçlü bir bağlantılı model sağlar. Sınıflandırma, Zaman Serisi, Tahmin yapma, Tıbbi Teşhis veya El Yazısı Tanıma gibi başarılı olduğu uygulamalar sadece birkaç tanesidir (Haykin, 1999).

YSA'nın mimarisi, kullanıcıların ileri beslemeli, tekrarlayan ve rekabetçi gibi farklı türlerde ağlar oluşturmasına olanak sağlar. Bunların arasında ileri beslemeli YSA, dikkate değer hesaplama hızı ile öne çıkıyor. Bu bağlamda, İBSA'nın diyabet teşhisi için etkili bir akıllı sistem olduğu kanıtlanmıştır (Erkaymaz ve ark., 2017).

Şekil 3.1'de gösterildiği gibi modelleme için tek bir ara katmanlı ileri beslemeli yapay sinir ağı kullanılır. YSA, giriş (girdi değerleri) ve çıktı (Sınıflandırma Kriteri Sonucu) arasındaki ilişkiyi öğrenebilen nöron tabanlı bir makine öğrenme algoritmasıdır. Yapısal olarak, insan biyolojik nöron ağlarına dayanan hesaplamalı bir modeldir. Sinyaller, ağırlıklı bağlantı bağlantıları üzerinden tanımlanmış sayıda nöron arasında geçirilir ve her nöron çıkış sinyalini belirlemek için bir aktivasyon işlevi kullanır (Chaudhuri ve ark., 2019).

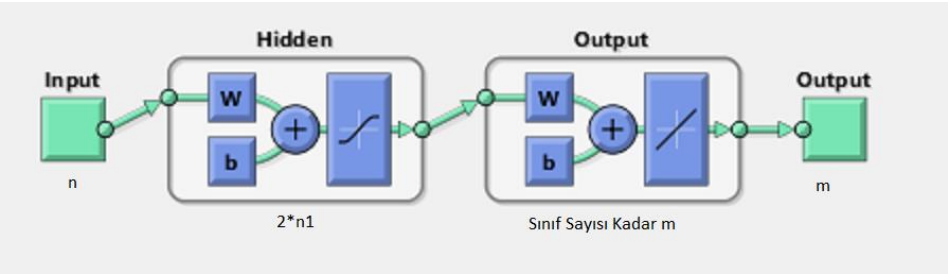


Şekil 3.1 Tek Ara Katmanlı İleri Beslemeli Yapay Sinir Ağı Yapısı

İleri Beslemeli Sinir Ağlarının eğitilmesi ve elde ettikleri doğrulukları test etmek amacıyla veriler rastgele bir şekilde dağıtımı gerçekleştirilmiştir. Eğitime katılmayan veriler ile ağın performans başarısı değerleri hesaplanmıştır.

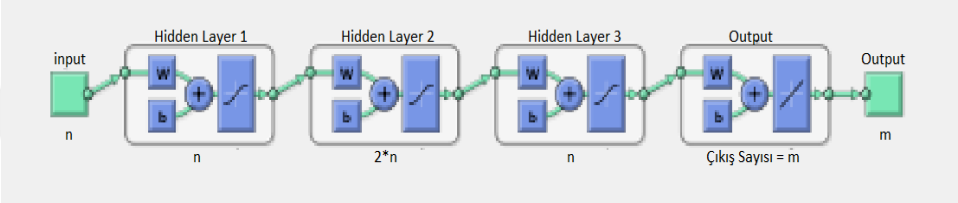
Çalışmamızda performans başarısına ait sonuçlarını daha iyi anlayabilmek için ağ topolojik yapısı için 2 ağ topolojisi tasarlanmıştır.

- Tek Ara Katmanlı İleri Beslemeli Sinir Ağları: Yapılan dinamik kodlama ile sisteme sunulan her veri setine ait özellik sayısının iki katının bir fazlası (2*n+1) nörona sahip tek ara katmanlı ağ sistemi tasarlanmıştır. Şekil 3.2'de Tek Ara Katmanlı İleri Beslemeli Sinir Ağları ağ topolojisinin taşırım şekli verilmiştir.



Şekil 3.2 Tek Ara Katmanlı İleri Beslemeli Sinir Ağ Topolojisi

- Çok katmanlı ve Çap Doğrulamalı Sinir Ağları: İsteğe göre 2 veya 3 katmanlı ara katmana sahip 10 Kat Çapraz Doğrulama sistemi tasarlanmıştır. Çalışmamızda 3 ara katmanlı sistem ile çalışmalar gerçekleştirilmiştir. Yapılan dinamik kodlama ile sisteme sunulan her veri setine ait özellik sayısı (n) kadar nörona sahip birinci ara katman, özellik sayısının iki katı (2*n) nörona sahip ikinci ara katman ve özellik sayısı kadar nörona (n) sahip üçüncü bir ara katmanlı bir ağ topoloji sistemi tasarlanmıştır. Şekil 3.3'te Çok Ara Katmanlı İleri Beslemeli Sinir Ağı topolojisinin tasarım şekli verilmiştir.



Şekil 3.3 Çok Ara Katmanlı İleri Beslemeli Sinir Ağı Topolojisi

3.3. Kademeli İleri Sinir Ağları

Kademeli İleri Sinir Ağı, ileri beslemeli sinir ağlarına benzer, ancak ileri beslemeli sinir ağlarında giriş katmanı ile çıkış katmanı arasında dolaylı bir bağlantı bulunuyorken Kademeli İleri Sinir Ağlarında giriş katmanı ile çıkış katmanı arasında doğrudan bir ilişki bulunmaktadır. Algılayıcı ve çok katmanlı ağ üzerindeki bağlantı formu birleştirilirse dolaylı olarak bağlantının yanı sıra giriş katmanı ile çıkış katmanı arasında doğrudan bağlantılı ağ oluşturulur. Bu bağlantı modelinden oluşan ağa Kademeli İleri Sinir Ağı (KİSA) denir. KİSA modelinden oluşturulan denklemler şu şekilde yazılabilir (Warsito ve ark., 2018).

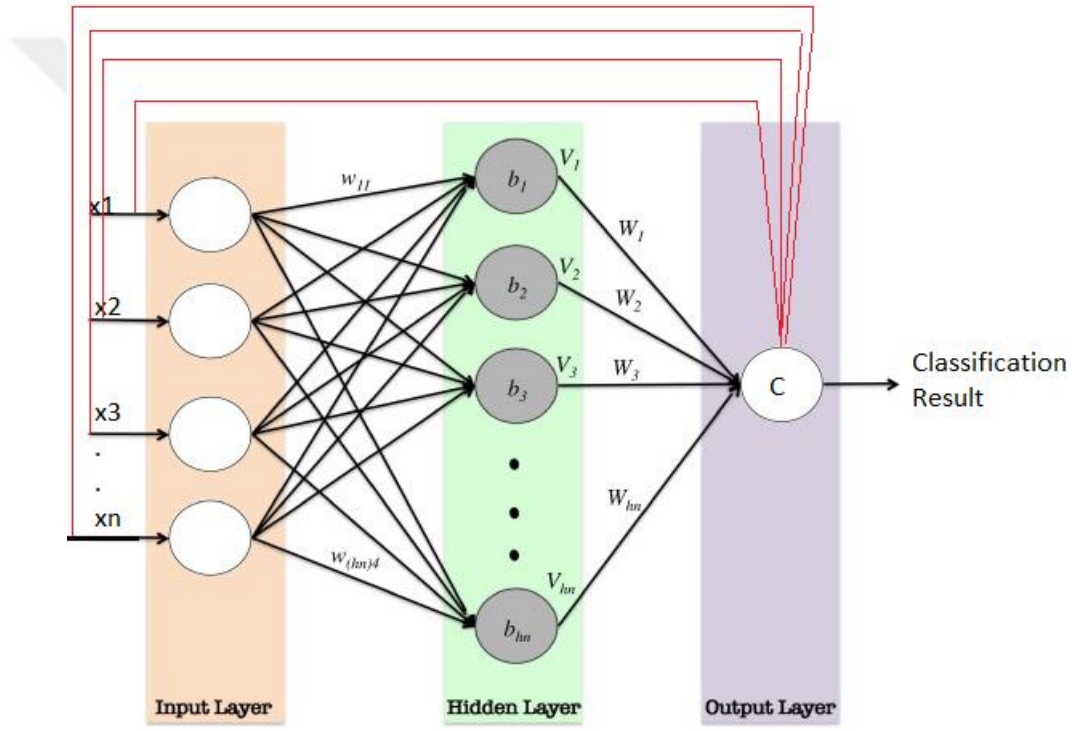
$$y = \sum_{i=1}^{n} f^{i} w_i^j x_i + f^0 (\sum_{j=1}^{k} w_j^0 f_j^h (\sum_{i=1}^{n} w_{ji}^h x_i)) \qquad (3.1)$$

f^i, girdi katmanından çıktı katmanına kadar olan aktivasyon fonksiyonu işlevidir ve w_i^j girdi katmanından çıktı katmanına kadar olan ağırlıktır. Giriş katmanına bir bias eklenirse ve gizli katmandaki her nöronun aktivasyon işlevi f^h ise denklem 3.2'deki gibi olur

$$y = \sum_{i=1}^{n} f^{i} w_i^j x_i + f^0(w^b + \sum_{j=1}^{k} w_j^0 f_j^h (w_j^b + \sum_{i=1}^{n} w_{ji}^h x_i)) \quad (3.2)$$

Optimal mimari hem girdi hem de gizli katmanlar için birimlerde artımlı arama yöntemi kullanılarak hesaplamalı olarak belirlendi. Önce basit olan, daha sonra birimler tek tek eklenerek daha karmaşık olanı inşa edildi. Daha sonra ortalama kare hata kriterleri kullanılarak en uygun olanı seçilir.

Şekil 3.2'de modelleme için kullanılan tek ara katmanlı KİSA yapısı gösterilmiştir.



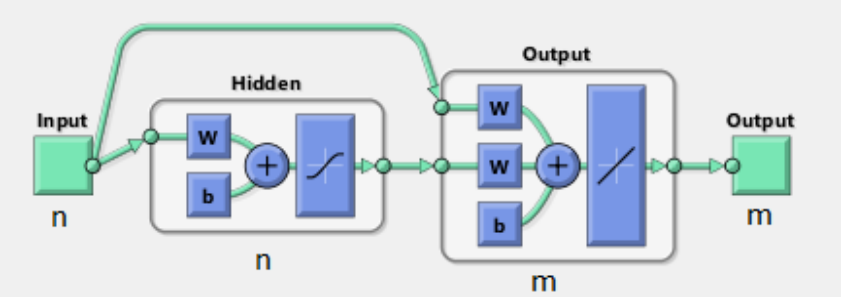
Şekil 3.4 Tek Ara Katmanlı KİSA Yapısı

KİSA'ların eğitilmesi ve elde ettikleri doğrulukları test etmek amacıyla veriler rastgele bir şekilde dağıtımı gerçekleştirilmiştir. Eğitime katılmayan veriler ile ağın performans başarısı değerleri hesaplanmıştır.

Çalışmamızda performans başarısına ait sonuçlarını daha iyi anlayabilmek için ağ topolojik yapısı için 2 ağ topolojisi tasarlanmıştır.

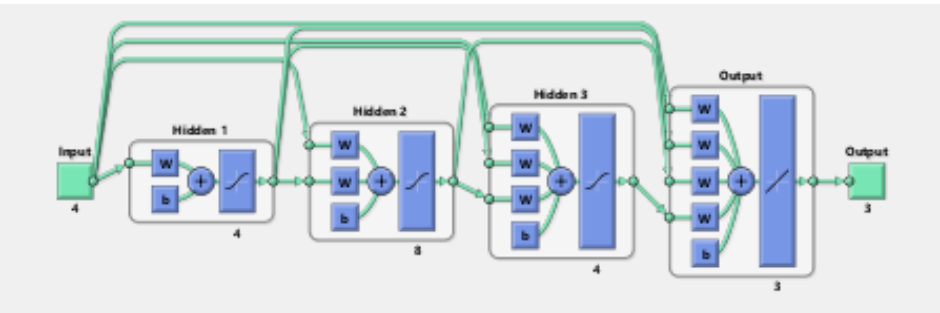
- Tek Ara Katmanlı KİSA: Yapılan dinamik kodlama ile sisteme sunulan her veri setine ait özellik sayısının iki katının bir fazlası (2*n+1) nörona

sahip tek ara katmanlı ağ sistemi tasarlanmıştır. Şekil 3.2'de Tek Ara Katmanlı KİSA ağ topolojisinin taşırım şekli verilmiştir.



Şekil 3.5 Tek Ara Katmanlı KİSA Topolojisi

- Çok ara katmanlı ve Çapraz Doğrulamalı KİSA: İsteğe göre 2 veya 3 ara katmanlı nörona sahip 10 Kat Çapraz Doğrulama sistemi tasarlanmıştır. Çalışmamızda 3 ara katmanlı sistem ile çalışmalar gerçekleştirilmiştir. Yapılan dinamik kodlama ile sisteme sunulan her veri setine ait özellik sayısı (n) kadar nörona sahip birinci ara katman, özellik sayısının iki katı (2*n) nörona sahip ikinci ara katman ve özellik sayısı kadar nörona (n) sahip üçüncü bir ara katmanlı bir ağ topoloji sistemi tasarlanmıştır. Şekil 3.3'te Çok Ara Katmanlı KİSA topolojisinin tasarım şekli verilmiştir.



