

T.C.
BEYKENT ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI
BİLGİSAYAR MÜHENDİSLİĞİ BİLİM DALI

**SEPSİS HASTALIĞININ DERİN ÖĞRENME YÖNTEMİYLE
TAHMİNİ**
Doktora Tezi

Tezi Hazırlayan:

Umut KAYA

İSTANBUL, 2022

T.C.
BEYKENT ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI
BİLGİSAYAR MÜHENDİSLİĞİ BİLİM DALI

**SEPSİS HASTALIĞININ DERİN ÖĞRENME YÖNTEMİYLE
TAHMİNİ**

Doktora Tezi

Tezi Hazırlayan:

Umut KAYA

130821002

ORCID: 0000-0002-1410-3444

Danışman:

Dr. Öğr. Üyesi Atınç YILMAZ

İSTANBUL, 2022

YEMİN METNİ

Doktora Tezi olarak sunduđum “**Sepsis Hastalığının Derin Öğrenme Yöntemiyle Tahmini**” başlıklı bu çalışmanın, bilimsel ahlak ve geleneklere uygun şekilde tarafımdan yazıldığını, bu proje/tezdeki bütün bilgileri akademik ve etik kurallar içinde elde ettiđimi, yararlandığım eserlerin tamamının kaynaklarda gösterildiđini ve çalışmamın içinde kullanıldıkları her yerde bunlara atıf yapıldığını, patent ve telif haklarını ihlal edici bir davranışımın olmadığını belirtir ve bunu onurumla doğrularım. 29.12.2022

Umut KAYA

TEZ ONAYI

Beykent Üniversitesi Lisansüstü Eğitim Enstitüsü *Bilgisayar Mühendisliği Doktora* öğrencisi *130821002* numaralı *Umut KAYA*'nın hazırladığı "*Sespi Hastalığının Derin Öğrenme Yöntemiyle Tahmini*" konulu DOKTORA TEZİ ile ilgili TEZ SAVUNMA SINAVI Lisansüstü Öğretim ve Sınav Yönetmeliğinin ilgili maddesi uyarınca 29.12.2022 günü saat 14:00'de Zoom programı aracılığıyla on-line olarak yapılmış, sorulan sorulara alınan cevaplar sonucunda adayın tezinin *KABUL*'üne *OYBİRLİĞİ*'yle karar verilmiştir.

JÜRİ ÜYESİ	KANAATI	İMZA
Dr. Öğr. Üyesi At*** YIL*** (Danışman) (Beykent Üniversitesi)		
Dr. Öğr. Üyesi Ed*** ŞA*** (Üye) (Beykent Üniversitesi)		
Dr. Öğr. Üyesi Se*** AY*** (Üye) (Yıldız Teknik Üniversitesi)		
Doç. Dr. Yü*** Ba*** SA*** (Üye) (Bahçeşehir Üniversitesi)		
Dr. Öğr. Üyesi Ze*** AL*** (Üye) (Beykent Üniversitesi)		

Adı ve Soyadı : Umut KAYA
Danışman : Dr. Öğr. Üyesi Atınç YILMAZ
Türü ve Tarihi : Doktora, 2022
Alanı : Bilgisayar Mühendisliği
Anahtar Kelimeler : Sepsis, Derin Öğrenme, Metasezgisel Algoritma, Optimizasyon, Yapay Zekâ

ÖZ

SEPSİS HASTALIĞININ DERİN ÖĞRENME YÖNTEMİYLE TAHMİNİ

Sepsis hastalığı erken teşhis edilmediği takdirde hastanın ölümüne neden olabilecek bir hastalıktır. Hastalığın erken teşhisi için daha önce yapılan çalışmalar bulunmaktadır.

Yapılan bu çalışma Türkiye’de Sepsis hastalığının teşhisinin derin öğrenme yöntemiyle yapılması açısından bir ilktir. Sadi Konuk Eğitim Araştırma Hastanesi Yoğun Bakımı’ na Sepsis şüphesi ile gelen hastaların ilk 12 saatlik verileri kullanılarak Sepsis olup olmadıkları tahmin edilmeye çalışılmıştır.

18-60 yaş arasındaki 640 hastadan 216 hastaya Sepsis teşhisi konurken 424 hasta sağlıklıdır. Bu çalışmada derin sinir ağlarıyla Sepsis hastalığının tahmini için kullanılan modelde yeni bir hibrit meta-sezgisel algoritma önerilmiştir.

Derin sinir ağlarının parametrelerinin optimizasyonunda kullanılan gradyan tabanlı algoritmalar iyi sonuçlar ortaya koymamıştır. Bunun nedeni literatürde yapılan çalışmalarda yerel minimum değerinde takılı kalmasıdır. Gradyan tabanlı algoritmalar global minimuma ulaşmada başarısız sonuçlar ortaya koymuştur.

Son yıllarda meta-sezgisel algoritmalar popülasyona dayalı çözümler sürü zekası ve evrimsel yaklaşımla iyi sonuçlar ortaya koymuşlardır. Önerilen algoritma, İnsan zihinsel arama algoritmasının (HMS) zihinsel arama operatörünü kullanarak parçacık sürü optimizasyonundaki (PSO) parçacıkların lokal arama stratejisiyle global minimuma ulaşmasını amaçlamaktadır.

Bu çalışmada, İnsan zihinsel arama (HMS) ve parçacık sürü optimizasyonu (PSO) algoritmalarının avantajı göz önünde bulundurularak HMS-PSO adlı yeni bir hibrit algoritma sunulmuştur.

Önerilen algoritma, yerel minimumdan kaçmaya yol açan ve küresel minimumu elde etme şansı sağlayan keşfetme (exploration) ve sömürme (exploitation) işlemini dengelemeye çalışır. Ardından, HMS-PSO'nun performansını ölçmek için benchmark fonksiyonlarının üzerinde çalıştırarak HMS ve PSO ile karşılaştırılmıştır. Önerilen algoritmanın diğer algoritmalara göre daha güvenilir, daha dayanıklı ve daha esnek olduğu gösterilmiştir.

HMS-PSO, derin sinir ağları (HMS-PSO-DNN) ile entegre edilmiştir. Sepsis hastalığının tahmininde kullanılacak uygun sinir ağı mimarisinin seçilebilmesi ve sinir ağının hiper parametrelerinin belirlenebilmesi için örneklendirilmiş Sepsis veri seti kullanılmıştır. Önerilen mimarinin tahmin performansını ölçmek için gerçek veri setleri olan diyabet, kalp yetmezliği, kriyoterapi ve immunoterapi medikal veri setleri kullanılmıştır.

Sonuçlar, önerilen entegrasyon modelinin doğruluk, sağlamlık ve performans açısından diğer mevcut gradyan tabanlılar ve bahsi geçen meta-sezgisel algoritmalarından daha iyi performans gösterdiğini ortaya koymuştur. Entegre edilen algoritmanın güvenilirliği ispat edildikten sonra 18-60 yaş arasındaki 640 hastadan oluşan Sepsis veri seti kullanılarak Sepsis hastalığı tahmin edilmeye çalışılmıştır.

Dengeli veri seti oluşturmak, Sepsis veri kümesinde modelin tek bir sınıfı öğrenmesini önlemeye yardımcı olduğu için modelin eğitimini kolaylaştırır. Çalışmamızda bu öğrenme probleminin çözümüne yönelik veri seti dengelenmiştir.

Önerilen algoritma ve diğer algoritmaların dengeli veri seti tahmini için 2000 iterasyon ve 30 bağımsız çalışma süresindeki performansları karşılaştırılmıştır ve sonuçlar ortaya konmuştur.

Ayrıca önerilen algoritmanın performansını literatürdeki çalışmalar ile karşılaştırabilmek için ilk 6 saatlik Sepsis veri seti ile tahmin yapılmıştır. Elde edilen sonuçlar literatürdeki çalışmalardan doğruluk değeri açısından daha iyi sonuç vermiştir.

Name and Surname : Umut KAYA
Supervisor : Dr. Lecturer Atınc YILMAZ
Degree and Date : PhD., 2022
Major : Computer Engineer
Key Words : Sepsis, Deep Learning, Metaheuristic Algorithm, Optimization, Artificial Intelligence

ABSTRACT

SEPSİS DISEASE PREDICTION BY DEEP LEARNING

Sepsis is a disease that can lead to death of the patient if not diagnosed early. There are previous studies for the early diagnosis of the disease. This study is a first in Turkey in terms of diagnosis of Sepsis disease using deep learning method.

It was tried to predict whether they had Sepsis by using the data of the first 12 hours of the patients who came to the Sadi Konuk Training and Research Hospital Intensive Care Unit with the suspicion of Sepsis. Sepsis was diagnosed in 216 patients out of 640 patients between the ages of 18-60, while 424 patients were healthy.

In this study, a new hybrid metaheuristic algorithm is proposed in the model used for the prediction of Sepsis disease with deep neural networks. The gradient-based algorithms used in the optimization of the parameters of deep neural networks did not show proper results. The reason for this is that it is stuck at the local minimum value in the studies in the literature. Gradient-based algorithms have failed to reach the global minimum.

