



T.C.
KONYA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



EVİRİMSEL HESAPLAMA ALGORİTMALARI
İLE YAPAY SİNİR AĞININ BAĞLANTI
OPTİMİZASYONU

Merve YILMAZ

YÜKSEK LİSANS TEZİ

Bilgisayar Mühendisliği Anabilim Dalı

Haziran-2022
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Merve YILMAZ tarafından hazırlanan “Evrimsel Hesaplama Algoritmaları ile Yapay Sinir Ağının Bağlantı Optimizasyonu” adlı tez çalışması 30/06/2022 tarihinde aşağıdaki jüri tarafından oy birliği / oy çokluğu ile Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Prof. Dr. Oğuz FINDIK

.....

Danışman

Prof. Dr. Mustafa Servet KIRAN

.....

Üye

Prof. Dr. Halife KODAZ

.....

Yukarıdaki sonucu onaylarım.

Prof. Dr. Saadettin Erhan KESEN
Enstitü 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.

Merve YILMAZ

Tarih:

ÖZET**YÜKSEK LİSANS TEZİ****EVİRİMSEL HESAPLAMA ALGORİTMALARI İLE YAPAY SİNİR AĞININ
BAĞLANTI OPTİMİZASYONU****Merve YILMAZ****Konya Teknik Üniversitesi
Lisansüstü Eğitim Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı****Danışman: Prof. Dr. Mustafa Servet KIRAN****2022, 90 Sayfa****Jüri****Prof. Dr. Mustafa Servet KIRAN
Prof. Dr. Oğuz FINDIK
Prof. Dr. Halife KODAZ**

Optimizasyon, bir problem için olası çözümler arasından en uygun çözümü bulma işlemidir. Optimizasyon problemleri kârın maksimuma çıkarılmasını ya da maliyetin minimuma indirilmesini amaçlamaktadırlar. Optimizasyon yöntemleri genel olarak klasik ve sezgisel yöntemler olmak üzere iki kategoride ele alınabilir. Parametre sayısının fazla olması ve arama uzayının büyük olması gibi nedenlerden dolayı gerçek dünya problemlerini çözmede klasik optimizasyon yöntemleri yetersiz kalmaktadır. Bu gibi durumlarda sezgisel optimizasyon yöntemleri tercih edilmektedir. Sezgisel optimizasyon yöntemleri, bir amacı gerçekleştirmek için çözüme ulaşmada doğal fenomenleri kullanmaktadırlar. Doğal fenomenlerin kullanılması sürü zekâsı kavramını ortaya çıkarmaktadır. Sürü zekâsı, kendi kendini organize eden ve merkezi olmayan sistemlerin toplu davranış şeklidir. Doğada bulunan sürü zekâsına kuş sürüleri, balıklar, karınca kolonileri vb. gibi sürü halinde yaşayan canlılar örnek verilebilir. Doğada bulunan canlıların hareketlerinden esinlenilerek geliştirilen Parçacık Sürü Optimizasyonu (PSO) da bir sürü zekâsı algoritmasıdır.

Biyolojik sinir hücrelerine benzer başlıca ağ tipleri Hopfield, Boltzman makineleri, tekrarlayan ağlar ve iğneli ağlardır. Bu ağların yapısı çoğu zaman rastgele olmakla beraber manuel olarak da oluşturulabilmektedir. Gün geçtikçe ilerleyen teknoloji sayesinde biyolojik sinir sistemlerini modelleyen bu yaklaşımların önü açılmıştır. Bu çalışmada biyolojik sinir hücrelerinden ilham alınarak geliştirilen yeni bir ağ mimarisi geliştirilmiştir. Oluşturulacak olan yapay sinir ağının en iyi sonucu verebilmesi amacıyla ağda bulunan bağlantılar, ikili bir problem olarak ele alınmıştır ve BPSO (İkili Parçacık Sürü Optimizasyonu) ile çözüm aranmıştır. Ayrıca yapay sinir ağında bulunan bağlantıların ağırlıkları da sürekli PSO ile optimize edilmiştir. Sonuç olarak, biyolojik sinir sistemi ile uyumlu ve farklı tiplerdeki problemlere uygulanabilen esnek ve doğruluğu yüksek bir ağ yapısı oluşturulmuştur. Oluşturulan bu ağ yapısı farklı veri setleri üzerinde uygulanarak ağırlıkları hem PSO hem de BP (Geri Yayılım) ile eğitilmiş tam bağlantılı yapay sinir ağları ile kıyaslanmıştır. Ayrıca literatürde yapay sinir ağının bağlantı optimizasyonu için sıklıkla tercih edilen evrimsel hesaplama yöntemlerinden biri olan GA (Genetik Algoritma) ile bağlantı optimizasyonu işlemi de gerçekleştirilerek önerilen yöntem ile kıyaslanmıştır. Sonuç olarak biyolojik sinir ağlarının yapısına daha uygun bir yapay sinir ağı tasarımı için bir sürü zekâsı algoritması önerilmiştir. Önerilen yöntemin performansı 4 veri seti üzerinde araştırılmış ve karşılaştırmalar yapılmıştır. Elde edilen sonuçlar yapay sinir ağı bağlantı optimizasyonunun ağı sınıflandırma performansını iyileştirdiği görülmüştür.

Anahtar Kelimeler: Bağlantı Optimizasyonu, Evrimsel Hesaplama, Genetik Algoritma, İkili Parçacık Sürü Optimizasyonu, Parçacık Sürü Optimizasyonu, Sezgisel Hesaplama, Sürü Zekâsı, Yapay Sinir Ağı

ABSTRACT**MS THESIS****CONNECTIVITY OPTIMIZATION OF ARTIFICIAL NEURAL NETWORK
WITH EVOLUTIONARY COMPUTATION ALGORITHMS****Merve YILMAZ****Konya Technical University
Institute of Graduate Studies
Department of Computer Engineering****Advisor: Prof. Dr. Mustafa Servet KIRAN****2022, 90 Pages****Jury****Prof. Dr. Mustafa Servet KIRAN
Prof. Dr. Oğuz FINDIK
Prof. Dr. Halife KODAZ**

Optimization is the process of finding the most suitable solution among possible solutions for a problem. Optimization problems aim at maximizing profit or minimizing cost. Optimization methods can generally be considered in two categories as classical and heuristic methods. Due to the large number of parameters and the large search space, classical optimization methods are insufficient in solving real-world problems. In such cases, heuristic optimization methods are preferred. Heuristic optimization methods use natural phenomena to reach a solution to achieve a goal. The use of natural phenomena reveals the concept of herd intelligence. Swarm intelligence is the collective behavior of self-organizing and decentralized systems. Flock of birds, fish, ant colonies etc. to the herd intelligence found in nature. Animals that live in flocks are examples. Particle Swarm Optimization (PSO), which is inspired by the movements of living things in nature, is also a swarm intelligence algorithm.

The main types of networks similar to biological neurons are Hopfield, Boltzman machines, repetitive networks, and needle networks. Although the structure of these networks is mostly random, they can also be created manually. Thanks to the advancement of technology day by day, these approaches that model biological nervous systems have been paved the way. In this study, a new network architecture was developed, inspired by biological nerve cells. In order for the artificial neural network to be created to give the best result, the connections in the network were considered as a binary problem and a solution was sought with BPSO (Binary Particle Swarm Optimization). In addition, the weights of the connections in the artificial neural network are continuously optimized with PSO. As a result, a flexible and highly accurate network structure has been created that is compatible with the biological nervous system and can be applied to different types of problems. This network structure was applied on different data sets and compared with fully connected artificial neural networks whose weights were trained with both PSO and BP (Backpropagation). In addition, the connection optimization process with GA (Genetic Algorithm), which is one of the most preferred evolutionary computation methods for the connection optimization of the artificial neural network in the literature, is also compared with the proposed method. As a result, a swarm intelligence algorithm has been proposed for an artificial neural network design that is more suitable for the structure of biological neural networks. The performance of the proposed method was investigated on 4 data sets and comparisons were made. The results show that neural network connectivity optimization improves the classification performance of the network.

Keywords: Artificial Neural Network, Binary Particle Swarm Optimization, Connectivity Optimization, Evolutionary Computation, Genetic Algorithm, Heuristic Methods, Particle Swarm Optimization, Swarm Intelligence

ÖNSÖZ

Yapay sinir ağıları bilgisayar bilimlerinde ve yapay zekâ arařtırmalarında son 50 yıldır önemli bir çalıřma alanı olarak karřımıza çıkmaktadır. Farklı ağı mimarileri farklı problemlerin çözümlünde başarılı şekilde kullanılmıř ve bu alan derin öğrenme yöntemlerinin önerilmesi ile birlikte halen güncelliğini korumaktadır. Bilindiđi üzere yapay sinir ağı, biyolojik sinir ağılarının karar-kontrol süreçlerine uygulanmasına odaklanır ve olabildiğince biyolojik sinir ağına benzemesi beklenmektedir. Bu tez çalıřmasında literatürde çok sık kullanılan tam bađlantılı ileri beslemeli bir ağı modeli üzerinde bađlantıların optimizasyonu için ikili parçacık sürü optimizasyonu algoritması önerilmiřtir. Bu optimizasyon sürecinde yapay sinir ağıının sınıflandırma performansını iyileřtiren yeni bir bađlantı řeması ortaya çıkarılmaktadır. Sınıflandırma performansının iyileřtirilmesinin yanı sıra dolaylı bir özellik seçim iřlemi de bazı veri setlerinde ortaya çıkmıřtır. Bu çalıřma, sadece gizli katman sayısı ve nöron sayılarının parametre olarak verilmesi yanında bađlantı řemasının da çıkarılması gerekliliđini ortaya koymaktadır.

Arařtırma konusunun belirlenmesinde, yöntemlerin seçiminde ve geliřtirilmesinde bana yol gösteren ve deđerli bilgileriyle katkı sunan danıřmanın Prof. Dr. Mustafa Servet KIRAN hocama, tez savunmasında eleřtirileri ile tezin hem içerik hem de sunum ađısından iyileřtirilmesine katkı veren tez savunma jüri üyeleri Prof. Dr. Ođuz FINDIK ve Prof. Dr. Halife KODAZ'a teřekkür ederim. Ayrıca her zaman beni destekleyen aileme ve arkadařlarıma teřekkürü bir borç bilirim.

Merve YILMAZ
KONYA-2022

İÇİNDEKİLER

ÖZET	iv
ABSTRACT	v
ÖNSÖZ	vi
İÇİNDEKİLER	vii
1. GİRİŞ	1
1.1. Optimizasyon	2
1.1.1. Klasik optimizasyon yöntemleri.....	2
1.1.2. Sezgisel optimizasyon yöntemleri	3
1.2. Sürü Zekâsı Optimizasyon Algoritmaları	3
1.2.1. Parçacık sürü optimizasyonu.....	3
1.2.2. İkili parçacık sürü optimizasyonu	6
1.3. Yapay Sinir Ağı.....	6
1.3.1. Geri yayılım algoritması	10
1.4. Genetik Algoritma.....	11
2. KAYNAK ARAŞTIRMASI	14
2.1. Yapay Sinir Ağları ile İlgili Kaynak Araştırması	14
2.2. Seyreltme (Dropout) Algoritması ile İlgili Kaynak Araştırması	18
2.3. Parçacık Sürü Optimizasyonu ile İlgili Kaynak Araştırması.....	20
2.3.1. İkili parçacık sürü optimizasyonu ile ilgili kaynak araştırması.....	22
2.4. Evrimsel Hesaplama ile İlgili Kaynak Araştırması.....	23
2.4.1. Genetik algoritma ile ilgili kaynak araştırması	24
2.5. Önerilen Yöntemin Farklılıkları ve Yenilikleri	25
3. MATERYAL VE YÖNTEM	26
3.1. Yapay Sinir Ağının Uygulanması	28
3.2. Geri Yayılım Algoritmasının Uygulanması.....	29
3.3. Parçacık Sürü Optimizasyonunun Uygulanması.....	30
3.4. İkili Parçacık Sürü Optimizasyonunun Uygulanması	30
3.5. Genetik Algoritma Uygulaması	31
3.6. Veri Setleri.....	32
3.6.1. Meme kanseri veri seti.....	32
3.6.2. Hepatit veri seti	33
3.6.3. Mamografik kütle veri seti.....	34
3.6.4. Haberman'nin hayatta kalma veri seti	35
3.7. SMOTE Algoritması	35
3.8. K -Katlı Çapraz Doğrulama	36
4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA	38
4.1. Meme Kanseri Veri Seti İçin Sonuçlar	40
4.2. Hepatit Veri Seti İçin Sonuçlar	48

4.3. Mamografik Kütle Veri Seti İçin Sonuçlar	60
4.4. Haberman'nin Hayatta Kalma Veri Seti İçin Sonuçlar	66
5. SONUÇLAR VE ÖNERİLER	74
5.1 Sonuçlar	74
5.2 Öneriler	75
KAYNAKLAR	76



SİMGELER VE KISALTMALAR

Simgeler

a	: Önerilen yöntem için iterasyon sayısı
c_1	: Yerel öğrenme katsayısı
c_2	: Global öğrenme katsayısı
d	: Önerilen yöntem için kullanılacak olan veri seti
M	: Gizli katman nöron sayısı
N	: Giriş katmanı nöron sayısı
n	: Bireyin bit dizisi uzunluğu
O	: Çıkış katmanı nöron sayısı
p_c	: Çaprazlama oranı (Crossover rate)
p_m	: Mutasyon oranı (Mutation rate)
r_1	: (0,1) aralığında rastgele değer
r_2	: (0,1) aralığında rastgele değer
V_{ij}^k	: k. iterasyonda i. parçacığın hızının j. Bileşeni
$V_{ij}(t)$: t. zamanda i. parçacığın hızının j. bileşeni
w	: Eylemsizlik ağırlığı
$X_{pbest_{ij}}$: i. parçacığın en iyi konumunun j. bileşeni
X_{gbest_j}	: Tüm popülasyonun en iyi konumu
X_{ij}	: Giriş katmanındaki i. nöron ile gizli katmadaki j. nöron arasındaki bağlantı
Y_{jk}	: Gizli katmanındaki j. nöron ile çıkış katmadaki k. nöron arasındaki bağlantı
X_{ij}^k	: k. iterasyonda i. parçacığın konumunun j. bileşenindeki i. nöron ile gizli katmada bulunan j. Nöron arasındaki bağlantı

Kısaltmalar

AS-Dropout	: Uyarlanabilir Aralıklı Seyreltme (Adaptive Sparse Dropout)
BP	: Geri Yayılım (Backpropagation)
BPSO	: İkili Parçacık Sürü Optimizasyonu (Binary Particle Swarm Optimization)
CPOSNN	: Geleneksel Parçacık Sürü Optimizasyonu Sinir Ağı (Conventional Particle Swarm Optimization Neural Network)
DFNN	: Derin Bulanık Sinir Ağı (Deep Fuzzy Neural Network)
DNN	: Derin Sinir Ağı (Deep Neural Network)
DTCWT	: Çift Ağaç Karmaşık Dalgacık Dönüşümü (Dual-tree Complex Wavelet Transform)
EBPSO	: Entropik İkili Parçacık Sürü Optimizasyonu (Entropic Binary Particle Swarm Optimization)
EMG	: Elektromiyografi
FN	: Yanlış Negatif (False Negative)
FP	: Yanlış Pozitif (False Positive)
FPGA	: Alanda Programlanabilir Kapı Dizisi (Field-programmable Gate Array)

FPSOCM	: Çapraz Mutasyona Dayalı Bulanık Parçacık Sürü Optimizasyonu (Fuzzy Particle Swarm Optimization with Cross-Mutated-Based)
GA	: Genetik Algoritma (Genetic Algorithm)
GSNNA	: Sinir Ağı Mimarisi için Aç Gözlü Arama (Greedy Search for Neural Network Architecture)
IBPSO	: İmmün İkili Parçacık Sürü Optimizasyonu (Immune Binary Particle Swarm Optimization)
MLE	: Maksimum Olasılık Tahmin (Maximum Likelihood Estimation)
LM-NN	: Levenberg-Marquardt Sinir Ağı (Levenberg-Marquardt Neural Network)
LMS	: Sıvı Durum Makineleri (Liquid State Machine)
LSM	: Heyelan Duyarlılık Hesaplama (Landslide Susceptibility Mapping)
LOCA	: Soğutma Sıvısı Kaybı Kazası (Loss of Coolant Accident)
PCA	: Temel Bileşen Analizi (Principal Component Analysis)
PID	: Oransal, İntegral, Türevsel (Proportional, Integral, Derivative)
PSO	: Parçacık Sürü Optimizasyonu (Particle Swarm Optimization)
SDSM	: Ayrılık Odaklı Sinaptik Modifikasyon (Seperation Driven Synaptic Modification)
SDWPSO	: Dinamik Ağırlık Parçacık Sürü Optimizasyonu Tabanlı Sinüs Haritası (A Dynamic Weight Particle Swarm Optimization-based Sine Map)
SISs	: Güvenlik Enjeksiyon Sistemleri (Safety Injection Systems)
SMOTE	: Sentetik Azınlık Aşırı Örnekleme Tekniği (Synthetic Minority Over-Sampling Technique)
SNNs	: İğnecikli Sinir Ağları (Spiking Neural Network)
TN	: Gerçek Negatif (True Negative)
TNR	: Gerçek Negatif Oranı (True Negative Rate)
TP	: Gerçek Pozitif (True Positive)
TPR	: Gerçek Pozitif Oranı (True Positive Rate)
YSA	: Yapar Sinir Ağı (Artificial Neural Network)

1. GİRİŞ

İnsanlar tarih boyunca ihtiyaçlarını gidermek veya karşılaştıkları zorluklarla başa çıkmak amacıyla çeşitli aletleri icat etmişler veya geliştirmişlerdir. Gerçekleştirilen bu icatlar insanın problem çözme konusundaki yeteneğinin bir göstergesi olan zekâyı kullanma becerisinden kaynaklanmaktadır. İnsanlarda bulunan bu yeni çözümler üretme, hafızada tutma, karşılaştırma gibi zekâyı dayalı davranışların benzetimleri ile çeşitli akıllı yaklaşımlar geliştirilmiştir. Bu yaklaşımlar sinir hücreleri örnek alınarak geliştirilen yapay olan sinir ağlarıdır. Gün geçtikçe ilerleyen teknoloji sayesinde biyolojik sinir sistemlerini modelleyen bu yaklaşımların önü açılmıştır. Genel olarak yapay sinir ağlarındaki bağlantılar sabit yapıda verilmektedir. Bu tez çalışmasında nöronlar arasındaki bağlantılar İkili Parçacık Sürü Optimizasyonu (BPSO) ile optimize edilmiştir. Geliştirilen yapay sinir ağının çeşitli problemleri çözme konusunda önemli bir yere sahip olacağı düşünülmektedir. Belirlenen gerçek dünya problemlerini çözmek için biyolojik sinir hücrelerinden ilham alınarak yeni bir ağ mimarisi geliştirilmiştir. Biyolojik sinir hücrelerine benzer olarak literatürde bulunan başlıca ağ tipleri Hopfield, Boltzman makineleri, tekrarlayan ağlar ve iğneli (spike) ağlardır. Bu ağların yapısı çoğu zaman rastgele olmakla beraber manuel olarak da oluşturulabilmektedir. Oluşturulacak olan yapay sinir ağının en iyi sonucu verebilmesi amacıyla ağ fonksiyonu olarak kullanılan bağlantıların optimizasyon işlemleri yapılmıştır. Sonuç olarak, biyolojik sinir sistemi ile uyumlu ve farklı tiplerdeki problemlere uygulanabilen esnek ve doğruluğu yüksek bir ağ yapısı oluşturulmuştur. Oluşturulan bu ağ yapısı gerçek problem veri kümeleri üzerinde uygulanarak kıyaslanmıştır. Böylece ağ parametrelerinin optimizasyon işleminin ağın sonucu üzerindeki etkisi görülmüştür. Ayrıca biyolojik sinir ağlarının yapısına daha uygun bir yapay sinir ağı tasarlanmıştır.

Bu tezde birinci bölümde genel hatlarıyla teze giriş yapılmıştır ve temel konulara değinilmiştir. İkinci bölümde tez çalışmasına dair literatürdeki çalışmalar incelenmiştir. Üçüncü bölümde tez çalışmasında kullanılan veri setleri ve yapılan işlemler genel olarak adım adım açıklanmıştır. Dördüncü bölümde yapılan çalışmanın sonuçları ve diğer yöntemle olan karşılaştırmaları verilmiştir. Son olarak beşinci bölümde ise genel olarak tez çalışmasından elde edilen sonuçlar ve önerilere yer verilmiştir.

1.1. Optimizasyon

İnsanlar hayatları boyunca çeşitli problemlerle karşılaşmaktadırlar. Karşılaşılan bu problemler için bulunan çözümler içerisinde en iyisinin seçilmesi, çözümden minimum zararın elde edilmesi veya maksimum faydanın sağlanması yapılacak olan en uygun değer seçimi ile mümkündür. Bu süreçlerin tamamı optimizasyon ile değerlendirilir ve çözümlenir (Kıran, 2014).

Optimizasyon, bir problem için verilen tüm çözümler arasından en iyi çözümü elde etme işlemine verilen addır. En iyileme olarak da bilinmektedir. Optimize edilecek olan fonksiyon, amaç fonksiyonu olarak ifade edilmektedir. Optimizasyon işlemi bu amaç fonksiyonunu minimize veya maksimize etmeye çalışmaktadır. Probleme ait amaç fonksiyonu bir tane ile sınırlı ise Tek Amaçlı Optimizasyon adını alırken birden fazla ise Çok Amaçlı Optimizasyon adını almaktadır (Arora, 2015).

Optimizasyon problemleri genel olarak maliyetin en aza indirilmesini ve kârın maksimuma çıkarılmasını amaçlamaktadır. Öğrenme süreci aslında ağırlıkların optimizasyonudur. Optimizasyon problemleri için günümüzde birçok farklı algoritma önerilmiştir. Bu algoritmalar genel olarak klasik ve sezgisel optimizasyon yöntemleri olmak üzere iki kategoride incelenmektedir.

Arama uzayının büyük olması, parametre sayısının fazla olması gibi nedenlerden dolayı gerçek hayat problemlerini çözme konusunda klasik optimizasyon yöntemleri yetersiz kalabilmektedir. Bu tarz durumlarda sezgisel yöntemler tercih edilmektedir.

1.1.1. Klasik optimizasyon yöntemleri

Klasik optimizasyon yöntemleri çoğunlukla matematiksel modellemeye dayanan toleranslar dahilinde optimum çözümü veren yöntemlerdir. Bu yöntemler Gradyan ve Hessian matrisine dayanarak çalışmaktadırlar. Çözümler başlangıç noktasına komşu bölgelerde aramaktadır. Amaç fonksiyonunun ve kısıtlamaların dik tepelere sahip olmasından dolayı en uygun noktaları bulmak zorlaşmaktadır. Ayrıca matematiksel olarak yapılan hesaplamalarda türevlerin hesaplanmasının karmaşıklığı, hesaplama için yüksek boyutlu belleklere duyulan ihtiyaç gibi zorluklar bu yöntemlerin tercih edilmesinin önüne geçmektedir (Shojaei ve Rahami, 2022).

1.1.2. Sezgisel optimizasyon yöntemleri

Sezgisel optimizasyon algoritmaları, bir amacı gerçekleştirmek için hedefe ulaşmada doğal fenomenleri kullanan algoritmalarlardır. Sezgisel optimizasyon algoritmaları en iyi çözümü bulmayı garanti etmezler. Yakınsama özelliği sayesinde kesin çözümün yakınlığında bir çözüm elde edilmektedir. Kesin çözümü aramamasından dolayı problemin çözümünü kısa bir sürede tamamlamaktadırlar. Bu yöntemin iyi kabul edilmesini etkileyen faktörler ne kadar kısa sürede ne kadar iyi sonuç verdiğidir. Klasik yöntemlere göre daha karışık bir yapıya sahiptirler. Klasik yöntemlerin yetersiz kaldığı durumlarda tercih edilmektedirler. Özellikle büyük boyutlu optimizasyon problemlerinin çözümünde kullanılmaktadırlar.

1.2. Sürü Zekâsı Optimizasyon Algoritmaları

Sürü zekâsı, kendi kendini organize eden ve merkezi olmayan sistemlerin toplu davranışı şeklinde tanımlanabilir. Sürü zekâsı sistemi, bir problemi çözmek için etkileşime giren basit ajanlardan oluşan popülasyondan meydana gelmektedir. Sürüdeki bireyler tek bir amacı gerçekleştirmek üzere birlikte çalışmaktadırlar.

Sürü zekâsının temel olarak ele aldığı iki kavram mevcuttur. Bunlar: kendi kendine örgütlenme ve iş bölümüdür. Kendi kendine örgütlenme, bir sistemin bileşenlerini herhangi bir dış yardım talep etmeksizin geliştirme anlamına gelmektedir. İş bölümü ise bireyler tarafından basit işlerin aynı anda yürütülebilmesi işlemidir. Bireyler birlikte daha karmaşık işleri de yürütmektedirler. Doğadaki sürü zekâsının örnekleri arasında karınca kolonileri, kuş sürüleri, bakteri üremesi ve balıklar sayılabilir (Inkaya ve ark., 2016).

1.2.1. Parçacık sürü optimizasyonu

Parçacık Sürü Optimizasyonu ilk olarak 1995 yılında James Kennedy ve Russel Eberhart tarafından geliştirilmiş bir optimizasyon yöntemidir (Kennedy ve Eberhart, 1995). PSO algoritması genel olarak kuş ve balık sürülerinin hareketlerinden esinlenerek geliştirilen sezgisel bir algoritmadır. Genel olarak bu canlıların besin kaynağı bulma esnasında sergiledikleri hareketler dikkate alınmaktadır.

PSO, popülasyon tabanlı çok parametrelili ve değişkenli optimizasyon problemlerine çözüm bulmayı amaçlar. Optimize edilecek olan problem bir başlangıç popülasyonu ile başlar. Popülasyondaki her bir bireye parçacık adı verilmektedir. Bu parçacıkların bir amaç için bir araya gelmesine ise sürü adı verilmektedir. Sürünün her bir parçacığı, bir çözümü temsil etmektedir. Parçacıklar başlangıçta rastgele olarak konumlandırılmıştır ve her birinin rastgele olarak belirlenen bir hızları mevcuttur. Parçacıklar arama uzayında hareket ederek kendi en iyilerini güncellerler. Her parçacık için amaç fonksiyonu değerlendirilir ve arama uzayında hangi pozisyonun en iyi olduğunu belirlemek için parçacıkların uygunluk değerleri elde edilir. Her yineleme adımında Denklem 1.1 ve Denklem 1.2 kullanılarak güncelleme işlemi yapılır:

$$V_{ij}^{k+1} = V_{ij}^k + c_1 r_1 (X_{pbest_{ij}}^k - X_{ij}^k) + c_2 r_2 (X_{gbest_j}^k - X_{ij}^k) \quad (1.1)$$

$$X_{ij}^{k+1} = X_{ij}^k + V_{ij}^{k+1} \quad (1.2)$$

Denklem 1.1’de X_{ij} ve V_{ij} sırasıyla i . parçacığın mevcut konumu ve hızını vermektedir. $X_{pbest_{ij}}$, i ’nci parçacığın önceki en iyi konumunu, X_{gbest_j} ise sürüdeki tüm parçacıklar arasındaki en iyi konumu ifade etmektedir. r_1 ve r_2 parametreleri (0,1) aralığında üretilen rastgele değerlerdir. c_1 ve c_2 değerleri ise sırasıyla parçacığın kendine ve sürüye olan güvenlerini vermektedir. Bu değerler Kennedy ve Eberhart tarafından 2 olarak belirlenmiştir. Bu değerler keşif ve sömürü esnasında dengeleme için oldukça önemlidirler. c_1 değerinin daha büyük olması parçacıkları yerel en iyi konuma, c_2 değerinin daha büyük bir değer alması ise parçacıkları global en iyi konuma daha hızlı ulaştırmaktadır. w eylemsizlik ağırlığıdır. Parçacığın verilen önceki hızının global ve yerel arama üzerindeki etkisini dengelemek amacıyla Shi ve Eberhart (1998) eylemsizlik ağırlığını hızın hesaplanması için kullanmışlardır. Eylemsizlik ağırlığı eklenmiş olan formül Denklem 1.3’de verilmiştir.

$$V_{ij}^{k+1} = wV_{ij}^k + c_1 r_1 (X_{pbest_{ij}}^k - X_{ij}^k) + c_2 r_2 (X_{gbest_j}^k - X_{ij}^k) \quad (1.3)$$

PSO'nun sözde kodu ise Şekil 1.1' verilmiştir.

```

PSO
1 begin
2   for popülasyondaki her bir parçacık i
3      $X_i$  için rastgele ilk değer ata
4      $V_i$  için rastgele ilk değer ata
5      $X_{pbest_i}$  için ilk değer ata
6   end
7   while (iterasyon sayısı kadar ya da sonlandırma şartı sağlanana kadar) do
8     begin
9       for popülasyondaki her bir parçacık i
10        amaç fonksiyonunu hesapla
11         $X_{pbest_i}$ 'yi güncelle
12      end
13      for her bir i
14         $gbest_j$ 'e en iyi  $X_{pbest_i}$  değerini ata
15         $V_i$ 'yi hesaplamak için Denklem 1.3'ü kullan
16        Denklem 1.2'yi kullanarak  $X_i$ 'yi güncelle
17      end
18    end
19  end

```

Şekil 1.1. PSO sözde kodu

Genel olarak PSO aşağıda verilen adımlardan oluşmaktadır;

- i. Rastgele üretilen hız ve konum değerleri ile birlikte başlangıç sürüsü oluşturulur.
- ii. Sürüde bulunan parçacıkların tamamı için uygunluk değerleri hesaplanır.
- iii. Sürüdeki her parçacık için en iyi değerleri ($pbest$) bulunur.
- iv. Sürüdeki parçacıklar için elde edilen bu en iyiler içinden global en iyi değer ($gbest$) seçilir.
- v. Sürüde bulunan her bir parçacığın konum ve hız değerleri sırasıyla Denklem 1.2 ve Denklem 1.3'ye göre güncellenir.
- vi. Maksimum iterasyon sayısına ulaşana kadar ya da durma kriteri sağlanana kadar ii. ve v. adımlar arasında işlemler tekrar edilirler.

Yukarıda verilen adımlar sırasıyla uygulanarak PSO'nun adımları tamamlanmış olacaktır.