Şekil 3.6 Çok Ara Katmanlı KİSA Topolojisi

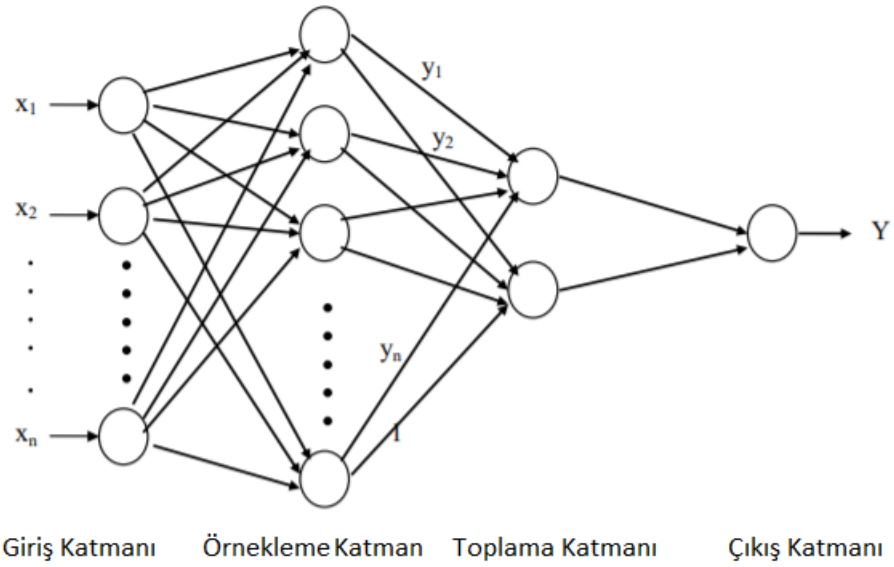
3.4. Genelleştirilmiş Regresyon Sinir Ağları

Genelleştirilmiş Regresyon Sinir Ağları (GRSA) ilk olarak Specht tarafından 1991'de sunulmuştur (Specht, 1991). Bir meta modelleme yöntemi olarak GRSA, çeşitli faydalara sahiptir. Parametrik olmayan regresyona dayalı bir yapı olarak, GRSA

örneklenen verilere göre oluşturulur, Parzen parametrik olmayan tahminini uygular ve ağın çıktısını maksimum olasılık ilkesine göre hesaplanır. Dolayısıyla, doğrusal olmayan tahminlerde büyük bir sınıflama ve tahmin kabiliyetine sahiptir. Hatta, GRSA kullanan eğitim süreci boyunca, radyal tabanlı sinir ağlarına karşılaştırıldığında öğrenme hızı ve tahmin yeteneği ile büyüleyicidir (Hu ve ark., 2017; Lotfinejad ve ark., 2018).

Düzeltme faktörünün ayarının hassas derecede duyarlı olmadığını belirtmek gerekir. Düzeltme faktörünün küçük hassasiyetlerinin olması parametrelerin seçiminde optimum kolaylık sağlar (Park ve Kim, 2017). GRSA yönteminde, her eğitim örneği bir küme olarak kabul edilir. Eğitime katılmayan yeni girdiler GRSA'yı verildiğinden, girdi ve her eğitim verisi örneği arasında Öklid mesafesini hesaplamaya başlar. Bunun sonucunda verilen girdiye göre GRSA, çıktıyı tahmin etmek için kullanılır (Lotfinejad ve ark., 2018).

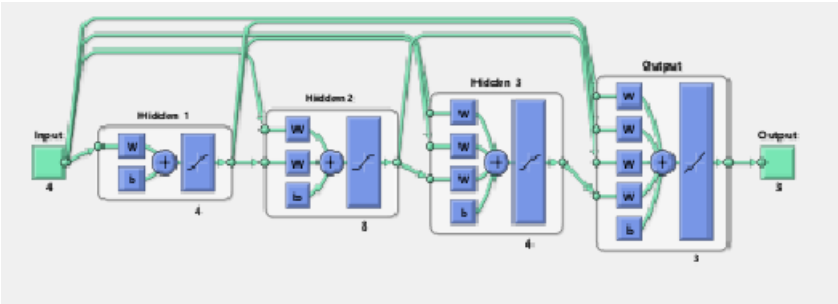
Eğitim seti genişledikçe tahmin hatası sıfıra iner. GRSA tıpkı standart regresyon tekniklerinde olduğu gibi sürekli değişkenlerin tahmini için kullanılmaktadır. Radyal tabanlı fonksiyon yapılarına benzer. Standart istatistik tekniklerinden çekirdek regresyon olarak adlandırılan bir tekniğe dayanır. Regresyon, x ve verilen eğitim seti ile bağımlı y değişkeninin olması en mümkün olan değerini x bağımsız değişkenine bağlı olarak tahmin eder. Regresyon metodu ortak kare hatasını en aza indirecek şekilde y'yi tahmin eder. GRSA, bir eğitim seti verildiğinde x ve y'nin ortak olasılık yoğunluk fonksiyonunu tahmin eden bir metottur. Olasılık yoğunluk fonksiyonu elimizdeki veriden herhangi bir ön kabul yapmadan hesaplandığı için sistem genel olarak idealdir. Genel bir GRSA Şekil3.7'de verilmiştir (Sürel, 2006).



Şekil 3.7 GRSA Yapısı

GRSA'larının eğitilmesi ve elde ettikleri doğrulukları test etmek amacıyla veriler rastgele bir şekilde dağıtımı gerçekleştirilmiştir. Eğitime katılmayan veriler ile ağın performans başarısı değerleri hesaplanmıştır.

GRSA, gizli katmandaki nöron sayısının ağa sunulan modellerin (veya prototiplerin) sayısı ile doğru orantılı olduğu içim radyal temel ağ türüdür. Burada sınıflandırma için kullanılan GRSA, MATLAB yazılımının NNTool'u kullanılarak uygulanmıştır. Bir GRSA oluşturmak için gerekli olan tek parametre, ampirik olarak 1 olarak belirlenen yayılma parametresidir (Yavuz ve ark., 2018). Şekil3.8'de Matlab GRSA NNtool ağ yapısı gösterilmektedir.

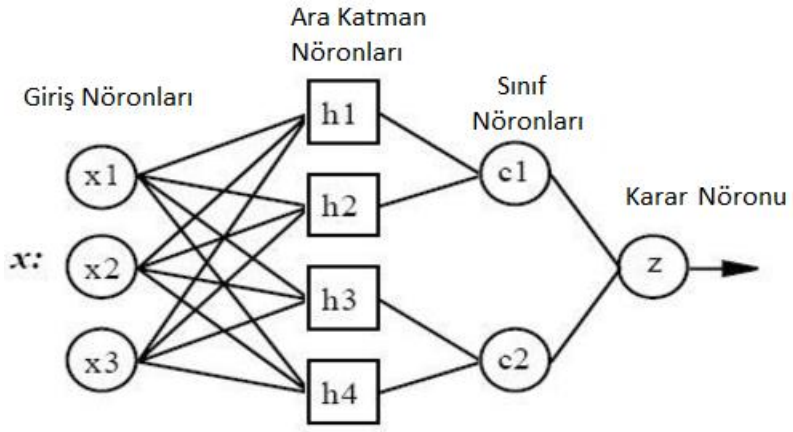


Şekil 3.8 GRSA NNtool Ağ Yapısı

3.5. Olasılıksak Sinir Ağları

Olasılıksak sinir ağı (OSA), Donald Specht'in geliştirmiş olduğu olasılık yoğunluk tahmininin (*probability density estimation*) bir ağ formülasyonudur ((Specht, 1991). "Kazanan hepsini alır" mantıksak yaklaşımına dayalı rekabetçi öğrenme sistemi üzerine kurulmuştur. İstatistikte Bayesian sınıflandırma modeli olarak ta adlandırılan bir yaklaşımı temel alarak sınıflandırma problemlerinde genel bir çözüm sağlar. OSA ağında genellikle, Bayes teorisinde gerekli olan "Olasılık Yoğunluk Fonksiyonu" yapısını geliştiren Parzen Yaklaşımı (Parzen Estimation) kullanılır (Alakoç ve ark., 2018). OSA, nöronları birbirine bağlayan bağlantı ağırlıklarının olasılık yoğunluk fonksiyonundan yararlanılarak hesaplandığı bir YSA yapısıdır. İstatistiksel özellikleri temel alması nedeniyle sınıflandırma problemlerinde oldukça sık olarak kullanılmaktadır (DEDE ve SAZLI, 2008).

Bir OSA; giriş katmanı, iki adet ara katman ve çıkış katmanı olmak üzere toplam dört katmandan oluşmaktadır. Bu yapıda, ilk ara katmanda giriş verisinin eğitim verisine olan uzaklığı hesaplanır. İkinci ara katmanda ise ilk ara katmanda elde edilen değerlerin uzaklıklar toplanır ve net çıkış vektörü için olasılıklar hesaplanır. Böylelikle model sınıfları oluşturulmuş olur. Çıktı katmanında oluşturulan model sınıflarından elde edilen en yüksek olasılığa ait model sınıfı ile YSA'nın çıktısı tayin edilir (DEDE ve SAZLI, 2008). Şekil 3.9'da tipik bir OSA mimari yapısı gösterilmiştir. Olasılıksak ağlarda sürdürülen eğitim safhası genel olarak çok katmanlı ağlara oranla daha hızlı olabilmekle birlikte sınıflandırma işlemi daha uzun sürebilmektedir. Fakat elde edilen sonuçlar diğer ağlara göre daha kesin değerler elde edilebilmektedir.



Şekil 3.9 OSA Mimari Yapısı

3.6. Tekrarlayan Sinir Ağları

Katman yinelenen sinir ağları, her katmanın kendisiyle ilişkili bir dokunma gecikmesiyle yinelenen bir bağlantıya sahip olması dışında ileri beslemeli ağlara benzer. Bu, ağın zaman serisi giriş verilerine sonsuz dinamik yanıta sahip olmasını sağlar. Bu ağ, sonlu giriş yanıtlarına sahip olan zaman gecikmesi (*timedelaynet*) ve dağıtılmış gecikmeli (*distdelaynet*) sinir ağlarına benzer (Documentation, 2021).

Tekrarlayan sinir ağları (TSA), düğümler arasındaki bağlantıların yönlendirilmiş bir döngü oluşturduğu yapay sinir ağı sınıfıdır. Bu, dinamik zamansal davranış sergilemesine izin verir. İleri beslemeli sinir ağlarından farklı olarak, TSA'lar kendi giriş belleğini girdilerin keyfi sıralarını işlemek için kullanabilirler.

TSA'lar, biyolojik beyin modülleri ile az ya da çok detaylı analoji ile tasarlanan geniş ve çeşitli hesaplama modelleri sınıfını temsil eder. Bir TSA'da çok sayıda soyut nöron benzer şekilde soyutlanmış sinaptik bağlantı(lar) ile birbirine bağlanır ve bu da aktivasyon fonksiyonlarının ağ boyunca yayılmasını sağlar. TSA'ları daha yaygın olarak kullanılan ileri beslemeli sinir ağlarından ayıran karakteristik özelliği , bağlantı topolojisinin döngülere sahip olmasıdır. Döngülerin varlığı, ağa derin bir etki sağlamaktadır:

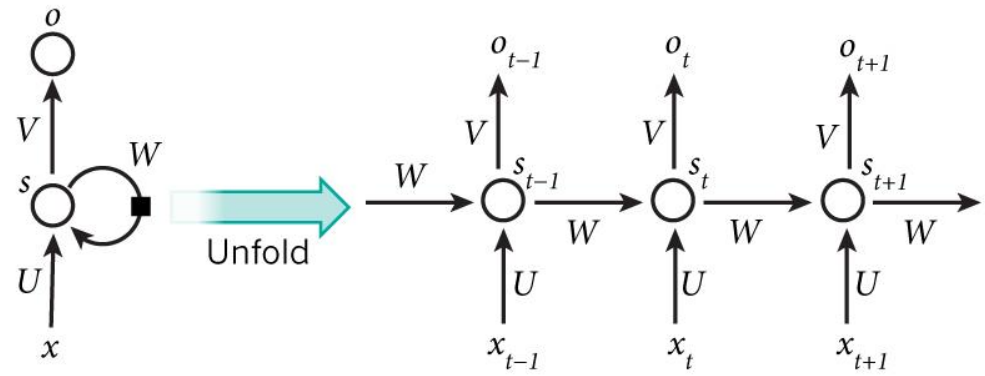
Bir TSA, girdi olmadığında bile tekrarlayan bağlantı yolları boyunca kendi kendini sürdüren bir zamansal aktivasyon dinamiği geliştirebilir. Matematiksel olarak, bu durum bir TSA'nın ileri beslemeli ağları bir fonksiyonu iken işlevsel olarak dinamik sistem olmasını sağlar.

Bir giriş sinyali tarafından tetikleniyorsa, TSA mevcut durumunda giriş geçmişinin doğrusal olmayan bir dönüşümünü korur başka bir deyişle, dinamik bir belleğe sahiptir ve zamansal bağlamda edindiği bilgisini yürütebilir.

TSA'lar çeşitli bilimsel amaçlar için kullanılır ve en az iki ana RNN modeli sınıfı mevcuttur: biyolojik beyinleri modellemek amacıyla veya teknik uygulamalar için mühendislik araçları olarak kullanılabilirler. İlk kullanım hesaplamalı sinirbilim alanına aitken, ikinci kullanım TSA'ların makine öğrenimi, hesaplama teorisi ve doğrusal olmayan sinyal işleme ve kontrol alanlarında kullanılabilir (Lukoševičius ve Jaeger, 2009).

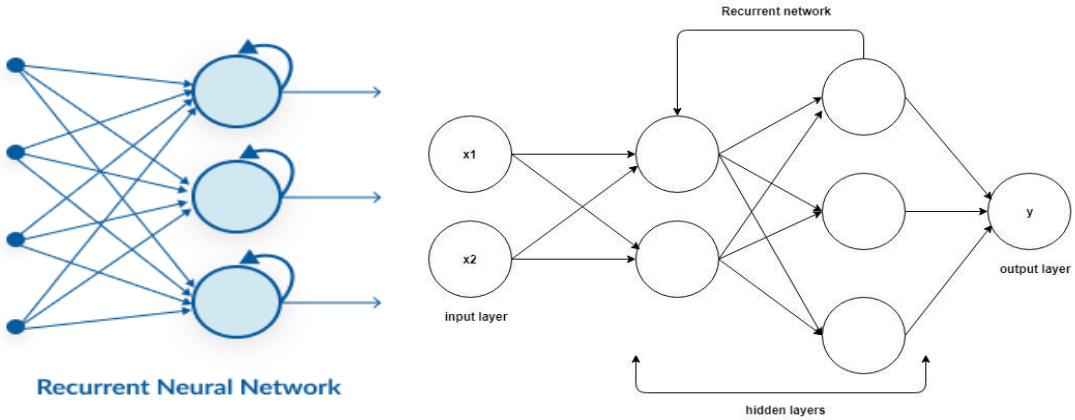
Tekrarlayan sinir ağlarının asıl hedefi ardışık bilgileri kullanmaktır. Sinir Ağlarını genel olarak tüm girdilerin (ve çıktıların) birbirleri ile bağımsız olduğunu farz

edilir. TSA'lar ise tekrarlayan olarak adlandırılmalarının sebebi bir dizinin tüm öğeleri için aynı işlevi yürütürler ve çıktı önceki hesaplamalara bağlıdır. TSA'lar pratikte birkaç adım geriye dönmekle sınırlıdır ve bu bilgileri kullanabilirler. Şekil 3.10'daki diyagram, bir RNN'nin tam bir ağa açılmasını gösterir.