In recent years, meta-heuristic algorithms, population-based solutions, swarm intelligence and evolutionary approach have shown good results. The proposed algorithm aims to reach the global minimum of particles in particle swarm optimization (PSO) by using the mental search operator of the Human mental search algorithm (HMS) with the local search strategy.

In this study, a new hybrid algorithm named HMS-PSO is presented, taking into account the advantage of human mental search (HMS) and particle swarm optimization (PSO) algorithms. The proposed algorithm tries to balance the exploration and exploitation process, which leads to escaping the local minimum and provides a chance to obtain the global minimum.

Then, to measure the performance of HMS-PSO, it was compared with HMS and PSO by running on benchmark functions. It has been shown that the proposed algorithm is more reliable, more durable and more flexible than other algorithms.

HMS-PSO is integrated with deep neural networks (HMS-PSO-DNN). A sampled Sepsis dataset was used to select the appropriate neural network architecture to be used in the prediction of sepsis disease and to determine the hyperparameters of the neural network.

To measure the predictive performance of the proposed architecture, real datasets, diabetes, heart failure, cryotherapy and immunotherapy medical datasets were used.

The results demonstrated that the proposed integration model outperforms other existing gradient-based and aforementioned meta-heuristic algorithms in terms of accuracy, robustness, and performance. After the reliability of the integrated algorithm was proven, Sepsis disease was tried to be predicted using the Sepsis data set consisting of 640 patients between the ages of 18-60.

Providing a balanced dataset simplifies the training of the model as it helps prevent the model from learning a single class in the Sepsis dataset. In our study, the data set for the solution of this learning problem was balanced.

The performances of the proposed algorithm and other algorithms for balanced data set estimation in 2000 iterations and 30 independent run times are compared and the results are presented. In addition, in order to compare the performance of the proposed algorithm with the studies in the literature, the first 6-hour Sepsis data set was estimated.

The results obtained gave better results in terms of accuracy than the studies in the literature.

İÇİNDEKİLER

Sayfa No.

ÖZ

ABSTRACT

TABLolar LİSTESİ..... iv

ŞEKİLLER LİSTESİ..... v

SÖZLÜK vi

GİRİŞ..... 1

BİRİNCİ BÖLÜM

SEPSİS HASTALIĞININ TAHMİNİ

1. SEPSİS İLE İLGİLİ LİTERATÜRDE YAPILAN ÇALIŞMALAR..... 2

1.1. Sepsis Tahmininde Kullanılan Yöntemler..... 3

İKİNCİ BÖLÜM

METASEZGİSEL ALGORİTMALAR

1. METASEZGİSEL ALGORİTMALAR VE KULLANIM ALANLARI..... 8

1.1. Metasezgisel Algoritmalar..... 8

1.2. Parçacık Sürü Optimizasyonu Algoritması (PSO) 12

1.3. İnsan Zihinsel Arama Algoritması (HMS) 14

1.4. Hibrit Metasezgisel Algoritmalar 17

2. ZİHİNSEL ARAMA TEMELLİ PARÇACIK SÜRÜ OPTİMİZASYONU (HMS-PSO) ALGORİTMASI..... 19

2.1. Zihinsel Arama Temelli Parçacık Sürü Optimizasyonu Algoritması (HMS-PSO)

Yaklaşımı 19

2.2. HMS-PSO Algoritmasının İspatı..... 22

2.3. HMS-PSO Algoritmasının Kalite Testi Fonksiyonları Kullanılarak PSO ve HMS

Algoritmaları ile Karşılaştırılması..... 24

ÜÇÜNCÜ BÖLÜM

YAPAY SİNİR AĞLARI VE DERİN SİNİR AĞLARI

1. YAPAY SİNİR AĞLARI..... 30

1.1. Yapay Sinir Ağları ve Kullanım Alanları..... 30

1.2. Yapay Sinir Ağlarının Optimizasyonunda Kullanılan Metasezgisel Algoritmalar 37

2. DERİN SİNİR AĞLARI	40
2.1. Derin Sinir Ağları ve Kullanım Alanları	40
2.2. Derin Sinir Ağı Mimarileri	44
2.2.1. Derin İleri Beslemeli Sinir Ağı	44
2.2.2. Yinelemeli Sinir Ağları.....	45
2.2.3. Uzun Kısa Süreli Bellek.....	46
2.2.4. Oto-Kodlayıcı	47
2.2.5. Derin İnanç Ağları	48
2.2.6. Derin Evrişimli Sinir Ağı.....	49

DÖRDÜNCÜ BÖLÜM

ÖNERİLEN DERİN SİNİR AĞI MODELİ VE DEĞERLENDİRİLMESİ

1. ÖNERİLEN DERİN SİNİR AĞI MODELİ	52
1.1. Önerilen Derin Sinir Ağı Modelinin Oluşturulması	52
2. VERİ SETİ	54
2.1. Veri Setinin Oluşturulması	54
3. BULGULAR VE TARTIŞMA	55
3.1. Performans Kriterleri	55
3.1.1. Doğruluk(Accuracy)	55
3.1.2. Ortalama Mutlak Hata (MAE)	55
3.1.3. Ortalama Karesel Hata (MSE)	55
3.1.4. Kök Ortalama Karesel Hata (RMSE)	56
3.1.5. Karmaşıklık Matrisi (CM)	56
3.1.6. Kesinlik (Precision).....	57
3.1.7. Duyarlılık(Recall)	57
3.1.8. F1 Puanı(F1-Score).....	57
3.1.9. Destek(Support)	58
3.1.10. R-Kare (R-Squared)	58
3.1.11. Alıcı Çalışma Karakteristik Eğrisi (ROC)	58
3.1.12. Eğri Altında Kalan Alan(AUC)	58
3.1.13. Standart Sapma	59
3.1.14. Varyans	59
3.2. Benchmark Veri Setleri Sonuçları	59
4. SEPSİS TAHMİNİ SONUÇLARI	63

4.1. Sepsis Tahmininde Kullanılan Algoritmaların Performans Sonuçları	63
SONUÇ VE ÖNERİLER.....	73
KAYNAKÇA	74



TABLolar LİSTESİ

Sayfa No.

Tablo 1. Tek Modlu Kalite Testi Fonksiyonları	23
Tablo 2. Çok Modlu Kalite Testi Fonksiyonları.....	23
Tablo 3. Sabit Boyutlu Çok Modlu Kalite Testi Fonksiyonları	23
Tablo 4. HMS-PSO, PSO ve HMS' ye Ait Tek Modlu Kalite Testi Fonksiyonları Sonuçları	24
Tablo 5. PSO_HMS, PSO ve HMS' ye Ait Çok Modlu Kalite Testi Fonksiyonları Sonuçları	26
Tablo 6. HMS-PSO, PSO ve HMS' ye Ait Sabit Boyutlu Çok Modlu Kalite Testi Fonksiyonları Sonuçları	27
Tablo 7. Diğer Kalite Test Fonksiyonlarında HMS-PSO, PSO ve HMS' ye Ait Kalite Testi Sonuçları	28
Tablo 8. Ağ modelleri.....	53
Tablo 9. HMS-PSO-DNN Kalp Yetmezliği Veri Setindeki Performansı	60
Tablo 10. Algoritmaların Kalp Yetmezliği Veri Setindeki Performansları.....	60
Tablo 11. HMS-PSO-DNN Algoritmasının Diyabet Veri Seti Performansı.....	61
Tablo 12. Algoritmaların Diyabet Veri Seti Performans Ortalaması	61
Tablo 13. HMS-PSO-DNN Algoritmasının Kriyoterapi Veri Seti Performansı.....	62
Tablo 14. Algoritmaların Kriyoterapi Veri Seti Performans Ortalamaları.....	62
Tablo 15. HMS-PSO-DNN Algoritmasının İmmunoterapi Veri Seti Performans Sonuçları..	63
Tablo 17. Sepsis tahmini için kullanılan optimizasyon algoritmalarının MSE performansı...	64
Tablo 18. Sepsis Tahmini İçin Kullanılan Optimizasyon Algoritmalarının RMSE Performansı	65
Tablo 19. Optimizasyon Algoritmalarının Sepsis Tahminindeki MSE Performans Ölçümleri.....	66
Tablo 20. Optimizasyon Algoritmalarının Sepsis Tahminindeki RMSE Performans Ölçümleri.....	67
Tablo 21. HMS-PSO-DNN Algoritması Dengeli Veri Seti Sonuçları	68
Tablo 22. Algoritmaların Sepsis Tahmini Performansının Karşılaştırılması	69
Tablo 23. HMS-PSO-DNN İlk 6 Saatlik Veriler İle Tahmin Sonucu	70
Tablo 24. HMS-PSO-DNN İlk 6 Saatlik Veriler İle Tahmin Sonucu Ortalaması	70

ŞEKİLLER LİSTESİ

Sayfa No.