1.2.2. İkili parçacık sürü optimizasyonu

Kennedy ve Eberhart (1997) ikili problemler için PSO'nun ayrık ikili versiyonunu önermişlerdir. İkili PSO'da parçacıklar 'evet' veya 'hayır', 'var' veya 'yok', 'doğru' veya 'yanlış' gibi ikili değerlere karar vermektedir. BPSO'da parçacıkların konum değerleri ikili bir vektördür. Hız değerleri ise (0,1) aralığında sürekli bir vektördür. Yine sürekli PSO da olduğu gibi BPSO'da da konum ve hız değerleri güncellenmektedir. Fakat burada dikkat edilmesi gereken hız vektörün (0,1) aralığında olmasıdır. Hız vektörünün değerini (0,1) aralığına normalleştirmek için ise Denklem 1.4'de verilen denklem kullanılmaktadır (Mojtaba Ahmadiéh ve ark., 2017).

$$V'_{ij} = \text{sig}(V_{ij}(t)) = \frac{1}{1+e^{-V_{ij}(t)}} \quad (1.4)$$

Denklem 1.4'de hız değerinin (0,1) aralığında normalleştirmek için Denklem 1.5'de verilen sigmoid fonksiyonu kullanılmıştır.

$$X_{ij}(t+1) = \begin{cases} 1 & \text{eğer } r_{ij} < \text{sig}(V_{ij}(t+1)) \\ 0 & \text{diğer durumlar} \end{cases} \quad (1.5)$$

Denklem 1.5'de parçacıkların konum değerleri güncellenmektedir. r_{ij} değeri rastgele olarak belirlenmektedir.

Burada sürekli PSO'dan farklı olarak konumu belirlemek için hız değerinin eklenmesi yerine, BPSO'da olasılığı belirlemek için hız girişi kullanılmaktadır (Nguyen ve ark., 2021).

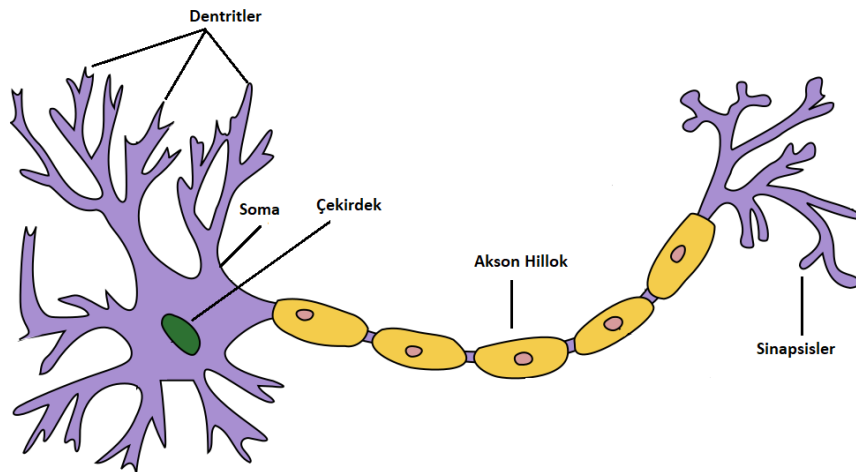
1.3. Yapay Sinir Ağı

İnsanlar tarih boyunca ihtiyaçlarını gidermek veya karşılaştıkları zorluklarla başa çıkmak amacıyla çeşitli aletleri icat etmişler veya geliştirmişlerdir. Gerçekleştirilen bu icatlar insanın problem çözme konusundaki yeteneğinin bir göstergesi olan zekâyı kullanma becerisinden kaynaklanmaktadır. İnsanlarda bulunan bu yeni çözümler üretme, hafızada tutma, karşılaştırma gibi zekâyı dayalı davranışların benzetimleri ile çeşitli akıllı yaklaşımlar geliştirilmiştir. Bu yaklaşımlarda yapay sinir hücreleri örnek alınarak yapay

olan sinir ağırları geliştirilmiştir. Yapay sinir ağırları oldukça karmaşık bir yapıya sahiptirler. Gün geçtikçe ilerleyen teknoloji sayesinde biyolojik sinir sistemlerini modelleyen bu yaklaşımların önü açılmıştır.

Yapay sinir ağırları, problemleri çözmek için insan beyninin biyolojik sinir yapısı modellenerek geliştirilmiştir. Taklit edilen bu yapay sinir hücreleri birbirleriyle bağlanılarak yapay sinir ağırlarını oluşturmaktadır. YSA genel olarak yapay sinir hücrelerini içeren katmanlardan oluşan bir yapıdadır (Yazici ve ark., 2007). YSA, biyolojik sinir hücreleri incelenerek geliştirilmiş bir matematiksel modeldir. YSA, örneklerle ilgili bilgileri toplayıp bu bilgiler ile genellemeler yapar ve hiç görmediği örnekler ile karşılaştığında öğrendiği bilgileri kullanarak karar vermektedir.

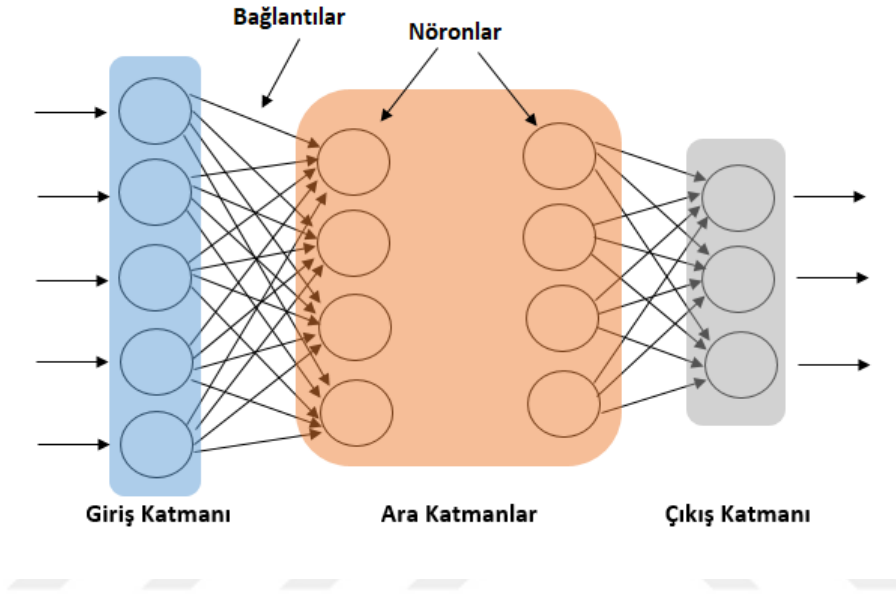
Biyolojik sinir ağırları insan vücudunda bulunan karmaşık sistemlerdir. Bu sistemler beyindeki nöron hücrelerinin birbirleri arasında kurduğu sinaptik bağları içermektedir. Bu nöronların yapısı Şekil 1.2' de gösterilmiştir. Nöronlar birbirlerine dentritler ile bağlıdır. Bir nöron sinyal ürettiği zaman bu sinyal bir başka nöronun dentriti tarafından algılanır. Algılanan bu sinyaller toplanır ve somaya aktarılır. Soma ve çekirdek bilginin işlenmesinde rol üstlenmezler sadece nöronun işlevsel olmasını sağlarlar. Eğer toplam girdi somanın Akson Hillok adı verilen kısmındaki eşik değerinden büyük ise nöron gelen sinyali dönüştürerek akson aracılığıyla diğer nöronlara iletir (Diler, 2003).



Şekil 1.2. Biyolojik Sinir Hücresinin Yapısı (Shrivastava, 2020)

Biyolojik sinir hücresindeki akson, yapay sinir ağındaki çıktılara; dentrit, toplama fonksiyonuna; çekirdek, aktivasyon fonksiyonuna ve sinaps ise ağırlıklara karşılık gelir.

YSA çok sayıda nöronun bir araya gelmesiyle oluşmaktadır. Bu nöronlar birbirleriyle bağlıdır ve bağlantıların her birinde ağırlıklar bulunmaktadır. Bağlantılardaki bu ağırlıklar öğrenme süreci boyunca güncellenmektedir. YSA modelleri ileri ve geri beslemeli olarak ikiye ayrılmaktadır. YSA'nın genel yapısı, katmanların dizilişi Şekil 1.3.' de gösterilmiştir.



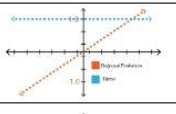
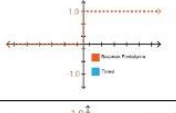
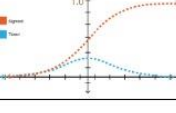
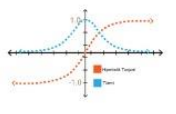
Şekil 1.3. YSA'nın Genel Yapısı

Giriş katmanında bulunan girdiler, ağı öğrenmesi istenilen örneklerden toplanan bilgilerdir. Ağırlıklar, ağı öğrenmesinde hangi özelliğin daha etkili olacağını belirleyen katsayılardır. Toplama fonksiyonu, bir hücreye ait net girdiyi hesaplamada kullanılmaktadır (Oztemel, 2006). Şekil 1.4' de çeşitli toplama fonksiyonları verilmiştir

Toplama Fonksiyonları		
	Net Giriş	Açıklama
Toplam	$\sum_{i=1}^N X_i * W_i$	Ağırlık değerleri girdiler ile çarpılır ve bulunan değerler birbirleriyle toplanarak Net girdi hesaplanır.
Çarpım	$\prod_{i=1}^N X_i * W_i$	Ağırlık değerleri girdiler ile çarpılır ve bulunan değerler birbirleriyle çarpılarak net girdi hesaplanır.
Maksimum	$Net = Max(X_i * W_i)$	n adet girdi içinden ağırlık girdilerle çarpıldıktan sonra içlerinden en büyüğü net girdi olarak kabul edilir.
Minimum	$Net = Min(X_i * W_i)$	n adet girdi içinden ağırlık girdilerle çarpıldıktan sonra içlerinden en küçüğü net girdi olarak kabul edilir.
Çoğunluk	$Net = \sum_{i=1}^N Sgn(X_i * W_i)$	n adet girdi içinden girdilerle ağırlıklar çarpıldıktan sonra pozitif ile negatif olanların sayısı bulunur. Büyük olan sayı hücrenin net girdisi olarak kabul edilir.
Kümülatif Toplam	$Net = Net(eski) + \sum_{i=1}^N X_i * W_i$	Hücreye gelen bilgiler ağırlıklı olarak toplanır. Daha önce hücreye gelen bilgilere yeni hesaplanan girdi değerleri eklenerek hücrenin net girdisi hesaplanır.

Şekil 1.4. Toplama Fonksiyonları (Çayıroğlu, 2015)

Aktivasyon ya da diğer adıyla transfer fonksiyonu, toplama fonksiyonundan hücreye gelen net girdiyi işleyerek hücrenin çıktısını belirleyen fonksiyondur. Yapay sinir hücresinden elde edilen çıktıyı oluşturmak için aktivasyon fonksiyonu kullanılmaktadır. En yaygın olarak kullanılan aktivasyon fonksiyonu, sigmoid fonksiyonudur. Şekil 1.5'de bazı aktivasyon fonksiyonları verilmiştir.

Aktivasyon Fonksiyonları			
	Denklem	Fonksiyon	Açıklama
Doğrusal (Linear)	$F(Net) = Net$		Doğrusal problemleri çözmek amacıyla aktivasyon fonksiyonu doğrusal olarak seçilebilir. Toplama fonksiyonundan çıkan sonuç, direk çıkış olarak kabul edilir.
A dım (Step)	$F(Net) = \begin{cases} 0 & \text{if } Net > \text{Eşik Değer} \\ 1 & \text{if } Net \leq \text{Eşik Değer} \end{cases}$		Gelen Net girdinin belirlenen bir eşik değerinin altında veya üstünde olmasına göre hücrenin çıktısı 1 veya 0 değerini alır.
Sigmoid	$F(Net) = \frac{1}{1 + e^{-Net}}$		Sigmoid aktivasyon fonksiyonu, sürekli ve türevi alınabilir bir fonksiyondur. Doğrusal olmayışı dolayısıyla yapay sinir ağı uygulamalarında en sık kullanılan fonksiyondur. Bu fonksiyon girdi değerlerinin her biri için 0 ile 1 arasında bir değer üretir.
Tanjant Hiperbolik	$F(Net) = \frac{e^{Net} - e^{-Net}}{e^{Net} + e^{-Net}}$		Tanjant hiperbolik fonksiyonu, sigmoid fonksiyonuna benzer bir fonksiyondur. Sigmoid fonksiyonunda çıkış değeri 0 ile 1 arasında değişirken hiperbolik tanjant fonksiyonunun çıkış değeri -1 ile 1 arasında değişmektedir.

Şekil 1.5. Bazı Aktivasyon Fonksiyonları (Çayıroğlu, 2015; Kızrak, 2019)

YSA'nın sonucunda üretilen çıktılar ile gerçek çıktılar kıyaslanarak hata miktarı hesaplanmaktadır. Başlangıçta rastgele olarak alınan ağırlıklar, çıktıları en az hata miktarını verecek şekilde yeniden güncellenmektedir. Ağırlıklar artık değişmediği zaman ise öğrenme tamamlanmış olmaktadır (Bozkurt ve ark., 2015). Öğrenme tamamlandıktan sonra yeni verilere karşı anlamlı çıktılar elde edilebilmektedir.

YSA modelleri yapılarına göre ileri ve geri beslemeli olarak ikiye, öğrenme algoritmalarına göre danışmanlı, danışmansız ve destekleyici olmak üzere üçe ve son olarak öğrenme zamanına göre ise statik ve dinamik olmak üzere ikiye ayrılır.

1.3.1. Geri yayılım algoritması

Geri yayılım algoritması, ağırlık alanındaki hata fonksiyonunun minimum değerini arar. Hata fonksiyonunu en aza indiren ağırlıkların öğrenme problemine bir çözüm olduğu düşünülmektedir. YSA'nın sonucunda üretilen çıktılar ile gerçek çıktılar kıyaslanarak hata miktarı hesaplanmaktadır. Başlangıçta rastgele olarak alınan ağırlıklar, çıktıları en az hata miktarını verecek şekilde yeniden güncellenmektedir. Ağırlıklar artık değişmediği zaman ise öğrenme tamamlanmış olmaktadır (Bozkurt ve ark., 2015). Öğrenme tamamlandıktan sonra yeni verilere karşı anlamlı çıktılar elde edilebilmektedir.

BP (geri yayılım) algoritmasındaki ağırlık güncelleme işlemi iteratif olarak devam etmektedir. Önceden belirlenen bir iterasyon sayısı sonucunda döngü sonlandırılabilirken hata değerinin belli bir değerin altına düştüğü durumda da sonlandırılabilir. İterasyon sayısının belirlenmesi oldukça önemlidir. Çünkü iterasyon sayısının az belirlenmesi hatayı yeterince düşüremezken, iterasyon sayısının çok belirlenmesi ise aşırı öğrenmeye (ezberleme) sebep olabilir (Akdoğan, 2017).

Geri yayılım algoritmasında giriş katmanında bulunan nöronlar, dış dünyadan girdi değerlerini alırlar ve bir sonraki katmana iletirler. Çıkış katmanındaki nöronlar ise ağırlık çıktısını verirler (Vishwakarma ve ark., 2020).

Geri yayılım algoritmasında yapay sinir ağındaki çıktı değerleri ile gerçek değerler arasındaki karesel farkların toplamı bize toplam hata fonksiyonunu vermektedir. Hata fonksiyonun yani diğer adıyla maliyet fonksiyonun hesaplanması için kare hata formülü kullanılmaktadır. Hesaplama işlemi sonucunda elde edilen hatanın minimum olması istenmektedir. Bu yüzden denklem lokal minimumuna doğru iteratif şekilde yakınsanmaktadır. Bir fonksiyonun lokal minimumuna gitmesi için kullanılan farklı

optimizasyon algoritmaları vardır. Bunların arasında gradyan iniş (gradient descent), Newton, Quasi-Newton ve Levenberg Marquardt sayılabilir.

Gradyan iniş, bir fonksiyonun minimumunu bulmak için yinelemeli bir optimizasyon algoritmasıdır. Gradyan iniş eğitim verisini göz önüne alarak hata oranını en az indirmeyi amaçlar. Gradyan inişin yakınsama yönü, gradyan doğrultusuna negatif yönde hareket etmektedir (Akca, 2020). Gradyan doğrultusunun tersi yönde minimum nokta ile öğrenme katsayısı ile çarpılarak bir sonraki yeni ağırlık bulunur. Bu öğrenme kuralına ise Delta Kuralı (Delta Rule) denir

Öğrenme katsayısının farklı problemlerde en uygun değerini bulmak için wolfe condition, goldstein ve BFGS (Broyden–Fletcher–Goldfarb–Shanno) gibi optimizasyon algoritmaları da kullanılabilir. Öğrenme katsayısı küçük seçildiği zaman lokal minimuma ulaşma ihtimali artar. Fakat işlem daha fazla iterasyona ihtiyaç duyar ve maliyeti artar. Öğrenme katsayısı büyük kullanılırsa daha az iterasyonda işlem tamamlanır ama lokal minimum yakalanamayabilir.

Geri yayılım algoritmasında toplam hata hesaplandıktan sonra hatanın sıfır olmadığı veya belli bir değerin altına inmediği durumlarda hata ağı geriyeye doğru yayılarak ağırlıklar güncellenmektedir. Hata değeri minimum değerine ulaşmaya kadar ileri ve geri yayılım adımları tekrarlanmaktadır.

1.4. Genetik Algoritma

Doğadaki canlılar kısıtlı bulunan kaynaklar için rekabet halindedirler. Bu rekabet sonucunda da en uygun bireyler hayatta kalmaktadır. Bireyin hayatta kalması sahip oldukları çeşitli özelliklere bağlıdır. Bu özelliklerin her biri de gen adı verilen temel bir birim tarafından kontrol edilmektedir. Özellikleri kontrol eden bu genler, bireyin hayatta kalmasını etkileyen kromozomları oluşturmaktadır. Doğada oluşan bu rekabet sonucunda en uygun bireyler daha zayıf bireylere hükmetmektedir. Sadece en uygun bireyler hayatta kalmakta ve çoğalmaktadır. Böylece en uygun bireylerin genleri yeni nesillere aktarılırken daha zayıf olan bireylerin genleri ise ölmektedir. Doğal seçim, en uygun genlerin hayatta kalmasına neden olmaktadır. Evrim süreci iki ebeveyninden gelen kromozomların yeniden birleşmesi ile başlar. Kromozomlar arasında oluşan gen değişimine çaprazlama adı verilmektedir. Çaprazlama sonucunda daha iyi bireylerin oluşma olasılığı oluşturulur. Seçim ve çaprazlama adımları ile gen havuzunun evrimi gerçekleşir (Srinivas ve Patnaik, 1994).

Genetik algoritma ilk olarak 1970'lerin başında Holland tarafından doğadaki evrimsel süreçler taklit ederek geliştirilmiştir. GA, temel olarak optimum çözümü bulmak için geliştirilen bir problem çözme stratejisidir.

GA'da rastgele çözümler ile başlangıç popülasyonu oluşturulur. Seçim, daha iyi çözümlerin hayatta kalmasını sağlayan süreçtir. Her çözümün ne kadar iyi olduğunu belirlemek için uygunluk değeri belirlenir. Bir bireyin uygunluk değeri ne kadar artarsa hayatta kalma ve üreme şansı da o kadar artmaktadır. Uygunluk değeri daha yüksek olan bireyler bir sonraki nesli üretmek üzere ebeveyn olarak seçilirler. Rekombinasyon ile seçilen ebeveynlerin kromozomları birleştirilir. Birleşme, parça alışverişi gerçekleştiren bir çaprazlama mekanizması ile gerçekleştirilmektedir. Mutasyon adı verilen başka bir işlem, dizi bitlerinin düzensiz ve rastgele değişmesine neden olur. Rekombinasyon ve mutasyon ile birlikte çeşitlilik sağlanmış olur ve yeni nesil bireyler üretilmiş olunur (Eiben ve Smith, 2003).

Şekil 1.6 'da GA'nın sözde kodu verilmiştir.

```

GA
1  begin
2      Çözümleri kodla
3      Uygunluk fonksiyonunu tanımla
4      Başlangıç popülasyonunu oluştur
5      Çaprazlama ( $p_c$ ) ve mutasyon ( $p_m$ ) oranlarını belirle
6      while (maksimum nesil sayısına kadar) do
7          begin
8              Çaprazlama ve mutasyonla yeni çözümler oluştur
9              if  $p_c > \text{rand}()$ 
10                 Çaprazlama();
11             end
12             if  $p_m > \text{rand}()$ 
13                 Mutasyon();
14             end
15             Uygunluğu artarsa yeni çözümü kabul et
16             Mevcut en iyiyi bir sonraki nesil için seç
17         end
18     end

```

Şekil 1.6. Genetik Algoritma Sözde Kodu

GA'da ilk aşama olan çözümlerin kodlaması aşamasında probleme uygun kodlama tipinin belirlenmesi oldukça önemlidir. Kodlama, çözümlerin nasıl oluşturulacağını belirlediği aşamadır. İkili kodlama, permütasyon kodlama, değer kodlama ve ağaç kodlama sıklıkla tercih edilen kodlama tipleridir.

Seçim, bir sonraki nesil için birleşecek olan ebeveyn bireylerin belirlendiği aşamadır (Thengade ve Dondal, 2012). Daha uygun çözümler hayatta kalırken, daha zayıf olan çözümler yok olmaktadır. Seçim yöntemleri olarak turnuva seçimi, rulet tekerleği seçimi ve sıralı seçim gibi yöntemler kullanılmaktadır.

Çaprazlama, ebeveyn olarak belirlenen bireylerden çocuk bireylerin üretildiği aşamadır. Birden fazla çaprazlama yöntemi mevcuttur. Bunların arasında tek nokta çaprazlama, çift nokta çaprazlama ve sıralı çaprazlama sayılabilir. En yaygın olarak kullanılan çaprazlama yöntemi tek noktalı çaprazlamadır (Thengade ve Dondal, 2012).

Seçim ve çaprazlama sonucunda yeni bir popülasyon oluşturulmaktadır. Oluşturulan yeni bireylerin tamamen aynı olmasının önüne geçmek için ise mutasyon işlemi gerçekleştirilmektedir. Mutasyon ile problemin çözüm alanını araştırmada yön değişiklikleri oluşturularak, çözüm arama işleminin kısır bir döngüye girmesinin önüne geçilmektedir. Mutasyon yeni bireylerde bulunan genlerden rastgele olarak seçilen genlerin değiştirilmesi ile gerçekleşmektedir (Thengade ve Dondal, 2012).

2. KAYNAK ARAŞTIRMASI

Bu tezde önerilen yöntem için şimdiye kadar bilinen farklı yapay sinir ağlarının literatür taraması yapılmıştır. Ayrıca yöntemimize yapı olarak benzer olduğu düşünülen seyreltme (dropout) algoritması kullanılarak gerçekleştirilen farklı çalışmalar da incelenmiştir. Seyreltme algoritmasından tez çalışmasındaki algoritmayı ayıran temel fark; seyreltme algoritmasında nöronlar ağdan silinirken tez çalışmasında bağlantılar silinmektedir.

Yapay sinir ağında kullanılan ağ fonksiyonlarının da ağ üzerindeki önemi düşünülerek, ağ fonksiyonlarının nasıl kullanıldığına dair genel bir incele yapılmıştır. Tez çalışmasında amaç fonksiyonu olarak kullanılacak olan PSO ve BPSO algoritmalarının literatür araştırması da yapılmıştır. Son olarak ise yapay sinir ağının bağlantı optimizasyonu için kullanılan evrimsel hesaplama yöntemlerine dair kaynak araştırması yapılmıştır. Yapılan bu kaynak araştırmasının temel odağı önerilen yöntem ile benzerliği olduğu düşünülen yöntemler arasındaki farklılıkları ortaya koymak ve önerilen yöntemin yeniliğini vurgulamaktır. Bundan dolayı literatür araştırmasının sonunda önerilen yöntemin katkısı maddeler halinde listelenmiştir.

2.1. Yapay Sinir Ağları ile İlgili Kaynak Araştırması

YSA, biyolojik sinir sisteminin benzetimi olmasından dolayı yapay zekâ alanında son yıllarda en çok araştırılan makine öğrenmesi algoritmalarından birisi olmuştur. Tek katmanlı algılayıcı, yapay sinir ağlarının temelini oluşturan ilk yaklaşımdır ancak doğrusal olmayan ve çok sınıflı problemleri çözememesi yapay sinir ağlarında uzun süren bir durgunluğa sebep olmuştur. 1980'lerde daha fazla işlem gücü gerektiren çok katmanlı algılayıcının keşfedilmesiyle birlikte yapay sinir ağlarının doğrusal olmayan sınıflandırma problemlerini çözebildiği gösterilmiştir. Böylece bugün, derin öğrenme araştırmalarına uzanan popüler bir araştırma alanı ortaya çıkmıştır.

Biyolojik sinir hücreleri karmaşık bir yapıya sahiptirler. Karmaşık yapıda olmalarına neden olarak zamansal bir düzen olması, hiyerarşik bir yerel düzen gözlenmesine rağmen hiyerarşiyi değiştiren ileri yönde veya geri yönde bağlantıların bulunması ve farklı işlevleri gerçekleştirebilmek için yardımcı elemanların kullanılması gösterilebilir. Bilgisayarların işlemcilerinin ve hafızalarının güçlenmesi ve sinir sisteminin biyolojik yapısı hakkında bilgi birikiminin gün geçtikçe artması, biyolojik sinir

sisteminin bu karmaşık yapısını daha iyi modelleyebilen algoritmaların geliştirilmesinin önünü açmıştır. Yapılan araştırmaların bir kısmı biyolojik sinir sisteminin keşfedilen yeni bir özelliğini problem odaklı incelerken diğer bir kısmı ise biyolojik yapıyı bir bütün olarak algılayarak daha kapsamlı bir şekilde ele almayı tercih etmiştir. Bu tezde önerilen yaklaşım biyolojik yapıyla uyumlu bir yapay sinir ağı mimarisini bağlantılar ve ağırlıklar olarak optimize edebilen bir araştırmadır.

İlk ve en temel ağ mimarisi ikili tipte nöronlardan oluşan ileri beslemeli çok katmanlı ağlardır. Birimlerinde sigmoid gibi bir aktivasyon fonksiyonu ve eğitiminde geri yayılım metodu kullanılan sürekli türleri günümüzde yaygın olarak kullanılmaktadır. Genellikle hesaplama maliyetinin daha düşük olması sebebi ile geri beslemesi olmayan katmanlı yapıdaki ileri yönlü ağlar problem odaklı olarak tasarlanmaktadır. Kontrol, robotik, biyoinformatik, örüntü tanıma gibi uygulamaları bulunmaktadır. Biyolojik sisteme olan benzerliğini arttırmayı amaçlayan uzak katmanlar arasında doğrudan bağlantıların yapılması, bazı bağlantıların budanması, katmanlarda farklı aktivasyon fonksiyonlarının kullanılması gibi çalışmalar bulunmaktadır. Örneğin Wang ve ark. (2021) öznelikleri otomatik olarak çıkarabilen rasgele evrişimli sinir ağı modeli öne sürmüşlerdir. Model rastgele oluşturulan giriş, gizli ve birleştirilmiş bir çıkış katmanından oluşmaktadır. Adabound olarak adlandırılan bir optimizasyon yöntemi ve budama tekniği ile ağın eğitim hızını artırmak ve yerel optimuma yakalanmayı önlemeyi amaçlamışlardır. Kaviani ve Sohn (2021) ileri beslemeli tip ağlarda farklı katmanlardaki nöronlar arasında kısa veya uzun menzilli bağlantı kuran iki farklı yöntemi karşılaştırmıştır. Uzun menzilli bağlantıların kullanıldığı yöntemin doğruluğu güçlü bir kararlılıkla yüksek tutması, aynı zamanda ağ gizli katman sayısından bağımsız hale getirmesi ve aşırı öğrenmeyi önlemesi sağlanmıştır. Chen ve ark. (1992) tasarımında ise her bir nesnenin öznelikleri giriş katmanında gruplanmış şekildedir ve nesnelerin bazı öznelikleri giriş katmanından çıkış katmanına doğrudan bağlanarak kullanılmıştır. Santra ve ark. (2020) ağın genelleme başarısını artırmak için deterministik bir budama yöntemi ile önemi daha düşük olan bağlantıları iptal etmişlerdir. DropConnect yöntemi ile ağı yeniden düzenleyerek milyonlarca parametreye sahip büyük ağların eğitiminde meydana gelen aşırı öğrenmeyi önlemeyi amaçlamıştır. Wan ve ark. (2013) DropConnect, budama yönteminin genelleştirilmiş bir versiyonu olarak tanımlanabilir ve rastgele seçilen bir ağırlık kümesini sıfır olarak ayarlamaktadır. Fahlman ve Lebiere (1997) ise budamaya alternatif olarak kaskat korelasyon olarak adlandırdıkları yöntemde eğitim aşamasında gerektikçe bir gizli düğüm ekleyerek ağ büyüklüğünü ve topolojisini adım adım geliştirmişlerdir.

Tüm nöronlar arasında bağlantıların var olması sebebiyle tez çalışmasına daha yakın olan ve tarihi önemi olan ilk yaklaşım ise Hopfield (2007) ağıdır. Tüm nöronlar arasında bağlantılar kurulmuştur ve aynı nöronlar hem giriş hem de çıkış olarak kullanılır. Katmanlı bir yapı söz konusu değildir. Bu açıdan sinir sistemine çok benzese de ara katmanları olmaması ve ağırlıkların simetrik oluşması sebebiyle biyolojik yapıyla uyumlu değildir. Diğer bir yaklaşım ise Hopfield ağlarının stokastik tekrarlayan karşılığı olan Boltzmann Makineleridir (Hinton, 2007). Boltzmann ağı görünür ve gizli düğümlere sahiptir. Bu özelliği ile ilk gizli nöronlara sahip ağ modelidir. Gizli nöron sayısına bağlı olarak öğrenme yavaştır. Özellikle ağırlıkların büyük olması durumunda ağın denge dağılımlarına yaklaşması uzun sürmektedir ve öğrenme sinyali gürültülü olabilmektedir. Bu sorunları çözmek için görünür ve gizli nöronların kendi içinde bağlantıları kaldırılarak Kısıtlı Boltzmann Makineleri geliştirilmiştir (Hinton, 2012). Kısıtlı Boltzmann Makineleri girdi seti üzerindeki olasılık dağılımlarını öğrenebilmektedir ve eğitilmiş bir Kısıtlı Boltzmann Makinesinin gizli katmanındaki aktiviteler daha yüksek seviyeli bir Kısıtlı Boltzmann Makinesinin eğitim verisi olabilir. Bu haliyle çok katmanlı algılayıcıyı andırmaktadır. Katmanları Kısıtlı Boltzmann Makinelerinden oluşan ağ yapısı günümüzde derin inanç ağları olarak bilinen derin öğrenme mimarilerinden birisidir. Ağırlıkların güncellenmesinde geri yayılıma göre yavaş olması, nöronların sadece ikili girişler ile çalışması ve geri beslemelerin olmaması sebebiyle bu gruptaki mimariler biyolojik sinir sisteminden ayrılmaktadır.