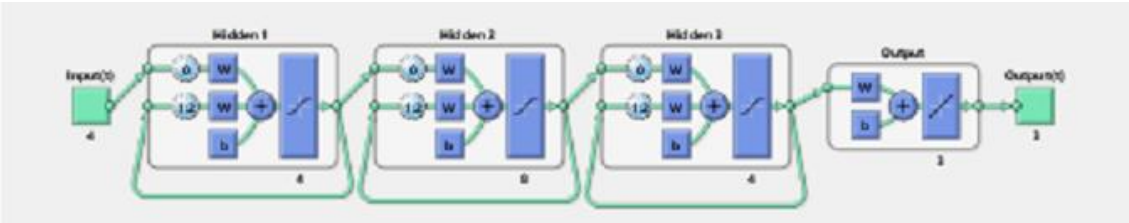
Şekil 3.10 TSA Ağa açılma Diyagramı

Şekil 3.11 de tipik TSA mimari yapısı verilmiştir.



Şekil 3.11 Tipik bir TSA Mimari Yapısı

Şekil3.12 de çalışmamıza ait NNtool işlevine ait TSA mimarisi gösterilmektedir.



Şekil 3.12 NNtool TSA Mimarisi

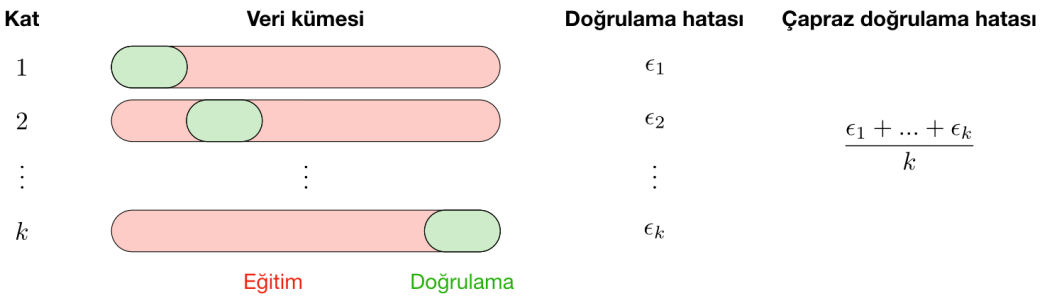
3.7. Çapraz Doğrulama

Genel olarak bir sınıflandırıcı öğrenme algoritması kullanılarak eğitim verilerinden bir sınıflandırıcı oluşturulur. Her sınıflandırıcı, gerçek hata olarak da adlandırılan ilişkili bir tahmin hatasına sahiptir. Ancak genellikle gerçek hata değeri bilinemez ve hesaplanamaz, bunu verilerden tahmin etmek zorundadır. Bu hataya tahmini tahmin hatası denir. Literatürde kadar birçok sınıflandırma hatası tahmin edici tekniği bulunmaktadır. Bu tekniklerden biri ve muhtemelen en popüler olanı k-katlamalı çapraz doğrulama (*k- Cross-Validation* (*k-cv)*) (Bengio ve Grandvalet, 2004). Sınıflandırma, yeni örneklerin sınıf değerlerini tahmin etmek için gerekli bir görevdir. Hem k- katlamalı hem de birini dışarıda bırakarak çapraz doğrulama, sınıflandırma algoritmalarının performansını değerlendirmek için çok popülerdir. Veri madenciliği, bilgisayarlarda depolanan büyük miktardaki veriyi otomatik olarak işlemek için ortaya çıkan bir tekniktir. Sınıflandırma, yeni örneklerin sınıf değerlerini atamak için veri madenciliğinde önemli bir görevdir. Bir veri setinde bir sınıflandırma algoritmasının performansını değerlendirmek için iki popüler yaklaşım, k- katlamalı ve birini dışarıda bırakmalı çapraz doğrulamadır. Veri miktarı büyük olduğunda, bir sınıflandırma algoritmasından indüklenen modelin doğruluğunu tahmin etmek için k-kat çapraz doğrulama kullanılmalıdır. Çünkü modelin eğitim verilerinden kaynaklanan doğruluk genellikle çok iyimserdir (Witten ve Frank, 2002).

Makine öğrenmesi tekniklerinde tasarlanan modelde yapılan eğitim işlemlerinin ardından test işleminin hatasını daha iyi tahmin edebilmek için Çapraz Doğrulama tekniği kullanılabilir. Çapraz doğrulamanın temelinde olan alan fikir, eğitim işleminde kullanılan verilerin doğrulama kümeleri olarak adlandırılan örnek gözlem bölümünü oluşturmaktır. Eğitim verileri modele yerleştirdikten sonra sınıflandırma performansını tespit etmek için her yeni doğrulama kümesinde sınıflandırma performansı ölçülür.

Çapraz doğrulama işleminin en basit metodu Holdout metodudur. Veri seti, eğitim seti ve test seti olarak iki gruba ayrılır. Sistemin Eğitilesi yalnızca belirlenen eğitim verileri üzerinde gerçekleştirilir. Devamında, elde edilen fonksiyon yaklaşımı ile eğitimde katılamamış test veri setindeki verilere ait çıkış değerlerini tahmin etmesi istenir. Yaptığı hatalar, modeli değerlendirmek için kullanılan ortalama mutlak test kümesi hatasını hesaplamak için biriktirilir. Çaprazlama sayısınca işlem gerçekleştirilir ortalama mutlak hata hesaplanır (URL2, 2021).

Şekil 3.13'te K-Kat çapraz doğrulama işlemi gösterilmiştir (URL3, 2021).



Şekil 3.13 K-Kat Çapraz Doğrulama İşlemi

3.8. Levenberg-Marquardt Algoritması

Levenberg-Marquardt (LM) Algoritması, doğrusal olmayan en küçük kareler problemlerini çözmek için kullanılır. Gradyan inişi ve Gauss-Newton yöntemlerinin birleşmesi sonucu oluşan eğri uydurma yöntemidir. Hem Gradyan inişi hem de Gauss-Newton yöntemleri yinelemeli algoritmalardır, yani bir çözüm bulmak için bir dizi hesaplama (x değerleri tahminlerine dayalı olarak) kullanırlar. Gradyan inişi, her yinelemede çözümün, işlev değerini küçülten değerleri seçerek güncellenmesi bakımından farklılık gösterir. Daha spesifik olarak, hataların karesi toplamı, en dik iniş yönüne doğru hareket ederek azaltılır. Her yinelemede, *Levenberg–Marquardt* Algoritması gradyan inişini veya Gauss Newton'u seçer ve çözümü günceller.

Yinelemeli güncelleme, bir algoritmik parametrenin değerine bağlıdır, λ - grafiği düzelten negatif olmayan bir sönümleme faktörüdür. Güncelleme işlemi eğer λ küçükse (yani optimal değere yakınsa) Gauss-Newton seçilir eğer λ büyükse bir gradyan inişi metodu seçilir (Gavin, 2011). Gauss-Newton, minimum hataya yakın olduğunda gradyan inişinden daha doğru ve daha hızlıdır. Bu nedenle, algoritma mümkün olan en kısa sürede Gauss-Newton algoritmasına doğru ilerleyecektir.

Avantajları:

1. Her yinelemede algoritmanın yönü için iki olası seçenek olduğundan, LM, Gauss-Newton'dan daha sağlamdır (Nelles, 2001).
2. Yakınsamak Gauss Newton veya gradyan inişinden daha hızlıdır.
3. Tam olarak bilinmeyen birden fazla serbest parametresi olan modelleri işleyebilir (çok büyük kümeler için algoritmanın yavaş olabileceğini unutmayın).

4. İlk tahmininiz hedeften uzaksa, algoritma yine de en uygun çözümü bulabilir.

Dezavantajları:

- Bazı durumlarda, LM'nin yakınsaması çok yavaş olabilir. Bu özellikle modelin, algoritmanın dar tanımlanmış bir gezinme alanı boyunca yavaşça ilerlemesini neden olabilecek çok sayıda parametresi olması durumunda geçerli olabilir (Waterfall ve ark., 2006).

3.9. Tahmin Testleri

YSA metotlarından elde edilen ikili sınıflar için karışıklık matrisi ve gösterimi yardımıyla doğruluk, hassasiyet, duyarlılık ve F1-Skor değerleri, bilimsel olarak ölçme işlemlerinin ana amaçlarından bir tanesidir ve tahmin işlemlerinin değerlendirilmesinde kullanılmaktadır. Genel olarak kullanılan göstergeler; doğruluk, duyarlılık ve belirleyicilik katsayıları Çizelge 3.1'de verilmiştir.

Çizelge 3.1 Belirleme Katsayıları

		TAHMİN		
GERÇEK		Tahmin Değeri 1. Sınıf	Tahmin Değeri 2. Sınıf	Toplam
	Gerçek Değeri 1.Sınıf	Doğru 1. Sınıf tp	Yanlış 2. Sınıf fn	Toplam 1 sınıflandırılan (tp+fn)
	Gerçek Değeri 2.Sınıf	Yanlış 1.Sınıf fp	Doğru 2. Sınıf tn	Toplam 2 sınıflandırılan (fp+tn)
	Toplam	Toplam 1 Sınıf (tp+fp)	Toplam 2 Sınıf (fn+tn)	tp+fp+tn+fn

Çizelge 3.1'de tp = gerçek 1. sınıf sayısı, fn = yanlış 2. sınıf sayısı, fp = yanlış 1. sınıf sayısı, tn = gerçek 2. sınıf sayısını göstermektedir.

İkili sınıflar için Karışıklık Matrisi ve gösterimi, bir sınıflandırma sistemi tarafından gerçekleştirilen tahmin edilen sınıflandırmalar hakkında bilgi içerir. Bu tür sistemlerin performansı matristeki veriler kullanılarak Denklem 3.3-3.6 göre değerlendirilebilir.

1. Genel $Doğruluk = \frac{tp + fp}{tp + fp + tn + fp} * 100$ (3.3)

2. $Hassasiyet = \frac{tp}{tp + fp} * 100$ (3.4)

3. $$Duyarlılık = \frac{tp}{tp + fn} * 100$$ (3.5)

4. $$F1 - Skoru = 2 * \frac{Hassasiyet * Duyarlılık}{Hassasiyet + Duyarlılık}$$ (3.6)

Çizelge 3.2'de karmaşıklık matrisini ve çoklu sınıflar için temsilini gösterir (Koklu ve Ozkan, 2020).

Çizelge 3.2 Karışıklık matrisi ve çoklu sınıfların gösterimi**.**

Tahmin edilen						
Gerçek		**C 1**	**C 2**	**C 3**	**...**	**C n**
	C 1	T_1	F_{12}	F_{13}	...	F_{1n}
	C 2	F_{21}	T_2	F_{23}	...	F_{2n}
	C 3	F_{31}	F_{32}	T_3	...	F_{3n}
	...	...	...	...	...	...
	C n	F_{n1}	F_{n2}	F_{n3}	...	T_n

Çok sınıf veri sınıflandırma ölçütleri ve ölçümlerin bu tür sistemlerin performansı matristeki veriler kullanılarak Denklem 3.7-3.10 göre değerlendirilebilir.

5. Ortalama Doğruluk = $$\frac{\sum_{i=1}^{l} \frac{tp_i + tn_i}{tp_i + fn_i + fp_i}}{l}$$ (3.7)

6. *Ortalama Hassasiyet* (P_M) = $$\frac{\sum_{i=1}^{l} \frac{tp_i}{tp_i + fp_i}}{l}$$ (3.8)

7. *Ortalama Duyarlılık* (r_M) = $$\frac{\sum_{i=1}^{l} \frac{tp_i}{tp_i + fn_i}}{l}$$ (3.9)

8. Ortalama *F1 Skoru* = $$\frac{2 * P_M * r_M}{P_M * r_M}$$ (3.10)

Bir testte hesaplanan duyarlılık ve hassasiyet katsayısının yüksek olması, testin koyduğu tanıların kesinlikle doğru, düşük olması da kesinlikle yanlış olmasını ifade etmeyebilir. Doğruluk; testin toplam doğru tanı koyma oranıdır.

4. DENEYSEL SONUÇLAR VE ANALİZ

Bu bölümde belirtilen YSA metotlarını test etmek amacıyla UCI Machine Learning Repository'de indirilen çok bilinen bir (1) tanesi iki sınıflı ve iki (2) tanesi çok sınıflı olmak üzere 3 veri kümesi üzerinde çalışmalar yapılmıştır. Bu çalışmalara ait deneysel sonuç ve analizleri açıklanmıştır.

4.1. İki Sınıflı Veri Setleri Üzerindeki Uygulamalar

İBSA, KİSA, GRSA, OSA ve TSA metotları kullanılarak ikili sınıf verileri üzerinde çalışma yapmak üzere UCI Machine Learning Repostory'den makine öğrenmesi veri tabanından elde edilen Ionosphere veri kümesi kullanılmıştır.

4.1.1. Ionosphere Veri Kümesi

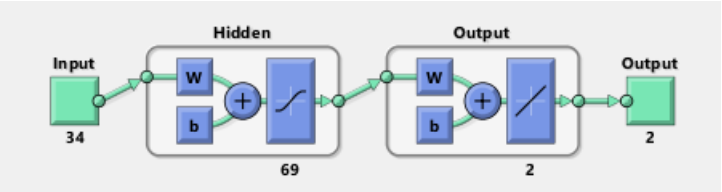
İBSA, KİSA, GRSA, OSA ve TSA metotları uygulamak üzere seçilen Ionosphere veri kümesidir (Sigillito ve ark., 1989).

Bu radar verileri, Labrador'daki Goose Bay'deki bir sistem tarafından toplandı. Bu sistem, 6,4 kilovat düzeyinde toplam iletim gücüne sahip 16 yüksek frekanslı antenden oluşan aşamalı bir diziden oluşur.

Veri sınıfı 2 sınıflı, 34 öznitelikten oluşan toplam 351 örnekten oluşmaktadır. Alınan sinyaller, bağımsız değişkenleri bir darbenin zamanı ve darbe sayısı olan bir otokorelasyon işlevi kullanılarak işlendi. Goose Bay sistemi için 17 nabız sayısı vardı. Bu veri tabanındaki örnekler, darbe sayısı başına 2 öznitelikle açıklanmaktadır.
Sınıflar 1 ve 2 olarak verilmiştir. Sınıf 1 (225 örnek) ve sınıf 2 (126 örnek) sırasıyla Good (sınıf 1) ve diyabet için Bad (sınıf 2) olan hastaları ifade etmektedir.