Şekil 1. PSO algoritmasının kaba kodu	13
Şekil 2. HMS algoritmasının kaba kodu	16
Şekil 3. HMS-PSO Algoritmasının Kaba Kodu.....	22
Şekil 4. Tek Girdili Nöron	31
Şekil 5. Lineer ve Lineer Olmayan Transfer Fonksiyonu.....	31
Şekil 6. Sabit Limitli Tek Girdili Sabit Limitli Nöronu.....	32
Şekil 7. Logsig transfer fonksiyonu	32
Şekil 8. Çok Girdili Nöron.....	33
Şekil 9. Çok Girdili Nöron İle Ağırlık ve Bias Yanlılık Toplamı.....	33
Şekil 10. S Adet Nöronlu Katman	34
Şekil 11. Girdileri Ağırlıklandırılmış S Nöronlu Katman.....	34
Şekil 12. 3 Katmanlı Ağ Yapısı	35
Şekil 13. Derin İleri Beslemeli Sinir Ağı Mimarisi	44
Şekil 14. Yinelemeli Sinir Ağı Mimarisi	46
Şekil 15. Uzun Kısa Süreli Bellek Ağ Mimarisi.....	47
Şekil 16. Oto-Kodlayıcı Ağ Mimarisi.....	48
Şekil 17. Derin İnanç Ağı Mimarisi.....	49
Şekil 18. Derin Evrişimli Sinir Ağı Mimarisi	51
Şekil 19. HMS-PSO Tarafından Optimize Edilmiş DNN Akış Şeması	52
Şekil 20. HMS-PSO Algoritması İle Ağırlıkları Optimize Edilmiş Derin Sinir Ağı Mimarisi(HMS-PSO-DNN).....	54
Şekil 21. Karmaşıklık Matrisi	57
Şekil 22. Sepsis Veri Seti Optimizasyon Algoritmaları MSE Performansı.....	66
Şekil 23. Sepsis Veri Seti Optimizasyon Algoritmaları RMSE Performansı	67
Şekil 24. HMS-PSO-DNN Dengeli Veri Seti AUC Sonucu.....	69
Şekil 25. HMS-PSO-DNN İlk 6 Saatlik Verilerdeki En İyi AUC	70
Şekil 26. HMS-PSO-DNN algoritması Doğrulama veri seti doğruluk ve kesinlik	71
Şekil 27. HMS-PSO-DNN Algoritması Doğrulama Veri Seti AUC Ve MSE Sonuçları	71
Şekil 28. HMS-PSO-DNN Doğrululuk Ve Kesinlik Performansı Sonuçları.....	72
Şekil 29. HMS-PSO-DNN Algoritması En İyi MSE Ve AUC Sonucu.....	72

SÖZLÜK

Derin Sinir Ağı: İki den fazla gizli katmana sahip Yapay Sinir Ağı'na denir.

Metasezgisel Algoritma: Optimizasyon problemlerinin çözümünde kullanılan algoritmalara denir.

Sepsis: Halk arasında kan zehirlenmesi olarak da bilinen bir hastalık türü.

Yapay Sinir Ağı: İnsan beynindeki bilgi akışının yapay nöronlar kullanılarak taklit edilmesine dayanan bir makine öğrenmesi yöntemlerindedir.



GİRİŞ

Sinir ağı parametrelerini ayarlamak için farklı optimizasyon stratejileri kullanılmaktadır. Gradyan tabanlı algoritmalar, arama probleminin yerel minimumlarında sıkışıp kaldığı ve fazla uydurma sorunlarına yol açmaktadırlar.

Bununla birlikte, son yıllarda sinir ağlarının parametrelerini optimize etmek için Metasezgisel algoritmalar yaygın olarak kullanılmaktadır. Parametreler bir optimizasyon problemi olarak tanımlanabilir.

Bu çalışmada, derin sinir ağlarının ağırlıklarının optimizasyon problemine odaklanılmaktadır. İnsan Zihinsel Arama (HMS) ve Parçacık Sürü Optimizasyonu (PSO) algoritmalarının avantajları dikkate alınarak HMS-PSO olarak adlandırılan yeni bir hibrit algoritma önerilmektedir.

Önerilen algoritma, yerel minimumdan kaçmaya yol açan ve küresel minimumu elde etme şansı sağlayan keşfetme ve sömürme işlemi dengelemeye çalışmaktadır. Kalite testi fonksiyonları kullanılarak, HMS-PSO' nun performansı HMS ve PSO algoritmaları ile karşılaştırılmaktadır. HMS-PSO algoritması Derin Sinir Ağı(DNN)' na entegre edilerek yeni bir Derin Sinir Ağı Mimarisi oluşturulmuştur.

Oluşturulan HMS-PSO-DNN mimarisinin performansını bahsedilen algoritmalar ile karşılaştırmak için benchmark veri setleri ile kullanılmaktadır. Önerilen modelin doğruluk, sağlamlık ve performans açısından diğer algoritmalarından daha iyi performans gösterdiği görülmektedir.

Önerilen model, Sadi Konuk Eğitim ve Araştırma Hastanesi yoğun bakım ünitesinde yatan hastaların semptomlarından alınan ve hastaların ilk 12 saatteki durumlarını dikkate alan gerçek bir veri setine uygulanmıştır.

Deneysel sonuçlar, HMS-PSO-DNN algoritmasının Sepsis hastalığının tahmininde diğer modeller ile doğruluk, kesinlik ve duyarlılık performans kriterleri açısından başarısını ortaya koymaktadır.

BİRİNCİ BÖLÜM

SEPSİS HASTALIĞININ TAHMİNİ

1. SEPSİS İLE İLGİLİ LİTERATÜRDE YAPILAN ÇALIŞMALAR

Sepsis, her yıl dünyada en az 26 milyon insanın etkilendiği ve enfeksiyon sonucu ortaya çıkan kişinin ölümüne neden olabilecek bir hastalıktır. Her 100.000 kişiden 149-240'nun Sepsis olduğu ve teşhis konulan hastaların % 30'nun da bu hastalıktan öldüğü bilinmektedir. Enfeksiyonun varlığı Sepsis tanısında önemli bir yer tutmaktadır.

Yeni antibiyotik tedavisi, akciğerlerde enfeksiyon olması, bakteri taraması esnasında kan kültüründe bakteri üremesi ya da bakteri enfeksiyonu saptanması, karın içi enfeksiyonun oluşması ve diğer enfeksiyonların araştırılması hastaya Sepsis tanısı konulmasına sebep olan etkenlerdir. Hızlı SOFA (QSOFA) kriterleri göz önünde bulundurularak hastadaki enfeksiyon belirlenmektedir.

QSOFA, hastanın bir dakikadaki soluk alıp verme sayısı, mental durumundaki değişiklik ve sistolik kan basıncı değerleri kullanılarak oluşturulan bir skorlama sistemidir. QSOFA skoru 2 ya da daha büyük ise, hastada Sepsis şüphesi oluşmaktadır. Sepsis tanısı ve Sepsis' in ciddiyetini belirlemek için başka bir değerlendirme ölçütü olan Sepsis' e bağlı organ yetmezliği değerlendirmesi (SOFA) kullanılmaktadır.

SOFA skoru, hastanın kanındaki pıhtılaşma düzeyi, karaciğer fonksiyonlarının değerlendirilmesi, kardiyovasküler sisteminin değerlendirilmesi, beyin ve böbrek fonksiyonlarının değerlendirilmesinden oluşmaktadır.

SOFA skorunun düşük olması hastanın durumunda olumlu bir gelişme olarak görülürken, SOFA skorunun yükselmesi doktorlar tarafından hastanın ölüme yakın olduğu şeklinde ifade edilir (Büke 2015), (Aydın 2002), (Angus ve ark. 2001), (Carcillo 2002).

Amerikan Tabipler Birliği tarafından Sepsis ve Septik Şok tanımları 2016 yılında yeniden düzenlenmiştir (Singer 2005). Yapılan yeni düzenlemede Bone ve arkadaşlarının yapmış olduğu tanımlar da kullanılmıştır (Bone ve ark. 1992).

Belirlenen yeni SIRS kriterlerine göre aşağıdaki durumlardan iki ya da daha fazlasının hastada görülmesi SIRS sendromunun ortaya çıkmasına ve hastaya SIRS tanısı konulmasına sebep olmaktadır (Singer ve ark. 2016):

1. Vücut ısısının 36 dereceden daha düşük ya da 38 dereceden daha yüksek olması.

2. Hastanın dakikada kalp atış sayısının 90'dan fazla olması
3. Hastanın 1 dakikadaki soluk alıp verme sayısının 20'den fazla olması
4. Hastanın 1 milimetre küp kanındaki lökosit sayısının 12.000'den fazla ya da 4000'den az olması
5. Hastanın 1 milimetre küp kanında immatür nötrofil sayısının % 10'dan fazla olması.