Geri beslemeli ağlar, $t-1$ anında gizli veya çıkış nöronlarının değerlerinin bir sonraki t anında giriş olarak kullanılması, Rumelhart ve ark. (1986) 'daki çalışmasına dayanır ve özyinelemeli veya tekrarlı sinir ağları olarak adlandırılmaktadır. Önceki durumun tutulması ağa hafıza yeteneğinin eklenmesi gibi düşünülebilir. Bu açıdan ileri beslemeli ağlardan farklıdır. Her bir veri örneğinin birbirinden bağımsız olmadığı sıralı veriler ve zaman serileri gibi bir önceki durumun anlamlı olduğu problemlerin çözümünde tercih edilirler. Özyinelemeli yapay sinir ağı çalışmalarında geriyayılım (Khotanzad ve ark., 1994; Hongkang ve ark., 2018) ve optimizasyon yöntemleri Parra Hernández ve ark. (1998) ağın eğitiminde en yaygın kullanılan eğitim yöntemleridir. Bunun yanı sıra Jianhui ve ark. (1998) tarafından yapılan PID ve Khalifa ve ark. (2021) tarafından yapılan gizli markov modelleri çalışmasındaki gibi farklı yöntemlerin uygulamaları veya amaç probleme göre özelleştirilmiş eğitim yöntemleri de mevcuttur. Araştırmaların bir kısmı ise ağın eğitimi yerine topolojisi ile ilgilenmiştir. Örneğin Ren ve ark. (2021) sınıfı çok olan problemleri sınıfı daha küçük problemlere bölen ağaç

biçiminde katmanlı bir özyinelemeli ağ yapısı oluşturmuştur ancak katmanlar arasında bir geri besleme yoktur ve parametreler için bir düzenleme yoktur. Deng ve ark. (2020) evrişim yöntemini özyinelemeli ağlar ile kullanmışlardır. Yöntem öznelik vektörlerini kendiliğinden türetebilmektedir fakat ağ yapısı sabittir ve parametreleri optimize eden bir yaklaşımda yoktur. Kumar ve Srivastava (2020) çıkıştan gizli katman düğümlerine daha stabil bir özyinelemeli güncelleme sağladığı için Lypunov fonksiyonu kullanan geri beslemeler inşa etmiştir. Bu çalışmada m adet düğümden oluşan gizli katman kullanıcı tanımlı ve sabit yapıdadır. Bu grup ağlarda özellikle geri beslemelerin rasgele seçilmesi, ağın bağlantı biçiminin optimize edilmemesi, ağ topolojisinin problem odaklı olması, ağ parametrelerinin dinamik bir şekilde ayarlanmaması, hesaplama maliyetinin yüksek olması genel olarak karşılaşılan dezavantajları oluşturmaktadır.

Biyolojik sinir hücreleri ani darbe sinyalleri oluştururlar ve çoğu hücre birbirleriyle bu darbe sinyaller üzerinden haberleşir. Aksiyon potansiyeli olarak bilinen ani darbe dizileri hücre gövdesinde oluşur ve aksonlar üzerinden dendritlere ulaşır. Biyolojik sinir sistemlerinde bilginin darbelerin zamanlaması ile kodlandığı düşünülmektedir (Rullen ve Thorpe, 2001). Spiking ağları biyolojik sinirsel bilgi işleme, esneklik ve öğrenme gibi beyindeki temel süreçlerin bir benzetimi olarak önerilmiştir. Doruk ve Zhang (2018) duyuşal nöronlar eğitmek için bir çalışma gerçekleştirmişlerdir. Uyarının verdiği tepki arka arkaya gerçekleşen aksiyon potansiyellerinin zirve anlarıdır. Tekrarlayan sinir ağı modeli, bir uyarıcı-yanıt veri çiftine olasılık fonksiyonu, sinir darbe sinyalinin Poisson istatistiklerinden türetildiği maximum likelihood estimation (MLE - maksimum olasılık tahmin) yöntemi, kullanılarak yerleştirilebilir. Tian ve ark. (2021) Sıvı Durum Makineleri (Liquid State Machine - LMS) mimarisi ve parametrelerini ayarlamak için arama tabanlı nöron mimarisi ileri sürmüşlerdir. LMS, spiking Neural Networks (SNNs) ağlarının tekrarlayan versiyonu olarak isimlendirilebilir. LMS, yüksek bir hesaplama gücüne, biyolojik olasılıklara, basit bir yapıya ve düşük eğitim karmaşıklığına sahiptir. LMS temel olarak üç aşamadan oluşur. Bunlar: kodlama katmanı, sıvı katman ve readout katmanıdır. Girdi verileri ilk olarak hız kodlaması, zaman kodlaması ve faz kodlaması gibi özel kodlama şemalarını takip eden kodlama katmanı tarafından bir diziye dönüştürülür. Daha sonra uyarıcı nöronları içeren bu kodlanmış nöronlar rastgele ve seyrek olacak şekilde sıvıda bulunan nöronlara bağlanırlar. Son aşama olan okuma katmanında ise sıvı katman sonucunda elde edilen uç sayısı kaydedilir ve özellik vektörleri halinde işlenir. LSM modelinde rastgele oluşturulan sıvılar genellikle yararlı bir filtre görevi görmezler ve yararlı bir filtre bulunana kadar birçok

rastgele sıvı üretmesi gerekebilir. Norton ve Ventura (2010) bu durumun önüne geçmek amacıyla LSM'nin rastgele oluşturulan sıvısını eğitmek için bir algoritma sunmaktadır. Önerilen bu algoritma sadece kullanılabilir filtreler bulmakla kalmamış ayrıca her sıvıyı bir eğitim yapılmadan değerlendirebilmiş ve arama sürecini sonlandırıcı bir kriter sağlayabilmiştir. Önerilen algoritma, sistemin doğruluğundan ziyade sıvının farklı girdi sınıflarını farklı davranış kalıplarına ayırma yeteneğini geliştirmeye çalışır. Bu ayırma odaklı yaklaşıma Separation Driven Synaptic Modification (SDSM) adı verilmektedir. Bu grupta özetlenen çalışmalardan da anlaşıldığı üzere ağ mimarisi biyolojik beyin ile daha uyumludur. Ağ mimarisi daha karmaşık ve hesaplama maliyeti yüksek olduğu için yapısıyla uyumlu özel tasarlanmış işlemciler kullanılmaktadır. Yeterli eğitim verilerinin bulunmaması ve gerçek dünya verilerini spike dizilerine çevirmenin zorluğu sebebiyle ticarileşmesi gerçekleşmemiştir.

Yapay sinir ağları çeşitli yöntemler kullanılarak optimize edilmeye çalışılmıştır. Doğruluk ve hesaplama maliyeti bakımından değerlendirildiği zaman literatürde kullanılan diğer algoritmalar ile yakın performans gösteren bir yöntem olarak Lupo Pasini ve ark. (2021) tarafından önerilen Sinir Ağı Mimarisi için Aç Gözlü Arama (GSNNA) yapısı verilebilir.

2.2. Seyreltme (Dropout) Algoritması ile İlgili Kaynak Araştırması

Son zamanlarda yaygın olarak kullanılan ağ mimarilerinden bir diğeri de Deep Neural Networks (DNN)'dir. DNN güç, zaman ve bellek bakımından yoğun eğitim gerektiren yapılardır. Ayrıca DNN aşırı eğitildikleri veya ağa çok uyum sağladıkları zaman over-fitting (ezberleme) meydana gelmektedir (Yeoh ve ark., 2021). Genellikle DNN'de ezberlemenin önüne geçebilmek amacıyla dropout uygulanmaktadır. Dropout işleminde ağda bulunan nöronlardan bazıları belli oranda rastgele olarak atılır. Çıkarılan düğüme giren ve çıkan bağlantılarda ağdan çıkarılmaktadır. Bu sayede hem ezberlemenin önüne geçilmiş hem de ağın büyüklüğü küçültülerek işlem maliyeti azaltılmış olmaktadır. Literatür incelendiği zaman derin öğrenme ağlarında dropout işlemini uygulayan birden fazla çalışmayla karşılaşmıştır.

Chen ve Yi (2021) sinir ağı eğitimi için klasik dropout yöntemden farklı olarak adaptive sparse dropout (AS-Dropout) yöntemini ileri sürmektedirler. Bu yöntemde aktif nöronları belirlemek için nöronlar olasılık hesaplama işlemine tabii tutulmaktadır. Olasılık hesaplama işlemi ise aktivasyon fonksiyonuna göre değer almaktadır. Olasılığı

düşük olan nöronlar ağdan atılarak AS-Dropout işlemi tamamlanmaktadır. Bu yöntem sayesinde derin sinir ağı kesinlik ve belirsizliği öğrenmektedir. Önerilen yöntemin klasik dropout ve geliştirilmiş diğer dropout yöntemlerine kıyasla daha iyi sonuç verdiği gözlemlenmiştir.

Derin sinir ağlarında büyük öneme sahip olan bir konu da belirsizliklerin değerlendirilmesi üzerinedir. Eğitim sürecinde görülmeyen örneklerle karşılaşılması durumunda ağı doğru sonuç üretebilmesi belirsizleşmektedir. İşte bu belirsiz verilerin tahmin edilebilmesi için Mae ve ark. (2021) Bayes tabanlı bir derin sinir ağı dropout yöntemi ileri sürmektedirler. Yöntem Monte-Carlo metodundaki hesaplama sorununa çözüm olarak örneklemsiz olarak geliştirilmiştir. Dropout kullanılarak eğitilen bir derin sinir ağını, varyans yayılımı aracılığıyla Bayes sinir ağına dönüştürmektedir. Bu sayede belirsiz örnekler hakkında bilgi edinilebilmektedir.

Klasik dropout yöntemini kullanan bir diğer çalışma ise Wang ve ark. (2019) tarafından gerçekleştirilmiştir. Klasik dropout yönteminde dropout oranı seçimi genelleme farkını artırabildiğinden dolayı Seyreltme Rademacher Karmaşıklığı (Dropout Rademacher Complexity) yönteminde dropout oranı bir kısıtlama fonksiyonu ile sınırlandırılmıştır. Farklı veri setleri üzerinde uygulanan bu yöntemin yakınsama ve tahmin olarak daha iyi sonuçlar verdiği kanıtlanmıştır.

Dropout yöntemi nükleer mühendislik alanında da bazı çalışmalarda kullanılmıştır. Buna örnek olarak Jo ve ark. (2021) çalışması verilebilir. Soğutma sıvısı kaybı kazası (LOCA), etkili bir şekilde yönetilmezse, bir LOCA'nın sonuçları reaktör çekirdeğinin zarar görmesine neden olabilir. Bu durumun önüne geçebilmek amacıyla güvenlik enjeksiyon sistemleri (SISs) kullanılmaktadır. Fakat bu sistemin çalışmaması durumunda ciddi kazalar ortaya çıkmaktadır. SISs sistemleri için kurtarılabilir maksimum çalışma süresine altın zaman adı verilmektedir. Altın zamanı tahmin etmek için geliştirilen bu çalışmada dropout kullanılan bir derin bulanık sinir ağı (DFNN) ileri sürülmüştür. Önerilen yöntem sayesinde SISs için kalan maksimum süre tahmin edilerek oluşabilecek ağır kazaların önüne geçilebilmektedir.

Dropout yönteminin literatür incelendiği zaman donanımsal olarak da bazı çalışmalarda kullanıldığı görülmüştür. Yeoh ve ark. (2021) yaptıkları çalışma da ise dropout algoritması donanım odaklı olarak kullanılmıştır. Alanda Programlanabilir Kapı Dizileri (Field-programmable gate array - FPGA) genellikle düşük çalışma gücü ve paralel veri işleme yapmasından dolayı gömülü sistemler için kullanılmaktadır. Fakat bir derin öğrenme ağı eğitim esnasında güç ve bellek bakımından yüksek performans

gerektirmektedir. Bu yüzden yapılan bu çalışmada daha az belleğe ihtiyaç duyan donanım odaklı bir yaklaşım öner sürülmektedir. Önerilen bu yöntem, genel dropout algoritmasıyla kıyaslandığı zaman daha az kaynak miktarıyla bile aynı performansı gösterebilmiştir.

2.3. Parçacık Sürü Optimizasyonu ile İlgili Kaynak Araştırması

Optimizasyon çeşitli çözümler arasından en iyi sonucu verecek olan optimum değerini bulunmasıdır. Optimizasyon problemlerini çözebilmek amacıyla farklı algoritmalar geliştirilmiştir. Bu algoritmalarından biri olan sezgisel algoritmalar farklı gruplarda incelenmektedir. Sürü tabanlı optimizasyon algoritmaları da bu gruplardan biridir ve PSO bu gruba dahildir. Literatürde PSO algoritması kullanılarak gerçekleştirilen oldukça farklı çalışma mevcuttur.

PSO, ilk kez 1995 yılında sosyolog-psikolog James Kennedy ve elektrik mühendisi Russel Eberhart tarafından ileri sürülmüştür. Bu yöntem doğrusal olmayan sürekli fonksiyonların optimizasyonu için önerilmiştir. PSO temel olarak iki metodolojinin birleşiminden meydana gelmektedir. Bu metodolojilerden ilki kuş ve balık sürülerine bağlı olan yapay yaşam metodolojisidir ve genel olarak ilk akla gelen metodolojidir. Diğeri ise evrimsel hesaplama ile ilgilidir (Kennedy ve Eberhart, 1995).

Literatür incelendiği zaman PSO ile alakalı yapılan çalışmaların beş temel grupta toplandığı görülmüştür. Bunlar PSO'nun modifikasyonları, popülasyon tabanlı yaklaşımlar, hibridizasyon, teorik analiz ve paralel uygulamalardır (Zhang ve ark., 2015).

Yapay sinir ağının eğitimi için PSO'nun kullanıldığı farklı çalışmalar literatürde mevcuttur. Bunlardan birçoğuna değinecek olursak: Das ve ark. (2014) kanal eşitleme problemi (problem of channel equalization) için PSO ile eğitilmiş bir yapay sinir ağı önermişlerdir. PSO bu çalışmada sadece ağınlıkların belirlenmesinde kullanılmayıp ayrıca ağı parametrelerini de optimize etmek için kullanılmıştır. Burada kastedilen ağı parametreleri: katman sayısı, giriş ve gizli katman nöron sayısı ve transfer fonksiyonudur. Yapılan çalışma sonucunda diğeri yapay sinir ağı tabanlı yaklaşımlara oranla PSO ile optimize edilmiş ağı daha iyi sonuç verdiği kanıtlanmıştır.

PSO ile YSA için en uygun parametrelerin seçilmesi ile gerçekleştirilen bir diğeri çalışma ise Quarto ve ark. (2022) tarafından gerçekleştirilmiştir. Çalışmadaki amaç μ EDM süreci için en uygun süreç parametrelerini seçmeye yönelik bir metodoloji kurmaktır.

Moayedi ve ark. (2019) çalışmalarında heyelan duyarlılık hesaplama (LSM) tahmini problemi için PSO ile optimize edilmiş bir YSA kullanmışlardır. Buradaki çalışmada YSA'nın optimizasyonu için PSO tercih edilmesinin nedeni yerel minimuma takılmaktan kurtulmak ve öğrenme hızını artırmaktır. PSO ile optimize edilmiş YSA ile orijinal YSA için elde edilen sonuçlar kıyaslanarak çalışmada sunulmuştur. Sonuç olarak PSO ile optimize edilen YSA'nın daha iyi sonuçlar verdiği kanıtlanmıştır.

Asadnia ve ark. (2014) Çin'de bulunan Heshui havzasında su seviyelerini tahmin etmek için geliştirilmiş PSO ile eğitilmiş bir yapay sinir ağı ileri sürmüşlerdir. Günlük yağış su seviyeleri öncelikle Levenberg-Marquardt sinir ağı (LM-NN) ile eğitilmiş YSA ile analiz edilmiştir. Analiz sonucunda elde edilen bu sonuçlar PSO tabanlı YSA'lar ile kıyaslanmıştır. Bunlar geleneksel PSO sinir ağı (CPSONN) ve pasif topluluk ile geliştirilmiş PSO sinir ağıdır. Sonuçlar PSO tabanlı YSA'ların LM-NN'ye göre daha iyi sonuç verdiğini kanıtlamıştır.

Khajeh ve Dastafkan (2014) gümüş nanopartiküllere dayalı katı faz ekstraksiyon yöntemi ve UV-sis spektrofotometrisi ile su numunelerinden eser miktarda molibdenin zenginleştirilmesi ve belirlenebilmesi için PSO ve YSA melezi bir yöntem önermişlerdir. Chai ve ark. (2014) çapraz mutasyona dayalı bulanık parçacık sürü optimizasyonu (FPSOCM) ile üç sınıflı insan bilgisayar etkileşimi ara yüzünün sınıflandırma işlemini gerçekleştirmişlerdir. Burada yapay sinir ağının eğitimi için FPSOCM kullanılmıştır.

Literatür incelendiği zaman geri yayılım yapay sinir ağlarının parametrelerinin PSO ile optimize edildiği çalışmalardan biri de Bai ve ark. (2021) tarafından gerçekleştirilmiştir. Çalışmada güvenilirlik tahmini için düşük doğruluk problemini çözmeyi amaçlayan bir geri yayılım sinir ağı ileri sürmüşlerdir. Ağın ağırlıklarını güncellemek için ise dinamik ağırlık PSO tabanlı sinüs haritası (SDWPSO) yöntemi geliştirmişlerdir.

PSO ve geri yayılım algoritmasının birlikte kullanıldığı bir diğer çalışma ise Nasimi ve Irani (2014) tarafından maya fermantasyon biyoreaktörlerinin tanımlanması ve modellenmesi için gerçekleştirilmiştir. PSO'nun küresel optimum civarında arama süreci çok yavaş olacağından, gradyan azalan yöntemi ile küresel optimum daha hızlı ve doğruluğu yüksek olarak tahmin edilebilmektedir. Önerilen yöntemde de gradyan tabanlı geri yayılım algoritmasının yerel arama kabiliyeti, PSO'nun ise küresel arama kabiliyeti birleştirilmiştir. Sonuç olarak önerilen hibrit yöntemin geri yayılım yapay sinir ağına göre daha iyi sonuç verdiğini kanıtlanmıştır.

2.3.1. İkili parçacık sürü optimizasyonu ile ilgili kaynak araştırması

Sürekli PSO, sürekli problemlerin birçoğunda başarılı sonuçlar üretmektedir. Fakat ayrık ve ikili problemleri çözebilmesi için modifiye edilmiştir. İşte bu gibi durumlarda ayrık ikili değişkenler üzerinde çalışmak üzere algoritmanın ikili sürümünü BPSO ileri sürülmüştür. İkili sürümünde koordinatın sıfır ve bir olması olasılığı ele alınmaktadır (Kennedy ve Eberhart, 1997).

Sarath ve Ravi (2013) birliktelik çıkarım kuralı için Priori ve FP-Growth algoritmalarına alternatif olabilecek bir birliktelik kuralı çıkarıcı model geliştirmişlerdir. Önerilen yöntem, Priori algoritmasının aksine minimum destek ve güven belirtilmeden bir Kombinatoryal Küresel Optimizasyon problemini formüle ederek işlem veri tabanından birliktelik kurallarını oluşturmaktadır. Oluşturulan kuralın kalitesi uygunluk fonksiyonu ile belirlenmektedir.

Ganesh ve ark. (2014) kontrolsüz ortamlara sahip yüz görüntülerinden kulak tahmin edebilmek için Entropik İkili Parçacık Sürü Optimizasyonu (EBPSO) isimli yeni bir yöntem ileri sürmüşlerdir. Çift Ağaç Karmaşık Dalgacık Dönüşümü (DTCWT) tabanlı arka plan budama ile yüz görüntülerinin arka planın çoğunu ortadan kaldırılmıştır. Bu sayede önerilen entropi sınıflandırıcı ile gözlenen entropi modellerine dayanarak kulak bölgeleri yüz özelliklerinden ayrılmıştır.

Zhai ve He (2013) maksimum sınıflandırma doğruluğu ile en küçük örnek kombinasyonunu bulma amacı bulunan zaman serisi sınıflandırması için örnek seçimi problemini çözmek için İmmün İkili Parçacık Sürü Optimizasyonunu (IBPSO) önermişlerdir. IBPSO aşılama ve bağışıklık seçimi için yeni bir immün mekanizması sunarak BPSO'nun küresel arama kapasitesini geliştirmektedir.

Mojtaba Ahmadih ve ark. (2017) standart ikili PSO yöntemini geliştirerek yeni bir yöntem ileri sürmüştür. Bu algoritmada ikili PSO'nun hız vektörü için yeni bir tanım önermişlerdir. Ayrıca w değeri için uygun değeri seçme sorunu ortadan kaldırılmıştır. Her parçacığın önceki yönü ve önceki durumu da dikkate alınmıştır.

BPSO'nun özellik seçimi için kullanıldığı çalışmalar da mevcuttur. Örneğin Xiong ve ark. (2019) eklem momentini tahmin ederken oluşan girdi karmaşıklığını azaltmak amacıyla BPSO dayalı yeni bir yöntem önermişlerdir. BPSO, elektromiyografi (EMG) ve eklem açışı verilerinden en uygun alt girdi kümelerini seçmek için kullanılmıştır. Sonuç olarak 16 adet olan girdi BPSO ile 11'e indirgenmiştir.

Yapılan çalışmalar incelendiği zaman, BPSO'nun birbirinden farklı çalışma alanlarında kullanıldığı görülmüştür. Ayrıca standart BPSO geliştirilerek yeni modellerin ileri sürülmüştür. BPSO ayrıca farklı algoritmalar ile birleştirilerek hibrit yöntemler geliştirmek için de kullanılmıştır.

2.4. Evrimsel Hesaplama ile İlgili Kaynak Araştırması

Tez çalışmasının üzerinde durduğu en temel konu bağlantı optimizasyonudur. Evrimsel hesaplama ile ilgili yapılan literatür araştırmasında da temel olarak yapay sinir ağının bağlantılarının evrimsel hesaplama ile optimize edildiği çalışmalar dikkate alınmıştır.

McDonnell ve Waagen (1993) ileri beslemeli bir yapay sinir ağında evrimsel programlama yöntemi ile bağlantı şemasını ve ağırlıkları eşzamanlı olarak geliştirmiştir. Bağlantı sayısı bir amaç fonksiyonuna dâhil edilerek ağ parametrelerinin optimizasyonu gerçekleştirilmiştir. Giriş katmanındaki her nöron gizli katmandaki her nöron ile bağlantılı değildir. Yapılan çalışma sonucunda rastgele seçim ile oluşturulan yapay sinir ağlarına göre evrimsel hesaplama ile oluşturulan yapay sinir ağının daha iyi sonuçlar ürettiği gözlemlenmiştir.

Pujol ve Poli (1998) evrimsel hesaplama dayalı sinir ağı inşasına yeni bir yaklaşım önermişlerdir. Ağın grafik temsiliyle birleştirilmiş doğrusal bir kromozom, genetik operatörler tarafından kullanılır. Bu sayede yerel ağırlıklar optimizasyonuna ihtiyaç duyulmaksızın ağırlıklar ve ağın mimarisi eş zamanlı olarak optimize edilmektedir. Önerilen bu yeni yaklaşım çeşitli ikili sınıflandırma problemlerine uygulanarak test edilmiştir.

Yong ve Xin (2001) çalışmalarında Hang Seng hisse senedi endeksi tahminine yönelik evrimsel bir sinir ağı yaklaşımını önermişlerdir. İleri beslemeli bir yapay sinir ağını hem ağırlıklar hem de mimari bakımından aynı evrimsel süreç içerisinde geliştirmişlerdir. Ağ yapısı büyüebilmekte ya da küçülebilmektedir. Deneysel sonuçlar ile evrimsel sinir ağı yaklaşımının daha iyi tahminler ürettiğini göstermişlerdir.

Yapılan literatür araştırmaları sonucunda evrimsel hesaplamanın hem ağın bağlantı ağırlıkları hem de bağlantıların kendisi üzerinde kullanıldığı çalışmaların olduğu görülmüştür. Temel olarak evrimsel hesaplama ile bağlantı optimizasyonu çalışmalarda elde edilen sonuçları olumlu yönde etkilemektedir.

2.4.1. Genetik algoritma ile ilgili kaynak araştırması

Whitley ve ark. (1990) yapay sinir ağının hem bağlantı ağırlıklarını hem de bağlantıların kendisi optimize etmişlerdir. Hem ikili hem de gerçek değerli temsilleri kullanarak ileri beslemeli bir yapay sinir ağında genetik algoritma kullanılarak optimize işlemi gerçekleştirilmiştir. Önerilen yöntemi 2 bitlik bir toplayıcı ve XOR problemi için test etmişlerdir. Önerilen yöntem ile budanmış ağ için elde edilen sonuçlar incelendiği zaman ise ağın öğrenme hızının arttığı ve sorunu öğrenmek için gereken geri yayılım döngülerinin sayısının da tutarlı olduğu sonucuna varılmıştır.

GA'da çaprazlama oranı ve mutasyon oranının belirlenmesi de oldukça önemli bir konudur. Bu iki oranın belirlenmesine dair de bir literatür araştırması yapılmıştır. Çaprazlama oranı, kromozomlar için çaprazlamanın meydana gelme sayısını vermektedir. Çaprazlama oranının %100 olması çaprazlama sonucunda oluşan yavruların tamamının çaprazlama ile oluştuğunu, %0 olması ise mutasyon sürecinde kaynaklananlar hariç yavruların tamamen popülasyondan kopyalandığını göstermektedir. Mutasyon oranı ise bir nesilde kaç kromozomun mutasyona uğraması gerektiğini belirlemektedir. (0,1) arasında değer alabilir (Hassanat ve ark., 2019).

Grefenstette (1986) çalışmasında, genetik algoritmalar için kontrol parametrelerini optimize etmiştir. Elde ettiği sonuçlara göre küçük boyutlu popülasyonlar için düşük mutasyon oranı ile yüksek çaprazlama oranı ve yüksek çaprazlama oranı ile düşük mutasyon oranının ilişkilidir. Orta ölçekli popülasyonlarda ise popülasyon büyüklüğü arttıkça çaprazlama oranının düştüğü görülmüştür.

Lin ve ark. (2003) çaprazlama ve mutasyon oranları için genel bir şema önermişlerdir. Şemaya göre çaprazlama ve mutasyon oranları gelecek nesildeki yavruların değerlendirme sonuçlarına yanıt olacak şekilde uyarlanmaktadır. Çalışmada yapılan deneyler sonucunda önerilen bu şema ile elde edilen sonuçların, GA ile elde edilen sonuçları önemli ölçüde geliştirdiği gözlemlenmiştir.

Hassanat ve ark. (2019) GA'da çaprazlama ve mutasyon oranlarının seçilmesi üzerine bir çalışma yapmışlardır. Çalışmada çaprazlama ve mutasyon oranlarını seçmek için kullanılacak çeşitli yöntemler ele alınmıştır. Ayrıca çaprazlama ve mutasyon oranları için yeni deterministik bir yöntem ileri sürmüşlerdir. Bu yöntem, yüksek mutasyon oranının dinamik azalması/düşük çaprazlama oranının dinamik artması (DHM/ILC) ve düşük mutasyon oranının dinamik artması/yüksek çaprazlama oranının

dinamik azalması (ILM/DHC) olarak isimlendirilmiştir. Önerilen yöntem sıklıkla kullanılan çaprazlama (0.9) ve mutasyon (0.003) oranları ile karşılaştırılmıştır.

2.5. Önerilen Yöntemin Farklılıkları ve Yenilikleri

Önerilen yönteme benzer olduğu düşünülen literatürdeki benzer çalışmalardan farklılıkları mevcuttur. Önerilen yöntemin benzer çalışmalardan farklılıkları ve literatüre katkı sağlayacağı düşünülen yenilikleri aşağıda maddeler halinde verilmiştir.

1. Önerilen yöntem klasik yapay sinir ağlarına göre biyolojik sinir sistemi ile daha uyumlu yeni bir modeldir.
2. Önerilen yöntemde bağlantıların optimizasyon işlemi gerçekleştirilerek ağın karmaşıklığı azaltılmaktadır ve yapay sinir ağının eğitim ve test için işlem maliyeti düşürülmektedir.
3. Önerilen yöntemde bağlantıların optimizasyon işlemi gerçekleştirilerek bazı nöronların ağdan silinmesi ile daha iyi sonuç üretirken daha az nöron kullanılmaktadır.
4. Önerilen yöntemde bağlantıların optimizasyon işlemi gerçekleştirilerek giriş katmanında bulunan bazı nöronların ağdan silinmesi ile özellik seçimi işlemi de kendiliğinden yapılmaktadır.
5. Önerilen yöntemde bazı nöronların yapay sinir ağından çıkartılması ile ezberlemenin de önüne geçilmektedir.
6. Önerilen yöntem farklı veri setlerine uygulanabilir. Her veri seti için yöntem farklı bir yapay sinir ağı oluşturmaktadır. Yani önerilen yöntem farklı durumlara adapte olabilmektedir.
7. Önerilen yöntemle benzerlik gösteren çalışmaların çoğu evrimsel hesaplama yöntemleri ile gerçekleştirilmiş çalışmalardır. Bu çalışmalar genellikle daha küçük boyutlu veri setleri üzerinde test edilmiştir. Bu tez çalışmasında önerilen yöntem ile yapılan çalışmalar literatürdeki çalışmalardan daha büyük veri setleri üzerinde test edilmiştir.

3. MATERYAL VE YÖNTEM

Bu tezde yapay sinir ağındaki bağlantılar ikili bir problem olarak ele alınmış ve optimizasyon işlemi gerçekleştirilmiştir. BPSO ile bağlantılar optimize edilmiştir. Ağın bağlantılarının ağırlıkları ise sürekli PSO ile iyileştirilmiştir. Yapılan literatür çalışması ile birlikte bağlantı optimizasyonu için evrimsel hesaplama yöntemlerinin tercih edildiği görülmüştür. Bu tez çalışmasında da literatürde tercih edilen bu yöntemlerden olan GA ile bağlantı optimizasyonu işlemi de gerçekleştirilmiştir.

Önerilen yöntemde öncelikle bağlantıların var olup olmaması durumu, ikili bir optimizasyon yöntemi olan BPSO yöntemi ile optimize edilmiştir. Bağlantıların var olması durumu 1, yok olması durumu ise 0 değerleri ile ifade edilmektedir. Tam bağlı bir ağda bulunması gereken tüm bağlantıların boyutu kadar rastgele bir bağlantı dizi oluşturulmuştur. Bu dizi 0 ve 1 değerlerinden oluşmaktadır.

Bağlantıların belirlenmesinde kullanılan BPSO'da uygunluk fonksiyonu olarak bağlantı dizisi ile oluşturulan YSA kullanılmıştır. Bu YSA'nın ağırlıklarının optimize edilmesi için ise sürekli PSO kullanılmıştır. Sürekli PSO'nun uygunluk fonksiyonu olarak ise yine YSA kullanılmıştır. YSA'dan sonuçlar ileri yönde hesaplama işlemleri ile alınmaktadır.