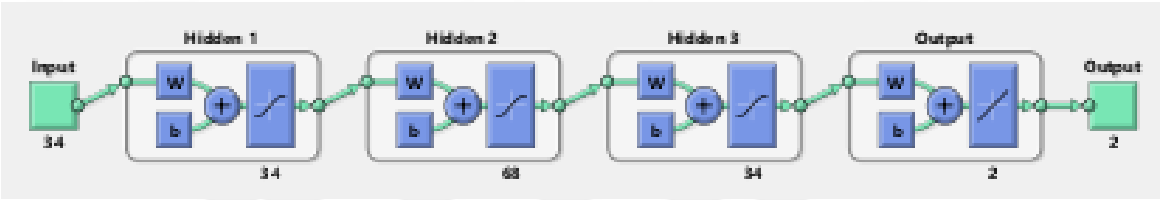
4.1.1.1. İBSA için Ionosphere veri kümesi uygulaması

Matlab NNtool fonksiyonu kullanılarak parametreler dinamik yazılım vasıtasıyla istediğimiz zaman güncellenebilen bir yapıda tasarlanmıştır. Bu çalışmada ara katmandaki nöron sayısının, n giriş parametre sayısı olmak üzere 2*n+1 nörondan oluşacak şekilde, Tek ara katmanlı İBSA Ionosphere veri kümesine göre tasarımı Şekil4.1'de gösterilmiştir.



Şekil 4.1 Tek Ara Katmanlı İBSA Yapısı

Çok ara katmanlı İBSA için değerlerimiz, Ara katman sayısının üç (3) olduğu birinci ara katmandaki nöron sayısının n, iki ara katmandaki nöron sayısının 2*n ve son ara katmandaki nöron sayısı n oluşacak şekilde, çok ara katmanlı İBSA Ionosphere veri kümesine göre tasarımı Şekil4.2'de gösterilmiştir.



Şekil 4.2 Çok Ara Katmanlı İBSA Yapısı

Çalışmanın sonucunda hem tek ara katmanlı hem de 3 ara katmanlı işlem yürütülmesinden sonra elde edilen Karışıklık Matrisleri ile Doğruluk *(Accuracy)*, Hassasiyet *(Precision)*, Duyarlılık *(Recall)*, F1-Skor, İşlem Süresi (sn) sonuçları verilmiştir.

Tek ara katmanlı İBSA için verimizin yarısı eğitim yarısı test işlemine ayrılmıştır. Çizelge 4.1'de karmaşıklık matrisi ve bunun sonucunda elde edilen Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, değerleri gösterilmektedir. İşlem Süresi 6,44sn sürmüş ve sınıflandırma doğruluğu %88,57 olarak hesaplanmıştır.

Çizelge 4.1. Tek Ara Katmanlı İBSA Karışıklık Matrisi, Sınıflar, Gerçek Sınıf Sayıları, Tahmin Edilen Sınıf Sayıları, Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, Değerleri

Karışıklık Matrisi			**Sınıf**	**Gerçek**	**Sınıflandırılmış**	**Genel Doğruluk**	**Hassasiyet**	**Duyarlılık**	**F1 Skoru**
1\2	**1**	**2**							
1	108	16	**1**	112	124	%88,57	0,87	0,96	0,92
2	4	47	**2**	63	51		0,92	0,75	0,82

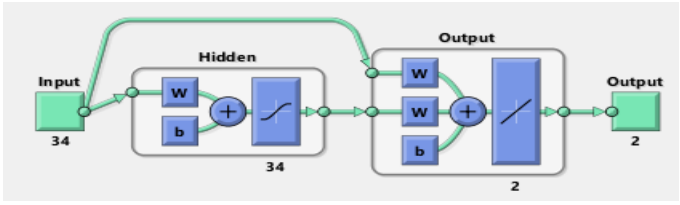
Çok ara katmanlı 10 kat çapraz doğrulama işlemi gerçekleştirilmiş İBSA'ya ait Çizelge 4.2'de karmaşıklık matrisi ve bunun sonucunda elde edilen Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, değerleri gösterilmektedir. İşlem Süresi 400,12sn sürmüş ve sınıflandırma doğruluğu %94,87olarak hesaplanmıştır.

Çizelge 4.2 Çok Ara Katmanlı ve 10 Kat Çapraz Doğrulamalı İBSA Karışıklık Matrisi, Sınıflar, Gerçek Sınıf Sayıları, Tahmin Edilen Sınıf Sayıları, Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, Değerleri

Karışıklık Matrisi			**Sınıf**	**Gerçek**	**Sınıflandırılmış**	**Genel Doğruluk**	**Hassasiyet**	**Duyarlılık**	**F1 Skoru**
1\2	**1**	**2**							
1	222	15	1	225	237	%94,87	0,94	0,99	0,96
2	3	111	2	126	114		0,97	0,88	0,93

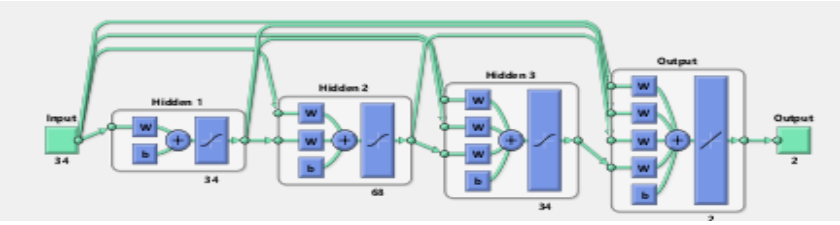
4.1.1.2. KİSA için ionosphere veri kümesi uygulaması

Matlab NNtool fonksiyonu kullanılarak parametreler dinamik yazılım vasıtasıyla istediğimiz zaman güncellenebilen bir yapıda tasarlanmıştır. Bu çalışmada ara katmandaki nöron sayısının, n giriş parametre sayısı olmak üzere n nörondan oluşacak şekilde, Tek ara katmanlı KİSA Ionosphere veri kümesine göre tasarımı Şekil 4.3'te gösterilmiştir.



Şekil 4.3 Tek Ara Katmanlı KİSA Yapısı

Çok ara katmanlı KİSA için değerlerimiz, Ara katman sayısının üç (3) olduğu birinci ara katmandaki nöron sayısının n, iki ara katmandaki nöron sayısının 2*n ve son ara katmandaki nöron sayısı n oluşacak şekilde, çok ara katmanlı KİSA Ionosphere veri kümesine göre tasarımı Şekil 4.4'te gösterilmiştir.



Şekil 4.4 Çok Ara Katmanlı KİSA Yapısı

Çalışmanın sonucunda hem tek ara katmanlı hem de 3 ara katmanlı işlem yürütülmesinden sonra elde edilen Karışıklık Matrisleri ile Doğruluk *(Accuracy)*, Hassasiyet *(Precision)*, Duyarlılık *(Recall)*, F1-Skor, İşlem Süresi (sn) sonuçları verilmiştir.

Tek ara katmanlı KİSA için verimizin yarısı eğitim yarısı test işlemine ayrılmıştır. Çizelge 4.3'de karmaşıklık matrisi ve bunun sonucunda elde edilen Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, değerleri gösterilmektedir. İşlem Süresi 1,36sn sürmüş ve sınıflandırma doğruluğu %86,86 olarak hesaplanmıştır.

Çizelge 4.3. Tek Ara Katmanlı KİSA Karışıklık Matrisi, Sınıflar, Gerçek Sınıf Sayıları, Tahmin Edilen Sınıf Sayıları, Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, Değerleri

Karışıklık Matrisi			**Sınıf**	**Gerçek**	**Sınıflandırılmış**	**Genel Doğruluk**	**Hassasiyet**	**Duyarlılık**	**F1 Skoru**
1\2	**1**	**2**							
1	110	21	1	112	131	%86,86	0,84	0,98	0,91
2	2	42	**2**	63	44		0,95	0,67	0,79

Çok ara katmanlı 10 kat çapraz doğrulama işlemi gerçekleştirilmiş KİSA'ya ait Çizelge 4.4'te karmaşıklık matrisi ve bunun sonucunda elde edilen Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, değerleri gösterilmektedir. İşlem Süresi 2166,47sn sürmüş ve sınıflandırma doğruluğu %96,58olarak hesaplanmıştır.

Çizelge 4.4 Çok Ara Katmanlı ve 10 Kat Çapraz Doğrulamalı KİSA Karışıklık Matrisi, Sınıflar, Gerçek Sınıf Sayıları, Tahmin Edilen Sınıf Sayıları, Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, Değerleri

Karışıklık Matrisi			**Sınıf**	**Gerçek**	**Sınıflandırılmış**	**Genel Doğruluk**	**Hassasiyet**	**Duyarlılık**	**F1 Skoru**
1\2	**1**	**2**							
1	219	6	1	225	225	%96,58	0,97	0,97	0,97
2	6	120	2	126	126		0,95	0,95	0,95

4.1.1.3. GRSA için ionosphere veri kümesi uygulaması

Bir GRSA oluşturmak için gerekli olan tek parametre, ampirik olarak 0,5 olarak belirlenen yayılma parametresi belirlenmiştir. Çalışmanın sonucunda hem tek ara katmanlı hem de 3 ara katmanlı işlem yürütülmesinden sonra elde edilen Karışıklık Matrisleri ile doğruluk *(Accuracy)*, hassasiyet *(Precision)*, Duyarlılık *(Recall)*, F1 Skor, İşlem Süresi (sn) sonuçları verilmiştir.

Tek ara katmanlı yarısı eğitim yarısı test işlemine ayrılmış GRSA'ya ait Çizelge 4.5'te karmaşıklık matrisi ve bunun sonucunda elde edilen Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, değerleri gösterilmektedir. İşlem Süresi 0,42sn sürmüş ve sınıflandırma Doğruluğu %87,43 olarak hesaplanmıştır.

Çizelge 4.5 Tek Ara Katmanlı GRSA Karışıklık Matrisi, Sınıflar, Gerçek Sınıf Sayıları, Tahmin Edilen Sınıf Sayıları, Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, Değerleri

Karışıklık Matrisi			**Sınıf**	**Gerçek**	**Sınıflandırılmış**	**Genel Doğruluk**	**Hassasiyet**	**Duyarlılık**	**F1 Skoru**
1\2	**1**	**2**							
1	110	20	1	112	130	%87,43	0,85	0,98	0,91
2	2	43	**2**	63	45		0,96	0,68	0,80

Çok ara katmanlı 10 kat çapraz doğrulama işlemi gerçekleştirilmiş GRSA'ya ait Çizelge 4.6'da karmaşıklık matrisi ve bunun sonucunda elde edilen Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, değerleri gösterilmektedir. İşlem Süresi 0,52sn sürmüş ve Sınıflandırma Doğruluğu %87,75 olarak hesaplanmıştır.

Çizelge 4.6 Çok Ara Katmanlı ve 10 Kat Çapraz Doğrulamalı GRSA Karışıklık Matrisi, Sınıflar, Gerçek Sınıf Sayıları, Tahmin Edilen Sınıf Sayıları, Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, Değerleri

Karışıklık Matrisi			**Sınıf**	**Gerçek**	**Sınıflandırılmış**	**Genel Doğruluk**	**Hassasiyet**	**Duyarlılık**	**F1 Skoru**
1\2	**1**	**2**							
1	220	38	**1**	225	258	%87,75	0,85	0,98	0,91
2	5	88	**2**	126	93		0,95	0,70	0,80

4.1.1.4. OSA için Ionosphere veri kümesi uygulaması

Bir OSA oluşturmak için gerekli olan tek parametre, ampirik olarak 0,5 olarak belirlenen yayılma parametresi belirlenmiştir. Çalışmanın sonucunda hem tek ara

katmanlı hem de 3 ara katmanlı işlem yürütülmesinden sonra elde edilen Karışıklık Matrisleri ile doğruluk *(Accuracy)*, hassasiyet *(Precision)*, Duyarlılık *(Recall)*, F1 Skor, İşlem Süresi (sn) sonuçları verilmiştir.

Tek ara katmanlı yarısı eğitim yarısı test işlemine ayrılmış OSA'ya ait Çizelge 4.7'de karmaşıklık matrisi ve bunun sonucunda elde edilen karışıklık matrisine ait Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, değerleri gösterilmektedir. İşlem Süresi 0,05 sn sürmüş ve Sınıflandırma Doğruluğu %85,14 olarak hesaplanmıştır.

Çizelge 4.7 Tek Ara Katmanlı OSA Karışıklık Matrisi, Sınıflar, Gerçek Sınıf Sayıları, Tahmin Edilen Sınıf Sayıları, Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, Değerleri

Karışıklık Matrisi			**Sınıf**	**Gerçek**	**Sınıflandırılmış**	**Genel Doğruluk**	**Hassasiyet**	**Duyarlılık**	**F1 Skoru**
1\2	**1**	**2**							
1	112	26	1	112	138	%85,14	0,81	1,0	0,90
2	0	37	**2**	63	37		1,0	0,59	0,74

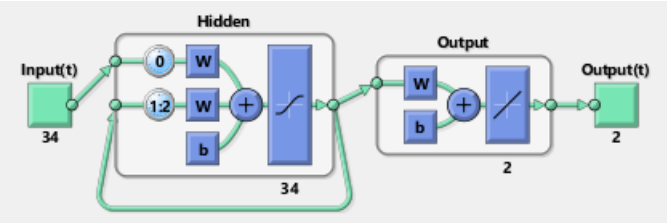
Çok ara katmanlı 10 kat çapraz doğrulama işlemi gerçekleştirilmiş OSA'ya ait Çizelge 4.8'de karmaşıklık matrisi ve bunun sonucunda elde edilen karışıklık matrisine ait Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, değerleri gösterilmektedir. İşlem Süresi 0,49 sn sürmüş ve Sınıflandırma Doğruluğu %88,32 olarak hesaplanmıştır.

Çizelge 4.8 Çok Ara Katmanlı ve 10 Kat Çapraz Doğrulamalı OSA Karışıklık Matrisi, Sınıflar, Gerçek Sınıf Sayıları, Tahmin Edilen Sınıf Sayıları, Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, Değerleri

Karışıklık Matrisi			**Sınıf**	**Gerçek**	**Sınıflandırılmış**	**Genel Doğruluk**	**Hassasiyet**	**Duyarlılık**	**F1 Skoru**
1\2	**1**	**2**							
1	220	36	**1**	225	256	%88,32	0,86	0,98	0,91
2	5	90	**2**	126	95		0,95	0,71	0,81

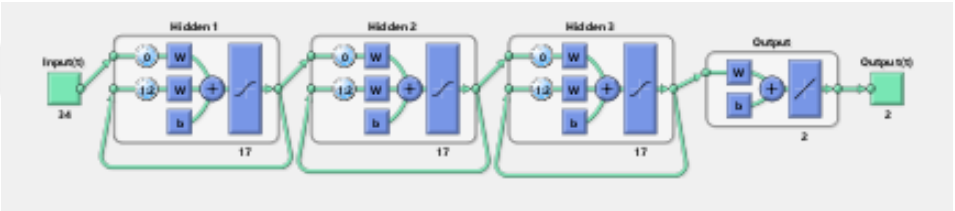
4.1.1.5. TSA için Ionosphere veri kümesi uygulaması

Matlab NNtool fonksiyonu kullanılarak parametreler dinamik yazılım vasıtasıyla istediğimiz zaman güncellenebilen bir yapıda tasarlanmıştır. Bu çalışmada ara katmandaki nöron sayısının, n giriş parametre sayısı olmak üzere n nörondan oluşacak şekilde, Tek ara katmanlı TSA Ionosphere veri kümesine göre tasarımı Şekil4.5'te gösterilmiştir.