Sepsis, fark edilmediği ya da tedavisine başlanılmadığı takdirde enfeksiyona bağlı ölümlerin birincil sebebidir ve acil müdahale gerektiren bir durumdur. Patojenik faktörler ve zamanla gelişen konak faktörleri tarafından şekillendirilen bir sendromdur.

Enfeksiyondan farklı olarak Sepsis, anormal ya da düzensiz konak yanıtına ve organ yetmezliğine sebep olur. Enfeksiyonu olan bir hastada Sepsis' in varlığının gizli organ yetmezliğine sebep olabileceği göz önünde bulundurularak, Sepsis olup olmadığı araştırılmalıdır. Bilinmeyen bir enfeksiyon da organ yetmezliğine sebep olabilmektedir.

Herhangi bir organdaki sebebi açıklanamayan bozukluğa enfeksiyonun neden olma ihtimali yüksektir. Akut hastalık, uzun süreli devam eden başka bir hastalık, alınan ilaçlar ve yapılan müdahaleler Sepsis' in klinik ve biyolojik fenotipinde değişikliğe neden olabilmektedir.

Sepsis ve septik şok hastalarını belirlemek için SOFA ve QSOFA kriterleri kullanılmaktadır (Singer ve ark. 2016).

Tıp alanında Yapay Zekâ yöntemlerinin kullanımının, hastalıkların erken teşhisine ve tedavisine sağladığı katkı, akciğer kanseri risk analizinin ve kardiyovasküler hastalık riskinin Yapay Sinir Ağları ile tahminiyle görülebilmektedir (Adetiba ve Olugbara 2015), (Liu ve ark. 2013).

Kanser vakalarında sıklıkla Sepsis görülmekte ve Türkiye' deki yoğun bakımdaki hastaların ölümüne sebep olmaktadır. Sepsis hastalığının Yapay Sinir Ağları ile tahminindeki amaç, doktorlara hastalığın tedavisinde yardımcı olmak ve bu hastalığın neden olduğu ölümlerin sayısını azaltmaktır.

1.1. Sepsis Tahmininde Kullanılan Yöntemler

Bu bölümde Sepsis tahmininde kullanılan makine öğrenmesi ve derin öğrenme yöntemlerinden bahsedilmiştir.

Parente ve arkadaşları, biyo-etiketleme sınıflandırıcılarını kullanarak daha hızlı ve daha doğru bir Sepsis tahmini yapmayı amaçlamışlar ve kullandıkları yöntemin faydalı olduğunu ortaya koymuşlardır (Parente ve ark. 2010).

Ongenaes ve arkadaşları, tıbbi veri tabanına eklenen zaman serisi verilerinin otomatik olarak sınıflandırılması için makine öğrenmesi yöntemlerini kullanmışlar ve klinik bozulmayı gösteren bir komplikasyonu belirlemeye çalışmışlardır (Ongenaes ve ark. 2010).

Baldini ve arkadaşları, yatağa konulan cihazlarda biyo-belirteçleri kullanarak anlık Sepsis teşhisi yapmayı amaçlamışlar ve entegre ya da taşınabilir bir cihazın Sepsis analizinde çok kısa zamanda daha iyi sonuçlar verdiğini belirtmişlerdir (Baldini ve ark. 2011).

Ward ve arkadaşları, Sepsis ile enfekte olmayan sistemik inflamatuvar yanıt sendromunu (SIRS) ayırmak ve SIRS şiddetini belirlemek için makine öğrenmesi yöntemlerinden yararlanmışlardır. Oluşturdukları öğrenme modelinin, 30 günlük ölüm oranını tahmin etmede ve Sepsis ile SIRS' ı ayırmada başarılı olduğunu ifade etmişlerdir (Ward ve ark. 2017).

Danner ve arkadaşları 53313 acil hastasının verileri üzerinde Sepsis tahmini yapmak için makine öğrenmesi yöntemlerini kullanmışlardır. Kalp atış hızı, nabız ve sıcaklık değişkenlerinin erken Sepsis tahmininde öncelikli belirleyiciler olduğu sonucuna varmışlardır (Danner ve ark. 2017).

Calvert ve arkadaşları, yüksek performanslı Sepsis tahmini için makine öğrenmesi yöntemlerinden faydalanmışlardır. Erken Sepsis uyarı algoritması geliştirerek, hastanın ilk beş saatlik SIRS evresinden üç saat önceye kadar Sepsis tahmini yapmışlardır. Önerdikleri algoritmanın mevcut uygulamalardan daha iyi sonuç verdiğini iddia etmişlerdir (Calvert 2016).

Saraiva ve arkadaşları, Sepsis teşhisi için geliştirdikleri Destekli Vektör Makinesi sınıflandırıcı tabanlı programın biyo-belirteçlerin öngörü başarısını arttırdığını söylemişlerdir (Saraiva 2016). Morales ve arkadaşları, Sepsis tanımındaki değişiklikleri doğrulamak için koşullu bağımsız haritalama yöntemini kullanmışlardır. Sepsis tanısında SIRS' in önemini vurgulamışlardır (Morales ve ark. 2016).

Vieira ve arkadaşları, Sepsis tahmini için PSO ile birlikte çalışan makine öğrenmesi yöntemlerini kullanarak özellik seçimi problemini çözmeye çalışmışlardır. Önerdikleri

yöntemin, daha düşük çalışma süresi ve daha az öznitelikle daha iyi sonuçlar verdiğini gözlemlemişlerdir (Vieira ve ark. 2012).

Bui ve arkadaşları, hastaların uzaktan takibi için sıcaklık sensörleri gibi yüksek frekanslı cihazları kullanarak Sepsis' in erken teşhisini amaçlamışlardır (Bui ve ark. 2016).

Guillen ve arkadaşları, şiddetli Sepsis tahmini için makine öğrenmesi yöntemlerini kullanmışlardır (Guillen ve ark. 2015).

Ghalwash ve arkadaşları, Sepsis erken tanısı ve kan temizleme ile Sepsis tedavisi için makine öğrenmesi yöntemlerini örüntü tanıma problemine uygulamışlardır. Geliştirdikleri yöntemin, Septik hastaların erken teşhisinde ve tedavisinde mevcut yöntemlerden daha iyi performans gösterdiğini gözlemlemişlerdir (Ghalwash ve ark. 2013).

Ghasemi ve Raoufy, yoğun bakım ünitesindeki Sepsis hastalarının hayatta kalan ve ölenlerin son 25 saatlik kalp hızı dinamiklerini zaman serisi yöntemini kullanarak karşılaştırmışlardır (Ghasemi ve ark. 2016).

Jiang ve arkadaşları, Sepsis evrelerinin belirlenmesi için dinamik Bayes Ağ modelini kullanmışlardır (Jiang ve ark. 2016).

Mitchell ve arkadaşları, Virginia Tıp Merkezi'ndeki hasta kabullerinden elde ettikleri verileri yeni Sepsis tanımı ile ilişkilendirerek, Sepsis başlangıcından 12-24 saat önce risk altındaki servis hastalarında Sepsis' in erken tespitini lojistik regresyon ile yapmaya çalışmışlardır (Mitchell ve ark. 2016).

Gunnarsdottir ve arkadaşları, yoğun bakımdaki hastaların Sepsis sınıflandırması için demografik bir model önermişlerdir (Gunnarsdottir ve ark. 2016).

Marshall ve arkadaşları, makine öğrenmesi yöntemlerini kullanarak bebeklerdeki Sepsis sağkalım bileşenlerini sınıflandırmak ve hastanede kalış sürelerini tahmin etmek için kullanmışlardır (Marshall ve ark. 2012).

Stanculescu ve arkadaşları, yeni doğan Sepsis' inin erken tespiti için makine öğrenmesi yöntemlerini kullanarak oluşturdukları modelin, gerçek zamanlı tahminler yapabildiğini ve eksik verilerle çalışabildiğini belirtmişlerdir (Stanculescu ve ark. 2014).

Moutzouri ve arkadaşları, diyabetin Sepsis hastalığına etkisini araştırdıkları çalışmalarında makine öğrenmesi yöntemlerini kullanmışlardır (Moutzouri ve ark. 2008).

Gültepe ve arkadaşları, Sepsis hastalığının erken teşhisi için arteriyel basınç ve laktat düzeyi kriterlerini kullanarak, Sepsis belirtileri gösteren hastaların özelliklerini belirlemek kümele analizinde Bayes Ağları' nı kullanmışlardır (Gültepe ve ark. 2012).

Yanes ve arkadaşları, tip 2 diyabetli hastaların Sepsis mortalitesini tahmin için istatistiksel analiz yöntemlerini uygulamışlardır (Yanes ve ark. 2015). Schuh, yoğun bakımdaki kalp ve göğüs hastalarının Sepsis ve Sepsis şok analizini Yapay Sinir Ağlarını kullanarak gerçekleştirmiştir (Schuh 2007).