Önerilen yöntemin matematiksel modeli Denklem 3.1 ve Denklem 3.2'de verilmiştir.

$$\text{Minimize } f(N, M, O, X, Y, a, d) \quad (3.1)$$

$$\text{subject to } \exists X_{ij} \in X, \exists Y_{jk} \in Y, X_{ij} Y_{jk} = 1 \quad (3.2)$$

$$X = \{X_{11}, X_{12}, X_{13}, \dots, X_{21}, X_{22}, \dots, X_{NM}\}$$

$$Y = \{Y_{11}, Y_{12}, Y_{13}, \dots, Y_{21}, Y_{22}, \dots, Y_{MO}\}$$

X_{ij} = Giriş katmanı ile gizli katman arası bağlantı, $i=1 \dots N$ $j=1 \dots M$

Y_{jk} = Gizli katman ile çıkış katman arası bağlantı, $j=1 \dots M$ $k=1 \dots O$

N : Giriş Katmanı Nöron Sayısı

M : Gizli Katman Nöron Sayısı

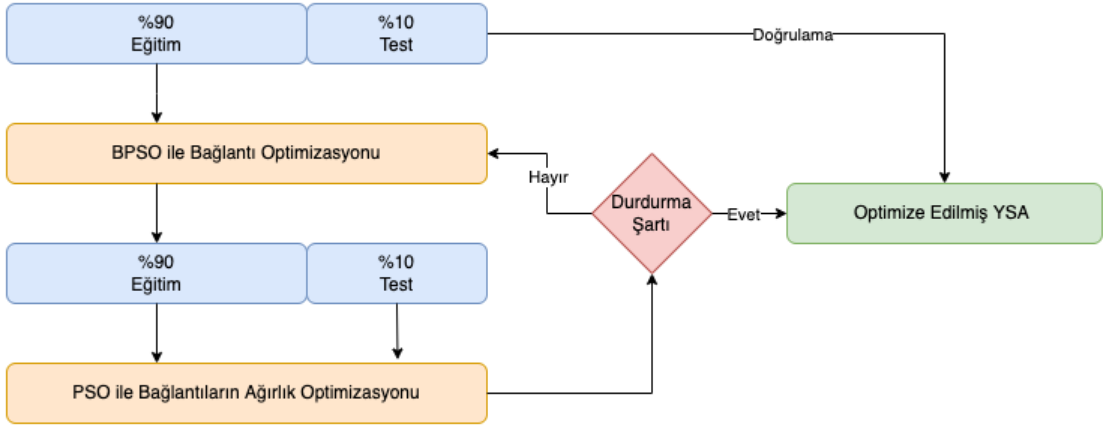
O : Çıkış Katmanı Nöron Sayısı

a : İterasyon Sayısı

d : Veri Seti

Önerilen yöntemde amaç hatayı minimize etmektir. Önerilen yönteme giriş katmanı nöron sayısı, gizli katman nöron sayısı, çıkış katmanı nöron sayısı, BPSO ile optimize edilecek olan tek boyutlu bağlantı dizisi, iterasyon sayısı ve veri seti parametre olarak verilmiştir. Fonksiyon verilen parametreler ile oluşturulan yapay sinir ağının test veri seti için hata oranını geri döndürmektedir. N , giriş katmanında bulunan nöron sayısını yani veri setinin özellik sayısını; M , gizli katmanda bulunan nöron sayısını ki bu sayı tezde giriş katmanı nöron sayısına eşit seçilmiştir; O , çıkış katmanında bulunan nöron sayısını, tezde tek sınıflı veri setleri tercih edildiği için bu değer her zaman 1 olarak alınmıştır. X ve Y , 0 ve 1 değerlerinden oluşan iki boyutlu bir bağlantı dizisidir. 0 değeri bağlantının olmamasını; 1 değeri ise bağlantının var olduğunu ifade etmektedir. a iterasyon sayısını ve d ise veri setini ifade etmektedir. X_{ij} giriş katmanı ile gizli katman arasında bulunan bağlantıları, Y_{jk} ise gizli katman ile çıkış katmanı arasında bulunan bağlantıları ifade etmektedir. Gizli katmanda bulunan en az bir nöronun hem giriş hem de çıkış bağlantısının bulunması gerekmektedir.

Şekil 3.1’de yapılan çalışmanın genel adımlarını içeren akış diyagramı verilmiştir. Veri setleri, eğitim ve test için ikiye bölünmüştür. Ezberleme probleminin önüne geçebilmek amacıyla çalışmada çapraz doğrulama işlemi uygulanmıştır. K -katlı çapraz doğrulama veri setleri k adet alt kümeye bölünmüştür. Çalışmada kullanılacak olan k alt küme sayısı olarak 10 değeri belirlenmiştir. Eğitim için $k-1$ adet alt küme kullanılmıştır. Test için ise geriye kalan alt küme kullanılmıştır. Test için ayrılan veri seti her alt küme olacak şekilde 10 sefer bu adımlar tekrarlanmıştır. Elde edilen test sonuçlarının ortalaması alınarak nihai test sonucu elde edilmiştir.



Şekil 3.1. Tez Çalışmasının Akış Diyagramı

K-katlı çapraz doğrulama için birinci iterasyonda 10 alt kümeye bölünen veri setlerinden %10'luk alt küme optimize edilmiş ağı test etmek amacıyla ayrılmaktadır. Geriye kalan %90'luk kısım ile bağlantı ve ağırlık optimizasyonu işlemi gerçekleştirilmektedir. Veri setinden eğitim için ayrılan bu kısım ile öncelikle BPSO ile bağlantı optimizasyonu işlemi gerçekleştiriliyor. BPSO'nun uygunluk fonksiyonu olarak YSA'nın ileri yönde ürettiği hata miktarı kullanılmaktadır. YSA'nın ileri yönde sonuç üretmesi için ise ağırlıkların PSO ile optimizasyonu işlemi de bu aşamada yapılmaktadır. YSA'nın bağlantı ağırlıkları PSO ile optimize edilirken veri seti tekrar %90 eğitim, %10 test olacak şekilde bölünmektedir. Bu aşamada doğrulama işlemi için herhangi bir işlem yapılmamaktadır. Bağlantı ağırlıkları PSO tarafından optimize edilen YSA'dan elde edilen hata oranı 0.01'in altındaysa veya gerekli iterasyon tamamlanmış ise durma şartı sağlanmaktadır. Aksi halde adımlar tekrar etmektedir. Durma şartı sağlandıktan sonra oluşan YSA ile ilk adımda veri setinde test için ayrılan %10'luk kısım ile doğrulama işlemi gerçekleştirilmektedir. Şekil 3.1'de verilen adımlar k-katlı çapraz doğrulama işleminin tek bir iterasyonu için verilmiştir. Diyagramdaki adımlar her bir iterasyonda tekrar edilmektedir.

3.1. Yapay Sinir Ağının Uygulanması

Bu tezde ağın parametrelerini optimize etmek için kullanılan sürü zekâsı algoritmalarının uygunluk fonksiyonu için YSA kullanılmıştır. Farklı veri setleri için farklı ağlar oluşturulmuştur. Fakat ağlar oluşturulurken aynı kurallara sadık kalınmıştır. Bütün veri setleri için ağlar üç katmandan oluşmaktadır. Bu katmanlar sırasıyla; giriş

katmanı, gizli katman ve çıkış katmanıdır. Giriş katmanında bulunan nöron sayısı veri setlerinde bulunan özellik miktarı ile aynı değerdedir. Her veri setinde farklı özellik sayısı bulunduğu için her ağın giriş katmanında bulunan nöron sayısı birbirinden farklıdır. Ağların gizli katman nöron sayısı giriş katmanı ile aynı olacak şekilde belirlenmiştir. Tezde kullanılan veri setlerinin hepsi tek sınıflı olduğu için çıkış katmanında ise tek nöron kullanılmıştır.

YSA'da bağlantıların ağırlıkları ilk olarak rastgele olarak belirlenmiştir. Toplama fonksiyonu olarak matris çarpımı işlemi uygulanmıştır. Aktivasyon fonksiyonu olarak ise sigmoid fonksiyonu tercih edilmiştir.

Çalışmada kullanılan YSA'da sonuçları elde etmek için yapılan işlem adımları şu şekilde sıralanabilir;

- i. Ağın giriş, gizli ve çıkış katman nöron sayıları belirlenmiştir.
- ii. Ağda bulunan ağların ağırlıkları başlangıçta rastgele olarak belirlenmiştir.
- iii. Gizli katmanda bulunan nöronlar için toplama fonksiyonu ile nörona giren yolların ağırlıkları toplanmıştır.
- iv. Toplanan ağırlık değerleri aktivasyon fonksiyonuna tabii tutularak nöronların çıkış net değerleri hesaplanmıştır.
- v. Gizli katmanda elde edilen çıkış değerleri kullanılarak çıkış katmanına giren bağlantı ağırlıkları toplanmıştır ve aktivasyon fonksiyonundan sistemin net çıkış değeri elde edilmiştir.

3.2. Geri Yayılım Algoritmasının Uygulanması

Bu tez çalışmasında geri yayılım algoritması, veri setleri üzerinde tam bağlantılı ağın eğitimi için kullanılmıştır. BP'da iterasyon sayısı olarak kıyaslama doğruluğunu artırmak için PSO ile ağ eğitiminde de tercih edilen 100 değeri tercih edilmiştir. Yine çalışmada kullanılan diğer tüm yöntemlerde olduğu gibi veri setinin eğitim doğruluğunu artırmak için çapraz doğrulama işlemi BP için de kullanılmıştır.

Yapay sinir ağının ileri yönde ürettiği sonuç ile ağın toplam hata miktarı hesaplanmıştır. Hata geriye doğru ağa yayılırken gradyan iniş algoritması kullanılmıştır. Gradyan iniş algoritması hesaplanırken kullanılan öğrenme katsayısı olarak bu çalışmada 0.01 değeri tercih edilmiştir.

3.3. Parçacık Sürü Optimizasyonunun Uygulanması

Parçacık Sürü Optimizasyonu, sürü halinde hareket eden canlıların yiyecek bulmak gibi temel ihtiyaçlarını karşılarken sergiledikleri hareketlerden esinlenerek Kennedy ve Eberhart tarafından 1995 yılında geliştirilmiş bir optimizasyon algoritmasıdır. PSO algoritması yapılan çalışmada oluşturulan ağırlıkların optimize edilmesi için kullanılmıştır.

Yapılan çalışmada c_1 ve c_2 değerleri için 2 değeri kullanılmıştır. w değerini belirlemek için Denklem 3.3'de verilen formül kullanılmıştır.

$$w = \frac{\text{Maksimum iterasyon} - \text{iterasyon}}{\text{Maksimum iterasyon}} \quad (3.3)$$

Parçacık sayısı olarak 50 değeri belirlenirken iterasyon sayısı olarak ise 100 değeri belirlenmiştir. Başlangıçta sürüde bulunan parçacıkların hız ve konum değerleri rastgele olarak oluşturulmuştur. Hız vektörü için değerler (-6,6) aralığında belirlenmiştir. Bundan sonraki işlemler belirlenen iterasyon sayısı boyunca devam ettirilmiştir. Parçacıkların uygunluk değerleri hesaplanmıştır. Elde edilen uygunluk değeri parçacığın en iyisinden daha iyi bir değer ise parçacığın en iyi değeri güncellenmiştir. Ayrıca her bir parçacığın en iyi değerleri global en iyi ile karşılaştırılmıştır ve global en iyi güncellenmiştir. Parçacıkların yeni hız değerleri de hesaplanarak güncellenmiştir. Güncellenen hız değerleri konum değerlerine eklenerek parçacıkların yeni konumları elde edilmiştir. İterasyon boyunca aynı güncelleme adımları devam ettirilmiştir. Sonuç olarak en iyi ağırlık değerleri elde edilmiştir.

PSO, iterasyon sayısını tamamladığı zaman ya da minimum hayata ulaştığı zaman durmaktadır. Minimum hata değeri olarak ise 0.01 değeri belirlenmiştir.

3.4. İkili Parçacık Sürü Optimizasyonunun Uygulanması

Yapılan çalışmada ikili PSO ağda bulunan bağlantıların var olup olmadığını belirlemek amacıyla kullanılmıştır. İkili PSO, ikili problemlerin çözümü için Kennedy ve Eberhart tarafından önerilmiştir.

İkili PSO'da yapılan işlemler sürekli PSO'daki adımlarla benzerdir. Buradaki farklardan biri konum değerlerinin 1 ve 0 değerlerinden oluşmasıdır. Ayrıca yeni hız

değerlerinin hesaplanma yöntemi farklıdır. Elde edilen yeni hız değerinin, (0,1) aralığında belirlenen rastgele bir değerden büyük olması halinde yeni konum değeri 1, aksi halde 0 değerini almaktadır.

Çalışmada kullanılan ikili PSO için de c_1 ve c_2 değerleri 2 olarak belirlenmiştir. w değeri olarak Denklem 3.3'de verilen formül kullanılmıştır. Ayrıca yine sürekli PSO'daki gibi iterasyon sayısı 50 ve parçacık sayısı 100 olarak belirlenmiştir. BPSO, iterasyon sayısı tamamlanınca durmaktadır.

3.5. Genetik Algoritma Uygulaması

Tez çalışmasında GA, bağlantıların optimizasyonu için kullanılmıştır. Yapay sinir ağında GA ile optimize edilen bağlantılar ile BPSO ile optimize edilen bağlantılar kıyaslanmıştır.

YSA'daki bağlantılar ikili bir problem olarak ele alındığı için GA'da kromozomlar oluşturulurken kodlama aşamasında ikili kodlama tercih edilmiştir. İkili kodlamada her bir kromozom 0 ve 1'lerden oluşmaktadır. Başlangıç popülasyonu olarak yine BPSO ile aynı sayıda 100 birey belirlenmiştir. Rastgele olarak başlangıç popülasyonu oluşturulmuştur. Uygunluk fonksiyonu olarak ileri beslemeli yapay sinir ağının ürettiği hata değeri ele alınmıştır.

Seçilim için çalışmada turnuva seçim yöntemi tercih edilmiştir. Turnuva seçimi yönteminde popülasyondan rastgele olarak belli sayıda birey seçilir. Seçilen bu bireylerden ise uygunluk değeri en yüksek olan birey seçilir. Rekombinasyon için kullanılacak olan birey sayısına ulaşıncaya seçilim işlemi tamamlanır. Tez çalışmasında rastgele olarak popülasyondan rastgele olarak 3 adet birey seçilmiştir ve rekombinasyon için 2 birey kullanılmıştır.

Çaprazlama için tek noktalı çaprazlama kullanılmıştır. Tek noktalı çaprazlama işleminde ilk ve son gen haricinde arada kalan genlerden rastgele bir gen seçilir. Seçilen bu kısma çaprazlama noktası adı verilir. Her iki birey için bu noktadan sonra gelen genler karşılıklı olarak yer değiştirilir. Çaprazlama sonucunda çocuk bireyler üretilmiş olunur. Tez çalışmasında çaprazlama katsayısı olarak literatürde de sıklıkla kullanılan 0.9 değeri kullanılmıştır.

Mutasyon aşamasında ise 1 biti 0 ile, 0 biti ise 1 ile yer değiştirmiştir. Mutasyon oranı olarak yine literatürde sıklıkla tercih edilen Denklem 3.4'deki formül kullanılmıştır.

Çaprazlama sonucu üretilen yeni bireylerin boyutunca rastgele üretilen bir sayıdan mutasyon katsayısı büyükse bit değiştirme işlemi gerçekleştirilmiştir.

$$p_m = 1/n \quad (3.4)$$

Denklem 3.4’de verilen n değeri ikili bit dizisinin boyutunu ifade etmektedir. İkili bit dizisi ise bir bireyi ifade etmektedir.

GA belirlenen iterasyon sayısı tamamlanınca durmaktadır. Yine karşılaştırma için BPSO ile aynı iterasyon sayısı olan 100 değeri belirlenmiştir.

3.6. Veri Setleri

Tez çalışmasında yapılan çalışma birden fazla veri seti üzerinde test edilmiştir. Meme kanseri, hepatit, mamografik kütle ve Haberman’nin hayatta kalma veri seti gibi makine öğrenmesi çalışmalarında sıklıkla tercih edilen veri setleri çalışmada kullanılmıştır.

Tez çalışmasında kullanılan bütün veri setleri iki sınıflı olacak şekilde seçilmiştir. Ayrıca verilen bütün veri setleri ortak olarak dengeleme işlemi uygulanmış, kategorik değerler nümerik olacak şekilde dönüştürülmüş ve değerlere özellik ölçeklendirme işlemi uygulanmıştır.

3.6.1. Meme kanseri veri seti

Meme kanseri veri seti oldukça sık kullanılan veri setleri arasında yer almaktadır. Tezde kullanılan meme kanseri veri seti ‘Kaggle’ platformu üzerinden indirilmiştir.

Meme kanseri veri setindeki veriler Wisconsin Üniversitesi Hastanelerinde gerçek vakalardan toplanmıştır. Örnekler periyodik olarak toplanmıştır. Çizelge 3.1’de verilen tabloda grup olarak elde edilen veriler ve toplanma tarihleri mevcuttur. Toplam 699 örnek mevcuttur (UCI, 1992).

Çizelge 3.1. Veri Seti Grup Bilgileri (UCI, 1992)

	Örnek Sayısı	Tarih
Grup 1	367	Ocak, 1989
Grup 2	70	Ekim, 1989
Grup 3	31	Şubat, 1990
Grup 4	17	Nisan, 1990
Grup 5	48	Ağustos, 1990
Grup 6	49	Ocak, 1991
Grup 7	31	Haziran, 1991
Grup 8	86	Kasım, 1991

Çizelge 3.2’de meme kanseri veri setine ait özellikler ve özelliklerin değer aralıkları verilmiştir. Özellikler nümerik değerlerden oluşmaktadır. Veri setinde toplam 11 özellik mevcuttur. Bu özelliklerden biri ‘class’ değişkenidir ve hastalığın iyi huylu olması durumunda 2, kötü huylu olması durumunda 4 değerini almaktadır. Bir diğer özelliğimiz ise ‘id’ değişkenimizdir ve her örnek için farklı bir değer almaktadır. Geriye kalan 9 özellik ise bize hastalık hakkında bilgiler veren değişkenlerdir ve 1 ile 10 arasında değerler almaktadırlar (UCI, 1992).

Çizelge 3.2. Meme Kanseri Veri Seti Özellikleri ve Değer Aralıkları (UCI, 1992)

Özellikler	Değerler
Sample code number	Birbirinden farklı id değerleri
Clump Thickness	1 ve 10 arası değerler
Uniformity of Cell Size	1 ve 10 arası değerler
Uniformity of Cell Shape	1 ve 10 arası değerler
Marginal Adhesion	1 ve 10 arası değerler
Single Epithelial Cell Size	1 ve 10 arası değerler
Bare Nuclei	1 ve 10 arası değerler
Bland Chromatin	1 ve 10 arası değerler
Normal Nucleoli	1 ve 10 arası değerler
Mitoses	1 ve 10 arası değerler
Class	2: iyi huylu, 4: kötü huylu

Veri setinde 16 adet kayıp veri mevcuttur. Kayıp değerlerin bulunduğu veriler veri setinden silinerek temizlenmiştir.

3.6.2. Hepatit veri seti

Hepatit veri seti yaygın olarak kullanılan bir diğer veri setidir. Tezde kullanılan hepatit veri seti ‘Kaggle’ platformu üzerinden elde edilmiştir.

Veri seti 20 özellikten oluşmaktadır. Veri setinde toplam 142 örnek mevcuttur ve eksik veri bulunmamaktadır. Çizelge 3.3’de bu özellikler ve özelliklerin alabileceği değerler verilmiştir.

Çizelge 3.3. Hepatit Veri Seti Özellikleri ve Değer Aralıkları (Harinir, 2018)

Özellikler	Değerler
Class	DIE, LIVE
AGE	10,20,30,40,50,60,70,80
SEX	male, female
STEROID	no, yes
ANTIVIRALS	no, yes
FATIGUE	no, yes
MALAISE	no, yes
ANOREXIA	no, yes
LIVER BIG	no, yes
LIVER FIRM	no, yes
SPLEEN PALPABLE	no, yes
SPIDERS	no, yes
ASCITES	no, yes
VARICES	no, yes
BILIRUBIN	0.39, 0.80, 1.20, 2.00, 3.00, 4.00
ALK PHOSPHATE	33, 80, 120, 160, 200, 250
SGOT	13, 100, 200, 300, 400, 500
ALBUMIN	2.1, 3.0, 3.8, 4.5, 5.0, 6.0
PROTIME	10, 20, 30, 40, 50, 60, 70, 80, 90
HISTOLOGY	no, yes

Veri setinde bulunan özellikler nümerik ve kategorik değerleri içermektedir. Kategorik değerler, nümerik değerlere dönüştürülmüştür. Sınıf değişkeni, ölü ve canlı olmak üzere iki farklı değer alabilmektedir. Sınıf değişkeni dışında kalan özellikler hastalar hakkında genel bilgileri içermektedir.

3.6.3. Mamografik kütle veri seti

Mamografi, meme dokusunun röntgen filminin çekilmesi işlemine verilen addır. Meme kanseri teşhisi için kullanılan en etkili yöntem olarak bilinmektedir. Ancak sonuçların yanlış değerlendirilmesi gereksiz biyopsilere neden olmaktadır. Bu gibi durumların önüne geçmek amacıyla bilgisayar destekli sistemlerden faydalanılmaktadır (Ovsen, 2016).

Tezde kullanılan hepatit veri seti, ‘Kaggle’ platformu üzerinden temizlenmiş şekilde elde edilmiştir. Veri seti, Çizelge 3.4’de verilen özellikleri içermektedir. Özelliklerden biri sonuç sınıfı, biri öngörülme değeri ve geriye kalan 4 özellik ise öngörücü değerleri içermektedir. 516 iyi huylu ve 445 kötü huylu olmak üzere toplam 961 veri mevcuttur. Veriler, Erlangen-Nuremberg Üniversitesi’ne 2003 ve 2006 yılları arasında gelen hastalardan elde edilmiştir (Ovsen, 2016).

Çizelge 3.4. Mamografik Kütle Veri Seti Özellikleri ve Değer Aralıkları (Ovsen, 2016)

Özellikler	Değerler
BI-RADS	1 ile 5 arasında değerler (sıralı, öngörüsüz)
Age	Hastaların yaş değerleri
Shape	1: yuvarlak, 2: oval, 3: lobüler, 4: düzensiz
Margin	1: sınırlı, 2: mikrolobule, 3: gizlenmiş, 4: kötü tanımlanmış, 5: dikenli
Density	1: yüksek, 2: eşit, 3: düşük, 4: yağ içeren
Severity	0: iyi huylu, 1: kötü huylu

Veri setinde kayıp veriler mevcuttur. BI-RADS için 2, Age için 5, Shape için 31, Margin için 48 ve Density için 76 değer kayıptır. Kayıp verilerin bulunduğu veriler veri setinden silinerek temizlenmiştir.

3.6.4. Haberman'nin hayatta kalma veri seti

Veri seti, Chicago's Billings Üniversitesi Hastanesinde 1958 ve 1970 yılları arasında meme kanseri ameliyatı geçirmiş hastaların ameliyat sonrasında hayatta kalma durumlarını içermektedir. Tezde kullanılan veri seti, 'Kaggle' platformu üzerinden elde edilmiştir (Gilsousa, 2017).

Veri setinde Çizelge 3.5'de verilen özellikler bulunmaktadır. Özellikler ameliyat geçirmiş hastalar hakkında genel bilgileri içermektedir.

Çizelge 3.5. Haberman'nin Hayatta Kalma Veri Seti Özellikleri ve Değer Aralıkları (Gilsousa, 2017)

Özellikler	Değerler
Age	Hastaların yaş değerleri
Year	Hastaların ameliyat geçirdikleri yıl
Nodes	Hastaların tespit edilen pozitif aksil sayısı
Class	Hastaların hayatta kalma durumu 1: 5 yıl ve üzeri hayatta kalma durumu 2: 5 yıl içinde ölme durumu

Veri seti, toplam 306 hastadan elde edilen verilerden oluşmaktadır. Verilerin tamamı nümerik değerlerde oluşmaktadır. Veriler içerisinde kayıp veri mevcut değildir.

3.7. SMOTE Algoritması

Veri kümesinde dolandırıcılık işlemlerinin pozitif olduğu durumların sayısının tüm veri kümesine oranının oldukça az olmasından dolayı veri kümesi oldukça dengesizdir. Dengesiz veri kümelerinde gerçekleştirilen makine öğrenmesi ve veri

madenciliği algoritmaları yanlış sonuçların üretilmesine neden olabilmektedir (Aydilek, 2018). Bu sorunu ortadan kaldırmak için dengesiz bir dağılım gösteren veri kümesini dengeli bir hale getirmek amacıyla Smote (Synthetic Minority Over-sampling Technique) algoritması kullanılmıştır. Smote algoritması, genel olarak azınlık durumunda bulunan sınıfın sayısını sentetik veriler üretip artırarak çoğunluk olan verilerle azınlık olan verilerin sayısını dengelemeyi amaçlar.

Smote algoritmasının adımları (Aydilek, 2018):

- i. Azınlık sınıfında bulunan örneğe yine aynı sınıfta bulunan 5 tane veri Öklid mesafesine bulunur,
- ii. Bulunan bu 5 örnek içinden rastgele olarak bir örnek seçilir,
- iii. Rastgele seçilen örnek 0 ile 1 arasında rastgele belirlenen bir değerle çarpılır,
- iv. Çarpma sonucunda elde edilen bu değer ile verinin başlangıçtaki değeri toplanarak yeni sentetik değer elde edilmiş olunur.

3.8. K -Katlı Çapraz Doğrulama

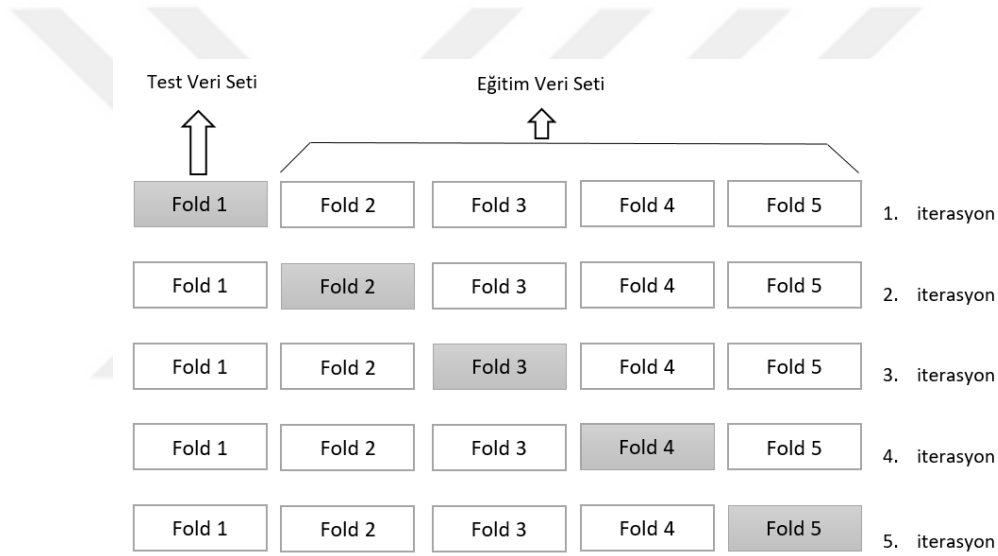
Sınıflandırma problemlerinde kullanılan veri setleri genel olarak eğitim ve test olmak üzere ikiye bölünmektedir. Eğitim veri seti, öğrenmenin gerçekleştirildiği eğitim süresince kullanılırken, test veri seti eğitim işlemi tamamlandıktan sonra modeli test etmek amacıyla kullanılmaktadır. Ancak veri setinin ikiye bölünmesi bazı problemlere neden olmaktadır. Eğitim ve test veri setlerindeki dağılım dengeli olmayabilir. Özellikle sınıf bilgisine göre sıralı bir veri setinde ikiye bölme işleminin de sıralı yapıldığını düşünürsek eğitim veya test için oluşturulan veri setlerinde tek sınıf bulunabilir. Ya da rastgele olarak eğitim ve test veri setleri oluşturulsa bile sadece belirli bir grup seçilmiş olabilir. Tüm bu durumlar ezberleme problemlerine neden olabilmektedir. Bu gibi durumların önüne geçmek amacıyla çapraz doğrulama kullanılmaktadır.

Çapraz doğrulama aynı zamanda modelin performansının rastgele olup olmadığına dair bize bilgi vermesi açısından da oldukça önemlidir. Çapraz doğrulama, genel olarak makine öğrenmesinde modellerin görmediği veriler üzerindeki performansını olabildiğince doğru ve nesnel bir şekilde değerlendirmek için kullanılan istatistiksel bir yöntemdir. Çapraz doğrulama yöntemlerinden en temel olarak k-katlı çapraz doğrulama yöntemi tercih edilmektedir.

K-katlı çapraz doğrulama temel olarak aşağıda verilen adımları içermektedir;

- i. Veri seti k adet alt kümeye bölünür
- ii. Tek bir fold için alt kümelere bir tanesi test için geriye kalan $k-1$ alt küme eğitim için kullanılır.
- iii. Seçilen test alt kümesi her iterasyon için farklı bir fold olacak şekilde veri seti içerisinde değiştirilerek tüm veri seti dolaşılır.
- iv. Son olarak elde edilen bütün istatistiksel sonuçların ortalaması alınarak sonuç elde edilir.

K değerinin belirlemek için kesin bir kural olmamasına rağmen gözlem sayısına uygun olarak belirlenmelidir. K değeri genellikle 5 ya da 10 olarak belirlenmektedir. Şekil 3.2’de k değeri 5 olarak belirlenen bir k -katlı çapraz doğrulama işleminde verinin nasıl bölüldüğüne örnek verilmiştir.



Şekil 3.2. k -katlı Çapraz Doğrulama ($k=5$)

K -katlı çapraz doğrulama sonucunda her iterasyon sonucunda elde edilen performans değerlerinin ortalaması alınarak gerçek sonuç elde edilmiş olacaktır.

4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

Bu tez çalışmasında, yeni bir ağ mimarisi yaklaşımı ile bağlantıların ve bağlantı ağırlıklarının optimizasyonu amaçlanmıştır. Yapay sinir ağları, canlı sinir hücrelerinden esinlenerek geliştirilen yapılardır. Biyolojik sinir hücrelerinin birbirleri ile yaptığı bağlantılar düşünüldüğü zaman, yapay sinir ağlarındaki katmanlı ve tam bağlantılı mimariden uzak bir yapıya sahip olduğu gözlemlenmiştir. Biyolojik sinir hücrelerinde bağlantılar rastgele olarak oluşmaktadır. Bu doğrultuda önerilen yapay sinir ağının bağlantılarının optimizasyonu yapılmıştır. Oluşturulan yapay sinir ağında bağlantılar ve ağırlıklar en iyi şekilde optimize edilmeye çalışılmıştır. Yapılan çalışmada oluşturulan ağın bağlantıları, ikili optimizasyon yöntemi olan BPSO ile iyileştirilmiştir. Bağlantılardaki ağırlıkların optimizasyonu için ise sürekli PSO kullanılmıştır.

Önerilen yapay sinir ağı ile bağlantı ağırlıkları sürekli PSO ile optimize edilmiş tam bağlantılı yapay sinir ağının sonuçları tez çalışmasında kullanılan veri setleri için verilmiştir. Ayrıca BP ile ağın eğitiminin gerçekleştirildiği yapay sinir ağının tüm veri setleri için sonuçları da verilmiştir. Literatürde bağlantı optimizasyonu için tercih edilen bir yöntem olan GA ile bağlantı optimizasyonu işlemi de tez çalışmasında kullanılan veri setleri için uygulanmış ve sonuçları karşılaştırılmak üzere verilmiştir. Yapılan çalışmaların tüm testleri PyCharm programı ile Python programlama dili kullanılarak gerçekleştirilmiştir.