Şekil 4.5 Tek Ara Katmanlı TSA Yapısı

Çok ara katmanlı TSA için değerlerimiz, çok fazla işlem gerçekleştirileceğinden ve giriş parametresinin çok olmasından dolayı, ara katman sayısının üç (3) olduğu birinci ara katmandaki nöron sayılarının n/2 olacak şekilde, çok ara katmanlı TSA Ionosphere veri kümesine göre tasarımı Şekil 4.6'de gösterilmiştir.



Şekil 4.6 Çok Ara Katmanlı TSA Yapısı

Çalışmanın sonucunda hem tek ara katmanlı hem de 3 ara katmanlı işlem yürütülmesinden sonra elde edilen Karışıklık Matrisleri ile doğruluk *(Accuracy)*, hassasiyet *(Precision)*, Duyarlılık *(Recall)*, F1 Skor, İşlem Süresi (sn) sonuçları verilmiştir.

Tek ara katmanlı, yarısı eğitim yarısı test işlemine ayrılmış TSA'ya ait Çizelge 4.9'da karmaşıklık matrisi ve bunun sonucunda elde edilen Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, değerleri gösterilmektedir. İşlem Süresi 11,94 sn sürmüş ve Sınıflandırma Doğruluğu %85,14 olarak hesaplanmıştır.

Çizelge 4.9 Tek Ara Katmanlı TSA Karışıklık Matrisi, Sınıflar, Gerçek Sınıf Sayıları, Tahmin Edilen Sınıf Sayıları, Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, Değerleri

Karışıklık Matrisi			**Sınıf**	**Gerçek**	**Sınıflandırılmış**	**Genel Doğruluk**	**Hassasiyet**	**Duyarlılık**	**F1 Skoru**
1\2	**1**	**2**							
1	106	20	1	112	138	%85,14	0,84	0,95	0,89
2	6	43	**2**	63	37		0,88	0,68	0,77

Çok ara katmanlı TSA çok fazla işlem tekrarı gerçekleştirildiğinden dolayı 3 kat çapraz doğrulama işlemi, ara katman sayılarını n/2=17 olacak şekilde 3 katman halinde

ve max epoks sayısını 100 ile güncelleme yapılarak gerçekleştirilmiş TSA'ya ait Çizelge 4.10'da karmaşıklık matrisi ve bunun sonucunda elde edilen Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, değerleri gösterilmektedir. İşlem Süresi 50,15 sn sürmüş ve Sınıflandırma Doğruluğu %91,74 olarak hesaplanmıştır.

.

Çizelge 4.10 Çok Ara Katmanlı ve 10 Kat Çapraz Doğrulamalı TSA Karışıklık Matrisi, Sınıflar, Gerçek Sınıf Sayıları, Tahmin Edilen Sınıf Sayıları, Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, Değerleri

Karışıklık Matrisi			**Sınıf**	**Gerçek**	**Sınıflandırılmış**	**Genel Doğruluk**	**Hassasiyet**	**Duyarlılık**	**F1 Skoru**
1\2	**1**	**2**							
1	218	22	**1**	225	240	%91,74	0,91	0,97	0,94
2	7	104	**2**	126	111		0,94	0,83	0,88

4.2. Çok Sınıflı Veri Setleri Üzerindeki Uygulamalar

İBSA, KİSA, GRSA, OSA ve TSA metotları kullanılarak 3 veya daha fazla sınıf verileri üzerinde çalışma yapmak üzere UCI Machine Learning Repostory'den makine öğrenmesi veri tabanından elde edilen iris ve şarap veri kümeleri kullanılmıştır.

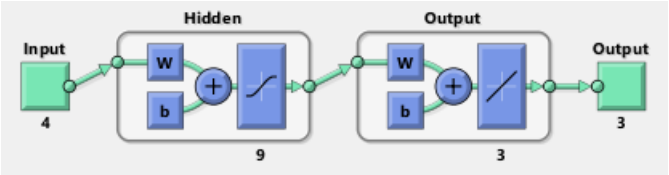
4.2.1. Iris Veri Kümesi

İBSA, KİSA, GRSA, OSA ve TSA metotlarını uygulamak üzere seçilen veri İris veri kümesidir. Bu, belki de örüntü tanıma literatüründe bulunabilecek en iyi bilinen veri tabanıdır. Fisher'in makalesi bu alanda bir klasiktir ve sık sık bu güne atıfta bulunulmaktadır (Fisher, 1936). Veri seti, her biri bir tür iris bitkisine atıfta bulunan her biri 50 örnek içeren 3 sınıf içerir. Bir sınıf diğer 2'den doğrusal olarak ayrılabilir; ikincisi birbirinden doğrusal olarak ayrılamaz. Veri setimizde 4 tane öznitelik verisi ve 3 çıkış sınıfından oluşmaktadır.

1. Çanak çömlek uzunluğu cm cinsinden
2. Sepal genişliği cm cinsinden
3. Petal uzunluğu cm cinsinden
4. Petal genişliği cm cinsinden
5. Sınıflandırma sonuçları:
   Iris Setosa (1)- Iris Versicolour (2)- Iris Virginica (3)

4.2.1.1. İBSA için iris veri kümesi uygulaması

Matlab NNtool fonksiyonu kullanılarak parametreler dinamik yazılım vasıtasıyla istediğimiz zaman güncellenebilen bir yapıda tasarlanmıştır. Bu çalışmada ara katmandaki nöron sayısının, n giriş parametre sayısı olmak üzere 2*n+1 nörondan oluşacak şekilde, Tek ara katmanlı İBSA iris veri kümesine göre tasarımı Şekil4.7'de gösterilmiştir.



Şekil 4.7 Tek Ara Katmanlı İBSA Yapısı

Çok ara katmanlı İBSA için değerlerimiz, Ara katman sayısının üç (3) olduğu, birinci ara katmandaki nöron sayısının n, iki ara katmandaki nöron sayısının 2*n ve son ara katmandaki nöron sayısı n oluşacak şekilde, çok ara katmanlı İBSA iris veri kümesine göre tasarımı Şekil 4.8'de gösterilmiştir.



Şekil 4.8 Çok Ara Katmanlı İBSA Yapısı

Çalışmanın sonucunda hem tek ara katmanlı hem de 3 ara katmanlı işlem yürütülmesinden sonra elde edilen Karışıklık Matrisleri ile doğruluk *(Accuracy),* hassasiyet *(Precision),* Duyarlılık *(Recall),* F1 Skor, İşlem Süresi (sn) sonuçları verilmiştir.

Tek ara katmanlı yarısı eğitim yarısı test işlemine ayrılmış İBSA'ya ait Çizelge 4.11'de karmaşıklık matrisi ve bunun sonucunda elde edilen Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, değerleri gösterilmektedir. İşlem Süresi 4,37 sn sürmüştür ve sınıflama doğruluğu %93,33'tür.

Çizelge 4.11 Tek Ara Katmanlı İBSA Karışıklık Matrisi, Sınıflar, Gerçek Sınıf Sayıları, Tahmin Edilen Sınıf Sayıları, Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, Değerleri

Karışıklık Matrisi				Sınıf	Gerçek	Sınıflandırılmış	Genel Doğruluk	Hassasiyet	Duyarlılık	F1 Skoru
	1	2	3							
1	25	0	0	**1**	25	25	93,33%	1,0	1,0	1,0
2	0	23	3	**2**	25	26		0,88	0,92	0,90
3	0	2	22	**3**	25	24		0,92	0,88	0,90

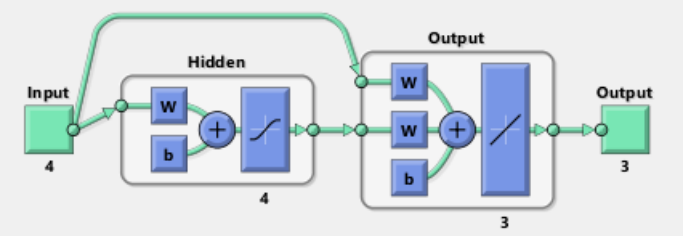
Çok ara katmanlı 10 kat çapraz doğrulama işlemi gerçekleştirilmiş İBSA'ya ait Çizelge 4.12'de karmaşıklık matrisi ve bunun sonucunda elde edilen Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, değerleri gösterilmektedir. İşlem Süresi 2,76 sn sürmüştür ve sınıflama doğruluğu %98'dir.

Çizelge 4.12 Çok Ara Katmanlı ve 10 Kat Çapraz Doğrulamalı İBSA Karışıklık Matrisi, Sınıflar, Gerçek Sınıf Sayıları, Tahmin Edilen Sınıf Sayıları, Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, Değerleri

				Sınıf	Gerçek	Sınıflandırılmış	Genel Doğruluk	Hassasiyet	Duyarlılık	F1 Skoru
	1	2	3							
1	50	0	0	**1**	50	50	98%	1,0	1,0	1,0
2	0	48	1	**2**	50	49		0,98	0,96	0,97
3	0	2	49	**3**	50	51		0,96	0,980	0,97

4.2.1.2. KİSA için iris veri kümesi uygulaması

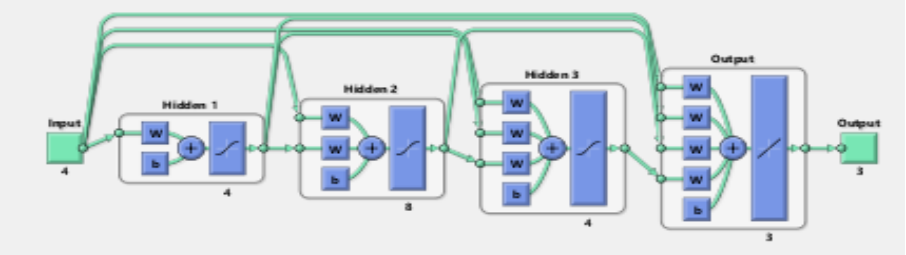
Matlab NNtool fonksiyonu kullanılarak parametreler dinamik yazılım vasıtasıyla istediğimiz zaman güncellenebilen bir yapıda tasarlanmıştır. Bu çalışmada ara katmandaki nöron sayısının, n giriş parametre sayısı olmak üzere 2*n+1 nörondan oluşacak şekilde, Tek ara katmanlı KİSA iris veri kümesine göre tasarımı Şekil 4.9'da gösterilmiştir.



Şekil 4.9 Tek Ara Katmanlı KİSA Yapısı

Çok ara katmanlı KİSA için değerlerimiz, Ara katman sayısının üç (3) olduğu, birinci ara katmandaki nöron sayısının n, iki ara katmandaki nöron sayısının 2*n ve son

ara katmandaki nöron sayısı n oluşacak şekilde, çok ara katmanlı KİSA iris veri kümesine göre tasarımı Şekil 4.10'da gösterilmiştir.



Şekil 4.10 Çok Ara Katmanlı KİSA Yapısı

Çalışmanın sonucunda hem tek ara katmanlı hem de 3 ara katmanlı işlem yürütülmesinden sonra elde edilen Karışıklık Matrisleri ile doğruluk (*Accuracy*), hassasiyet *(Precision)*, Duyarlılık *(Recall),* F1 Skor, İşlem Süresi (sn) sonuçları verilmiştir.

Tek ara katmanlı yarısı eğitim yarısı test işlemine ayrılmış KİSA'ya ait Çizelge 4.13'te karmaşıklık matrisi ve bunun sonucunda elde edilen Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, değerleri gösterilmektedir. İşlem Süresi 0,44 sn sürmüştür ve sınıflama doğruluğu %93,33'tür.

Çizelge 4.13 Tek Ara Katmanlı KİSA Karışıklık Matrisi, Sınıflar, Gerçek Sınıf Sayıları, Tahmin Edilen Sınıf Sayıları, Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, Değerleri

Karışıklık Matrisi				**Sınıf**	**Gerçek**	**Sınıflandırılmış**	**Genel Doğruluk**	**Hassasiyet**	**Duyarlılık**	**F1 Skoru**
	1	**2**	**3**							
1	25	0	0	**1**	25	25	93,33%	1,0	1,0	1,0
2	0	23	3	**2**	25	25		0,88	0,92	0,90
3	0	2	22	**3**	25	25		0,92	0,88	0,90

Çok ara katmanlı 10 kat çapraz doğrulama işlemi gerçekleştirilmiş KİSA'ya ait Çizelge 4.14'de karmaşıklık matrisi ve bunun sonucunda elde edilen Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, değerleri gösterilmektedir. İşlem Süresi 5,25 sn sürmüş ve sınıflama doğruluğu %98'dir.

Çizelge 4.14 Çok Ara Katmanlı ve 10 Kat Çapraz Doğrulamalı KİSA Karışıklık Matrisi, Sınıflar, Gerçek Sınıf Sayıları, Tahmin Edilen Sınıf Sayıları, Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, Değerleri

Karışıklık Matrisi				**Sınıf**	**Gerçek**	**Sınıflandırılmış**	**Genel Doğruluk**	**Hassasiyet**	**Duyarlılık**	**F1 Skoru**
	1	**2**	**3**							
1	50	0	0	1	50	50	98%	1,0	1,0	1,0
2	0	48	1	**2**	50	50		0,96	0,98	0,96
3	0	2	49	3	50	50		0,98	0,96	0,96

4.2.1.3. GRSA için iris veri kümesi uygulaması

Bir GRSA oluşturmak için gerekli olan tek parametre, ampirik olarak 0,5 olarak belirlenen yayılma parametresi belirlenmiştir. Çalışmanın sonucunda hem tek ara katmanlı hem de 3 ara katmanlı işlem yürütülmesinden sonra elde edilen Karışıklık Matrisleri ile doğruluk *(Accuracy)*, hassasiyet *(Precision)* , Duyarlılık *(Recall)*, F1 Skor, İşlem Süresi (sn) sonuçları verilmiştir.

Tek ara katmanlı yarısı eğitim yarısı test işlemine ayrılmış GRSA'ya ait Çizelge 4.15'te karmaşıklık matrisi ve bunun sonucunda elde edilen Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, değerleri gösterilmektedir. İşlem Süresi 0,37 sn sürmüş ve sınıflandırma doğruluğu %96'dır.