Saqip ve arkadaşları, makine öğrenmesi yöntemleri ile derin öğrenme yöntemlerinden olan LSTM ağlarının Sepsis tahmini performansını karşılaştırmak için hastaların ilk 24 ile 36 saatlik yaşamsal bulgularını ve laboratuvar sonuçlarını kullanmışlardır (Saqip ve ark. 2018).

Zhang ve arkadaşları, Sepsis mortalite tahmini için, Oto-Kodlayıcı ve K-Ortalamları Kümeleme yöntemlerinden oluşan gen sınıfı tahmin modelini geliştirmişlerdir. Önerdikleri modelin, Sepsis mortalitesinin tahmininde Apache II skoruna eşdeğer bir performans gösterdiğini belirtmişlerdir (Zhang ve ark. 2020).

Perng ve arkadaşları, septik hastaların mortalitesini tahmin için Evrişimli Sinir Ağlarını kullanmışlardır (Perng ve ark. 2019).

Rodriguez ve arkadaşları, acil servislerde Sepsis tanısı ile hastaneye yatırılan hastaların mortalite tahmini için makine öğrenmesi ve derin öğrenme yöntemlerini karşılaştırmışlardır (Rodriguez ve ark. 2020).

Rafiei ve arkadaşları, yoğun bakıma ünitesindeki hastaların Sepsis başlangıcını tahmin etmek için LSTM ve Evrişimli Sinir Ağları' ndan oluşan bir mimari tasarlamışlardır (Rafiei ve ark. 2020).

Wernly ve arkadaşları, yoğun bakım ünitesindeki hastaların hastaneye kabulden sonraki 96 saat içindeki ölüm oranını tahmin etmek için Derin Sinir Ağları yöntemini kullanmışlardır (Wernly ve ark. 2021).

Meiring ve arkadaşları, yoğun bakımdaki hastaların Sepsis mortalite tahmini için makine öğrenmesi ve derin öğrenme yöntemlerini mevcut risk sınıflandırma araçları ile karşılaştırmışlardır (Meiring ve ark. 2018).

Kamal ve arkadaşları Sepsis' in başlangıcının ve mortalitesinin tahmini için, öz-dikkat ağırlıklarını analiz eden Değer Katmanlı bir derin öğrenme modeli önermişler ve önerdikleri

modelin ölüm ile ilgili anlamlı tıbbi vaka kalıpları ürettiğini belirtmişlerdir (Kamal ve ark. 2020).

Bedoya ve arkadaşları, Tekrarlayan Sinir Ağları ve Çok Değişkenli Gauss sürecini kullanarak bir derin öğrenme modeli geliştirmişlerdir. Önerdikleri modelin Sepsis hastalığını ortalama 5 saat önceden tespit ettiğini yaptıkları deneylerle göstermişlerdir (Bedoya ve ark. 2020).

Parreco ve arkadaşları, yoğun bakımdaki hastaların mortalite tahmini için derin öğrenme temelli sınıflandırıcılar ile farklı algoritmalara sahip sınıflandırıcıları karşılaştırmışlardır (Parreco ve ark. 2018).

Ahmed ve arkadaşları, yoğun bakım ünitesine kabul edilen hastalarda Sepsis mortalite tahmini için Derin Sinir Ağı ve makine öğrenmesi yöntemlerini kullanmışlardır (Ahmet ve ark. 2020).

Zhang ve arkadaşları, acil servisteki hastaların teşhisten 4 saat önceki Sepsis başlangıcını tahmin etmek için klinik zaman serilerini modelleyen ve tahmin performansını arttıran LSTM tabanlı bir model önermişlerdir (Zhang ve ark. 2021).

Wickramaratne ve arkadaşları, hastaların yaşamsal değerleri, laboratuvar sonuçları ve demografik özelliklerini kullanarak çift yönlü tekrarlayan birimleri kullanan bir derin öğrenme modeli önermişlerdir. Geliştirdikleri modelin Sepsis başlangıcını 6 saat önceden tahmin etmede başarılı olduğunu belirtmişlerdir (Wickramaratne ve ark. 2020).

Tang ve arkadaşları, alüminyum tozu patlaması sırasında yaralanan ve ciddi derecede yanıkları olan hastalarda akut böbrek hasarının risk tahmin modelini oluşturarak Sepsis tahmini yapmak için makine öğrenmesi yöntemlerini kullanmışlardır (Tang ve ark. 2018).

Shashikumar ve arkadaşları, erken Sepsis tahmini için tekrarlayan sinir ağlarını kullanarak Derin Yapay Zekâ Sepsis Uzmanı modelini önermişlerdir (Shashikumar ve ark. 2021).

İKİNCİ BÖLÜM

METASEZGİSEL ALGORİTMALAR

1. METASEZGİSEL ALGORİTMALAR VE KULLANIM ALANLARI

1.1. Metasezgisel Algoritmalar

Bu bölümde Metasezgisel algoritmalar ve bunların kullanım alanlarından bahsedilmiştir.

Optimizasyon, bir arama uzayında en uygun çözümü arama işlemi olarak tanımlanmaktadır. Analitik, sayma ve sezgisel arama teknikleri optimizasyonda kullanılan tekniklerdir. Arama algoritmaları gradyan ya da ikinci dereceden kısmi türev ile yönlendirilebildiğinden yerel minimumda takılı kalma problemine sebep olmaktadır.

Bununla birlikte Analitik arama hesaplama temellidir. Sayma ve rastgele arama yönlendirilmeyen arama metotları olup, arama uzayını basit bir şekilde sayan ve etraflıca arama yaparak optimal çözüme ulaşan yöntemlerdir. Sezgisel arama, genellikle yüksek performanslı çözümler üreten güdümlü bir aramadır.

Karmaşık ortamlara uyum sağlama mekanizmasını araştıran hesaplamalı zekâ yapay zekânın bir alanıdır. Yapay zekâ insan tecrübesinden bilgi edinirken, hesaplamalı zekâ eldeki sayısal verilerden bilgi çıkarımını gerçekleştirmektedir. Hesaplamalı zekâ doğadan ilham alan bir dizi hesaplama paradigmasını içermektedir.

Sinir ağları ile örüntü tanıma, bulanık sistemler ile belirsizlik içeren durumlarda karar verme ve stokastik optimizasyon araması için evrimsel hesaplama, hesaplamalı zekânın temel konularındandır. Bir boyuttaki fonksiyonun türevinin birden fazla boyuttaki bir fonksiyona genelleştirilmesi olan gradyan, fonksiyonun en büyük artış hızı yönüne işaret eder ve büyüklüğü grafiğin o yöndeki tanjantının eğimidir.

Artan bir fonksiyonu temsil etmek için pozitif gradyan kullanılırken, azalan bir fonksiyonu belirtmek için negatif gradyan ifadesi kullanılır. Eğrinin düz olduğu durumda gradyan sıfırdır. Gradyanın sıfır olduğu nokta durağan nokta ya da aşırı nokta olarak tanımlanır. Optimum çözüm için uç noktalara ihtiyaç vardır (Du ve Swamy 2016).

Sürekli ve türevlenebilir fonksiyonların optimum çözümünü bulmak için klasik optimizasyon yöntemleri kullanılabilir. Analitik olan bu yöntemler diferansiyel hesaplama metotlarını kullanarak optimum noktaların bulunmasını sağlar. Ancak sürekli ve

türevlenebilir olmayan nesnel fonksiyonları içeren bazı problemlerde klasik optimizasyon yöntemlerinin kapsamının sınırlı olduğu bilinmektedir (Rao 2009).

GA'lar, fonksiyonları optimize ederek biyolojik süreçleri kopyalayan basit algoritmalarıdır. GA'da kullanılan parametrelerin çoğu kromozomu temsil ederken, kalan parametreler genleri gösterir. GA'nın faydaları şu şekilde özetlenebilir:

- a) Hem sürekli hem de ayrık parametreleri optimize edebilir.
- b) Herhangi bir türev verisi gerektirmez.
- c) Amaç fonksiyonunu incelemek için geniş bir arama uzayını keşfedebilir.
- d) Birçok faktöre uyarlanabilir.
- f) Aynı anda çalışabilir.
- f) Karmaşık amaç fonksiyonunun parametrelerini, kendisini yerel minimum ve maksimuma bağlamadan optimize etme yeteneğine sahiptir.
- g) Birden fazla çözüm gerektiğinde optimal çözümlerin elde edilmesini sağlar.

GA'lar, optimizasyon ve arama ile ilgili sorunları çözme teknikleridir. GA'lar, diğer algoritmaların aksine hesaba en iyiyi seçmek için zaman sınırlaması uygulayan en yakın yöntemlerden biridir.

GA'lar, herhangi bir ön bilgiye sahip olmadan olayları ve bilgileri öğrenebilir ve toplayabilir, bu da onların çevreye uyum sağlamalarına olanak tanır. GA kullanarak çok parametrelili, doğrusal olmayan problemlerin çözümü için geleneksel yaklaşımlardan daha iyi sonuçlar elde etmek mümkündür.