Tez çalışmasında, makine öğrenmesi modellerinin veri seti üzerindeki başarısını ölçmeye yarayan performans ölçütlerinin en çok tercih edilenleri için sonuçlar verilmiştir. Çalışmada elde edilen sonuçları değerlendirmek amacıyla kullanılan bazı performans metrikleri şöyledir;

- Doğruluk (Accuracy)
- Duyarlılık (Sensitivity)
- Özgüllük (Specificity)
- Keskinlik (Precision)
- F1 Score (F1 Puanı)

Karmaşıklık matrisi, makine öğrenmesinde kullanılan sınıflandırma modellerini performans bakımından değerlendirmek amacıyla tahmin ve gerçek değerlerin karşılaştırıldığı bir matristir. Dört değerlendirmeye sahiptir. Bunlar True Positive (TP),

True Negative (TN), False Posivite (FP) ve False Negative (FN). TP, doğruya doğru demek; TN, yanlışla yanlış demek; FP, doğruya yanlış demek; FN, yanlışla doğru demektir.

Doğruluk, doğru tahminlerin tüm tahminler içindeki oranıdır. Doğruluk değeri her sınıfa ait eşit miktarda örnek varsa daha doğru sonuçlar vermektedir. Doğruluk değeri, Denklem 4.1’de verilen denklem ile hesaplanmaktadır.

$$\text{Doğruluk} = (TP + TN) / (TP + TN + FP + FN) \quad (4.1)$$

Duyarlılık, gerçek pozitif oranıdır (True Positive Rate). Bir hastalık tahmininden bahsediyorsak hasta olanların hangi oranda tespit edildiğidir. Duyarlılık, Denklem 4.2.’de verilen denklem ile hesaplanmaktadır.

$$\text{Duyarlılık} = TP / (TP + FN) \quad (4.2)$$

Özgüllük, gerçek negatif oranıdır (True Negative Rate). Bir hastalık tahmininden bahsediyorsak hasta olmayanların hangi oranda tespit edildiğidir. Özgüllük değeri, Denklem 4.3’de verilen formül ile hesaplanmaktadır.

$$\text{Özgüllük} = TN / (TN + FP) \quad (4.3)$$

Keskinlik, pozitif olarak tahmin edilenlerin ne kadar doğru tahmin edildiğidir. Bir hastalık tahmininden bahsediyorsak hasta olarak tahmin ettiklerimizden gerçekten kaç tanesinin hasta olduğunun oranıdır. Denklem 4.4’de verilen formül ile keskinlik değeri hesaplanmaktadır.

$$\text{Keskinlik} = TP / (TP + FP) \quad (4.4)$$

F1 Puanı, keskinlik ve duyarlılık değerlerinin harmonik ortalamasıdır. Harmonik ortalamanın tercih edilmesinin nedeni ise uç durumların göz ardı edilmek istenmemesidir. F1 puanı, Denklem 4.5’de verilen formül ile hesaplanmaktadır.

$$\text{F1 Puanı} = 2 * \frac{\text{Keskinlik} * \text{Duyarlılık}}{\text{Keskinlik} + \text{Duyarlılık}} \quad (4.5)$$

Bu tez çalışmasında makine öğrenmesi modellerinde sıklıkla kullanılan meme kanseri, hepatit, mamografik kütle ve Haberman'nin hayatta kalma veri setleri kullanılmıştır. Kullanılan bütün veri setleri için ağırlıkları PSO ile optimize edilmiş tam bağlantılı yapay sinir ağı sonuçları, ağırlıkları BP ile optimize edilmiş yapay sinir ağı sonuçları, bağlantıları GA ile optimize edilmiş yapay sinir ağı sonuçları ve son olarak önerilen yöntem olan bağlantıları BPSO ile optimize edilmiş yapay sinir ağı sonuçları verilmiştir.

4.1. Meme Kanseri Veri Seti İçin Sonuçlar

Bu tez çalışmada öncelikle kullanılan veri setlerinden meme kanseri veri setinin sonuçları incelenmiştir. Çizelge 4.1'da PSO ile ağırlıkları optimize edilmiş tam bağlantılı bir yapay sinir ağının meme kanseri veri seti için elde edilen test sonuçları verilmiştir. K-katlı çapraz doğrulama ile elde edilen sonuçların her bir iterasyonu için sonuçları Çizelge 4.1'de listelenmektedir. Sonuçlarda makine performans ölçütlerinin en çok tercih edilenleri için sonuçlar verilmiştir.

Çizelge 4.1. PSO ile Eğitilmiş Tam Bağlantılı YSA için Meme Kanseri Veri Seti Performans Ölçütleri

k Değeri	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F1 Puanı
1	0.942	0.943	0.941	0.943	0.943
2	0.985	1.0	0.963	0.977	0.988
3	0.985	0.976	1.0	1.0	0.988
4	0.912	0.933	0.895	0.875	0.903
5	0.926	0.917	0.937	0.943	0.929
6	0.970	0.961	1.0	1.0	0.980
7	0.956	0.979	0.90	0.959	0.969
8	0.926	0.915	1.0	1.0	0.956
9	1.0	1.0	1.0	1.0	1.0
10	0.956	0.945	1.0	1.0	0.972
Ortalama	0.956	0.957	0.964	0.970	0.963

Meme kanseri veri seti için Çizelge 4.1'de her bir iterasyonda elde edilen doğruluk değerlerinin ortalaması alınırsa sonuçların yüzde 95 doğruluğa sahip olduğu gözlemlenmektedir. Gerçek doğruları tahmin etme oranı yani duyarlılık ise yüzde 95 olarak bulunmuştur. Özgüllük değeri yani gerçek hasta olmayanları tahmin etme oranı ise yüzde 96 olarak bulunmuştur. Kesinlik değeri yüzde 97 ve f1 puanı da yüzde 96 olarak bulunmuştur.

Meme kanseri veri seti için yapay sinir ağının parametrelerinin PSO ile optimizasyon işlemi 50 parçacık belirlenmiştir ve 100 iterasyon ile işlemler

gerçekleştirilmiştir. PSO'da kullanılan uygunluk fonksiyonu YSA'nın ileri yönde oluşturduğu sonuçtur. PSO ile optimizasyon işlemi toplamda 50 saniyede tamamlanmıştır.

Çizelge 4.2 'de meme kanseri için bağlantı ağırlıkları BP ile optimize edilmiş tam bağlantılı yapay sinir ağı için çapraz doğrulama sonuçları verilmiştir.

Çizelge 4.2. BP ile Eğitilmiş Tam Bağlantılı YSA için Meme Kanseri Veri Seti Performans Ölçütleri

k Değeri	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F1 Puanı
1	0.927	0.943	0.912	0.917	0.929
2	0.985	1.0	0.963	0.977	0.988
3	0.971	0.951	1.0	1.0	0.975
4	0.897	0.933	0.868	0.848	0.888
5	0.926	0.917	0.937	0.943	0.929
6	0.985	0.981	1.0	1.0	0.990
7	0.970	0.979	0.95	0.979	0.979
8	0.956	0.949	1.0	1.0	0.974
9	1.0	1.0	1.0	1.0	1.0
10	0.985	0.982	1.0	1.0	0.991
Ortalama	0.960	0.963	0.963	0.966	0.964

Meme kanseri veri seti için Çizelge 4.2'de çapraz doğrulama için her bir iterasyonda elde edilen doğruluk değerlerinin ortalaması alınırsa sonuçların yüzde 96 doğruluğa sahip olduğu gözlemlenmektedir. Duyarlılık, özgüllük, kesinlik ve fl puanı için de ortalama yüzde 96 değeri bulunmuştur. BP için iterasyon sayısı olarak karşılaştırmanın doğruluğunu artırmak için 100 değeri tercih edilmiştir. İşlem 2 saniyede tamamlanmıştır.

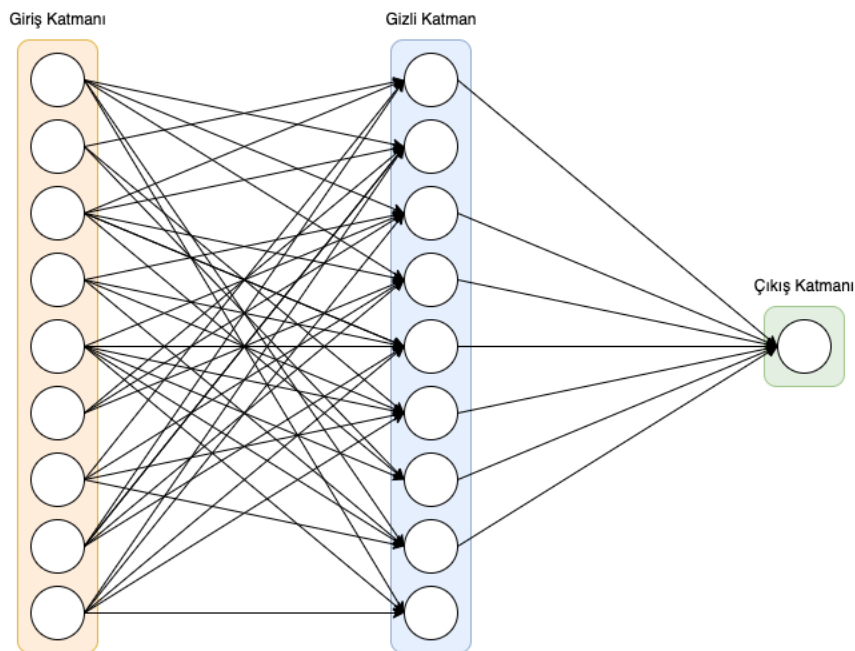
Bağlantı optimizasyonu için literatürde örnekleri bulunan bir yöntem de GA ile bağlantı optimizasyonudur. Meme kanseri veri seti için bağlantıları GA ve bağlantı ağırlıkları PSO ile optimize edilmiş yapay sinir ağının sonuçları Çizelge 4.3'de verilmiştir. Çizelge 4.3'de çapraz doğrulamanın her bir iterasyonu için elde edilen sonuçların performans ölçütlerinin verilmiştir.

Çizelge 4.3. Bağlantıları GA ve Ağırlıkları PSO ile Eğitilmiş YSA için Meme Kanseri Veri Seti Performans Ölçütleri

k Değeri	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F1 Puanı
1	0.985	0.978	1.0	1.0	0.989
2	0.952	0.976	0.928	0.952	0.964
3	0.965	0.954	0.96	0.977	0.965
4	0.941	0.907	1.0	1.0	0.951
5	0.989	0.978	1.0	1.0	0.989
6	0.985	0.98	1.0	1.0	0.990
7	0.970	0.958	1.0	1.0	0.979
8	0.970	1.0	0.928	0.952	0.976
9	0.985	0.978	1.0	1.0	0.989
10	0.970	0.976	0.961	0.976	0.976
Ortalama	0.971	0.968	0.978	0.985	0.977

Çizelge 4.3’de meme kanseri veri seti için sonuçların ortalama yüzde 97 doğruluğa sahip olduğu gözlemlenmektedir. Duyarlılık değeri yüzde 96 ve özgüllük değeri ise yüzde 97 olarak bulunmuştur. Ayrıca kesinlik değeri yüzde 98 ve f1 puanı da yüzde 97 olarak bulunmuştur. Meme kanseri veri seti için bağlantı ve ağırlık optimizasyon işlemi toplamda 4 gün 19 saat 20 dakikada tamamlanmıştır.

Meme kanseri veri seti için GA ile düğümler arasındaki bağlantıların optimize edildiği yapay sinir ağının yapısı Şekil 4.1’de verilmiştir. Şekil 4.1’de verilen yapay sinir ağı çapraz doğrulamada 6. iterasyon sonucunda oluşan ağ yapısı verilmiştir.



Şekil 4.1. Meme Kanseri Veri Seti için Bağlantıları GA ve Bağlantı Ağırlıkları PSO Optimize Edilmiş Yapay Sinir Ağı Yapısı

Meme kanseri veri seti için bağlantıları GA ve bağlantıların ağırlıkları ise PSO ile optimize edilmiş olan yapay sinir ağının, giriş ve gizli katman arasında bulunan bağlantıların optimize edilen ağırlık değerleri Çizelge 4.4’de verilmiştir.

Çizelge 4.4. Meme Kanseri Veri Seti için Bağlantıları GA ve Bağlantı Ağırlıkları PSO Optimize Edilmiş Yapay Sinir Ağı Yapısı için Giriş ve Gizli Katman Arasında Bulunan Bağlantı Ağırlıkları


Giriş Katmanı	Gizli Katman								
	H1	H2	H3	H4	H5	H6	H7	H8	H9
I1	-	0.233	-6.305	0.348	-	-	-	1.605	8.453
I2	6.736	-	-	-	-	-10.809	8.749	-	-
I3	8.047	-2.459	-	-12.015	-15.176	-	-	-12.462	-
I4	-	-	-0.709	-	-1.668	3.280	-	2.011	-
I5	-	-	-10.651	-	1.443	-15.966	-8.310	0.933	-13.461
I6	-	4.804	-17.644	0.029	-	-	-	-	-
I7	7.432	-	-	3.253	-	-7.761	-	-4.746	-
I8	-13.866	-3.508	-13.321	0.619	2.212	-	-	-	-
I9	-	-0.631	3.008	-	-23.817	8.274	-	-	-0.379

Şekil 4.1’de meme kanseri veri seti için GA ile optimize edilmiş tam bağlantılı yapay sinir ağının, gizli ve çıkış katmanı arasında bulunan bağlantıların optimize edilen ağırlık değerleri Çizelge 4.5’de verilmiştir.

Çizelge 4.5. Meme Kanseri Veri Seti için Bağlantıları GA ve Bağlantı Ağırlıkları PSO Optimize Edilmiş Yapay Sinir Ağı Yapısı için Gizli ve Çıkış Katman Arasında Bulunan Bağlantı Ağırlıkları

Gizli Katman	Çıkış Katmanı
H1	5.307
H2	-
H3	9.074
H4	-14.660
H5	9.432
H6	1.214
H7	-5.201
H8	13.129
H9	-

Şekil 4.1 incelendiği zaman gizli katmanda bulunan iki nöronun sonucu etkilemediği gözlemlenmektedir. Sonuca etkisi olmayan nöronlar ağdan silinerek ağdaki düğüm sayıları optimize edilmiş olunacaktır. Gizli katmanda bulunan nöron sayısı 9’dan 7’ye indirgenmiştir. Sonucu etkilemeyen nöronlar ve bağlantıların silinmesi ile elde edilen yapay sinir ağı Şekil 4.2’de verilmiştir.



Şekil 4.2. Meme Kanseri Veri Seti için Bağlantıları GA ve Bağlantı Ağırlıkları PSO Optimize Edilmiş ve Gerekli Olmayan Nöronları Silinmiş Yapay Sinir Ağı Yapısı

Çizelge 4.6’da meme kanseri veri setinin bağlantıların BPSO ile optimize edildiği yaklaşım ile elde edilen çapraz doğrulama test sonuçları verilmiştir.

Çizelge 4.6. Bağlantıları BPSO ve Ağırlıkları PSO ile Eğitilmiş YSA için Meme Kanseri Veri Seti Performans Ölçütleri

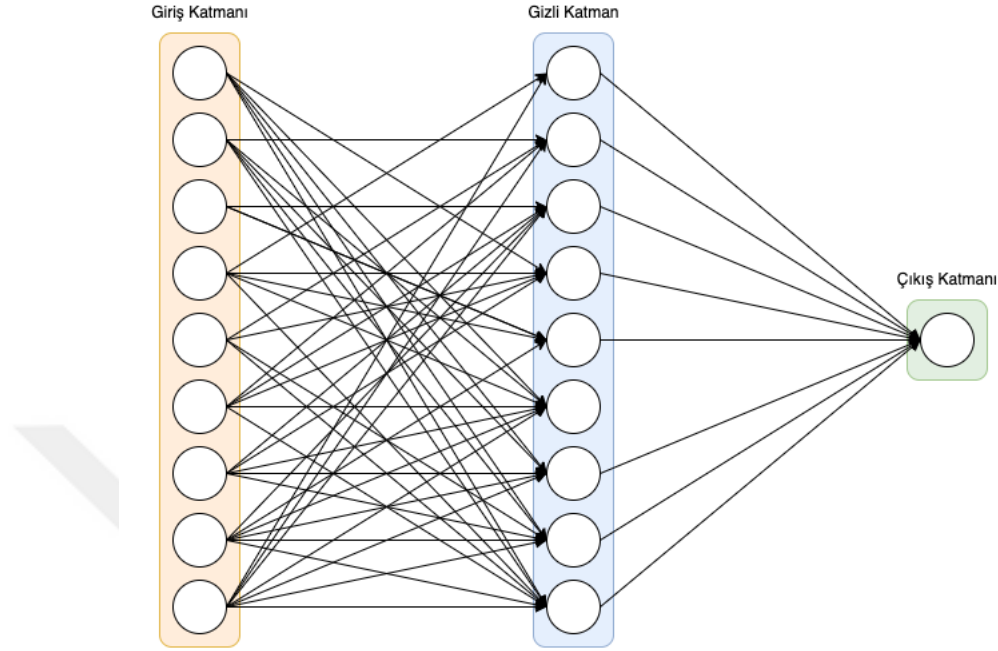
k Değeri	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F1 Puanı
1	0.971	0.978	0.956	0.978	0.978
2	0.956	0.976	0.928	0.952	0.964
3	0.942	0.954	0.92	0.954	0.954
4	0.970	0.953	1.0	1.0	0.976
5	0.970	0.977	0.956	0.977	0.977
6	0.941	0.96	0.888	0.96	0.96
7	0.970	0.958	1.0	1.0	0.979
8	0.985	1.0	0.964	0.976	0.988
9	0.970	0.977	0.956	0.977	0.977
10	0.985	0.976	1.0	1.0	0.988
Ortalama	0.966	0.971	0.957	0.977	0.974

Önerilen yöntem ile düğümler arası bağlantılar BPSO ile optimize edilmiştir. Yapay sinir ağı parametreleri ise PSO ile optimize edilmiştir. K-katlı çapraz doğrulama ile elde edilen sonuçlar Çizelge 4.6’da verilmiştir. Her bir iterasyon için elde edilen doğruluk değerlerinin ortalaması alınınca yüzde 96 değeri elde edilmiştir. Doğruluk değeri, PSO ve BP ile ağırlıkları optimize edilmiş tam bağlantılı ağların sonucunda elde edilen doğruluk değerleri ile kıyaslandığı zaman; yüzde 1’lik bir artış gözlemlenmektedir.

Ayrıca önerilen yöntem ile oluşturulan YSA ve bağlantıları GA ile optimize edilmiş YSA kıyaslanırsa doğruluk bakımından yüzde 1'lik bir düşüş olduğu görülmektedir. Önerilen yöntem ortalama yüzde 97 duyarlılığa sahiptir. Duyarlılık değeri, PSO ile ağırlıkları optimize edilmiş tam bağlantılı ağ sonucunda elde edilen duyarlılık değeri ile kıyaslandığı zaman; yüzde 2'lik bir artış gösterirken bağlantı ağırlıkları BP ile optimize edilmiş ağ ile kıyaslandığı zaman ise yüzde 1'lik bir artış göstermektedir. Son olarak GA ile optimize edilmiş ağ ile kıyaslandığı zaman ise yüzde 1'lik bir artış göstermektedir. Önerilen yöntem yüzde 95 özgüllüğe sahiptir. Önerilen yöntemin özgüllük değeri, PSO ile ağırlıkları optimize edilmiş tam bağlantılı ağ sonucunda elde edilen özgüllük değeri ile kıyaslandığı zaman yüzde 1'lik bir düşüş gözlemlenmektedir. Bağlantı ağırlıkları BP ile optimize edilmiş YSA ile kıyaslandığı zaman da yüzde 1'lik bir düşüş söz konusudur. GA ile bağlantıları optimize edilmiş ağ ile özgüllük değeri bakımından kıyaslandığında ise önerilen yöntemin yüzde 2 oranında düştüğü gözlemlenmiştir. Önerilen yöntem yüzde 97 kesinliğe sahiptir. Kesinlik değeri, PSO ile ağırlıkları optimize edilmiş tam bağlantılı ağ sonucunda elde edilen kesinlik değeri ile kıyaslandığı zaman binde 7'lik bir artış gösterirken, BP ile ağırlıkları optimize edilmiş ağa göre ise yüzde 1'lik bir artış göstermektedir. GA ile bağlantıları optimize edilmiş ağ ile kıyaslandığı zaman ise yüzde 1'lik bir azalış gözlemlenmektedir. Son olarak önerilen yöntem yüzde 97 fl skoruna sahiptir ve PSO ile ağırlıkları optimize edilmiş tam bağlantılı ağ sonucunda elde edilen fl skoru ile kıyaslandığı zaman; yüzde 1'lik bir artış gözlemlenmektedir. BP ile ağırlıkları optimize edilmiş yapay sinir ağına göre önerilen yöntem fl puanı bakımından yüzde 1'lik bir artış gösterirken GA ile bağlantıları optimize edilmiş ağ ile kıyaslanırsa binde 3'lük bir azalış söz konusudur. Genel olarak meme kanseri veri seti için önerilen yöntem ile elde edilen sonuçlar, PSO ile ağırlıkları optimize edilmiş tam bağlantılı yapay sinir ağı ile kıyaslandığı zaman kesinlik değeri hariç diğer performans metriklerinde artış göstermiştir. BP ile bağlantı ağırlıkları optimize edilen YSA ile kıyaslandığı zaman doğruluk, duyarlılık, kesinlik ve fl puanı bakımından önerilen yöntem yüksek sonuçlar vermiştir. GA ile bağlantı optimizasyonu yapılan ağ ile kıyaslandığı zaman ise duyarlılık dışında kalan değerlerde önerilen yöntem düşük sonuçlar üretmiştir. Meme kanseri veri seti için BPSO ile ağırlıklarının ve PSO ile ağırlıklarının optimizasyon işlemi 9 gün 14 saat 15 dakika 17 saniyede tamamlanmıştır.

Meme kanseri veri seti için önerilen yöntem ile düğümler arasındaki bağlantıların BPSO ile optimize edildiği yapay sinir ağının yapısı Şekil 4.3'de verilmiştir. Şekil 4.3'de

verilen yapay sinir ağı k-katlı çapraz doğrulama sonuçlarında en yüksek doğruluğa sahip olan 10. iterasyon sonucunda oluşan ağ yapısı verilmiştir.



Şekil 4.3. Bağlantıları BPSO ve Ağırlıkları PSO ile Meme Kanseri Veri Seti için Optimize Edilmiş Yapay Sinir Ağı Yapısı

Çizelge 4.7’de, Şekil 4.3’de verilen önerilen yöntem ile optimize edilmiş olan yapay sinir ağının, giriş ve gizli katmanı arasında bulunan bağlantıların ağırlık değerleri verilmiştir.

Çizelge 4.7. Bağlantıları BPSO ve Ağırlıkları PSO ile Optimize Edilmiş Ağın Meme Kanseri Veri Seti için Giriş ve Gizli Katman Arasında Bulunan Bağlantı Ağırlıkları

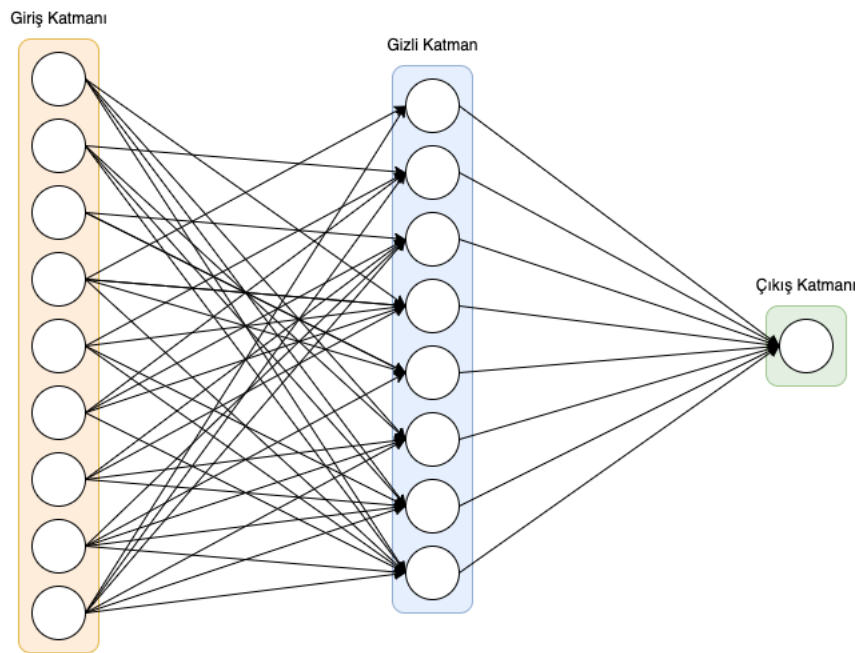
Giriş Katmanı	Gizli Katman								
	H1	H2	H3	H4	H5	H6	H7	H8	H9
I1	-	-	-	13.468	-	10.905	2.412	11.543	-5.293
I2	-	4.617	-	-	-	-14.176	16.430	-2.048	-6.465
I3	-	-	-2.349	-	6.115	-	-	-	-
I4	-23.701	-	-	-9.123	-14.222	-5.258	-	-	-5.359
I5	-	-7.495	-	-16.250	-	-	-	9.781	-7.627
I6	-	-25.416	-11.596	-7.166	-	6.448	-	-	-9.923
I7	-	-	-16.030	-1.449	-	-0.795	-8.298	-27.160	-
I8	-	-	19.562	-	-9.293	-15.658	-9.450	17.654	1.216
I9	5.510	-2.916	-3.335	-	-	21.827	2.078	-11.653	12.818

Meme kanseri veri seti için bağlantıları BPSO ve ağırlıkları PSO ile optimize edilmiş yapay sinir ağının, gizli ve çıkış katmanı arasında bulunan bağlantılarının ağırlık değerleri Çizelge 4.8’de verilmiştir.

Çizelge 4.8. Bağlantıları BPSO ve Ağırlıkları PSO ile Optimize Edilmiş Ağın Meme Kanseri Veri Seti için Gizli ve Çıkış Katman Arasında Bulunan Bağlantı Ağırlıkları

Gizli Katman	Çıkış Katmanı
H1	-23.239
H2	-1.505
H3	3.465
H4	15.109
H5	-1.881
H6	-
H7	0.271
H8	-8.083
H9	-18.000

Şekil 4.3 incelendiği zaman gizli katmanda bulunan bir nöronun sonucu etkilemediği gözlemlenmektedir. Sonuca etkisi olmayan bu nöron ağdan silinerek ağdaki düğüm sayıları optimize edilmiş olacaktır. Şekil 4.4’de sonucu etkilemeyen nöron ve bağlantılarının silinmesi ile elde edilen yapay sinir ağı verilmiştir.



Şekil 4.4. Bağlantıları BPSO ve Ağırlıkları PSO ile Meme Kanseri Veri Seti için Optimize Edilmiş ve Gerekli Olmayan Nöronları Silinmiş Yapay Sinir Ağı Yapısı

Şekil 4.4, meme kanseri veri seti için önerilen yöntem ile oluşturulan yapay sinir ağının son halini vermektedir. Gizli katmanda bulunan bir nöron ağdan silinmiştir. Bu sayede gizli katman nöron sayısı optimizasyon işlemi de gerçekleştirilmiştir. Gizli katman nöron sayısı 9’dan 8’e indirgenmiştir.

4.2. Hepatit Veri Seti İçin Sonuçlar

Çizelge 4.9’da PSO ile ağırlıkları optimize edilmiş tam bağlantılı bir yapay sinir ağının hepatit veri seti için çapraz doğrulama sonuçları verilmiştir. Sonuçlarda her iterasyon için makine öğrenmesi modellerinin veri seti üzerindeki başarısını ölçmeye yarayan performans ölçütlerinden en çok tercih edilenleri verilmiştir.

Çizelge 4.9. PSO ile Eğitilmiş Tam Bağlantılı YSA için Hepatit Veri Seti Performans Ölçütleri

k Değeri	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F1 Puanı
1	0.533	0.5	1.0	1.0	0.667
2	0.733	0.714	1.0	1.0	0.833
3	0.5	0.461	1.0	1.0	0.631
4	0.571	0.571	Tanımsız	1.0	0.727
5	0.714	0.727	0.667	0.889	0.780
6	0.857	0.8	1.0	1.0	0.889
7	0.643	0.6	0.75	0.857	0.706
8	0.786	0.727	1.0	1.0	0.842
9	0.714	0.7	0.75	0.875	0.778
10	0.714	0.667	0.8	0.857	0.875
Ortalama	0.677	0.647	0.797	0.948	0.772

Çizelge 4.9’da verilen doğruluk değerlerinin ortalaması alınırsa ağırlıkları PSO ile optimize edilmiş tam bağlantılı yapay sinir ağının yüzde 67 doğruluğa sahip olduğu görülmektedir. Duyarlılık değerleri incelendiği zaman hastaları tahmin etme oranının ortalama yüzde 64 olduğu bulunmuştur. Özgüllük değeri olan gerçek hasta olmayanların tahmin edilme oranı ise yüzde 79 olarak bulunmuştur. Kesinlik değeri yüzde 94 olarak bulunurken fl puanı ise yüzde 77 olarak bulunmuştur.

BP ile bağlantı ağırlıkları optimize edilmiş tam bağlantılı yapay sinir ağının hepatit veri seti için sonuçları Çizelge 4.10’da verilmiştir.

Çizelge 4.10. BP ile Eğitilmiş Tam Bağlantılı YSA için Hepatit Veri Seti Performans Ölçütleri

k Değeri	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F1 Puanı
1	0.867	0.857	1.0	1.0	0.923
2	0.733	0.714	1.0	1.0	0.833
3	0.714	0.692	1.0	1.0	0.818
4	0.643	0.643	Tanımsız	1.0	0.783
5	0.928	0.909	1.0	1.0	0.952
6	0.857	0.8	1.0	1.0	0.889
7	0.714	0.7	0.75	0.875	0.778
8	0.928	0.909	1.0	1.0	0.952
9	0.643	0.6	0.75	0.857	0.706
10	0.714	0.555	1.0	1.0	0.714
Ortalama	0.774	0.738	0.85	0.973	0.835

Çizelge 4.10’da verilen sonuçlar incelendiği zaman doğruluk değerlerinin ortalaması alınırsa yüzde 77 değeri bulunmaktadır. Duyarlılık değerleri incelendiği zaman hastaları tahmin etme oranının ortalama yüzde 73 olduğu bulunmuştur. Özgüllük değeri olan gerçek hasta olmayanların tahmin edilme oranı ise yüzde 85 olarak bulunmuştur. Kesinlik değeri yüzde 97 olarak bulunurken f1 puanı ise yüzde 83 olarak bulunmuştur. Hepatit veri setinde BP ile optimizasyon işlemi toplamda 4 saniye gibi oldukça hızlı bir sürede tamamlanmıştır.