Çizelge 4.15. Tek Ara Katmanlı GRSA Karışıklık Matrisi, Sınıflar, Gerçek Sınıf Sayıları, Tahmin Edilen Sınıf Sayıları, Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, Değerleri

Karışıklık Matrisi				**Sınıf**	**Gerçek**	**Sınıflandırılmış**	**Genel Doğruluk**	**Hassasiyet**	**Duyarlılık**	**F1 Skoru**
	1	**2**	**3**							
1	25	0	0	1	25	25	96,00%	1,0	1,0	1,0
2	0	24	2	**2**	25	26		0,92	0,96	0,94
3	0	1	23	3	25	24		0,96	0,92	0,94

Çok ara katmanlı 10 kat çapraz doğrulama işlemi gerçekleştirilmiş GRSA'ya ait Çizelge 4.16'da karmaşıklık matrisi ve bunun sonucunda elde edilen Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, değerleri gösterilmektedir. İşlem Süresi 0,57 sn sürmüş ve sınıflandırma doğruluğu %96,67'dir.

Çizelge 4.16 Çok Ara Katmanlı ve 10 Kat Çapraz Doğrulamalı GRSA Karışıklık Matrisi, Sınıflar, Gerçek Sınıf Sayıları, Tahmin Edilen Sınıf Sayıları, Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, Değerleri

Karışıklık Matrisi				**Sınıf**	**Gerçek**	**Sınıflandırılmış**	**Genel Doğruluk**	**Hassasiyet**	**Duyarlılık**	**F1 Skoru**
	1	**2**	**3**							
1	50	0	0	1	50	50	96,67%	1,0	1,0	1,0
2	0	48	3	**2**	50	51		0,96	0,94	0,95
3	0	2	47	3	50	49		0,94	0,96	0,95

4.2.1.4. OSA için iris veri kümesi uygulaması

Bir OSA oluşturmak için gerekli olan tek parametre, ampirik olarak 0,5 olarak belirlenen yayılma parametresi belirlenmiştir. Çalışmanın sonucunda hem tek ara katmanlı hem de 3 ara katmanlı işlem yürütülmesinden sonra elde edilen Karışıklık Matrisleri ile doğruluk *(Accuracy)*, hassasiyet *(Precision)*, Duyarlılık *(Recall)*, F1 Skor, İşlem Süresi (sn) sonuçları verilmiştir.

Tek ara katmanlı yarısı eğitim yarısı test işlemine ayrılmış OSA'ya ait Çizelge 4.17'de karmaşıklık matrisi ve bunun sonucunda elde edilen Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, değerleri gösterilmektedir. İşlem Süresi 0,16 sn sürmüş ve sınıflandırma doğruluğu %96'dır.

Çizelge 4.17 Tek Ara Katmanlı OSA Karışıklık Matrisi, Sınıflar, Gerçek Sınıf Sayıları, Tahmin Edilen Sınıf Sayıları, Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, Değerleri

Karışıklık Matrisi				**Sınıf**	**Gerçek**	**Sınıflandırılmış**	**Genel Doğruluk**	**Hassasiyet**	**Duyarlılık**	**F1 Skoru**
	1	**2**	**3**							
1	25	0	0	1	25	25	96%	1,0	1,0	1,0
2	0	24	2	**2**	25	26		0,96	0,92	0,94
3	0	1	23	3	25	24		0,92	0,96	0,94

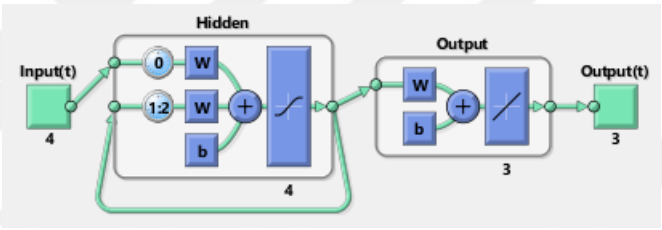
Çok ara katmanlı 10 kat çapraz doğrulama işlemi gerçekleştirilmiş OSA'ya ait Çizelge 4.18'de karmaşıklık matrisi ve bunun sonucunda elde edilen Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, değerleri gösterilmektedir. İşlem Süresi 0,50 sn sürmüş ve sınıflandırma doğruluğu %98,67'dir.

Çizelge 4.18 Çok Ara Katmanlı ve 10 Kat Çapraz Doğrulamalı OSA Karışıklık Matrisi, Sınıflar, Gerçek Sınıf Sayıları, Tahmin Edilen Sınıf Sayıları, Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, Değerleri

Karışıklık Matrisi				Sınıf	Gerçek	Sınıflandırılmış	Genel Doğruluk	Hassasiyet	Duyarlılık	F1 Skoru
	1	2	3							
1	50	0	0	1	50	50	98,67%	1,0	1,0	1,0
2	0	49	1	2	50	50		0,98	0,98	0,98
3	0	1	49	3	50	50		0,98	0,98	0,98

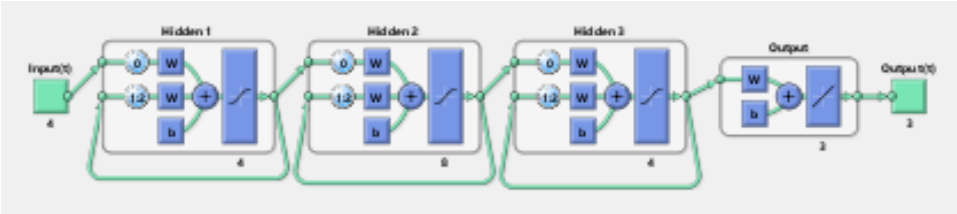
4.2.1.5. TSA için iris veri kümesi uygulaması

Matlab NNtool fonksiyonu kullanılarak parametreler dinamik yazılım vasıtasıyla istediğimiz zaman güncellenebilen bir yapıda tasarlanmıştır. Bu çalışmada ara katmandaki nöron sayısının, n giriş parametre sayısı olmak üzere n nörondan oluşacak şekilde, Tek ara katmanlı TSA iris veri kümesine göre tasarımı Şekil4.11'de gösterilmiştir.



Şekil 4.11 Tek Ara Katmanlı TSA Yapısı

Çok ara katmanlı TSA için değerlerimiz, Ara katman sayısının üç (3) olduğu, birinci ara katmandaki nöron sayısının n, iki ara katmandaki nöron sayısının 2*n ve son ara katmandaki nöron sayısı n oluşacak şekilde, çok ara katmanlı TSA iris veri kümesine göre tasarımı Şekil 4.12'de gösterilmiştir.



Şekil 4.12 Çok Ara Katmanlı TSA Yapısı

Çalışmanın sonucunda hem tek ara katmanlı hem de 3 ara katmanlı işlem yürütülmesinden sonra elde edilen Karışıklık Matrisleri ile doğruluk *(Accuracy)*,

hassasiyet *(Precision)*, Duyarlılık *(Recall)*, F1 Skor, İşlem Süresi (sn) sonuçları verilmiştir.

Tek ara katmanlı yarısı eğitim yarısı test işlemine ayrılmış TSA'ya ait Çizelge 4.19'da karmaşıklık matrisi ve bunun sonucunda elde edilen Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, değerleri gösterilmektedir. İşlem Süresi 0,65 sn sürmüş ve sınıflandırma doğruluğu %98,67'dır.

Çizelge 4.19 Tek Ara Katmanlı TSA Karışıklık Matrisi, Sınıflar, Gerçek Sınıf Sayıları, Tahmin Edilen Sınıf Sayıları, Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, Değerleri

Karışıklık Matrisi				**Sınıf**	**Gerçek**	**Sınıflandırılmış**	**Genel Doğruluk**	**Hassasiyet**	**Duyarlılık**	**F1 Skoru**
	1	**2**	**3**							
1	25	0	0	1	25	25	98,67%	1,0	1,0	1,0
2	0	24	0	**2**	25	24		1,0	0,96	0,98
3	0	1	25	3	25	26		0,96	1,0	0,98

Çok ara katmanlı TSA'ya ait Çizelge 4.20'de karmaşıklık matrisi ve bunun sonucunda elde edilen karışıklık matrisine ait Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, değerleri gösterilmektedir. İşlem Süresi 4,98 sn sürmüş ve sınıflandırma doğruluğu %100'dür.

Çizelge 4.20 Çok Ara Katmanlı ve 10 Kat Çapraz Doğrulamalı TSA Karışıklık Matrisi, Sınıflar, Gerçek Sınıf Sayıları, Tahmin Edilen Sınıf Sayıları, Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, Değerleri

Karışıklık Matrisi				**Sınıf**	**Gerçek**	**Sınıflandırılmış**	**Genel Doğruluk**	**Hassasiyet**	**Duyarlılık**	**F1 Skoru**
	1	**2**	**3**							
1	50	0	0	1	50	50	100%	1,0	1,0	1,0
2	0	50	0	**2**	50	50		1,0	1,0	1,0
3	0	0	50	3	50	50		1,0	1,0	1,0

4.2.2. Şarap Veri Kümesi

İBSA, KİSA, GRSA, OSA ve TSA metotlarını uygulamak üzere seçilen veri şarap veri kümesidir (Forina, 1991). Bu veriler, İtalya'da aynı bölgede yetiştirilen ancak üç farklı çeşitten elde edilen şarapların kimyasal analizinin sonuçlarıdır. Analiz, üç şarap türünün her birinde bulunan 13 bileşenin miktarlarını belirledi. Veri setimiz 13 öznitelik ve 178 örnekten oluşmaktadır. 3 farklı sınıftan oluşmaktadır. Öznitelikler aşağıdaki şekilde sıralanmıştır.

1) Alkol

2) Malik asit

3) Kül

4) Külün alkalinitesi

5) Magnezyum

6) Toplam fenoller

7) Flavanoidler

8) Flavanoid olmayan fenoller

9) Proantosiyaninler

10) Renk yoğunluğu

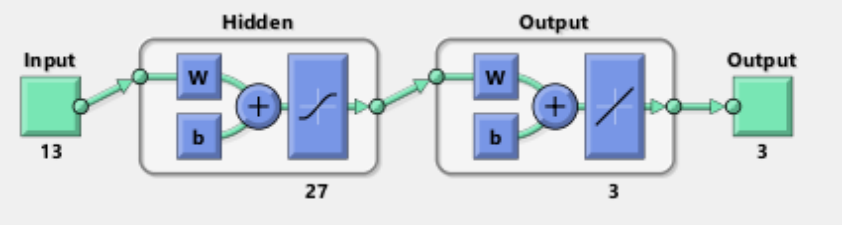
11) Ton

12) Seyreltilmiş şarapların OD280 / OD315'i

13) Prolins Virginica

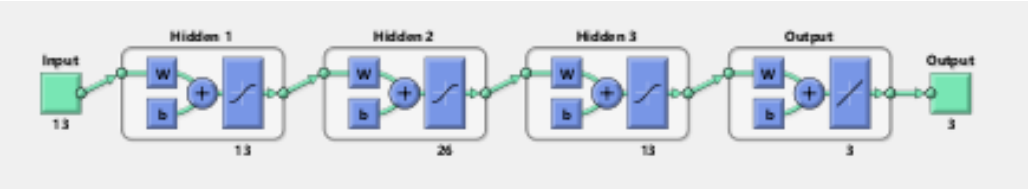
4.2.2.1. İBSA'nın için şarap veri kümesi uygulaması

Matlab NNtool fonksiyonu kullanılarak parametreler dinamik yazılım vasıtasıyla istediğimiz zaman güncellenebilen bir yapıda tasarlanmıştır. Bu çalışmada ara katmandaki nöron sayısının, n giriş parametre sayısı olmak üzere 2*n+1 nörondan oluşacak şekilde, Tek ara katmanlı İBSA iris veri kümesine göre tasarımı Şekil 4.13'te gösterilmiştir.



Şekil 4.13 Tek Ara Katmanlı İBSA Yapısı

Çok ara katmanlı İBSA için değerlerimiz, Ara katman sayısının üç (3) olduğu, birinci ara katmandaki nöron sayısının n, iki ara katmandaki nöron sayısının 2*n ve son ara katmandaki nöron sayısı n oluşacak şekilde, çok ara katmanlı İBSA iris veri kümesine göre tasarımı Şekil 4.14'te gösterilmiştir.



Şekil 4.14 Çok Ara Katmanlı İBSA Yapısı

Çalışmanın sonucunda hem tek ara katmanlı hem de 3 ara katmanlı işlem yürütülmesinden sonra elde edilen Karışıklık Matrisleri ile doğruluk *(Accuracy)*, hassasiyet *(Precision)*, Duyarlılık *(Recall)*, F1 Skor, İşlem Süresi (sn) sonuçları verilmiştir.

Tek ara katmanlı yarısı eğitim yarısı test işlemine ayrılmış İBSA'ya ait Çizelge 4.21'de karmaşıklık matrisi ve bunun sonucunda elde edilen Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, değerleri gösterilmektedir. İşlem Süresi 0,55 sn sürmüştür ve sınıflama doğruluğu %96,63'tür.

Çizelge 4.21 Tek Ara Katmanlı İBSA Karışıklık Matrisi, Sınıflar, Gerçek Sınıf Sayıları, Tahmin Edilen Sınıf Sayıları, Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, Değerleri

Karışıklık Matrisi				**Sınıf**	**Gerçek**	**Sınıflandırılmış**	**Genel Doğruluk**	**Hassasiyet**	**Duyarlılık**	**F1 Skoru**
	1	**2**	**3**							
1	29	3	0	1	29	32	96,63%	0,91	1,0	0,95
2	0	33	0	**2**	35	33		1,0	0,92	0,96
3	0	0	24	3	25	24		1,0	1,0	1,0

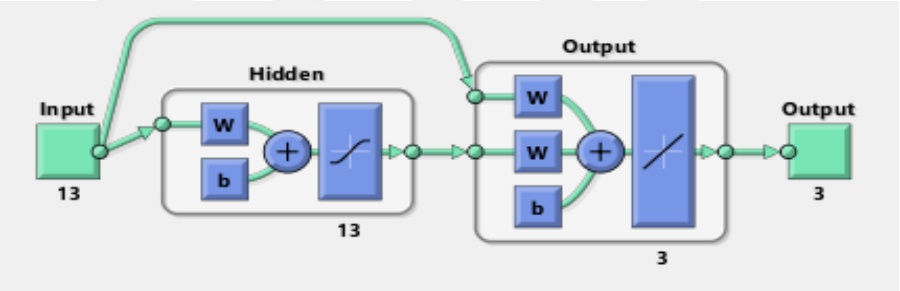
Çok ara katmanlı 10 kat çapraz doğrulama işlemi gerçekleştirilmiş İBSA'ya ait Çizelge 4.22'de karmaşıklık matrisi ve bunun sonucunda elde edilen Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, değerleri gösterilmektedir. İşlem Süresi 8,54sn sürmüştür ve sınıflama doğruluğu %99,44'tür.