İlk olarak GA aracılığıyla rastgele bir popülasyon oluşturulur. Sonra birkaç ek popülasyon görünmeye başlar. Algoritma, her aşamada mevcut neslin üyelerini kullanır. En iyi uygunluk değerine ulaşıldığında algoritma sonlandırılır. Uygunluk ölçeğine göre, seçim sonraki neslin ebeveynleri için geçerlidir.

Algoritma, mevcut neslin birkaç üyesinden vektör girdileri veya genler seçerek çapraz çocuklar oluşturur. Bir çocuk yaratmak için bir kişi değiştirilir. Sistem, çaprazlama sayesinde birkaç kişiden en iyi genleri çıkarabilir. Nüfus çeşitliliği mutasyondan etkilenir. En iyi uygunluk göstergelerine sahip en iyi kişiler belirlenene kadar süreç tekrarlanır (Nanda ve Panda 2014).

Sayısal optimizasyon problemlerinin çözümünde kullanılmak üzere geliştirilen Evrimsel Strateji Algoritması, ayrık optimizasyon problemlerinin çözümünde de kullanılmaktadır. Kodlamaya ya da kod çözümüne gereksinim duymayan Evrimsel Strateji Algoritmasında hedef, parametreler ve strateji parametreleri düzenli sayısal gösterim kullanılarak doğrudan kromozoma kodlanmaktadır.

Sonlu bir alfabede dizi sembolü olarak kodlanan ortamdaki değişiklikleri tahmin etmek için her kromozomun bir sonlu durum makinesi olarak kodlanarak geliştirilmiştir. Bu yaklaşım geliştirilerek, sayısal Gauss yaklaşımına dayalı optimizasyon problemlerinin çözümünde de kullanılmaya başlanmıştır (Du ve Swamy 2016).

Diferansiyel Evrim Algoritması, çok ebeveynli üreme stratejisi ile yeni aday çözümler ortaya koyan, her bireyin yavruları arasına karşılık seçim ve üreme ilişkisini kullanan bir algoritmadır. Çok ebeveynli üreme stratejisi nedeniyle biyolojik olarak uygun değildir.

Evrimsel Algoritmalarından farklı olarak Diferansiyel Evrim Algoritması, varyantları rastgele seçilen ve farklı popülasyon üyelerinin ölçeklenmiş farklılıklarıyla mevcut nesildeki popülasyon üyelerini rahatsız etmektedir. Bu yüzden mevcut deneme çözümlerini değiştirmek için Nelder-Mead algoritmasına ve kontrollü rastgele arama algoritmasına ihtiyaç duymaktadır.

Adayın bir ebeveynin yerini alabilmesi için daha hareketli olması gerekir. Doğruluk, yakınsama hızı ve dayanıklılık performansı açısından Diferansiyel Evrim Algoritması gerçek dünya problemlerinin çözümünde tercih edilmektedir (Du ve Swamy 2016).

Yapay Bağışıklık Sistemi, biyolojik olarak bağışıklık sisteminden esinlenilerek oluşturulmuştur. Vücuttaki savunma mekanizmaları topluluğu olan bağışıklık sistemi, vücuda giren patojenleri ve kötü huylu hücreleri tespit ederek, bunları tanımlayarak ve yok ederek vücudu hastalıklardan korumaktadır.

Sistem konakçı organizmanın kendi molekülleri ve patojenik moleküller arasında ayırım yapar. Bağışıklık çeşitliliğini arttırmak ve korumak için doğal mekanizmaları barındırır. Omurgalı canlılardaki bağışıklık sistemleri, patojen olarak isimlendirilen virüs, zararlı bakteri, parazit ve mantar gibi yabancı maddelerin saldırısına karşı vücudu korur ve bozulmuş hücreleri vücuttan temizler.

Bağışıklık sistemi önceden karşılaşılan patojenlerin hafızasına sahiptir. Vücuda ait olmayan hücreleri ortadan kaldırarak, patojenleri hafızasına depolayarak vücudu dış

zararlılardan korur. Bağışıklık sistemi kendi kendine organize olan ve dağıtılmış bir yapıya sahiptir (Du ve Swamy 2016).

Karınca ve termitler, aynı sosyal yapıya sahip olan, genellikle bir ya da birden fazla üreme yeteneğine sahip bireyin yavruları olan kastlardaki kısır işçilerden oluşan kalabalık kolonilerdir. Bu koloniler koordineli bir şekilde hedefe yönelik olarak hareket etmektedirler. Karıncalar yiyecek arama davranışına sahip canlılardır.

Termit sürüleri arasındaki iletişim için kimyasal sinyal ya da dokunsal bir dil vardır. Termitlerdeki sürü psikolojisi, sürünün bilişsel yeteneklerinin sürü içindeki diğerleri arasındaki etkileşiminden kaynaklanmaktadır. Feromon salgılayan karıncalar besin ile koloni arasındaki en kısa yolu bulma yeteneğine sahiptir.

Karınca Kolonisi Optimizasyonu karıncaların yiyecek arama davranışından esinlenmiştir. Ayrık ya da sürekli olan optimizasyon problemlerinin çözümünde kullanılan bir yaklaşım türüdür. Koloni içindeki karıncalar birbirleriyle feromon aracılığıyla iletişim kurmaktadır. Kolonideki tüm karıncalar, optimizasyonu sağlamak için işbirliği yapar. Feromon izleri, karıncalar tarafından kullanılan bir iletişim mekanizmasıdır.

Tüm karıncalar, çevreyi zenginleştiren ve önceki izlerin buharlaşmasına neden olan feromon salgılar. Karınca, feromon yoğunluğuna bağlı olarak olasılıksal bir bağlantı seçer. Karınca koloni sistemindeki karıncalar iletişim için sadece bir tür feromon kullanırken, doğal karıncalar da dokunsal bilgileri kullanır ve çevrelerini öğrenmek için mikro beyinlerini kullanabilirler (Du ve Swamy 2016).

Yapay Arı Kolonisi (ABC) algoritması öncelikle sürekli optimizasyon içeren problemleri çözmek için kullanılır. Beslenirken bir arı sürüsünün yaptığı sallanma dansını taklit eder. Diğer algoritmalarla karşılaştırıldığında, ABC yöntemi bir fonksiyon optimizasyon problemini çözerken daha iyi performans gösterir. Her yinelemede yerel arama yapma yeteneği, en önemli avantajlarından biridir.

Birçok optimizasyon probleminde ABC, daha optimal bir çözüm üretebildiği için diğer yaklaşımlardan daha verimlidir. ABC'de, bir gıda kaynağının konumu, potansiyel bir problem çözümünü temsil eder ve bir gıda kaynağının nektar içeriği, çözümün etkinliğini yansıtır.

ABC rastgele çözümlerle başlar ve daha iyilerini bulup bulamayacağını görmek için en iyilerinin çevresine bakar. Çözümlerin her biri, bir gıda kaynağının temsili ile bir işçi arıya

bağlıdır. Kullanılacak besin kaynaklarından biri kalite veya uygunluk esas alınarak rulet çarkı seçim yöntemi kullanılarak eşit sayıda seyirci arı tarafından seçilir. İşçi ve gözlemci arılar, bir besin kaynağının konumunun rastgele belirlenmiş bir boyutunu başka bir rastgele seçilen besin kaynağına doğru karıştırarak, mevcut besin kaynaklarına yakın daha iyi besin kaynakları bulmaya çalışırlar (Du ve Swamy 2016).

Ateşböceği algoritması, PSO gibi, ateşböceklerinin çiftleşme amacıyla diğer ateşböceklerini çekmek için ışık üretme kapasitesi tarafından motive edilir. Başlangıçta sürekli multimodal optimizasyon için önerildi. Kısıtlı sürekli optimizasyon sorunları da ateş böceği algoritması kullanılarak çözülmüştür. Bir ateş böceğinin parlaltısının birincil amacı, olası çiftleşme ortaklarını ve avını çekmektir. Flaşlar aynı zamanda koruyucu bir uyarı sistemi işlevi görür.

Ateşböceği algoritmasında cinsiyetleri ne olursa olsun bir ateşböceği diğer ateşböceklerine çekilir. Parlaklığı ve güzelliği ters orantılıdır ve her ikisi de mesafe arttıkça azalır. Hiç kimse ondan daha parlak değilse, bir ateş böceği rastgele hareket edecektir. Bir ateş böceğinin amaç fonksiyonunun, onun ne kadar parlak olduğu üzerinde etkisi vardır (Du ve Swamy).

1.2. Parçacık Sürü Optimizasyonu Algoritması (PSO)

Çalışmanın bu bölümünde Parçacık sürü optimizasyonu algoritması anlatılmıştır. Parçacık sürü optimizasyonu (PSO), bir problemi parçacıklar olarak adlandırılan aday çözümlerin popülasyonuna sahip olarak ve bu parçacıkların arama uzayında basit matematiksel formüle göre parçacığın konumu ve hızı üzerinde hareket ettirerek çözmektedir.