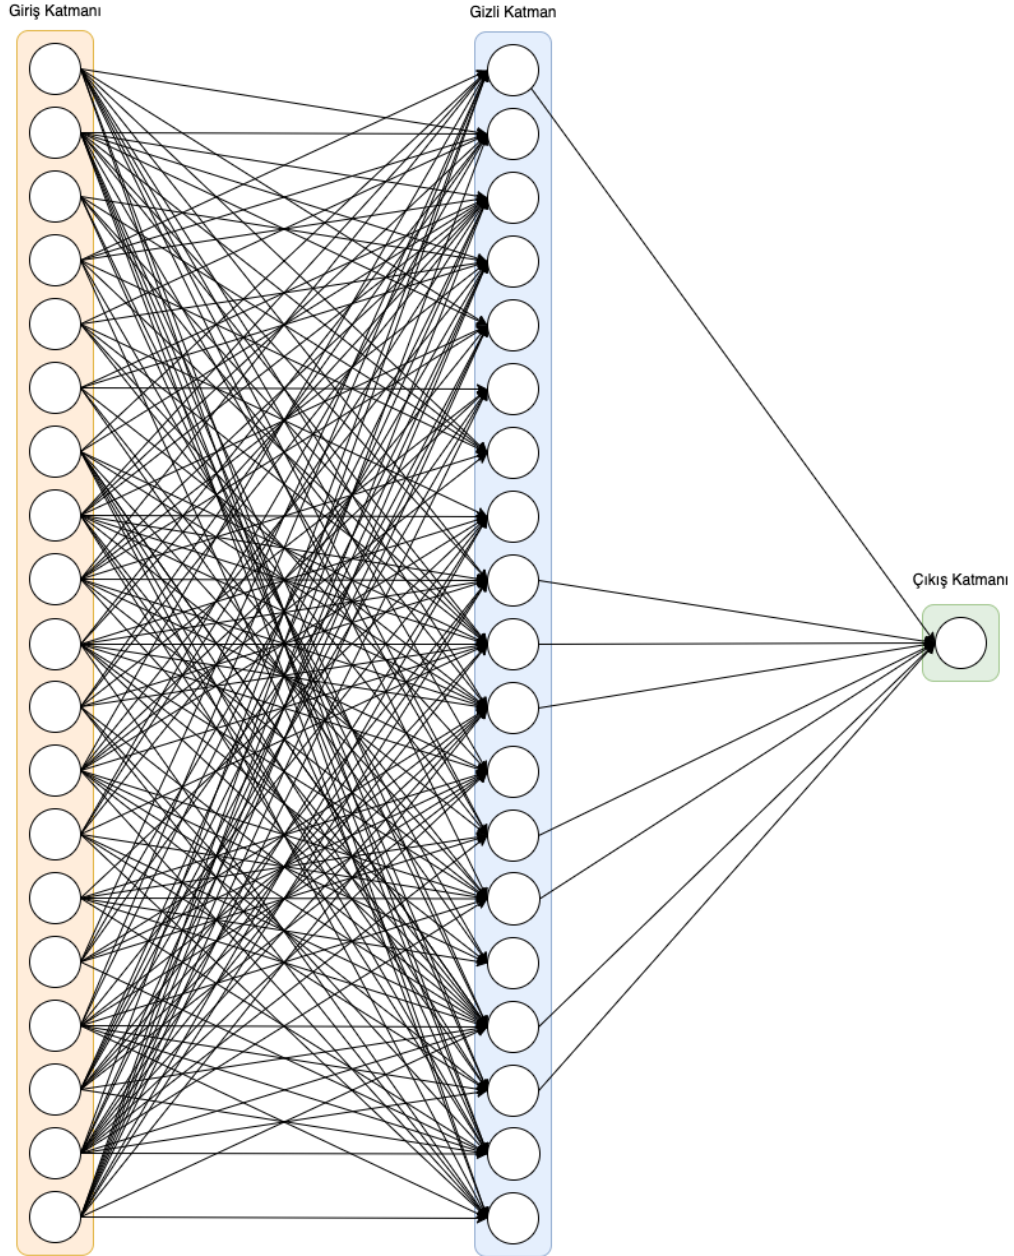
GA ile bağlantıları ve bağlantı ağırlıkları PSO ile optimize edilmiş yapay sinir ağı için elde edilen k-katlı çapraz doğrulama sonuçları Çizelge 4.11’de gösterilmiştir. Tüm iterasyon sonuçları için makine öğrenmesi modellerinin veri seti üzerindeki başarısını ölçmeye yarayan performans ölçütlerinden en çok tercih edilenleri Çizelge 4.11’de verilmiştir.

Çizelge 4.11. Bağlantıları GA ve Ağırlıkları PSO ile Eğitilmiş YSA için Hepatit Veri Seti Performans Ölçütleri

k Değeri	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F1 Puanı
1	0.667	0.643	1.0	1.0	0.783
2	0.734	0.75	0.667	0.9	0.818
3	0.5	0.5	Tanımsız	1.0	0.667
4	0.857	0.9	0.75	0.9	0.9
5	0.786	0.910	0.333	0.833	0.869
6	0.571	0.538	1.0	1.0	0.70
7	0.643	0.583	1.0	1.0	0.739
8	0.786	0.819	0.667	0.9	0.857
9	0.786	0.8	0.75	0.889	0.842
10	0.857	0.889	0.8	0.889	0.889
Ortalama	0.719	0.733	0.663	0.931	0.806

Hepatit veri seti için Çizelge 4.11’de her bir iterasyonda elde edilen doğruluk değerlerinin ortalaması alınırsa sonuçların yüzde 71 doğruluğa sahip olduğu gözlemlenmektedir. Duyarlılık değeri yüzde 73, özgüllük değeri ise yüzde 66, kesinlik değeri yüzde 93 ve f1 puanı da yüzde 80 olarak bulunmuştur. İşlem toplamda 4 gün 2 saat 13 dakikada tamamlanmıştır.

Şekil 4.5’de hepatit veri seti için GA ile düğümler arasındaki bağlantıların ve PSO ile bağlantı ağırlıklarının optimize edildiği yapay sinir ağı verilmiştir.



Şekil 4.5. Hepatit Veri Seti için Bağlantıları GA ve Bağlantı Ağırlıkları PSO Optimize Edilmiş Yapay Sinir Ağı Yapısı

Şekil 4.5’de verilen yapay sinir ağı, k-katlı çapraz doğrulamada 4. iterasyon için elde edilen sonuçlardır. Çapraz doğrulama sonucunda en yüksek doğruluğa sahip iterasyon 4. iterasyon olduğu için yapay sinir ağı şekil olarak verilirken bu sonuçlar tercih edilmiştir.

Şekil 4.5’de hepatit veri seti için bağlantıları GA ve bağlantıların ağırlıkları ise PSO ile optimize edilmiş olan yapay sinir ağının, giriş ve gizli katman arasında bulunan bağlantıların optimize edilen ağırlık değerleri Çizelge 4.12’de verilmiştir.

Çizelge 4.12. Hepatit Veri Seti için Bağlantıları GA ve Bağlantı Ağırlıkları PSO Optimize Edilmiş Yapay Sinir Ağı Yapısı için Giriş ve Gizli Katman Arasında Bulunan Bağlantı Ağırlıkları

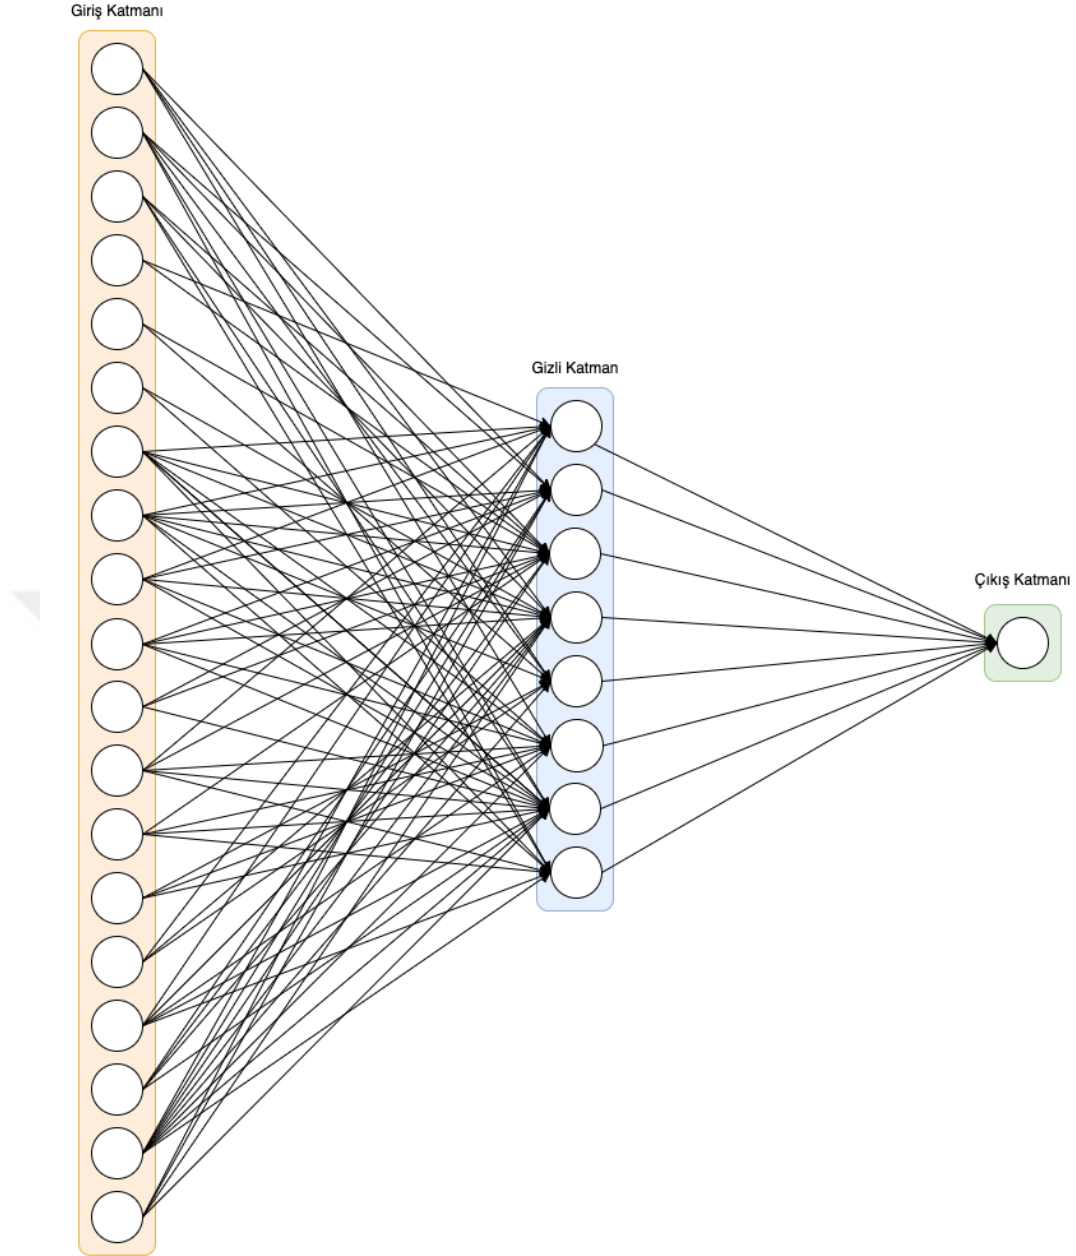
Gizli Katman	Çıkış Katmanı																		
	H1	H2	H3	H4	H5	H6	H7	H8	H9	H10	H11	H12	H13	H14	H15	H16	H17	H18	H19
I1	-	-24.428	-	-	4.332	-	-3.092	-	-19.879	-	-25.011	88.417	31.892	2.699	-	-	-	-17.940	-19.283
I2	-	19.177	25.402	-2.477	9.190	-	-15.959	-	2.725	6.758	-	-	16.367	-	-	-16.469	-6.017	6.507	-39.094
I3	-	-	-	8.274	-	-	-4.001	-	-	0.678	5.705	-	-	-	-	13.922	0.834	-	-
I4	25.320	22.683	22.456	-	-	-	-12.833	-	-	4.985	-	-	-	-	7.835	-	-	-6.346	-
I5	-	-5.230	-	17.848	-	-	-	-15.436	-	8.908	-	2.059	-6.500	-	-	-	-	-	-
I6	-	-	-24.679	-23.823	-	-17.086	-	-	-	-	1.653	-	-	-14.873	-7.248	-	-	-	-
I7	-6.8450	-	-31.167	-	-	-	-	-	-	-16.147	15.910	-	-	-4.291	-	-24.468	-14.270	6.894	0.965
I8	-15.663	28.601	-7.230	-	1.305	-	-	-8.934	29.033	22.264	-14.754	-	9.293	-	-	11.200	-14.141	29.656	-
I9	-38.307	-	6.590	-8.347	-1.413	-	0.277	-	-20.060	-	-32.223	-1.031	-	-2.081	-	-21.585	-	-	-
I10	-	28.695	13.365	-	-	-	-	8.691	10.142	4.220	-31.377	-2.960	-	26.989	-9.895	31.903	-	-	31.903
I11	-	-9.294	24.975	-	-	-16.249	-	-	-0.418	-20.009	-	-	-	-	-	1.598	-	-26.691	-3.924
I12	31.166	-	-	21.120	-	23.756	16.300	-10.673	-	6.340	-	-	-	-24.323	-1.770	-42.177	19.339	-	2.302
I13	-	-13.557	-12.543	-	14.550	-	-	-	-	12.730	-	-	-	3.395	-	-11.410	-14.441	-	7.600
I14	-	-	-	-	-	-	-	-13.865	-	-	-	31.360	13.367	-17.352	-34.245	5.055	-	10.206	-
I15	-14.194	-	-	7.567	-	-4.991	-	-	-	-	-17.616	4.256	-1.187	-	-	-	-	-10.448	-
I16	-14.112	-	-20.363	-	-	-	-	-21.409	-	-	-4.073	-38.269	-	-25.378	-	1.752	-5.930	-30.248	3.147
I17	-	-	-34.714	21.092	-9.386	3.146	-	-	27.529	-7.0723	-38.613	-33.542	-	-	-	0.354	-	-2.823	-
I18	-18.820	-	-	-31.468	3.890	-	-	-3.996	4.452	-7.214	-16.218	-19.026	-5.751	-9.008	-	3.588	-7.810	9.492	-
I19	2.586	23.718	-18.502	19.452	-5.517	-8.996	-	-10.413	-1.141	-	-14.159	-	-	-	-	-	7.390	-	4.651

Şekil 4.5’de hepatit veri seti için gizli ve çıkış katmanı arasında bulunan bağlantıların var olup olmama durumu GA ve bu bağlantıların ağırlık değerleri PSO ile iyileştirilen yapay sinir ağının ağırlık değerleri Çizelge 4.13’de verilmiştir.

Çizelge 4.13. Hepatit Veri Seti için Bağlantıları GA ve Bağlantı Ağırlıkları PSO Optimize Edilmiş Yapay Sinir Ağı Yapısı için Gizli ve Çıkış Katman Arasında Bulunan Bağlantı Ağırlıkları

Gizli Katman	Çıkış Katmanı
H1	-0.913
H2	-
H3	-
H4	-
H5	-
H6	-
H7	-
H8	-
H9	-8.607
H10	-31.478
H11	-2.314
H12	-
H13	-7.547
H14	15.146
H15	-
H16	-6.155
H17	-29.121
H18	-
H19	-

Şekil 4.5 incelendiği zaman gizli katmanda bulunan 11 nöronun sonucu etkilemediği gözlemlenmektedir. Bu nöronlar yapay sinir ağından silinerek gizli katmanda bulunan düğüm sayısı optimize edilmiş olunacaktır. Sonucu etkilemeyen nöronlar ve bağlantıların silinmesi ile elde edilen yapay sinir ağı Şekil 4.6’da verilmiştir.



Şekil 4.6. Hepatit Veri Seti için Bağlantıları GA ve Bağlantı Ağırlıkları PSO Optimize Edilmiş ve Gerekli Olmayan Nöronları Silinmiş Yapay Sinir Ağı Yapısı

Hepatit veri setinin önerilen yöntem ile test edilmesiyle elde edilen sonuçlar Çizelge 4.14’de gösterilmiştir. K-katlı çapraz doğrulama ile elde edilen sonuçların yine her bir iterasyon için ayrı ayrı sonuçları listelenmiştir. Tüm iterasyon sonuçları için makine öğrenmesi modellerinin veri seti üzerindeki başarısını ölçmeye yarayan performans ölçütlerinden en çok tercih edilenleri verilmiştir.

Çizelge 4.14. Bağlantıları BPSO ve Ağırlıkları PSO ile Eğitilmiş Hepatit Veri Seti Performans Ölçütleri

k Değeri	Doğruluk	Duyarlılık	Özgüllük	Keskinlik	F1 Puanı
1	0.667	0.643	1.0	1.0	0.783
2	0.734	0.667	1.0	1.0	0.8
3	0.571	0.571	Tanımsız	1.0	0.727
4	0.929	1.0	0.75	0.909	0.952
5	0.714	0.818	0.333	0.818	0.818
6	0.714	0.692	1.0	1.0	0.818
7	0.5	0.5	0.5	0.857	0.631
8	0.857	0.818	1.0	1.0	0.9
9	0.928	0.9	1.0	1.0	0.947
10	0.571	0.777	0.2	0.636	0.7
Ortalama	0.719	0.739	0.678	0.922	0.808

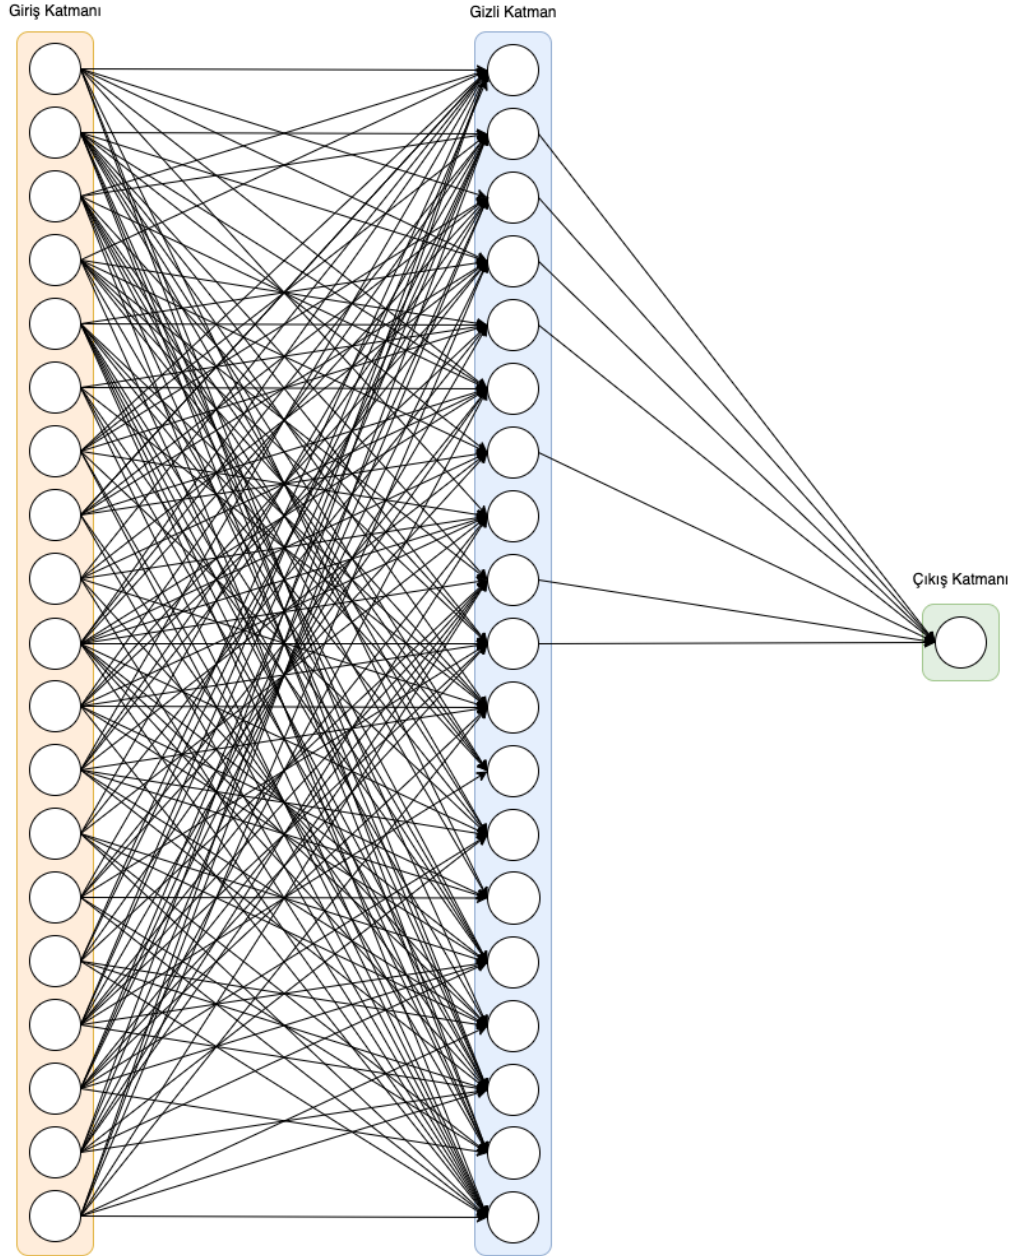
Çizelge 4.14’de verilen doğruluk değerlerinin çapraz doğrulama sonucunda ortalaması alınınca yüzde 71 değeri elde edilmiştir. Doğruluk değeri, PSO ile ağırlıkları optimize edilmiş tam bağlantılı ağ sonucunda elde edilen doğruluk değeri ile kıyaslandığı zaman yüzde 4’lük bir artış gösterirken BP ile ağırlıkları optimize edilmiş tam bağlantılı ağ sonucu ile kıyaslandığı zaman yüzde 6’lık bir düşüş göstermektedir. Önerilen yöntemin doğruluk değeri, bağlantıları GA ile optimize edilmiş YSA ile kıyaslandığında ise sabit kalmıştır. Önerilen yöntem ortalama yüzde 73 duyarlılığa sahiptir. Duyarlılık değeri, PSO ile ağırlıkları optimize edilmiş tam bağlantılı ağ sonucunda elde edilen duyarlılık değeri ile kıyaslandığı zaman; yüzde 9’luk bir artış gösterirken bağlantıları GA ile optimize edilmiş YSA ile kıyaslandığı zaman binde 3’lük bir artış gözlemlenmektedir. Bağlantı ağırlıkları BP ile eğitilmiş ağa göre önerilen yöntem duyarlılık bakımından binde 1’lik bir artış göstermiştir. Özgüllük değeri, bağlantıları GA ile optimize edilmiş ağ ile kıyaslandığı zaman ise yüzde 1’lik artış göstermiştir. Önerilen yöntem ortalama yüzde 67 özgüllüğe sahiptir ve PSO ile ağırlıkları optimize edilmiş tam bağlantılı ağ sonucunda elde edilen özgüllük değeri ile kıyaslandığı zaman; yüzde 12’lik bir azalış gözlemlenmektedir. Önerilen yöntem özgüllük bakımından BP ile eğitilmiş tam bağlantılı ağa göre yüzde 18 oranında bir düşüş göstermektedir. Önerilen yöntem yüzde 92 keskinliğe sahiptir. PSO ile eğitilmiş tam bağlantılı yapay sinir ağı ile kıyaslandığı zaman önerilen yöntem keskinlik bakımından yüzde 2’lik bir azalış gösterirken BP ile eğitilmiş yapay sinir ağına göre ise yüzde 5’lik bir azalış göstermektedir. GA ile bağlantıları optimize edilmiş YSA ile kıyaslandığı zaman ise önerilen yöntem yüzde 1’lik bir düşüş göstermiştir. Son olarak önerilen yöntem yüzde 80 fl puanına sahiptir ve tam bağlantılı ağ ile kıyaslandığı zaman yüzde 3’lük bir artış söz konusudur. GA ile bağlantıları optimize edilen ağ ile kıyaslandığı zaman ise binde 2’lik bir artış söz konusudur. BP ile eğitilmiş ağa göre ise önerilen yöntem yüzde 3 oranında azalmıştır.

Hepatit veri seti için elde edilen tüm sonuçlara genel bakıldığı zaman doğruluk, özgüllük, kesinlik ve fl puan değeri olarak en iyi sonucu BP ile eğitimin gerçekleştirildiği yapay sinir ağının verdiği görülmektedir. Duyarlılık değeri için ise en iyi sonucu önerilen yöntem vermiştir.

Hepatit veri setinde önerilen yöntem ile bağlantıların ve ağırlıkların optimizasyon işlemi 5 gün 19 saat 51 dakika 36 saniyede tamamlanmıştır. Tam bağlantılı yapay sinir ağı ile işlem süresi bakımından karşılaştırılsa önerilen yöntem daha uzun zaman almaktadır.

Önerilen yöntem ile düğümler arasındaki bağlantıların optimize edildiği yapay sinir ağı Şekil 4.7'de verilmiştir. Şekil 4.7'de verilen ağ k-katlı çapraz doğrulama sonuçlarında en yüksek doğruluğa sahip olan 4. iterasyon sonucunda oluşan ağ yapısıdır.





Şekil 4.7. Bağlantıları BPSO ve Ağırlıkları PSO ile Hepatit Veri Seti İçin Optimize Edilmiş Yapay Sinir Ağı

Şekil 4.7’de giriş ve çıkış katmanı arasında bulunan bağlantıları optimize edilmiş olan ağı, giriş ve gizli katmanı arasında bulunan bağlantıların optimize edilen ağırlık değerleri Çizelge 4.15’te verilmiştir.

Çizelge 4.15. Bağlantıları BPSO ve Ağırlıkları PSO ile Optimize Edilmiş Ağın Hepatit Veri Seti için Giriş ve Gizli Katman Arasında Bulunan Bağlantı Ağırlıkları

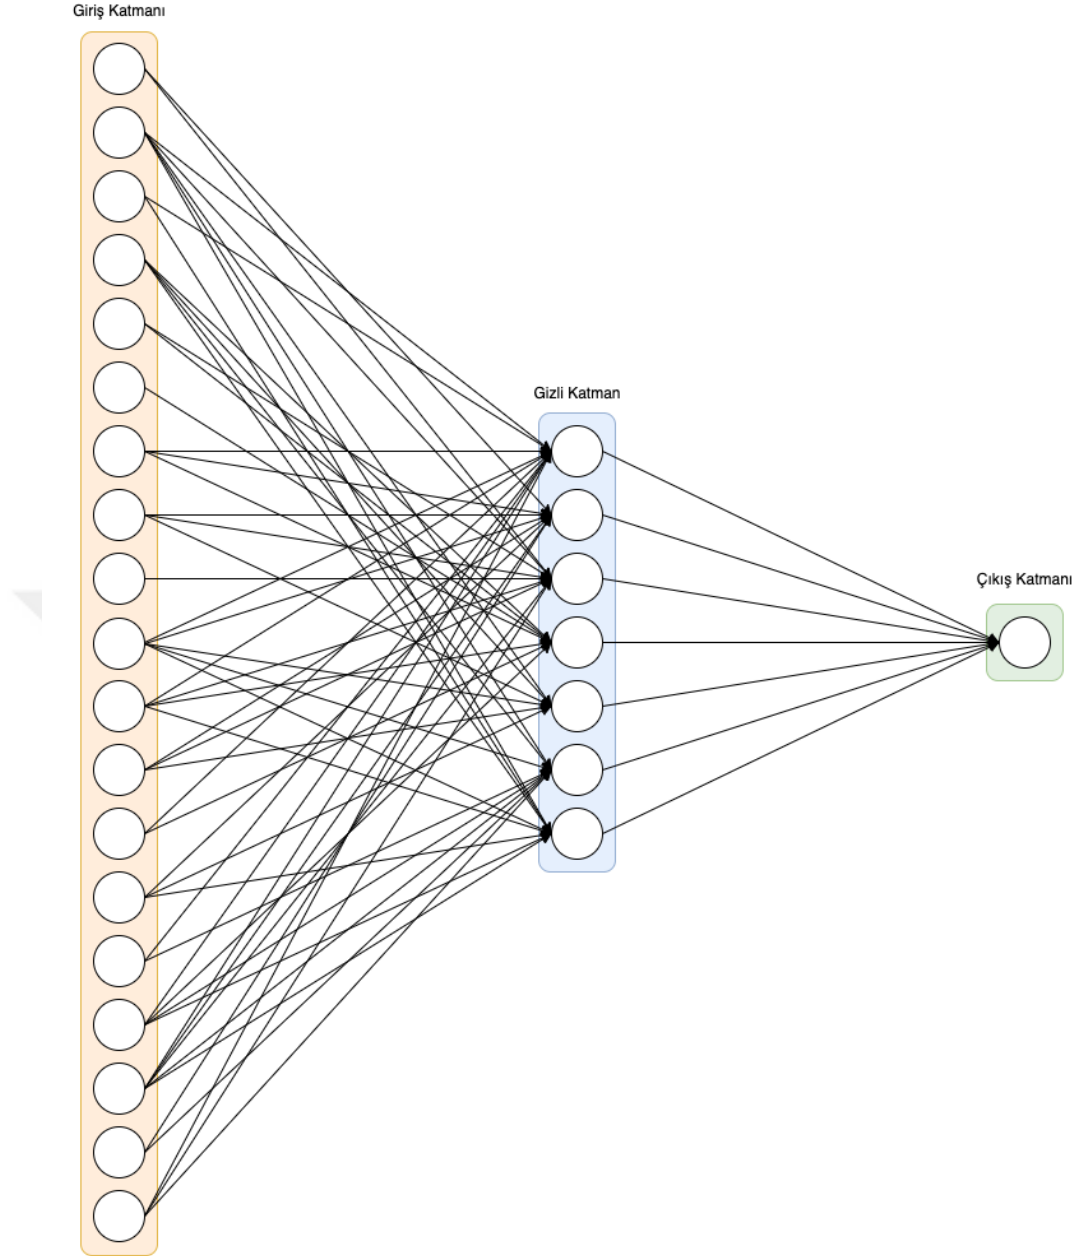
Gizli Katman	Çıkış Katmanı																		
	H1	H2	H3	H4	H5	H6	H7	H8	H9	H10	H11	H12	H13	H14	H15	H16	H17	H18	H19
I1	3.121	-	-4.866	-15.940	-	-4.481	-	-5.734	-	-	-	-	-	0.594	-	-	-6.914	-16.437	-
I2	-	6.054	-	-3.473	-	-5.077	13.743	-	-19.209	-15.049	-17.155	-9.345	9.734	-	-	-10.779	-10.512	21.578	-
I3	-2.405	-3.173	-	-	-	-1.431	-	-	-	-3.196	-	-11.111	-4.935	3.185	-6.795	-	-5.192	-	2.802
I4	-1.387	-	-	-	6.149	-	-0.039	-	-23.485	0.826	-12.638	-4.101	-	-	-0.368	-	-	-10.626	-
I5	-	-	-	-1.810	-4.828	-	-	-	-	-	-25.474	-18.553	-21.324	-	16.992	-19.429	-9.187	-10.968	-0.553
I6	-	-	-	-	11.373	15.381	-	-	-	-	-9.642	-	-	-	8.733	-	4.824	-	-7.925
I7	10.279	10.507	-8.373	-	-19.756	-	-	-25.338	-	-	-	-	7.581	-	-	-	-	-12.289	10.407
I8	-11.912	-0.667	-2.269	4.072	-	-13.484	-3.172	-	-	-	-	-	-	-	-	-	-27.001	-	1.882
I9	-10.953	-	-	-7.665	-	11.427	-	-3.609	-	-	-7.788	-	-	-	-	-19.064	-	-	10.045
I10	-21.562	-19.097	5.242	-	-	-8.499	16.817	1.105	-5.205	-25.742	-	-	-25.045	-	-4.874	2.878	10.746	-	-2.464
I11	-	-5.928	-	-10.540	-1.506	-	-	3.677	-	9.474	-11.489	-	-	-0.310	3.762	-	-	-	1.626
I12	10.377	-	-11.460	-0.348	-	-	7.372	-	-	-	-8.054	-	14.270	-1.938	-	-0.601	-4.412	-	-
I13	-	-10.180	-	-	-7.422	-	-	-9.978	-	-	-	-	-	-	-12.634	-3.088	-	-11.664	-20.068
I14	-	-	3.748	-	-	11.389	3.748	-	-	-4.900	-	-	-	-4.982	-	-	-	-19.070	-3.372
I15	12.603	-5.529	-	-	-	0.992	-	-	-9.176	-	-	-	-	-	-	-9.984	11.030	-	-26.618
I16	-15.930	7.589	-	-	-0.833	-	-	-4.037	1.033	2.543	-	2.271	-	-	-2.673	-	9.969	-	-
I17	-	-11.7981	-4.217	-9.206	-	-	-	-	5.999	-7.273	-4.861	-	2.471	-	8.788	-	-	15.500	-
I18	10.835	-	14.039	-	-	-0.624	-	-6.298	-14.313	-	-	-	4.322	-	-11.625	-	-5.776	-	-
I19	8.578	-30.310	-	-9.359	-	-	-	-	-6.415	-	-7.061	-	-	-	-	-19.610	3.036	-	-12.999

Şekil 4.7’de verilen yapay sinir ağının gizli ve çıkış katmanı arasında bulunan bağlantılarının BPSO ve ağırlıkların PSO ile optimize edilmiş ağırlık değerleri Çizelge 4.16’da verilmiştir.