Çizelge 4.22 Çok Ara Katmanlı ve 10 Kat Çapraz Doğrulamalı İBSA Karışıklık Matrisi, Sınıflar, Gerçek Sınıf Sayıları, Tahmin Edilen Sınıf Sayıları, Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, Değerleri

Karışıklık Matrisi				Sınıf	Gerçek	Sınıflandırılmış	Genel Doğruluk	Hassasiyet	Duyarlılık	F1 Skoru
	1	2	3							
1	59	1	0	1	59	60	99,44%	0,98	1,0	0,99
2	0	70	0	**2**	70	70		1,0	0,99	0,99
3	0	0	48	3	48	48		1,0	1,0	1,0

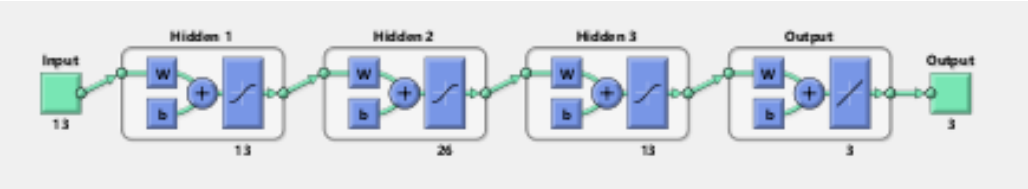
4.2.2.2. KİSA'nın için şarap veri kümesi uygulaması

Matlab NNtool fonksiyonu kullanılarak parametreler dinamik yazılım vasıtasıyla istediğimiz zaman güncellenebilen bir yapıda tasarlanmıştır. Bu çalışmada ara katmandaki nöron sayısının, n giriş parametre sayısı olmak üzere n nörondan oluşacak şekilde, Tek ara katmanlı KİSA iris veri kümesine göre tasarımı Şekil 4.15'te gösterilmiştir.



Şekil 4.15 Tek Ara Katmanlı KİSA Yapısı

Çok ara katmanlı KİSA için değerlerimiz, Ara katman sayısının üç (3) olduğu, birinci ara katmandaki nöron sayısının n, iki ara katmandaki nöron sayısının 2*n ve son ara katmandaki nöron sayısı n oluşacak şekilde, çok ara katmanlı KİSA iris veri kümesine göre tasarımı Şekil 4.16'da gösterilmiştir.



Şekil 4.16 Çok Ara Katmanlı KİSA Yapısı

Çalışmanın sonucunda hem tek ara katmanlı hem de 3 ara katmanlı işlem yürütülmesinden sonra elde edilen Karışıklık Matrisleri ile doğruluk *(Accuracy)*, hassasiyet *(Precision)*, Duyarlılık *(Recall)*, F1 Skor, İşlem Süresi (sn) sonuçları verilmiştir.

Tek ara katmanlı yarısı eğitim yarısı test işlemine ayrılmış KİSA'ya ait Çizelge 4.23'te karmaşıklık matrisi ve bunun sonucunda elde edilen Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, değerleri gösterilmektedir. İşlem Süresi 0,27 sn sürmüştür ve sınıflama doğruluğu %96,63'tür.

Çizelge 4.23 Tek Ara Katmanlı KİSA Karışıklık Matrisi, Sınıflar, Gerçek Sınıf Sayıları, Tahmin Edilen Sınıf Sayıları, Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, Değerleri

Karışıklık Matrisi				Sınıf	Gerçek	Sınıflandırılmış	Genel Doğruluk	Hassasiyet	Duyarlılık	F1 Skoru
	1	**2**	**3**							
1	29	2	0	1	29	31	96,63%	0,94	1,0	0,97
2	0	33	1	**2**	36	34		0,97	0,94	0,96
3	0	0	24	3	24	24		1,0	0,96	0,98

Çok ara katmanlı 10 kat çapraz doğrulama işlemi gerçekleştirilmiş KİSA'ya ait Çizelge 4.24'te karmaşıklık matrisi ve bunun sonucunda elde edilen Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, değerleri gösterilmektedir. İşlem Süresi 19,82 sn sürmüş ve sınıflama doğruluğu %99,44'tür.

Çizelge 4.24 Çok Ara Katmanlı ve 10 Kat Çapraz Doğrulamalı KİSA Karışıklık Matrisi, Sınıflar, Gerçek Sınıf Sayıları, Tahmin Edilen Sınıf Sayıları, Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, Değerleri

Karışıklık Matrisi				Sınıf	Gerçek	Sınıflandırılmış	Genel Doğruluk	Hassasiyet	Duyarlılık	F1 Skoru
	1	**2**	**3**							
1	59	1	0	1	59	60	99,44%	0,98	1,0	0,99
2	0	70	0	**2**	70	70		1,0	0,99	0,99
3	0	0	48	3	48	48		1,0	1,0	1,0

4.2.2.3. GRSA'nın için şarap veri kümesi uygulaması

Bir GRSA oluşturmak için gerekli olan tek parametre, ampirik olarak 1 olarak belirlenen yayılma parametresi belirlenmiştir. Çalışmanın sonucunda hem tek ara katmanlı hem de 3 ara katmanlı işlem yürütülmesinden sonra elde edilen Karışıklık Matrisleri ile doğruluk *(Accuracy)*, hassasiyet *(Precision)*, Duyarlılık *(Recall)*, F1 Skor, İşlem Süresi (sn) sonuçları verilmiştir.

Tek ara katmanlı yarısı eğitim yarısı test işlemine ayrılmış GRSA'ya ait Çizelge 4.25'te karmaşıklık matrisi ve bunun sonucunda elde edilen Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, değerleri gösterilmektedir. İşlem Süresi 0,37 sn sürmüş ve sınıflandırma doğruluğu %80,9'dur.

Çizelge 4.25 Tek Ara Katmanlı GRSA Karışıklık Matrisi, Sınıflar, Gerçek Sınıf Sayıları, Tahmin Edilen Sınıf Sayıları, Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, Değerleri

Karışıklık Matrisi				**Sınıf**	**Gerçek**	**Sınıflandırılmış**	**Genel Doğruluk**	**Hassasiyet**	**Duyarlılık**	**F1 Skoru**
	1	**2**	**3**							
1	25	0	1	1	30	26		0,96	0,83	0,89
2	3	27	6	**2**	35	36	80,9%	0,75	0,77	0,76
3	2	8	17	3	24	27		0,63	0,71	0,67

Çok ara katmanlı 10 kat çapraz doğrulama işlemi gerçekleştirilmiş GRSA'ya ait Çizelge 4.26'da karmaşıklık matrisi ve bunun sonucunda elde edilen Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, değerleri gösterilmektedir. İşlem Süresi 0,57sn sürmüş ve sınıflandırma doğruluğu %78,09'dur.

Çizelge 4.26 Çok Ara Katmanlı ve 10 Kat Çapraz Doğrulamalı GRSA Karışıklık Matrisi, Sınıflar, Gerçek Sınıf Sayıları, Tahmin Edilen Sınıf Sayıları, Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, Değerleri

Karışıklık Matrisi				**Sınıf**	**Gerçek**	**Sınıflandırılmış**	**Genel Doğruluk**	**Hassasiyet**	**Duyarlılık**	**F1 Skoru**
	1	**2**	**3**							
1	51	4	3	1	59	58		0,88	0,86	0,87
2	3	56	13	**2**	71	72	78,09%	0,78	0,79	0,78
3	5	11	32	3	48	48		0,67	0,67	0,67

4.2.2.4. OSA'nın için şarap veri kümesi uygulaması

Bir OSA oluşturmak için gerekli olan tek parametre, ampirik 1 olarak belirlenen yayılma parametresi belirlenmiştir. Çalışmanın sonucunda hem tek ara katmanlı hem de 3 ara katmanlı işlem yürütülmesinden sonra elde edilen Karışıklık Matrisleri ile doğruluk *(Accuracy)*, hassasiyet *(Precision)*, Duyarlılık *(Recall)*, F1 Skor, İşlem Süresi (sn) sonuçları verilmiştir.

Tek ara katmanlı yarısı eğitim yarısı test işlemine ayrılmış OSA'ya ait Çizelge 4.27'de karmaşıklık matrisi ve bunun sonucunda elde edilen Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, değerleri gösterilmektedir. İşlem Süresi 0,07 sn sürmüş ve sınıflandırma doğruluğu %73,03'tür.

Çizelge 4.27 Tek Ara Katmanlı OSA Karışıklık Matrisi, Sınıflar, Gerçek Sınıf Sayıları, Tahmin Edilen Sınıf Sayıları, Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, Değerleri

Karışıklık Matrisi				Sınıf	Gerçek	Sınıflandırılmış	Genel Doğruluk	Hassasiyet	Duyarlılık	F1 Skoru
	1	2	3							
1	25	1	0	1	29	26	73,03%	0,96	0,86	0,94
2	0	29	13	**2**	36	42		0,69	0,81	0,74
3	4	6	11	3	24	21		0,52	0,46	0,49

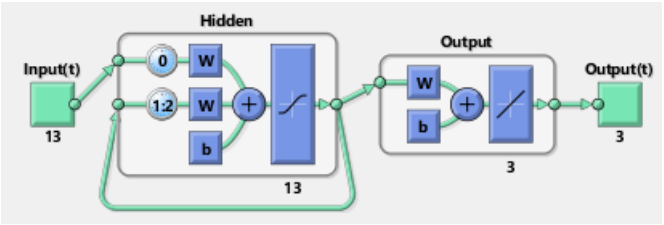
Çok ara katmanlı 10 kat çapraz doğrulama işlemi gerçekleştirilmiş OSA'ya ait Çizelge 4.28'de karmaşıklık matrisi ve bunun sonucunda elde edilen Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, değerleri gösterilmektedir. İşlem Süresi 0,52sn sürmüş ve sınıflandırma doğruluğu %74,12'dir.

Çizelge 4.28 Çok Ara Katmanlı ve 10 Kat Çapraz Doğrulamalı OSA Karışıklık Matrisi, Sınıflar, Gerçek Sınıf Sayıları, Tahmin Edilen Sınıf Sayıları, Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, Değerleri

Karışıklık Matrisi				Sınıf	Gerçek	Sınıflandırılmış	Genel Doğruluk	Hassasiyet	Duyarlılık	F1 Skoru
	1	2	3							
1	50	5	3	1	59	58	74,12%	0,86	0,85	0,85
2	3	51	14	**2**	71	68		0,75	0,72	0,73
3	6	15	31	3	48	52		0,60	0,65	0,62

4.2.2.5. TSA'nın için şarap veri kümesi uygulaması

Matlab NNtool fonksiyonu kullanılarak parametreler dinamik yazılım vasıtasıyla istediğimiz zaman güncellenebilen bir yapıda tasarlanmıştır. Bu çalışmada ara katmandaki nöron sayısının, n giriş parametre sayısı olmak üzere n nörondan oluşacak şekilde, Tek ara katmanlı TSA iris veri kümesine göre tasarımı Şekil4.17'de gösterilmiştir.



Şekil 4.17 Tek Ara Katmanlı TSA Yapısı

Çok ara katmanlı TSA için değerlerimiz, Ara katman sayısının üç (3) olduğu, birinci ara katmandaki nöron sayısının n, iki ara katmandaki nöron sayısının 2*n ve son

ara katmandaki nöron sayısı n oluşacak şekilde, çok ara katmanlı TSA iris veri kümesine göre tasarımı Şekil 4.18'de gösterilmiştir.



Şekil 4.18 Çok Ara Katmanlı TSA Yapısı

Çalışmanın sonucunda hem tek ara katmanlı hem de 3 ara katmanlı işlem yürütülmesinden sonra elde edilen Karışıklık Matrisleri ile doğruluk *(Accuracy)*, hassasiyet *(Precision)*, Duyarlılık *(Recall)*, F1 Skor, İşlem Süresi (sn) sonuçları verilmiştir.

Tek ara katmanlı yarısı eğitim yarısı test işlemine ayrılmış TSA'ya ait Çizelge 4.29'da karmaşıklık matrisi ve bunun sonucunda elde edilen Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, değerleri gösterilmektedir. İşlem Süresi 0,49 sn sürmüş ve sınıflandırma doğruluğu %95,51'dır.

Çizelge 4.29 Tek Ara Katmanlı TSA Karışıklık Matrisi, Sınıflar, Gerçek Sınıf Sayıları, Tahmin Edilen Sınıf Sayıları, Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, Değerleri

Karışıklık Matrisi				**Sınıf**	**Gerçek**	**Sınıflandırılmış**	**Genel Doğruluk**	**Hassasiyet**	**Duyarlılık**	**F1 Skoru**
	1	**2**	**3**							
1	30	1	0	1	30	31	95,51%	0,97	1,0	0,98
2	0	31	0	**2**	35	31		1,0	0,89	0,94
3	0	3	24	3	24	27		0,89	1,0	0,94

Çok ara katmanlı TSA'ya ait Çizelge 4.30'da karmaşıklık matrisi ve bunun sonucunda elde edilen Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, değerleri gösterilmektedir. İşlem Süresi 269,66 sn sürmüş ve sınıflandırma doğruluğu %100'dür.

Çizelge 4.30 Çok Ara Katmanlı ve 10 Kat Çapraz Doğrulamalı TSA Karışıklık Matrisi, Sınıflar, Gerçek Sınıf Sayıları, Tahmin Edilen Sınıf Sayıları, Doğruluk, Hassasiyet, Duyarlılık ve F1-Skor, Değerleri

Karışıklık Matrisi				**Sınıf**	**Gerçek**	**Sınıflandırılmış**	**Genel Doğruluk**	**Hassasiyet**	**Duyarlılık**	**F1 Skoru**
	1	**2**	**3**							
1	59	0	0	1	59	59	100%	1	1	1
2	0	71	0	**2**	71	71		1	1	1
3	0	0	48	3	48	48		1	1	1

5. SONUÇLAR VE ÖNERİLER

5.1 Sonuçlar

YSA'nın makine öğrenmesindeki en çok kullanılan sınıflandırma problemlerinden bir tanesidir. Literatürde YSA eğitilmesinde ve sınıflandırma problemlerinde kullanılmak üzere birçok algoritma geliştirilmiştir. Çalışmamızda YSA eğitilmesinde geliştirilen İBSA, KİSA, GRSA, OSA ve TSA metotları ile UCI Machine Learning Repository'de yar alan 3 veri kümesi üzerinde uygulanmış çalışma performansları incelenmiştir. Yapılan çalışmalar neticesinde:

Ionosphere veri kümesi üzerinde Tek Ara Katmanlı metotlardan %88,57 ile en yüksek doğruluk derecesi İBSA metodu ile sağlanırken, Çok Ara Katmanlı ve 10 Kat Çapraz Doğrulama kullanan metotlardan %96,58 ile en yüksek doğruluk derecesine KİSA metodu ulaşmıştır.

Iris veri kümesi üzerinde Tek Ara Katmanlı metotlardan %98,67 ile en yüksek doğruluk derecesi TSA metodu ile sağlanırken, Çok Ara Katmanlı ve 10 Kat Çapraz Doğrulama kullanan metotlardan %100 ile en yüksek doğruluk derecesine TSA metodu ulaşmıştır.