Her parçacığın hareketi, yerel olarak en iyi bilinen konumundan etkilenmektedir. Ancak, diğer parçacıklar tarafından daha iyi konumlar bulunursa, güncellenen arama uzayındaki en iyi bilinen konumlara doğru parçacıklar yönlendirilir. Böylece sürünün en iyi çözümlere doğru hareket etmesi sağlanır. PSO, optimize edilmekte olan problem ile ilgili çok az varsayımda bulunur ya da hiçbir varsayımda bulunmaz. Bunun yerine geniş aday çözüm uzaylarını aramaya çalışan bir meta-sezgisel algoritmadır. İlk kez Kennedy ve Eberhart tarafından ortaya atılmıştır (Kennedy ve Eberhart 1995). Bununla birlikte PSO, optimize edilen problemin gradyanına ihtiyaç duymamaktadır. Bu PSO' nun gradyan iniş ve Newton yöntemleri gibi klasik optimizasyon yöntemlerinin gerektirdiği gibi optimizasyon probleminin türevlenebilir olmasına ihtiyaç duymadığı anlamına gelmektedir. Ancak, PSO gibi meta-sezgisel yöntemler, daima en uygun çözümün bulunacağını garanti etmemektedir.

PSO algoritması, parçacık olarak adlandırılan aday çözümlerden oluşur ve sürü adı verilen bir popülasyona sahip olarak çalıştığı için popülasyon tabanlı bir meta-sezgisel algoritmadır. Parçacıkların hareketleri, arama uzayındaki en iyi bilinen konumlarıyla birlikte tüm sürünün en iyi bilinen konumu tarafından yönlendirilirler. Daha iyi konumlar keşfedildiğinde, bu konumlar sürünün hareketlerini yönlendirmek için kullanılırlar. İşlemin tekrarlanmasıyla sonuçta daha tatmin edici bir çözümün bulunması beklenmektedir (Zhang 2015), (Bratton ve Kennedy 2007). Aşağıda, PSO algoritmasının kaba kodu Şekil 1’de görülmektedir.

```

1. Initialize population
2. for t = 1: maximum generation
3.     Initialize global and local best particles ( $p_i$  and  $p_g$ )
4.     for i = 1: population size
5.         for d = 1: dimension
6.              $v_{i,d}(t+1) = w(t) * v_{i,d}(t) + c_1 * r_1 * (p_i - x_{i,d}(t)) + c_2 * r_2 * (p_g - x_{i,d}(t));$ 
7.             if  $v_{i,d}(t+1) > v_{max}$  then  $v_{i,d}(t+1) = v_{max};$ 
8.             else if  $v_{i,d}(t+1) < v_{min}$  then  $v_{i,d}(t+1) = v_{min};$ 
9.             end
10.             $x_{i,d}(t+1) = x_{i,d}(t) + v_{i,d}(t+1);$ 
11.            if  $x_{i,d}(t+1) > x_{max}$  then  $x_{i,d}(t+1) = x_{max};$ 
12.            else if  $x_{i,d}(t+1) < x_{min}$  then  $x_{i,d}(t+1) = x_{min};$ 
13.            end
14.        end
15.        if  $f(x_{i,d}(t)) < f(p_i(t))$  then  $p_i(t) = x_{i,d}(t);$ 
16.    end
17. end
18.  $f(p_g(t)) < \min_i (f(p_i(t)));$ 
19.  $w(t) = \frac{t_{max}-t}{t_{max}}(w_{max} - w_{min}) + w_{min};$ 
20. end

```

Şekil 1. PSO algoritmasının kaba kodu

Karmaşık davranışlar üretmek için basit şekilde hareket eden birçok parçacığın kullanılması fikri öncelikle bilgisayar animasyonlarında görüntü oluşturmak için tasarlanmıştır.

Parçacıklar stokastik olarak bir dizi hareketli nokta üretmektedirler. Her parçacığa başlangıç hız vektörü atanır. Parçacık, renk, doku ve kullanım ömrü gibi özelliklere de sahip olabilir. Rastgele değişkenler kullanılarak hız vektörleri yinelemeli şekilde ayarlanabilir. Bilgisayar oyunlarında ve grafiklerinde üretilen ateş, duman ve bulut gibi efektler parçacık sistemleri kullanılarak oluşturulmaktadır.

Global optimizasyon problemlerinin çözümünde parçacık sistemleri ön plana çıkmaktadır. Parçacık Sürü Optimizasyonu birlikte hareket eden kuş sürüsü, balık sürüsü ve arı sürüsü çalışmalarından elde edilmiştir. Parçacık adı verilen bireyin sürüdeki sosyal davranışına göre çalışan algoritmalarıdır. Her bir tekrarda Parçacık Sürü Optimizasyonu Algoritması parçacıkların bilişsel yön ve sosyal yöndeki konumlarına göre her bir parçacığın hareket eden vektörünün basitçe ayarlanması ile global en iyi çözümü bulmayı amaçlamaktadır.

İlk kez Kennedy ve Eberhart tarafından ortaya atılmıştır. Bununla birlikte PSO, optimize edilen problemin gradyanına ihtiyaç duymamaktadır. Bu PSO' nun gradyan iniş ve Newton yöntemleri gibi klasik optimizasyon yöntemlerinin gerektirdiği gibi optimizasyon probleminin türevlenebilir olmasına ihtiyaç duymadığı anlamına gelmektedir. Ancak, PSO gibi meta-sezgisel yöntemler, daima en uygun çözümün bulunacağını garanti etmemektedir.

PSO algoritması, parçacık olarak adlandırılan aday çözümlerden oluşur ve sürü adı verilen bir popülasyona sahip olarak çalıştığı için popülasyon tabanlı bir meta-sezgisel algoritmadır. Parçacıkların hareketleri, arama uzayındaki en iyi bilinen konumlarıyla birlikte tüm sürünün en iyi bilinen konumu tarafından yönlendirilirler. Daha iyi konumlar keşfedildiğinde, bu konumlar sürünün hareketlerini yönlendirmek için kullanılırlar. İşlemin tekrarlanmasıyla sonuçta daha tatmin edici bir çözümün bulunması beklenmektedir.

1.3. İnsan Zihinsel Arama Algoritması (HMS)

Mousavirad ve Ebrahimpour-Komleh tarafından literatüre kazandırılan İnsan zihinsel arama algoritması(HMS) çevrimiçi açık arttırmalarda teklif alanının keşif stratejilerini taklit eden, Levy uçuşuna dayalı olarak her bir çözümün etrafındaki bölgeyi araştıran zihinsel aramayı kullanan ve gelecek vaat eden bir bölgeyi belirleyen gruplandırma işlemi uygulayarak, çözümleri en iyi stratejiye doğru hareket ettiren, meta-sezgisel bir algoritmadır (Mousavirad ve Ebrahimpour 2017).

Gerçek dünya problemlerinin çözümünde kullanılan klasik optimizasyon yöntemlerinin yerel optimum durgunluğundan kaçınan HMS algoritması, rastgelelik operatörüne sahip olduğu için problemde bağımsızdır. Rastgelelik bu algoritmanın temel özelliklerinden biridir.

İstatistik ve mühendislik problemlerinin çözümünde rastgelelik süreçleri önemli bir yer tutmaktadır. Popülasyon tabanlı meta-sezgisel algoritmalar, yerel optimum çözümde takılı kalmaktan kaçınırlar. Popülasyon tabanlı meta-sezgisel algoritmaların sahip olduğu yoğunlaştırma en iyi çözümleri araştırarak daha iyi çözümler bulmaya çalışır ve çeşitlendirme de algoritmanın umut vadeden arama uzayı alanını keşfetme yeteneğini temsil etmektedir.

Meta-sezgisel algoritmaların geliştirilmesindeki zorluklardan birisi bu iki özellik arasındaki dengeyi sağlamaktır. Meta-sezgisel algoritmalar bazı problemlerin çözümünde başarılı olur iken bazılarında ise yeterli başarıyı gösteremeyebilirler. Buradaki en önemli noktalardan birisi araştırma alanının geliştirilmesidir. Bunun için de birçok meta-sezgisel algoritma geliştirilmeye çalışılmaktadır.

Müziyenlerin hoş bir armoni bulmada doğaçlama sürecini taklit etmeye çalışan meta-sezgisel bir arama algoritması olan Harmoni arama algoritması (Askarzadeh 2017) ve sosyal tabanlı emperyalist rekabetçi algoritma (Atashpaz-Gargari ve Lucas 2007), insan davranışlarını ve özelliklerini taklit eden insan temelli meta-sezgisel algoritmalarındandır.