Çizelge 4.16. Bağlantıları BPSO ve Ağırlıkları PSO ile Optimize Edilmiş Ağın Hepatit Veri Seti için Gizli ve Çıkış Katman Arasında Bulunan Bağlantı Ağırlıkları

Gizli Katman	Çıkış Katmanı
H1	-
H2	1.994
H3	-7.583
H4	1.197
H5	-10.054
H6	-
H7	1.345
H8	-
H9	2.926
H10	-2.035
H11	-
H12	-
H13	-
H14	-
H15	-
H16	-
H17	-
H18	-
H19	-

Şekil 4.7 incelendiği zaman gizli katmanda bulunan bazı nöronları sonucu etkilemediği gözlemlenmektedir. Bu nöronlar ağdan silinerek ağdaki düğüm sayıları optimize edilmiş olacaktır. Ayrıca gizli katmanda bulunan ve sonucu etkileyen düğümler için de giriş katmanındaki tüm düğümler ile bağlantısının olmaması hesaplama maliyetini düşürecektir. Sonucu etkilemeyen nöronlar ve bağlantıların silinmesi ile elde edilen yapay sinir ağı Şekil 4.8’de verilmiştir.



Şekil 4.8. Bağlantıları BPSO ve Ağırlıkları PSO ile Hepatit Veri Seti için Optimize Edilmiş ve Gereksiz Nöronları Temizlenmiş Yapay Sinir Ağı

Bağlantıların BPSO ve bağlantı ağırlıklarının PSO ile optimize edildiği yapay sinir ağının hepatit veri seti için BPSO ile katmanlar arası bağlantıları optimize edilmiştir. Yapay sinir ağının parametresi olan ağırlıklar ise sürekli PSO ile optimize edilmiştir. Gizli katman nöron sayısı 19'dan 7'e indirgenmiştir. Giriş katmanda bulunan nöron sayılarında herhangi bir değişiklik meydana gelmemiştir.

4.3. Mamografik Kütle Veri Seti İçin Sonuçlar

Çizelge 4.17’de PSO ile ağırlıkları optimize edilmiş tam bağlantılı bir yapay sinir ağının mamografik kütle veri seti için test sonuçları verilmiştir. Çapraz doğrulama ile elde edilen sonuçların her bir iterasyon için ayrı ayrı sonuçları listelenmektedir. Sonuçlarda makine öğrenmesi modellerinin veri seti üzerindeki başarısını ölçmeye yarayan performans ölçütlerinin en çok tercih edilenleri verilmiştir.

Çizelge 4.17. PSO ile Eğitilmiş Tam Bağlantılı YSA için Mamografik Kütle Veri Seti Performans Ölçütleri

k Değeri	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F1 Puanı
1	0.807	0.818	0.795	0.818	0.818
2	0.879	0.828	0.916	0.879	0.853
3	0.855	0.762	0.951	0.941	0.842
4	0.855	0.894	0.805	0.857	0.875
5	0.879	0.814	0.95	0.946	0.875
6	0.807	0.75	0.851	0.794	0.771
7	0.843	0.786	0.902	0.892	0.835
8	0.843	0.697	0.94	0.885	0.780
9	0.892	0.878	0.905	0.9	0.888
10	0.518	0.35	0.674	0.5	0.412
Ortalama	0.818	0.758	0.869	0.841	0.754

Mamografik veri seti için tam bağlantılı bir yapay sinir ağının parametreleri PSO ile optimize edilmiştir. Sonuçlar incelendiği zaman, k-katlı çapraz doğrulamanın her bir iterasyonunda elde edilen doğruluk değerlerinin ortalaması alınırsa genel bir doğruluk değeri olarak yüzde 81 değeri bulunmaktadır. Sonuçların duyarlılık değerleri incelendiği zaman gerçek doğruları yani hastaları tahmin etme oranının ortalama olarak yüzde 75 bulunmuştur. Özgüllük değeri olan gerçek hasta olmayanların tahmin oranı ise yüzde 86 değeri bulunmuştur. Kesinlik değeri yüzde 84, f1 puanı ise yüzde 75 olarak bulunmuştur.

Mamografik kütle veri seti için yapay sinir ağının PSO ile optimizasyon işlemi toplamda 30 saniye gibi oldukça hızlı bir sürede tamamlanmıştır.

BP ile eğitilmiş yapay sinir ağının mamografik kütle veri seti için k-katlı çaprazlama doğrulama ile elde edilen sonuçları Çizelge 4.18’de listelenmektedir.

Çizelge 4.18. BP ile Eğitilmiş Tam Bağlantılı YSA için Mamografik Kütle Veri Seti Performans Ölçütleri

k Değeri	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F1 Puanı
1	0.783	0.818	0.773	0.783	0.8
2	0.795	0.886	0.729	0.704	0.785
3	0.843	0.905	0.780	0.808	0.854
4	0.807	0.872	0.722	0.804	0.837
5	0.867	0.884	0.85	0.864	0.873
6	0.747	0.805	0.702	0.674	0.734
7	0.735	0.786	0.683	0.717	0.75
8	0.819	0.879	0.78	0.725	0.794
9	0.855	0.854	0.857	0.854	0.854
10	0.771	0.85	0.698	0.723	0.782
Ortalama	0.802	0.854	0.757	0.766	0.806

Çizelge 4.18’de verilen sonuçlar incelendiği zaman k-katlı çapraz doğrulamının her bir iterasyonunda elde edilen doğruluk değerlerinin ortalaması alınırsa doğruluk yüzde 80 olarak bulunmaktadır. Sonuçların duyarlılık değerleri incelendiği zaman yüzde 85 değeri bulunmuştur. Özgüllük değeri olan gerçek hasta olmayanların tahmin oranı ise yüzde 75 olarak bulunmuştur. Son olarak kesinlik değeri yüzde 76 ve f1 puanı yüzde 80 olarak bulunmuştur. Mamografik kütle veri seti için yapay sinir ağının BP ile optimizasyon işlemi toplam 2 saniyede tamamlanmıştır.

GA ile bağlantıları optimize edilmiş yapay sinir ağı için elde edilen k-katlı çapraz doğrulama sonuçları Çizelge 4.19’da gösterilmiştir. Çapraz doğrulamının tüm iterasyon sonuçları için performans ölçütleri verilmiştir.

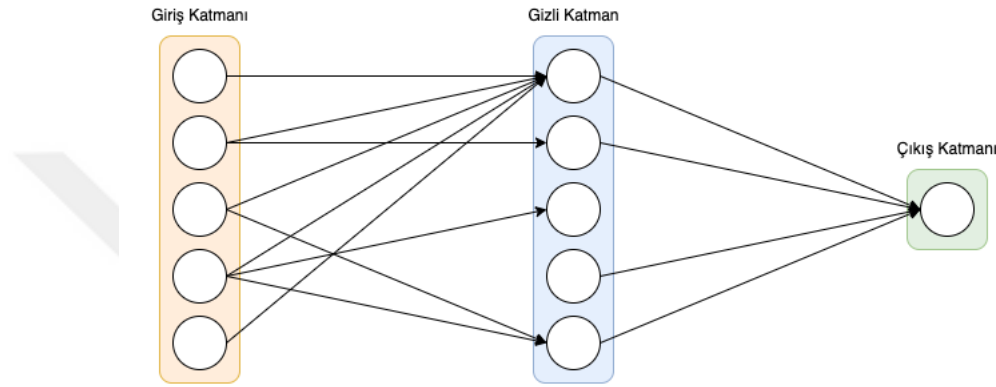
Çizelge 4.19. Bağlantıları GA ve Ağırlıkları PSO ile Eğitilmiş YSA için Mamografik Kütle Veri Seti Performans Ölçütleri

k Değeri	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F1 Puanı
1	0.843	0.737	0.933	0.903	0.811
2	0.819	0.730	0.891	0.844	0.783
3	0.831	0.791	0.875	0.872	0.829
4	0.819	0.755	0.895	0.895	0.819
5	0.855	0.710	0.978	0.964	0.818
6	0.807	0.684	0.911	0.867	0.765
7	0.819	0.761	0.892	0.897	0.823
8	0.795	0.921	0.689	0.714	0.804
9	0.795	0.675	0.907	0.871	0.760
10	0.807	0.825	0.791	0.786	0.804
Ortalama	0.819	0.759	0.876	0.841	0.802

Mamografik kütle veri seti için Çizelge 4.19’da her bir iterasyonda elde edilen doğruluk değerlerinin ortalaması alınırsa sonuçların yüzde 81 doğruluğa sahip olduğu gözlemlenmektedir. Duyarlılık değeri yüzde 75, özgüllük değeri ise yüzde 87, kesinlik

değeri yüzde 84 ve f1 puanı da yüzde 80 olarak bulunmuştur. İşlem toplamda 6 gün 18 saat 12 dakikada tamamlanmıştır.

Mamografik kütle veri seti için GA ile düğümler arasındaki bağlantıları optimize edilmiş ve PSO ile bağlantı ağırlıkları optimize edilmiş yapay sinir ağının yapısı Şekil 4.9'da verilmiştir. Şekil 4.9'da verilen yapay sinir ağı k-katlı çapraz doğrulama sonuçlarında en yüksek doğruluğa sahip olan 5. iterasyon sonucunda oluşan ağ yapısı verilmiştir.



Şekil 4.9. Mamografik Kütle Veri Seti için Bağlantıları GA ve Bağlantı Ağırlıkları PSO Optimize Edilmiş Yapay Sinir Ağı Yapısı

Şekil 4.9'da mamografik kütle veri seti için bağlantıları GA ve bağlantıların ağırlıkları ise PSO ile optimize edilmiş olan yapay sinir ağının, giriş ve gizli katman arasında bulunan bağlantıların optimize edilen ağırlık değerleri Çizelge 4.20'de verilmiştir.

Çizelge 4.20. Mamografik Kütle Veri Seti için Bağlantıları GA ve Bağlantı Ağırlıkları PSO Optimize Edilmiş Yapay Sinir Ağı Yapısı için Giriş ve Gizli Katman Arasında Bulunan Bağlantı Ağırlıkları

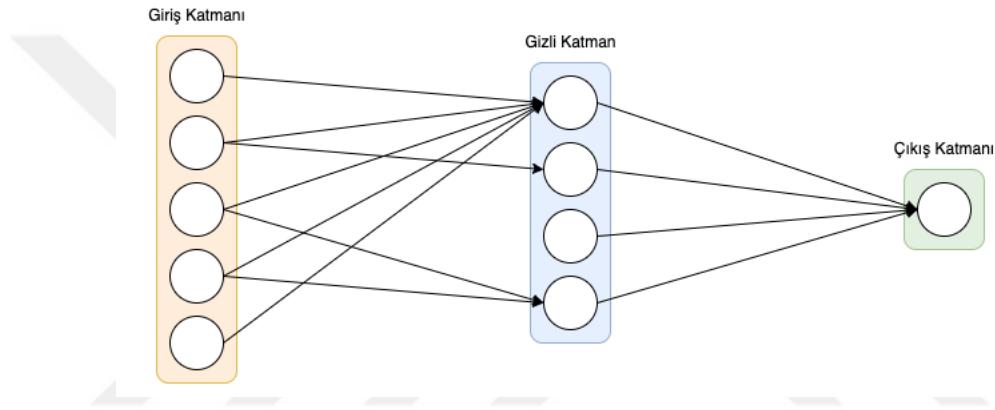
Giriş Katmanı	Gizli Katman				
	H1	H2	H3	H4	H5
I1	0.0075938	-	-	-	-
I2	0.00032092	0.00650616	-	-	-
I3	0.00231316	-	-	-	0.00620218
I4	0.00677179	-	0.00302639	-	0.0010025
I5	0.00816538	-	-	-	-

Mamografik kütle veri seti için GA ile bağlantıları optimize edilmiş olan yapay sinir ağının, gizli ve çıkış katmanı arasında bulunan bağlantıların optimize edilen ağırlık değerleri Çizelge 4.21'de verilmiştir.

Çizelge 4.21. Mamografik Kütle Veri Seti için Bağlantıları GA ve Bağlantı Ağırlıkları PSO Optimize Edilmiş Yapay Sinir Ağı Yapısı için Gizli ve Çıkış Katman Arasında Bulunan Bağlantı Ağırlıkları

Gizli Katman	Çıkış Katmanı
H1	0.00769461
H2	0.00229259
H3	-
H4	0.00531678
H5	0.00892983

Şekil 4.9 incelendiği zaman gizli katmanda bir nöronun sonuca etkisinin olmadığı gözlemlenmektedir. Sonucu etkilemeyen bu nöronun ve bağlantılarının silinmesi ile elde edilen yapay sinir ağı Şekil 4.10'da verilmiştir.



Şekil 4.10. Mamografik Kütle Veri Seti için Bağlantıları GA ve Bağlantı Ağırlıkları PSO Optimize Edilmiş ve Gereklisi Olmayan Nöronları Silinmiş Yapay Sinir Ağı Yapısı

Çizelge 4.22'de mamografik kütle veri setinin BPSO ile bağlantıları ve PSO ile bağlantı ağırlıkları optimize edilmiş yapay sinir ağının k-katlı çapraz doğrulamanın her bir iterasyonu için performans ölçütleri verilmiştir.

Çizelge 4.22. Bağlantıları BPSO ve Ağırlıkları PSO ile Eğitilmiş Mamografik Kütle Veri Seti Performans Ölçütleri

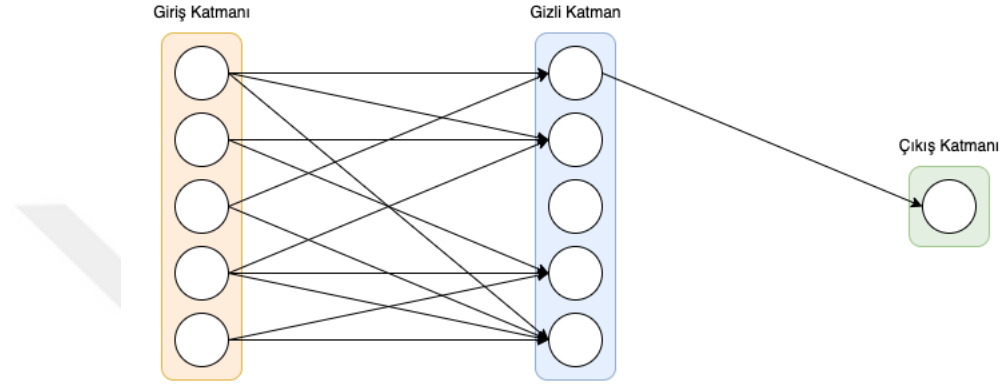
k Değeri	Doğruluk	Duyarlılık	Özgüllük	Keskinlik	F1 Puanı
1	0.843	0.737	0.933	0.903	0.811
2	0.819	0.730	0.891	0.844	0.783
3	0.831	0.791	0.875	0.872	0.829
4	0.831	0.777	0.895	0.897	0.833
5	0.855	0.710	0.977	0.964	0.818
6	0.807	0.684	0.911	0.866	0.765
7	0.819	0.761	0.892	0.897	0.823
8	0.783	0.921	0.666	0.7	0.795
9	0.831	0.7	0.953	0.933	0.8
10	0.831	0.85	0.814	0.809	0.829
Ortalama	0.825	0.766	0.88	0.868	0.809

Mamografik kütle veri seti için her bir iterasyonda elde edilen doğruluk değerlerinin ortalaması alınınca, ortalama olarak yüzde 82 değeri elde edilmiştir. Doğruluk değeri, PSO ile ağırlıkları optimize edilmiş tam bağlantılı ağ sonucunda elde edilen doğruluk değeri ile kıyaslandığı zaman yüzde 1'lik bir artış gösterirken, bağlantıları GA ile optimize edilmiş YSA ile kıyaslandığı zaman da yüzde 1'lik bir artış göstermektedir. BP ile ağırlıkları optimize edilmiş ağ ile kıyaslandığı zaman ise yüzde 2'lik bir artış söz konusudur. Önerilen yöntem ortalama yüzde 76 duyarlılığa sahiptir. Duyarlılık değeri, PSO ile ağırlıkları optimize edilmiş tam bağlantılı ağ ve bağlantıları GA ile optimize edilmiş tam bağlantılı ağ sonucunda elde edilen duyarlılık değeri ile kıyaslandığı zaman her iki yöntemde de yüzde 1'lik bir artış gözlemlenmektedir. Bağlantı ağırlıkları BP ile eğitilmiş yapay sinir ağı ile önerilen yöntem kıyaslandığı zaman ise yüzde 9'luk bir azalma söz konusudur. Önerilen yöntem yüzde 88 özgüllüğe sahiptir. PSO ile ağırlıkları optimize edilmiş tam bağlantılı ağ sonucunda elde edilen özgüllük değeri ile kıyaslandığı zaman; yüzde 2'lik bir artış gözlemlenirken, bağlantıları GA ile optimize edilen ağa göre ise yüzde 1'lik bir artış gözlemlenmektedir. Özgüllük değeri bakımından BP ile optimize edilen ağa göre önerilen yöntem yüzde 13 oranında artmıştır. Önerilen yöntem yüzde 86 kesinliğe sahiptir. Kesinlik değeri, PSO ile ağırlıkları optimize edilmiş tam bağlantılı ağ sonucunda elde edilen kesinlik değeri ile kıyaslandığı zaman; yüzde 2'lik bir artış gözlemlenmektedir. Önerilen yöntem, kesinlik değeri olarak BP ile eğitilen yapay sinir ağına göre yüzde 12 oranında artmıştır. GA ile bağlantıları optimize edilen ağ ile önerilen yöntem kesinlik değeri bakımından kıyaslandığı zaman yüzde 2'lik bir artış göstermektedir. Son olarak önerilen yöntem yüzde 80 fl skoruna sahiptir ve PSO ile ağırlıkları optimize edilmiş tam bağlantılı ağ sonucunda elde edilen fl skoru ile kıyaslandığı zaman; yüzde 5'lik bir artış gözlemlenmektedir. BP ile optimize edilen ağ sonucundan elde edilen fl puanı ile önerilen yöntem sonucundan elde edilen fl puanı kıyaslandığı zaman ise önerilen yöntem binde 3 oranında artış göstermiştir. Ayrıca GA ile bağlantıları optimize edilen YSA ile kıyaslanırsa da binde 7'lik bir artış gözlemlenmektedir.

Mamografik kütle veri seti için önerilen yöntem ile elde edilen sonuçlar hem PSO ile ağırlıkları optimize edilmiş tam bağlantılı yapay sinir ağ sonuçlarına hem de GA ile bağlantıları optimize edilen yapay sinir ağ sonuçlarına göre artış göstermiştir. BP ile optimize edilen ağa göre ise duyarlılık değeri haricinde geriye kalan metriklerde önerilen yöntem ile elde edilen sonuçlar daha iyi çıkmıştır.

Mamografik kütle veri seti için Önerilen yöntem ile optimize edilen YSA toplam 9 gün 5 saat 16 dakika 10 saniyede tamamlanmıştır.

Mamografik kütle veri seti için önerilen yöntem ile düğümler arasındaki bağlantıların BPSO ile optimize edildiği yapay sinir ağının yapısı Şekil 4.11'de verilmiştir. Şekilde verilen yapay sinir ağı k-katlı çapraz doğrulama sonuçlarında en yüksek doğruluğa sahip olan 5. iterasyon sonucunda oluşan ağ yapısı verilmiştir.



Şekil 4.11. Bağlantıları BPSO ve Ağırlıkları PSO ile Mamografik Kütle Veri Seti için Optimize Edilmiş Yapay Sinir Ağı Yapısı

Şekil 4.11'de mamografik kütle veri seti için önerilen yöntem ile optimize edilmiş olan yapay sinir ağının, giriş ve gizli katman arasında bulunan bağlantıların optimize edilen ağırlık değerleri Çizelge 4.23'te verilmiştir.

Çizelge 4.23. Bağlantıları BPSO ve Ağırlıkları PSO ile Optimize Edilmiş Ağın Mamografik Kütle Veri Seti için Giriş ve Gizli Katman Arasında Bulunan Bağlantı Ağırlıkları

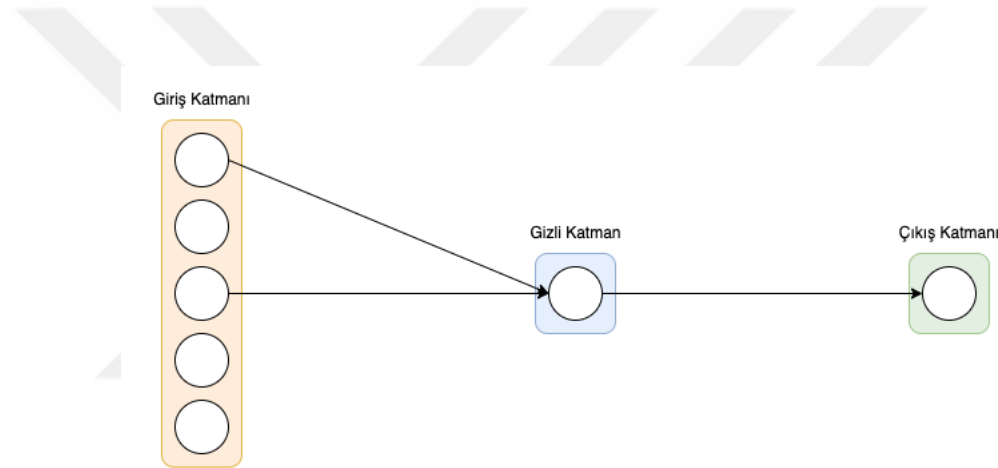
Giriş Katmanı	Gizli Katman				
	H1	H2	H3	H4	H5
I1	0.00885574	0.0018397	-	-	0.00060631
I2	-	0.00650616	-	0.00335078	-
I3	-0.00013007	-	-	-	0.00476889
I4	-	0.00069	-	0.00511034	0.00030188
I5	-	-	-	0.0036784	0.0064838

Şekil 4.11'de mamografik kütle veri seti için önerilen yöntem ile optimize edilmiş olan yapay sinir ağının, gizli ve çıkış katmanı arasında bulunan bağlantıların optimize edilen ağırlık değerleri Çizelge 4.24'de verilmiştir.

Çizelge 4.24. Bağlantıları BPSO ve Ağırlıkları PSO ile Optimize Edilmiş Ağın Mamografik Kütle Veri Seti için Gizli ve Çıkış Katman Arasında Bulunan Bağlantı Ağırlıkları

Gizli Katman	Çıkış Katmanı
H1	0.0007375
H2	-
H3	-
H4	-
H5	-

Şekil 4.11 incelendiği zaman gizli katmanda bulunan bazı nöronları sonucu etkilemediği gözlemlenmektedir. Hatta gizli katmanda bulunan sadece tek bir nöronun sonuca etkisi olduğu görülmektedir. Sonuca etkisi olmayan nöronlar ağdan silinerek ağdaki düğüm sayıları optimize edilmiş olunacaktır. Sonucu etkilemeyen nöronlar ve bağlantıların silinmesi ile elde edilen yapay sinir ağı Şekil 4.12’de verilmiştir.



Şekil 4.12. Bağlantıları BPSO ve Ağırlıkları PSO ile Mamografik Kütle Veri Seti için Optimize Edilmiş ve Gerekli Olmayan Nöronları Silinmiş Yapay Sinir Ağı Yapısı

Şekil 4.12 incelendiği zaman nöronların ve bağlantıların silinmesi ile bu veri setinde özellik seçimi işleminin de gerçekleştiği görülmektedir. Giriş katmanında bulunan özelliklerden sadece ikisinin sonucu etkisinin olduğu gözlemlenmiştir.

4.4. Haberman'nin Hayatta Kalma Veri Seti İçin Sonuçlar

Çizelge 4.25’te PSO ile ağırlıkları optimize edilmiş tam bağlantılı bir yapay sinir ağının Haberman'nin hayatta kalma veri seti için test sonuçları verilmiştir. K-katlı çapraz doğrulama ile elde edilen sonuçların her bir iterasyon için ayrı ayrı sonuçları listelenmektedir. Sonuçlarda makine öğrenmesi modellerinin veri seti üzerindeki başarısını ölçmeye yarayan performans ölçütlerinin en çok tercih edilenleri verilmiştir.

Çizelge 4.25. PSO ile Eğitilmiş Tam Bağlantılı YSA için Haberman'nin Hayatta Kalma Veri Seti Performans Ölçütleri

k Değeri	Doğruluk	Duyarlılık	Özgüllük	Keskinlik	F1 Puanı
1	0.742	0.666	0.75	0.222	0.333
2	0.548	0.5	0.56	0.214	0.3
3	0.677	0.5	0.823	0.7	0.583
4	0.677	0.625	0.696	0.417	0.5
5	0.806	0.875	0.783	0.583	0.7
6	0.645	0.583	0.684	0.538	0.56
7	0.666	0.666	0.666	0.333	0.444
8	0.733	0.555	0.809	0.555	0.555
9	0.633	0.5	0.681	0.363	0.421
10	0.766	0.714	0.783	0.5	0.588
Ortalama	0.69	0.618	0.723	0.442	0.498

Haberman'nin hayatta kalma veri seti için sonuçlar incelendiği zaman her bir iterasyonda elde edilen doğruluk değerlerinin ortalaması alınırsa yüzde 69 değeri bulunmaktadır. Duyarlılık değerleri incelendiği zaman ortalama olarak yüzde 61 bulunmuştur. Özgüllük değeri olan ise yüzde 72 değeri bulunmuştur. Keskinlik değeri Haberman'nin hayatta kalma veri seti için yüzde 44 ve f1 puanı yüzde 49 bulunmuştur.

Haberman'nin hayatta kalma veri seti için ağırlıkların PSO ile optimizasyon işlemi toplamda 20 saniyede tamamlanmıştır.

Bağlantı ağırlıkları BP ile eğitilmiş YSA'nın Haberman'nin hayatta kalma veri seti için sonuçları Çizelge 4.26'da verilmiştir.

Çizelge 4.26. BP ile Eğitilmiş Tam Bağlantılı YSA için Haberman'nin Hayatta Kalma Veri Seti Performans Ölçütleri

k Değeri	Doğruluk	Duyarlılık	Özgüllük	Keskinlik	F1 Puanı
1	0.387	0.333	0.393	0.055	0.095
2	0.452	0.333	0.48	0.133	0.190
3	0.645	0.571	0.706	0.615	0.592
4	0.548	0.625	0.522	0.312	0.417
5	0.516	0.5	0.522	0.267	0.348
6	0.387	0.333	0.421	0.267	0.296
7	0.5	0.5	0.5	0.2	0.286
8	0.667	0.667	0.667	0.451	0.545
9	0.733	0.875	0.681	0.5	0.636
10	0.7	0.857	0.652	0.428	0.571
Ortalama	0.554	0.559	0.554	0.323	0.398

Çizelge 4.26'da verilen sonuçlar incelendiği zaman her bir iterasyonda elde edilen değerlerinin ortalaması alınırsa doğruluk, duyarlılık ve özgüllük için yüzde 55 değeri bulunmaktadır. Keskinlik değeri yüzde 32 ve f1 puanı ise yüzde 39 bulunmuştur.

Haberman'nin hayatta kalma veri seti için BP ile optimizasyon işlemi toplamda 2 saniyede tamamlanmıştır.


Çizelge 4.27’de GA ile bağlantıları ve PSO ile bağlantı ağırlıkları optimize edilmiş yapay sinir ağı için elde edilen k-katlı çapraz doğrulama sonuçları gösterilmiştir. K-katlı çapraz doğrulamanın tüm iterasyon sonuçları için performans ölçütleri verilmiştir.

Çizelge 4.27. Bağlantıları GA ve Ağırlıkları PSO ile Eğitilmiş YSA için Haberman’ nin Hayatta Kalma Veri Seti Performans Ölçütleri

k Değeri	Doğruluk	Duyarlılık	Özgüllük	Keskinlik	F1 Puanı
1	0.613	0.5	0.684	0.5	0.5
2	0.613	0.385	0.778	0.555	0.454
3	0.710	0.0	1.0	Tanımsız	Tanımsız
4	0.580	0.25	0.696	0.222	0.235
5	0.871	0.8	0.905	0.80	0.80
6	0.871	0.875	0.869	0.7	0.778
7	0.833	0.0	1.0	Tanımsız	Tanımsız
8	0.80	0.75	0.818	0.6	0.667
9	0.633	0.2	0.72	0.125	0.154
10	0.766	1.0	0.741	0.3	0.461
Ortalama	0.729	0.476	0.821	0.380	0.405

Haberman’ nin hayatta kalma veri seti için Çizelge 4.27’de her bir iterasyonda elde edilen doğruluk değerlerinin ortalaması alınırsa sonuçların yüzde 72 doğruluğa sahip olduğu gözlemlenmektedir. Duyarlılık değeri yüzde 47, özgüllük değeri ise yüzde 82, keskinlik değeri yüzde 38 ve f1 puanı da yüzde 40 olarak bulunmuştur. İşlem toplamda 4 gün 2 saat 3 dakikada tamamlanmıştır.

Haberman’ nin hayatta kalma veri seti için GA ile düğümler arasındaki bağlantıları optimize edilmiş ve PSO ile bağlantı ağırlıkları optimize edilmiş yapay sinir ağının yapısı Şekil 4.13’te verilmiştir. Şekil 4.13’te verilen yapay sinir ağı k-katlı çapraz doğrulama sonuçlarında en yüksek doğruluğa sahip olan 5. iterasyon sonucunda oluşan ağ yapısı verilmiştir.