Şarap veri kümesi üzerinde Tek Ara Katmanlı metotlardan %96,63 ile en yüksek doğruluk derecesine İBSA ve KİSA metotları ile sağlanırken, Çok Ara Katmanlı ve 10 Kat Çapraz Doğrulama kullanan metotlardan %100 ile en yüksek doğruluk derecesine TSA metodu ulaşmıştır.

5.2 Tartışma

Literatürde aynı veri setleri ile yapılan çalışmalarla karşılaştırıldığında;

Ionosphere veri seti için Dhande ve Dandekar (2011) yapmış olduğu "İyonosferden Radar Getirilerinin Sınıflandırılması için Optimal Sınıflandırıcı Olarak PSO Tabanlı SVM" adlı çalışmada %82,78 bir doğruluk değeri elde etmişlerdir (Dhande ve Dandekar, 2011). Çalışmamızda 10kat çapraz doğrulama yöntemiyle %96,58 bir doğruluk oranına ulaşılmıştır.

Iris veri seti için Devasene ve ark. (2011) yapmış olduğu "Kural Tabanlı Sınıflandırıcıların Etkinlik Değerlendirmesi" adlı çalışmada %96 en yüksek sınıflandırma oranını İç İçe Olmayan Genelleştirilmiş Örnekler (NNGE) sınıflandırma yöntemini kullanarak elde etmişlerdir (Devasena ve ark., 2011). Çalışmamızda iris veri seti için %100 doğruluk ile sınıflandırma işleminde ciddi bir başarı oranı elde edilmiştir.

Şarap veri seti için Panahi ve ark. (2011) yapmış olduğu “PCA, LDA ve çeşitli sınıflandırıcılar kullanılarak farklı veri kümelerinin tanınması” adlı çalışmada %100 en yüksek sınıflandırma oranını elde etmişlerdir (Panahi ve ark., 2011). Çalışmamızda iris veri seti için %100 doğruluk ile sınıflandırma işleminde aynı başarı oranı elde edilmiştir.

Yapmış olduğumuz çalışmada kullanılan yapay sinir ağı metotları ile başarılı sonuçlar elde edildiği görülmüştür.

5.3 Öneriler

Sonuçlar incelediğimizde hala bazı veri kümelerinde ve YSA metotlarında %100 başarıya hepsinin ulaşılamadığı görülmektedir. Bu yüzden YSA eğitilmesi için geliştirilecek metotların ve algoritmaların olabileceği görülmektedir.

Yaptığımız çalışma neticesinde işlem süreleri dikkate alındığında 10 Kat Çapraz Doğrulama sistemlerinin doğal olarak daha uzun süre aldıkları görülmektedir. Ancak elde ettikleri doğruluk dereceleri bakımından daha iyi ve güvenilir sonuçlar ürettiği söylenebilir. Bu yüzden sınıflandırma problemlerinin güvenilirliğini açıklamak adına 10 Kat Çapraz Doğrulama yöntemlerini kullanan YSA metotlarının kullanılmasını öneriyoruz.

KAYNAKLAR

Abiodun, O. I., Jantan, A., Omolara, A. E., Dada, K. V., Mohamed, N. A. ve Arshad, H., 2018, State-of-the-art in artificial neural network applications: A survey, *Heliyon*, 4 (11), e00938.

Ağyar, Z., 2015, Yapay sinir ağlarının kullanım alanları ve bir uygulama, *Mühendis ve Makine*, 56 (662), 22-23.

Alakoç, Y., Akdoğan, V., Korkmaz, M. ve Er, O., 2018, Osteoporoz Ön Tanısının Olasılıksal Sinir Ağları (OSA) Yardımıyla Gerçekleştirilmesi, *Sakarya University Journal of Computer and Information Sciences*, 1 (3), 1-6.

Aljarah, I., Faris, H. ve Mirjalili, S., 2018, Optimizing connection weights in neural networks using the whale optimization algorithm, *Soft Computing*, 22 (1), 1-15.

Arı, A. ve Berberler, M. E., 2017, Yapay sinir ağları ile tahmin ve sınıflandırma problemlerinin çözümü için arayüz tasarımı, *Acta Infologica*, 1 (2), 55-73.

Arı, A., 2019, Yapay Sinir Ağları Kullanılarak Kalp Hastalığının Öngörülmesi, *Dokuz Eylül Üniversitesi*.

Asteris, P. G., Roussis, P. C. ve Douvika, M. G., 2017, Feed-forward neural network prediction of the mechanical properties of sandcrete materials, *Sensors*, 17 (6), 1344.

Ataseven, B., 2013, Yapay sinir ağları ile öngörü modellemesi.

Bengio, Y. ve Grandvalet, Y., 2004, No unbiased estimator of the variance of k-fold cross-validation, *Journal of machine learning research*, 5 (Sep), 1089-1105.

Chaudhuri, T., Soh, Y. C., Li, H. ve Xie, L., 2019, A feedforward neural network based indoor-climate control framework for thermal comfort and energy saving in buildings, *Applied energy*, 248, 44-53.

Cigizoglu, H. K. ve Alp, M., 2006, Generalized regression neural network in modelling river sediment yield, *Advances in Engineering Software*, 37 (2), 63-68.

Çelebi, M., 2020, Kompleks Değerli Yapay Sinir Ağları İçin Yeni Aktivasyon Fonksiyonlarının Tanımlanması, Yüksek Lisans, *Konya Teknik Universitesi*.

Dave, V. S. ve Dutta, K., 2014, Neural network based models for software effort estimation: a review, *Artificial Intelligence Review*, 42 (2), 295-307.

DEDE, G. Y. ve SAZLI, M. H. T. D., 2008, Yapay sinir ağları ile konuşma tanıma, *Ankara Üniversitesi Fen Bilimleri Enstitüsü Elektronik Mühendisliği Anabilim …*.

Devasena, C. L., Sumathi, T., Gomathi, V. ve Hemalatha, M., 2011, Effectiveness evaluation of rule based classifiers for the classification of iris data set, *Bonfring*

International Journal of Man Machine Interface, 1 (Special Issue Inaugural Special Issue), 05-09.

Dhande, J. D. ve Dandekar, D., 2011, PSO Based SVM as an Optimal Classifier for Classification of Radar Returns from Ionosphere, *International Journal on Emerging Technologies*, 2 (2), 1-3.

Documentation, M. H., 2021, Recurrent Neural Network (layrecnet (layerDelays,hiddenSizes,trainFcn)),

Erkaymaz, O., Ozer, M. ve Perc, M., 2017, Performance of small-world feedforward neural networks for the diagnosis of diabetes, *Applied Mathematics and Computation*, 311, 22-28.

Fisher, R. A., 1936, The use of multiple measurements in taxonomic problems, *Annals of eugenics*, 7 (2), 179-188.

Forina, M., 1991, An extendible package for data exploration, *Classification and Correlation. Institute of Pharmaceutical and Food Analysis and Technologies, Genoa, Italy*, 4.

Gavin, H., 2011, The Levenberg-Marquardt method for nonlinear least squares curve-fitting problems, *Department of Civil and Environmental Engineering, Duke University*, 28, 1-5.

Haykin, S., 1999, A Comprehensive Foundation: Neural Networks, Prentice Hall Upper Saddle River.

He, H. ve Garcia, E. A., 2009, Learning from imbalanced data, *IEEE Transactions on knowledge and data engineering*, 21 (9), 1263-1284.

Hibat-Allah, M., Ganahl, M., Hayward, L. E., Melko, R. G. ve Carrasquilla, J., 2020, Recurrent neural network wave functions, *Physical Review Research*, 2 (2), 023358.

Hu, R., Wen, S., Zeng, Z. ve Huang, T., 2017, A short-term power load forecasting model based on the generalized regression neural network with decreasing step fruit fly optimization algorithm, *Neurocomputing*, 221, 24-31.

İçel, Y., 2019, Güneş Enerji Sistemlerinin Performans Tahmini İçin Yapay Sinir Ağları İle Modellenmesi Ve Verimliliğin İncelenmesi, *İnönü Üniversitesi*.

Ilonen, J., Kamarainen, J.-K. ve Lampinen, J., 2003, Differential evolution training algorithm for feed-forward neural networks, *Neural Processing Letters*, 17 (1), 93-105.

Kamber, M. ve Pei, J., 2001, Data mining: Concepts and techniques, Morgan Kaufmann Publishers San Francisco, p.

Karaca, Ö. F., 2020, Fırat - Dicle Havzasındakı Akım Ve Sediment Taşınımının Yapay Sinir Ağları İle Tahmini, *Tokat Gaziosmanpaşa Üniversitesi*.

Karakaş, B., 2020, Sincap Arama Algoritması İle Yapay Sinir Ağlarının Eğitimi, *Erciyes Üniversitesi*.

Kohonen, T., 1990, The self-organizing map, *Proceedings of the IEEE*, 78 (9), 1464-1480.

Koklu, M. ve Ozkan, I. A., 2020, Multiclass classification of dry beans using computer vision and machine learning techniques, *Computers and Electronics in Agriculture*, 174, 105507.

Köklü, M., 2014, Sınıflandırma problemlerinde kural çıkarımı için yeni bir yöntem geliştirilmesi ve uygulamaları, *Selçuk Üniversitesi Fen Bilimleri Enstitüsü*.

Köprü, E. Y., 2020, Yapay Sinir Ağları İle Sıvı Ham Demir Tahmini Ve 5. Yüksek Fırın Uygulaması, *Karabik Üniversitesi*.

Li, H.-Z., Guo, S., Li, C.-J. ve Sun, J.-Q., 2013, A hybrid annual power load forecasting model based on generalized regression neural network with fruit fly optimization algorithm, *Knowledge-Based Systems*, 37, 378-387.

Lotfinejad, M. M., Hafezi, R., Khanali, M., Hosseini, S. S., Mehrpooya, M. ve Shamshirband, S., 2018, A comparative assessment of predicting daily solar radiation using bat neural network (BNN), generalized regression neural network (GRNN), and neuro-fuzzy (NF) system: A case study, *Energies*, 11 (5), 1188.

Lukoševičius, M. ve Jaeger, H., 2009, Reservoir computing approaches to recurrent neural network training, *Computer Science Review*, 3 (3), 127-149.

Mendes, R., Cortez, P., Rocha, M. ve Neves, J., 2002, Particle swarms for feedforward neural network training, *Proceedings of the 2002 International Joint Conference on Neural Networks. IJCNN'02 (Cat. No. 02CH37290)*, 1895-1899.

Mitchell, R., Michalski, J. ve Carbonell, T., 2013, An artificial intelligence approach, Springer, p.

Mohanty, M. N. ve Palo, H. K., 2020, Child emotion recognition using probabilistic neural network with effective features, *Measurement*, 152, 107369.

Mozaffari, A., Emami, M. ve Fathi, A., 2019, A comprehensive investigation into the performance, robustness, scalability and convergence of chaos-enhanced evolutionary algorithms with boundary constraints, *Artificial Intelligence Review*, 52 (4), 2319-2380.

Panahi, N., Shayesteh, M. G., Mihandoost, S. ve Varghahan, B. Z., 2011, Recognition of different datasets using PCA, LDA, and various classifiers, *2011 5th International Conference on Application of Information and Communication Technologies (AICT)*, 1-5.

Park, J. ve Kim, K.-Y., 2017, Meta-modeling using generalized regression neural network and particle swarm optimization, *Applied Soft Computing*, 51, 354-369.

Perera, A., Rathnayake, U. ve Azamathulla, H., 2020, Comparison of different Artificial Neural Network (ANN) training algorithms to predict atmospheric temperature in Tabuk, Saudi Arabia, *Quarterly Journal of Meteorology, Hydrology, and Geophysics*, 71 (2), 233-244.

Saatçioğlu, D. ve Özçakar, N., YAPAY SİNİR AĞLARI YÖNTEMİ İLE ARALIKLI TALEP TAHMİNİ, *Beykoz Akademi Dergisi*, 4 (1), 1-32.

Sahrin, A., Tjahjono, A., Pujiantara, M. ve Purnomo, M. H., 2017, The modeling of directional overcurrent relay in loop system using cascade forward neural network, *2017 International Seminar on Intelligent Technology and Its Applications (ISITIA)*, 69-74.

Sigillito, V. G., Wing, S. P., Hutton, L. V. ve Baker, K. B., 1989, Classification of radar returns from the ionosphere using neural networks, *Johns Hopkins APL Technical Digest*, 10 (3), 262-266.

Specht, D. F., 1991, A general regression neural network, *IEEE transactions on neural networks*, 2 (6), 568-576.

Sürel, A., 2006, Genelleştirilmiş Regresyon Yapay Sinir Ağının Su Kaynakları Mühendisliğinde Kullanımı, *Fen Bilimleri Enstitüsü*.

Turkoglu, B. ve Kaya, E., 2020, Training multi-layer perceptron with artificial algae algorithm, *Engineering Science and Technology, an International Journal*, 23 (6), 1342-1350.

Türkoğlu, B., 2018, Yapay sinir ağlarının yapay alg algoritması ile eğitimi, *Selçuk Üniversitesi Fen Bilimleri Enstitüsü*.

URL1, 2021, https://tr.wikipedia.org/wiki/Yapay_sinir_a%C4%9Flar%C4%B1, [10.01.2021].

URL2, 2021, https://veribilimcisi.com/2017/07/13/capraz-dogrulama-cross-validation-nedir/,

URL3, 2021, https://stanford.edu/~shervine/l/tr/teaching/cs-229/cheatsheet-machine-learning-tips-and-tricks,

Warsito, B., Santoso, R. ve Yasin, H., 2018, Cascade forward neural network for time series prediction, *J. Phys. Conf. Ser*, 012097.

Waterfall, J. J., Casey, F. P., Gutenkunst, R. N., Brown, K. S., Myers, C. R., Brouwer, P. W., Elser, V. ve Sethna, J. P., 2006, Sloppy-model universality class and the Vandermonde matrix, *Physical review letters*, 97 (15), 150601.

Witten, I. H. ve Frank, E., 2002, Data mining: practical machine learning tools and techniques with Java implementations, *Acm Sigmod Record*, 31 (1), 76-77.

Yavuz, E., Kasapbaşı, M. C., Eyüpoğlu, C. ve Yazıcı, R., 2018, An epileptic seizure detection system based on cepstral analysis and generalized regression neural network, *Biocybernetics and Biomedical Engineering*, 38 (2), 201-216.

Zhang, X.-Y., Yin, F., Zhang, Y.-M., Liu, C.-L. ve Bengio, Y., 2017, Drawing and recognizing chinese characters with recurrent neural network, *IEEE transactions on pattern analysis and machine intelligence*, 40 (4), 849-862.