Şekil 4.13. Haberman’ nin Hayatta Kalma Veri Seti için Bağlantıları GA ve Bağlantı Ağırlıkları PSO Optimize Edilmiş Yapay Sinir Ağı Yapısı

Şekil 4.13'te Haberman'nin hayatta kalma veri seti için bağlantıları GA ve bağlantıların ağırlıkları ise PSO ile optimize edilmiş olan yapay sinir ağının, giriş ve gizli katman arasında bulunan bağlantıların optimize edilen ağırlık değerleri Çizelge 4.28'de verilmiştir.

Çizelge 4.28. Haberman'nin Hayatta Kalma Veri Seti için Bağlantıları GA ve Bağlantı Ağırlıkları PSO Optimize Edilmiş Yapay Sinir Ağı Yapısı için Giriş ve Gizli Katman Arasında Bulunan Bağlantı Ağırlıkları


Gizli Katman	Çıkış Katmanı		
	H1	H2	H3
I1	-	0.02984661	-
I2	-0.00571463	-	-
I3	-0.01626059	-	-0.02873557

Şekil 4.13'te Haberman'nin hayatta kalma veri seti için GA ile optimize edilmiş olan ağı, gizli ve çıkış katmanı arasında bulunan bağlantıların optimize edilen ağırlık değerleri Çizelge 4.29'da verilmiştir.

Çizelge 4.29. Haberman'nin Hayatta Kalma Veri Seti için Bağlantıları GA ve Bağlantı Ağırlıkları PSO Optimize Edilmiş Yapay Sinir Ağı Yapısı için Gizli ve Çıkış Katman Arasında Bulunan Bağlantı Ağırlıkları

Gizli Katman	Çıkış Katmanı
H1	-
H2	0.0482911
H3	-0.03301065

Şekil 4.13'te gizli katmanda bulunan sonucu etkilemeyen bir nöron ağdan silinerek ağda bulunan gizli katman nöron sayısı 3'ten 2'ye indirgenmiştir. Sonucu etkilemeyen nöronlar ve bağlantıların silinmesi ile elde edilen yapay sinir ağı Şekil 4.14'te verilmiştir.



Şekil 4.14. Haberman'nin Hayatta Kalma Veri Seti için Bağlantıları GA ve Bağlantı Ağırlıkları PSO Optimize Edilmiş ve Gerekli Olmayan Nöronları Silinmiş Yapay Sinir Ağı Yapısı

Şekil 4.14 incelendiği zaman nöronların ve bağlantıların silinmesi ile bu veri setinde özellik seçimi işleminin de gerçekleştiği görülmektedir. Giriş katmanında bulunan ikinci özelliğin sonuca herhangi bir etkisi bulunmamaktadır.

Haberman'nin hayatta kalma veri setinin önerilen yöntem ile test edilmesiyle elde edilen sonuçlar Çizelge 4.30'da gösterilmiştir. K-katlı çapraz doğrulama ile elde edilen sonuçların her iterasyon için ayrı ayrı sonuçları listelenmektedir. Sonuçlarda makine öğrenmesi modellerinin veri seti üzerindeki başarısını ölçmeye yarayan performans ölçütlerinden en çok tercih edilenleri verilmiştir.

Çizelge 4.30. Bağlantıları BPSO ve Ağırlıkları PSO ile Eğitilmiş Haberman'nin Hayatta Kalma Veri Seti Performans Ölçütleri

k Değeri	Doğruluk	Duyarlılık	Özgüllük	Keskinlik	F1 Puanı
1	0.613	0.5	0.684	0.5	0.5
2	0.613	0.385	0.777	0.555	0.454
3	0.710	0.0	1.0	Tanımsız	Tanımsız
4	0.581	0.25	0.696	0.222	0.235
5	0.871	0.8	0.905	0.8	0.8
6	0.806	0.875	0.783	0.583	0.7
7	0.833	0.0	1.0	Tanımsız	Tanımsız
8	0.7	0.75	0.681	0.461	0.571
9	0.633	0.2	0.72	0.125	0.154
10	0.733	0.666	0.740	0.222	0.333
Ortalama	0.71	0.442	0.799	0.266	0.375


Önerilen yöntem ile optimize edilmiş yapay sinir ağının Haberman'nin hayatta kalma veri seti için doğruluk değerlerinin çapraz doğrulama sonucunda ortalaması alınca, ortalama doğruluk değeri olarak yüzde 71 değeri elde edilmiştir. Doğruluk değeri, PSO ile ağırlıkları optimize edilmiş tam bağlantılı ağ sonucunda elde edilen doğruluk değeri ile kıyaslandığı zaman yüzde 2'lik bir artış gözlemlenmektedir. Bağlantı ağırlıkları BP ile optimize edilmiş yapay sinir ağı ile önerilen yöntem doğruluk değeri bakımından kıyaslandığı zaman ise yüzde 16'lık bir artma söz konusudur. GA ile bağlantıları optimize edilen yapay sinir ağı ile kıyaslandığı zaman ise yüzde 1'lik bir düşüş söz konusudur. Önerilen yöntem ortalama yüzde 44 duyarlılığa sahiptir. Duyarlılık değeri, PSO ile ağırlıkları optimize edilmiş tam bağlantılı ağ sonucunda elde edilen duyarlılık değeri ile kıyaslandığı zaman yüzde 17'lik bir fark gözlemlenirken bağlantıları GA ile optimize edilen ağ ile kıyaslandığı zaman ise yüzde 3'lük bir düşüş gözlemlenmektedir. BP ile eğitilmiş tam bağlantılı ağ ile kıyaslandığı zaman ise önerilen yöntem yüzde 11 oranında düşük bir değere sahiptir. Önerilen yöntem yüzde 79 özgüllüğe sahiptir ve PSO ile ağırlıkları optimize edilmiş tam bağlantılı ağ sonucunda elde edilen

özgüllük değeri ile kıyaslandığı zaman yüzde 7'lik bir artış gözlemlenmektedir. Özgüllük değeri bakımından önerilen yöntem, ağırlıkları BP ile optimize edilen ağa göre yüzde 24 oranında daha iyi sonuç üretmektedir. Bağlantıları GA ile optimize edilen YSA ile kıyaslandığı zaman ise yüzde 3'lük bir azalış gözlemlenmiştir. Kesinlik değeri önerilen yöntem için yüzde 26 bulunmuştur ve PSO ile optimize edilen ağa göre kesinlik değerinde yüzde 18'lik bir azalış görülmüştür. BP ile eğitilen ağa göre önerilen yöntem kesinlik bakımından yüzde 6 oranında daha düşük bir değer üretmektedir. Bağlantıları GA ile optimize edilen ağ ile önerilen yöntem kesinlik bakımından kıyaslandığı zaman ise yüzde 12'lik bir düşüş görülmektedir. Önerilen yöntemin fl puanı yüzde 37'dir. Önerilen yöntem ile tam bağlantılı YSA fl puanı bakımından kıyaslanacak olursa yüzde 12'lik bir düşüş gözlemlenmektedir. BP ile eğitilen ağa göre ise önerilen yöntem yüzde 2 oranında daha kötü sonuç vermektedir. Ayrıca GA ile bağlantıları optimize edilen ağ ile önerilen yöntem fl puanı bakımından kıyaslanırsa yüzde 3'lük bir fark görülmektedir.

Haberman'nin hayatta kalma veri seti için elde edilen tüm sonuçlara bakılacak olursa önerilen yöntemin bu veri seti üzerinde daha kötü sonuç verdiği görülecektir. Duyarlılık, kesinlik ve fl puanı bakımından en iyi sonucu, PSO ile ağırlıkları optimize edilen tam bağlantılı yapay sinir ağı vermiştir. Doğruluk ve özgüllük bakımından ise en iyi sonucu GA ile bağlantı optimizasyonu yapılan yapay sinir ağı vermiştir.

Haberman'nin hayatta kalma veri setinde önerilen yöntem ile ağın ve ağırlıkların optimizasyon işlemi 4 gün 3 saat 40 dakika 16 saniyede tamamlanmıştır. İlk yöntemle karşılaştırıldığı zaman süre bakımından önerilen yöntem oldukça maliyetlidir.

Önerilen yöntem ile düğümler arasındaki bağlantıların optimize edildiği ağın yapısı Haberman'nin hayatta kalma veri seti için Şekil 4.15'te verilmiştir. Şekilde verilen ağ k-katlı çapraz doğrulama sonuçlarında en yüksek doğruluğa sahip olan 5. iterasyon sonucunda oluşan ağ yapısıdır.



Şekil 4.15. Bağlantıları BPSO ve Ağırlıkları PSO ile Haberman'nin Hayatta Kalma Veri Seti için Optimize Edilmiş Yapay Sinir Ağı Yapısı

Şekil 4.15'te giriş ve çıkış katmanı arasında bulunan bağlantıları Haberman'nin hayatta kalma veri seti için önerilen yöntem ile optimize edilmiş olan ağı, giriş ve gizli katmanı arasında bulunan bağlantıların optimize edilen ağırlık değerleri Çizelge 4.31'de verilmiştir.

Çizelge 4.31. Bağlantıları BPSO ve Ağırlıkları PSO ile Optimize Edilmiş Ağı Haberman'nin Hayatta Kalma Veri Seti için Giriş ve Gizli Katman Arasında Bulunan Bağlantı Ağırlıkları


Gizli Katman	Çıkış Katmanı		
	H1	H2	H3
I1	-	0.00061271	-
I2	-	-	0.00636951
I3	-	-	0.00486168

Şekil 4.15'te giriş ve çıkış katmanı arasında bulunan bağlantıları Haberman'nin hayatta kalma veri seti için optimize edilmiş olan ağı, gizli ve çıkış katmanı arasında bulunan bağlantıların optimize edilen ağırlık değerleri Çizelge 4.32'de verilmiştir.

Çizelge 4.32. Bağlantıları BPSO ve Ağırlıkları PSO ile Optimize Edilmiş Ağı Haberman'nin Hayatta Kalma Veri Seti için Gizli ve Çıkış Katman Arasında Bulunan Bağlantı Ağırlıkları

Gizli Katman	Çıkış Katmanı
H1	-
H2	-
H3	0.00258112

Şekil 4.15 incelendiği zaman gizli katmanda bulunan bazı nöronları sonucu etkilemediği gözlemlenmektedir. Bu nöronlar ağdan silinerek ağdaki düğüm sayıları optimize edilmiş olacaktır. Ayrıca gizli katmanda bulunan ve sonucu etkileyen düğümler için de giriş katmanındaki tüm düğümler ile bağlantı olmaması hesaplama maliyetini düşürecektir. Sonucu etkilemeyen nöronlar ve bağlantıların silinmesi ile elde edilen yapay sinir ağı Şekil 4.16'da verilmiştir.



Şekil 4.16. Bağlantıları BPSO ve Ağırlıkları PSO ile Haberman'nin Hayatta Kalma Veri Seti için Optimize Edilmiş ve Gerekli Olmayan Nöronları Silinmiş Yapay Sinir Ağı Yapısı

Şekil 4.16 incelendiği zaman nöronların ve bağlantıların silinmesi ile bu veri setinde özellik seçimi işleminin de gerçekleştiği görülmektedir. Giriş katmanında bulunan ilk özelliğın sonuca herhangi bir etkisi bulunmamaktadır. Bu yüzden bu özellik göz ardı edilebilir.



5. SONUÇLAR VE ÖNERİLER

Bu tez çalışmasında yeni bir ağ yapısı ortaya konmuştur. Ağ parametrelerinin optimize edildiği ağ yapılarından farklı olarak düğümler arasında bulunan yolların da optimize edilmesi sağlanmıştır. Bu sayede ağın minimum bağlantı ve düğüm sayısı ile en iyi sonucu vermesi sağlanmıştır.

Önerilen yöntemin çeşitli veri setleri üzerindeki sonuçları, ağ parametreleri ayrı ayrı PSO ve BP ile optimize edilmiş tam bağlantılı yapay sinir alarını ve bağlantıları GA ile optimize edilmiş yapay sinir ağı ile kıyaslanarak verilmiştir.

5.1 Sonuçlar

Bu tezde önerilen yöntem ve PSO ile bağlantı ağırlıkları optimize edilen tam bağlantılı ağlar kıyaslandığı zaman, çalışmada kullanılan veri setlerin hemen hemen hepsinde önerilen yöntem ile yapılan sınıflandırma işleminin daha iyi sonuçlar verdiği gözlemlenmiştir. Makine öğrenmesi algoritmalarının performansını ölçmek amacıyla kullanılan performans ölçütleri bakımından önerilen yöntemin diğer yöntemlere kıyasla daha yüksek sonuçlar verdiği kanıtlanmıştır.

Bağlantıları BP ile eğitilen tam bağlantılı yapay sinir ağı, önerilen yöntemle kıyaslandığı zaman hepatit veri seti hariç meme kanseri, mamografik kütle ve Haberman'nin hayatta kalma veri seti için doğruluk olarak daha iyi sonuçlar vermektedir.

Bağlantı optimizasyonu GA ile yapılan yapay sinir ağı ile önerilen yöntem kıyaslandığı zaman ise BPSO'nun GA'a göre meme kanseri ve Haberman'nin hayatta kalma veri setleri için daha düşük, hepatit veri seti için eşit ve mamografik kütle veri seti için ise daha yüksek sonuç verdiği gözlemlenmiştir.

Sonuçlar süre bakımından değerlendirildiği zaman önerilen yöntemin işlem karmaşıklığı ve hesaplama maliyeti bakımından diğer yöntemlerden daha maliyetli olduğu da gözlemlenmiştir. Fakat elde edilen sonuçların doğruluk derecesinin daha yüksek olması sonuçların bu maliyetini göz ardı edilebileceğini göstermiştir.

Ağda bulunan yolların tamamını bir küme olarak düşünürsek; doğruluğu etkilemeyen yolların ağdan silinmesi ile elde edilen sonuç yolların tamamının bulunduğu kümenin altkümesi olacağından dolayı, yolların tamamının olması ile elde edilen sonuçla kıyaslandığı zaman ya aynı doğruluk değerini vermeli ya da daha iyi sonuç vermelidir. Çünkü daha iyi sonuç vermeyecek ise bağlantının silinmesine gerek yoktur ve bu

durumda sonuç sabit kalacaktır. Bu da önerilen yöntemin tam bağlantılı bir ağ ile kıyaslandığı zaman ya aynı sonucu ya da daha iyi bir sonuç vereceğini göstermektedir. Önerilen yöntemin daha kötü bir sonuç vermesi beklenemez.

5.2 Öneriler

Bu tez çalışmasında biyolojik sinir hücresi ile uyumlu bir ağ tasarımı amaçlanmıştır. Biyolojik sinir hücreleri incelendiği zaman sinir sistemi ağ yapısının rastgelelikler üzerine kurulu olduğunu kanaatine varılmıştır. Bu doğrultuda ağda bulunan düğümlerin ve yolların optimizasyon işlemi gerçekleştirilmiştir. Ancak gerçekleştirilen ağ yapısı tam anlamıyla biyolojik bir sistemin rastgele oluşunu karşılamamaktadır. Uzun vadede biyolojik sistemlere daha uyumlu olan yapının tasarlanması planlanmaktadır. Bu hedef doğrultusunda ağın giriş ve çıkış düğümleri rastgele belirlenip optimize edilebilir. Ayrıca ağda kullanılan aktivasyon fonksiyonu, toplama fonksiyonu gibi parametreler de optimize edilebilir.

İlerleyen çalışmalarda önerilen yöntem ile elde edilen yapay sinir ağında bulunan bağlantı sayısının belli bir eşik değeri üzerinde sadeleştirilmesi düşünülebilir. Ayrıca önerilen yöntemin matematiksel ifadesine bu amaçla bir katsayı eklenebilir.

BPSO ile bağlantı optimizasyonu işleminde bağlantı dizisinde bulunan tüm değerleri 1 olacak şekilde ele alınabilir. Bu sayede başlangıçta tam bağlantılı bir ağ yapısı düşünülüp daha sonra bu bağlantıların optimizasyon işlemi gerçekleştirilebilir.

Önerilen yöntemin yenilikçi bir yaklaşım olması ve geliştirmeye açık olduğu unutulmaması gereken bir gerçektir.

KAYNAKLAR

- Akca, M. F., 2020, Gradient descent nedir?, <https://veribilimeci.com/2017/07/18/dereceli-azalma-nedir-gradient-descent/>: [12.04.2021].
- Akdoğan, E., 2017, Mekatronik mühendisliği uygulamalarında yapay zeka, <http://ytubiomechatronics.com/wp-content/uploads/2017/10/YSA.pdf>: [20.05.2021].
- Arora, R. K., 2015, Optimization: algorithms and applications, Taylor & Francis Group, LLC, p.
- Asadnia, M., Chua, L. H. C., Qin, X. S. ve Talei, A., 2014, Improved particle swarm optimization-based artificial neural network for rainfall-runoff modeling, *Journal of Hydrologic Engineering*, 19 (7), 1320-1329.
- Aydilek, I. B., 2018, Analyzing and improving information gain of metrics used in software defect prediction in decision trees, *Pamukkale University Journal of Engineering Sciences-Pamukkale Üniversitesi Muhendislik Bilimleri Dergisi*, 24 (5), 906-914.
- Bai, B., Zhang, J., Wu, X., Wei Zhu, G. ve Li, X., 2021, Reliability prediction-based improved dynamic weight particle swarm optimization and back propagation neural network in engineering systems, *Expert Systems with Applications*, 177, 114952.
- Bozkurt, F., Altay, Ş., Y. ve Yağanoğlu, M., 2015, Yapay sinir ağları ile Ankara ilinde hava kalitesi sağlık indeksi tahmini. 2.Ulusal Yönetim Bilişim Sistemleri Kongresi. Erzurum.
- Chai, R., Ling, S. H., Hunter, G. P., Tran, Y. ve Nguyen, H. T., 2014, Brain-computer interface classifier for wheelchair commands using neural network with fuzzy particle swarm optimization, *IEEE Journal of Biomedical and Health Informatics*, 18 (5), 1614-1624.
- Chen, S. T., Yu, D. C. ve Moghaddamjo, A. R., 1992, Weather sensitive short-term load forecasting using nonfully connected artificial neural network, *IEEE Transactions on Power Systems*, 7 (3), 1098-1105.
- Chen, Y. ve Yi, Z., 2021, Adaptive sparse dropout: learning the certainty and uncertainty in deep neural networks, *Neurocomputing*, 450, 354-361.
- Çayiroğlu, İ., 2015, Yapay sinir ağları, http://www.ibrahimcayiroglu.com/Dokumanlar/GoruntuIsleme/Goruntu_Isleme_Ders_Notlari-11.Hafta.pdf: [31.05.2022].
- Das, G., Pattnaik, P. K. ve Padhy, S. K., 2014, Artificial neural network trained by particle swarm optimization for non-linear channel equalization, *Expert Systems with Applications*, 41 (7), 3491-3496.
- Deng, M., Meng, T., Cao, J., Wang, S., Zhang, J. ve Fan, H., 2020, Heart sound classification based on improved MFCC features and convolutional recurrent neural networks, *Neural Networks*, 130, 22-32.
- Diler, A. İ., 2003, İMKB ulusal-100 endeksinin yönünün yapay sinir ağları hata geriye yayma yöntemi ile tahmin edilmesi, *İstanbul Menkul Kıymetler Borsası Dergisi*, 7, 65-81.
- Doruk, R. O. ve Zhang, K., 2018, Fitting of dynamic recurrent neural network models to sensory stimulus-response data, *Journal of Biological Physics*, 44 (3), 449-469.
- Eiben, A. E. ve Smith, J. E., 2003, Introduction to evolutionary computing, *New York*, Springer, p.

- Fahlman, S. E. ve Lebiere, C., 1997, The cascade-correlation learning architecture, Carnegie-Mellon Univ Pittsburgh Pa School Of Computer Science.
- Ganesh, M. R., Krishna, R., Manikantan, K. ve Ramachandran, S., 2014, Entropy based binary particle swarm optimization and classification for ear detection, *Engineering Applications of Artificial Intelligence*, 27, 115-128.
- Gilsousa, 2017, Haberman's survival data set, <https://www.kaggle.com/datasets/gilsousa/habermans-survival-data-set>: [16.05.2022].
- Grefenstette, J. J., 1986, Optimization of control parameters for genetic algorithms, *Ieee Transactions on Systems Man and Cybernetics*, 16 (1), 122-128.
- Harinir, 2018, Hepatitis, <https://www.kaggle.com/datasets/harinir/hepatitis>: [21.05.2021].
- Hassanat, A., Almohammadi, K., Alkafaween, E. a., Abunawas, E., Hammouri, A. ve Prasath, V. B. S., 2019, Choosing mutation and crossover ratios for genetic algorithms-a review with a new dynamic approach, *Information (2078-2489)*, 10 (12), 390-390.
- Hinton, G. E., 2007, Boltzmann machine, 2 (5), 1668.
- Hinton, G. E., 2012, A practical guide to training restricted boltzmann machines, *In Neural networks: Tricks of the trade*, 599-619.
- Hongkang, W., Li, L., Yong, W., Fanjia, M., Haihua, W. ve Sigrimis, N. A., 2018, Recurrent neural network model for prediction of microclimate in solar greenhouse, *IFAC-PapersOnLine*, 51 (17), 790-795.
- Hopfield, J. J., 2007, Hopfield network, 2 (5), 1977.
- Inkaya, T., Kayaligil, S. ve Ozdemirel, N. E., 2016, Swarm intelligence-based clustering algorithms: a survey, Springer International Publishing, p. 303–341.
- Jianhui, W., Qibing, G. ve Shusheng, G., 1998, A novel recurrent neural network and its algorithm, *IFAC Proceedings Volumes*, 31, 249-253.
- Jo, H. S., Koo, Y. D., Park, J. H., Oh, S. W., Kim, C.-H. ve Na, M. G., 2021, Prediction of golden time for recovering SISs using deep fuzzy neural networks with rule-dropout, *Nuclear Engineering and Technology*, 53 (12), 4014-4021.
- Kaviani, S. ve Sohn, I., 2021, Study of scale-free structures in feed-forward neural networks against backdoor attacks, *ICT Express*, 7 (2), 265-268.
- Kennedy, J. ve Eberhart, R., 1995, Particle swarm optimization, *In Proceedings of the IEEE International Conference on Neural Networks IV*, 1942–1948.
- Kennedy, J. ve Eberhart, R. C., 1997, A discrete binary version of the particle swarm algorithm, *InProceed-ings of the conference on systems, man, and cybernetics*, 4104–4109.
- Khajeh, M. ve Dastafkan, K., 2014, Removal of molybdenum using silver nanoparticles from water samples: Particle swarm optimization–artificial neural network, *Journal of Industrial and Engineering Chemistry*, 20 (5), 3014-3018.
- Khalifa, Y., Mandic, D. ve Sejdić, E., 2021, A review of hidden markov models and recurrent neural networks for event detection and localization in biomedical signals, *Information Fusion*, 69, 52-72.
- Khotanzad, A., Abaye, A. ve Maratukulam, D., 1994, An adaptive recurrent neural network system for multi-step-ahead hourly prediction of power system loads, *1994 Ieee International Conference on Neural Networks, Vol 1-7*, 3393-3397.
- Kıran, M. S., 2014, Optimizasyon problemlerinin çözümü için yapay arı kolonisi algoritması tabanlı yeni yaklaşımlar, Doktora Tezi, *Selçuk Üniversitesi Fen Bilimleri Enstitüsü*, Konya, 129.

- Kızrak, A., 2019, Derin öğrenme için aktivasyon fonksiyonlarının karşılaştırılması, <https://ayyucekizrak.medium.com/derin-%C3%B6%C4%9Frenme-i-%C3%A7in-aktivasyon-fonksiyonlar%C4%B1n%C4%B1n-kar%C5%9F%C4%B1la%C5%9Ft%C4%B1r%C4%B1lmas%C4%B1-cee17fd1d9cd>: [22.06.2022].
- Kumar, R. ve Srivastava, S., 2020, Externally recurrent neural network based identification of dynamic systems using lyapunov stability analysis, *ISA Transactions*, 98, 292-308.
- Lin, W. Y., Lee, W. Y. ve Hong, T. P., 2003, Adapting crossover and mutation rates in genetic algorithms, *Journal of Information Science and Engineering*, 19 (5), 889-903.
- Lupo Pasini, M., Yin, J., Li, Y. W. ve Eisenbach, M., 2021, A scalable algorithm for the optimization of neural network architectures, *Parallel Computing*, 104-105, 102788.
- Mae, Y., Kumagai, W. ve Kanamori, T., 2021, Uncertainty propagation for dropout-based Bayesian neural networks, *Neural Networks*, 144, 394-406.
- McDonnell, J. R. ve Waagen, D., 1993, Evolving neural network connectivity, *International Conference on Neural Networks*, San Francisco, CA, USA.
- Moayed, H., Mehrabi, M., Mosallanezhad, M., Rashid, A. S. A. ve Pradhan, B., 2019, Modification of landslide susceptibility mapping using optimized PSO-ANN technique, *Engineering with Computers*, 35 (3), 967-984.
- Mojtaba Ahmadi, K., Mohammad, T. ve Mahdi Aliyari, S., 2017, A novel binary particle swarm optimization.
- Nasimi, R. ve Irani, R., 2014, Identification and modeling of a yeast fermentation bioreactor using hybrid particle swarm optimization-artificial neural networks, *Energy Sources, Part A: Recovery, Utilization, and Environmental Effects*, 36 (14), 1604-1611.
- Nguyen, B. H., Xue, B., Andreae, P. ve Zhang, M., 2021, A new binary particle swarm optimization approach: momentum and dynamic balance between exploration and exploitation, *IEEE Transactions on Cybernetics*, 51 (2), 589-603.
- Norton, D. ve Ventura, D., 2010, Improving liquid state machines through iterative refinement of the reservoir, *Neurocomputing*, 73 (16-18), 2893-2904.
- Ovsen, 2016, Mammographic mass data set, <https://www.kaggle.com/datasets/overratedgman/mammographic-mass-data-set>: [20.05.2022].
- Oztemel, E., 2006, Yapay sinir ağları, Papatya Yayıncılık Eğitim Bilgisayar Sis. San. ve Tic. A.Ş, p.
- Parra Hernández, R., Álvarez Gallegos, J. ve Hernández Reyes, J. A., 1998, Simple recurrent neural network: a neural network structure for control systems, *Neurocomputing*, 23 (1-3), 277-289.
- Pujol, J. C. F. ve Poli, R., 1998, Evolving the topology and the weights of neural networks using a dual representation, *Applied Intelligence*, 8 (1), 73-84.
- Quarto, M., D'Urso, G. ve Giardini, C., 2022, Micro-EDM optimization through particle swarm algorithm and artificial neural network, *Precision Engineering*, 73, 63-70.
- Ren, X., Gu, H. ve Wei, W., 2021, Tree-RNN: Tree structural recurrent neural network for network traffic classification, *Expert Systems with Applications*, 167, 114363.
- Rullen, R. ve Thorpe, S., 2001, Rate coding versus temporal order coding: what the retinal ganglion cells tell the visual cortex, *Neural computation*, 13, 1255-1283.
- Rumelhart, D. E., Hinton, G. E. ve Williams, R. J., 1986, Learning representations by back-propagating errors, *Nature*, 323 (6088), 533-536.

- Santra, B., Paul, A. ve Mukherjee, D. P., 2020, Deterministic dropout for deep neural networks using composite random forest, *Pattern Recognition Letters*, 131, 205-212.
- Sarath, K. N. V. D. ve Ravi, V., 2013, Association rule mining using binary particle swarm optimization, *Engineering Applications of Artificial Intelligence*, 26 (8), 1832-1840.
- Shi, Y. ve Eberhart, R., 1998, A modified particle swarm optimizer, 69-73.
- Shojaei, I. ve Rahami, H., 2022, A heuristic swarm-based optimization method using multi-variate normal distributions with self-adaptive variance matrices, *Structures*, 36, 372-391.
- Shrivastava, T., 2020, MP neuron model, <https://medium.com/analytics-vidhya/mp-neuron-model-f4feb53c21a2>: [20.06.2022].
- Srinivas, M. ve Patnaik, L. M., 1994, Genetic algorithms: a survey, *Computer*, 27 (6), 17-26.
- Thengade, A. ve Dondal, R., 2012, Genetic algorithm – survey paper. MPGI National Multi Conference 2012 (MPGINMC-2012) International Journal of Computer Applications. ISSN: 0975 - 8887.
- Tian, S., Qu, L., Wang, L., Hu, K., Li, N. ve Xu, W., 2021, A neural architecture search based framework for liquid state machine design, *Neurocomputing*, 443, 174-182.
- UCI, M. L. R., 1992, Breast cancer wisconsin (original) data set, <https://archive.ics.uci.edu/ml/datasets/Breast+Cancer+Wisconsin+%28Original%29>: [22.04.2021].
- Vishwakarma, G. K., Paul, C. ve Elsayah, A. M., 2020, An algorithm for outlier detection in a time series model using backpropagation neural network, *Journal of King Saud University - Science*, 32 (8), 3328-3336.
- Wan, L., Zeiler, M., Zhang, S., LeCun, Y. ve Fergus, R., 2013, Regularization of neural networks using DropConnect, *Proceedings of the 30th International Conference on Machine Learning*, 1058-1066.
- Wang, H., Yang, W., Zhao, Z., Luo, T., Wang, J. ve Tang, Y., 2019, Rademacher dropout: an adaptive dropout for deep neural network via optimizing generalization gap, *Neurocomputing*, 357, 177-187.
- Wang, R., Chen, H. ve Guan, C., 2021, Random convolutional neural network structure: an intelligent health monitoring scheme for diesel engines, *Measurement*, 171, 108786.
- Whitley, D., Starkweather, T. ve Bogart, C., 1990, Genetic algorithms and neural networks - optimizing connections and connectivity, *Parallel Computing*, 14 (3), 347-361.
- Xiong, B., Li, Y., Huang, M., Shi, W., Du, M. ve Yang, Y., 2019, Feature selection of input variables for intelligence joint moment prediction based on binary particle swarm optimization, *Ieee Access*, 7, 182289-182295.
- Yazici, A. C., Ogus, E., Ankarali, S., Canan, S., Ankarali, H. ve Akkus, Z., 2007, Artificial neural networks: review, *Turkiye Klinikleri Tip Bilimleri Dergisi*, 27 (1), 65-71.
- Yeoh, Y. J., Morie, T. ve Tamukoh, H., 2021, An efficient hardware-oriented dropout algorithm, *Neurocomputing*, 427, 191-200.
- Yong, L. ve Xin, Y., 2001, Evolving neural networks for Hang Seng stock index forecast, *Proceedings of the 2001 Congress on Evolutionary Computation (IEEE Cat. No.01TH8546)*, Seoul, South Korea.
- Zhai, T. ve He, Z., 2013, Instance selection for time series classification based on immune binary particle swarm optimization, *Knowledge-Based Systems*, 49, 106-115.

Zhang, Y. D., Wang, S. H. ve Ji, G. L., 2015, A comprehensive survey on particle swarm optimization algorithm and its applications, *Mathematical Problems in Engineering*, 2015.