HMS algoritması, zihinsel arama, gruplandırma ve hareket operatörlerine sahip olan, gelişmiş çeşitlendirme ve yoğunlaştırma özelliklerini sağlayan Levy uçuşuna dayalı bir çözüm etrafında yeni çözümler oluşturan, çözümlerin kümeleme algoritması kullanılarak bazı bölgelerde gruplandırılmasını sağlayan ve gelecek vaat eden bölgeye yaklaşmak için alternatif çözümleri deneyen, hareket operatörünü kullanan, popülasyon tabanlı meta-sezgisel bir algoritmadır. Radicci ve arkadaşları, İnsanların çevrimiçi açık arttırmalarda teklif alanını keşfetmek için Levy uçuş stratejisini uyguladıklarını söylemişlerdir (Radicchi ve ark. 2012), (Radicchi ve Baronchelli 2012).

Teklif uzayının keşfi soyut bir uzayda çalıştığı için zihinsel türden bir arama süreci olarak bilinmektedir. En düşük L değerinden en yüksek H değerine kadar her hangi bir değerde insanlar çevrimiçi açık arttırmalarda teklif verebilmektedirler. Açık arttırmanın galibi en düşük ya da en yüksek benzersiz teklifi vererek pahalı ürünleri daha düşük fiyata sahip alabilme şansına sahiptir. Radicchi ve arkadaşlarına göre (Radicchi ve ark. 2012), (Radicchi

ve Baronchelli 2012) teklif uzayının keşfinin Levy uçuşu ile tutarlılık gösterdiğini, müzayede sonunda kaybeden katılımcıların kazananın stratejisini seçme eğiliminde olduklarını ve daha sonraki müzayede için kazananın stratejisine yaklaştıklarını belirtmişlerdir. HMS algoritmasını geliştirmede kullanılan kavramlar:

1. Her katılımcıya ait olan bir strateji vardır.
2. Her katılımcı teklif verebilmektedir.
3. Katılımcıların bir sonraki teklifleri Levy uçuş dağılımı ile tutarlılık gösterir.
4. Birden fazla teklif vermeye izin verilir.
5. Sonraki müzayedeler için kaybeden katılımcılar kazanan katılımcının stratejisini seçmeye çalışır.

HMS algoritmasının kaba kodu aşağıda Şekil 2’de görülmektedir.

```

1.  begin
2.  X = Initialize a population of  $N_{pop}$  bids
3.  Calculate the cost of bids
4.   $x^*$  = Find the best bid in the initial population
5.  for i from 1 to  $N_{pop}$  do
6.       $\beta_i$  = generate an integer random number between a lower and upper bound
7.  end - for
8.  for iter from 1 to  $MaxIter$  do
9.       $q_i$  = generate an integer random number between  $M_L$  and  $M_h$ 
10. end - for
11. for i from 1 to  $N_{pop}$  do
12.     for j from 1 to  $q_i$  do
13.          $s = (2 - Iter * (2/MaxIter)) * 0.01 * \frac{u}{v^{1/\beta_i}} * (x^i - x^*)$ 
14.          $NS_j = X^i + s$ ;
15.     end - for
16.     t = find NS with the lowest cost
17.     if  $cost(t) < cost(X^i)$ 
18.          $X^i = t$ 
19.     end - if
20. end - for
21. for i from 1 to  $N_{pop}$  do
22.     for n from 1 to  $N_{var}$  do
23.          $X_n^i = X_n^i + C * (r * winner_n - X_n^i)$ 
24.     end - for
25. end - for
26. for i from 1 to  $N_{pop}$  do
27.      $\beta_i$  = generate a random number between a lower and upper bound
28. end - for
29.  $x^+$  = Find the best bid in the current bids
30. if  $cost(x^+) < cost(x^*)$  do
31.      $x^* = x^+$ 
32. end - if
33. end - for
34. end - begin

```

Şekil 2. HMS Algoritmasının Kaba Kodu

1.4. Hibrit Metasezgisel Algoritmalar

Bu bölümde hibrit Metasezgisel algoritmalarından bahsedilmiştir.

Xue ve arkadaşları, makine öğrenmesi ve veri madenciliği uygulamalarında özellik seçimini daha verimli hale getirmek ve hesaplamak karmaşıklığını azaltmak için parçacık sürü optimizasyonu algoritmasına (PSO) ve genetik almoritmaya (GA) dayanan bir hibrit algoritma önermiştir.

Sınıflandırma sürecindeki özellik seçiminin, veri boyutunun azaltılması ve makine öğrenmesi yöntemlerinin etkinliğini artırılmasında önemli bir süreç olduğunu ifade etmişlerdir. Özellik seçimi sorunlarını çözmek için geleneksel optimizasyon yöntemlerine olan üstünlükleri nedeniyle algoritmaların arama ve yakınsama oranını arttıran meta-sezgisel yöntemler kullanmışlardır. Önerdikleri hibrit yöntemin performansını UCI makine öğrenmesi veri setini kullanarak bir dizi simülasyon sürecinde test etmişlerdir (Xue ve ark. 2021).

Singh ve Singh, yakınsama performansını geliştirmek için doğadan ilham alan, GWO' nun keşif yeteneği ile PSO nun sömürü yeteneğini kullanan HPSOGWO hibrit algoritmasını geliştirmişlerdir. Önerdikleri hibritin problem çözme yeteneğini ve performansını ölçmek için tek modlu ve sabit boyutlu çok modlu test fonksiyonlarını kullanmışlardır.

Sonuçların hibrit algoritmanın problem çözme yeteneğinin, kararlılığının, yakınsama hızının ve global optimumu bulma yeteneğinin PSO ve GWO dan daha iyi performans gösterdiğini ifade etmişlerdir. Algoritmaları tek modlu her bir fonksiyon için 30 kez çalıştırarak test etmişlerdir. Hibrit algoritmanın makul yinelemelerle daha iyi sonuçlar elde etmede daha güvenilir ve arama sürecinin yerel optimal noktaya erken yakınsamasını engellediğini ve arama rotasının üstün keşfini sağladığı sonucuna vardıklarını söylemişlerdir (Singh ve Singh 2017).

Ghodrati ve Lotfi, guguk kuşu arama (CS) ve parçacık sürü optimizasyonu (PSO) algoritmalarını kullanarak hibrit bir meta-sezgisel algoritmayı optimizasyon problemlerinin çözümü için önermişlerdir. Mevcut CS algoritmasında guguk kuşlarının Levy uçuşuna dayalı yeni yerler aradığını, önerdikleri hibrit algoritmada ise guguk kuşlarının birbirlerinin konumlarını bildiğini ve daha iyi çözümlere ulaşmak için PSO' nun sürü zekâsından faydalandıklarını belirtmişlerdir. Önerdikleri hibrit algoritmanın standart test fonksiyonları ile yapılan karşılaştırma sonuçlarına göre umut verici bir performans gösterdiğini söylemişlerdir (Ghodrati ve Lotfi 2012).

Yang ve Wang, karmaşık sistem optimizasyonu probleminin çözümü için DE ve PSO dan oluşan hibrit bir algoritma önermişlerdir. Zamana dayalı sistem yeniden yapılandırma modelinde sipariş üzerine bağlantı yerleşim modelinin sipariş akıllı operasyon serisinin, diferansiyel evrim(DE) algoritması ile hibrit bir pso tarafından yönlendirildiğini söylemişlerdir.

PSO' nun karma arama işlemi esnasında DE için ilk çözümü sağladığını ve sürü boyutunu bir parçacık olarak ayarlayarak geleneksel DE' ye dönüştürebildiğini belirtmişlerdir. Simülasyon sonuçlarının önerilen model ve algoritmanın değerlendirme ve uygulama sıralamasında etkili olduğunu ifade etmişlerdir (Wang ve Yang 2010).

Zhang ve Wu, global arama algoritması olan parçacık sürü optimizasyonu ile yerel arama algoritması olan tabu aramasını kullanarak optimal minimumu bulma olasılığının önemli ölçüde artırılması için her yinelemede hem global hem de yerel arama yapan hibrit bir TS-PSO algoritması önermişlerdir. Önerdikleri hibrit algoritmanın performansını ölçmek için Easom, Hump, Rosenbrock ve Rastrigin test fonksiyonlarını kullanmışlardır. Deneysel sonuçlarda hibrit algoritmanın performansının GA, TS ve PSO' dan daha yüksek olduğunu belirtmişlerdir (Zhang ve Wu 2011).

Rosendo ve Pozo, ayrık optimizasyon problemlerinin çözümü için, parçacığın hızının güncellenmesinde temel PSO konseptine dayanan, yerel arama ve yol yeniden bağlamayı da kullanan hibrit bir PSO algoritması önermişlerdir. Önerdikleri hibrit algoritmayı Gezgin Satıcı Probleminin çözümünde kullanmışlardır. Sonuçları daha önce önerilen PSO algoritmaları ile karşılaştırmışlardır. Elde ettikleri sonuçların ayrık optimizasyon problemlerinin çözümünde PSO' nun daha iyi sonuçlar sağlayabileceği fikrini güçlendirdiğini belirtmişlerdir (Rosendo ve Pozo 2010).

Chen ve arkadaşları, üç boyutlu yerleşim problemi olarak da bilinen uydu yerleşim optimizasyon tasarımı probleminin çözümü için diferansiyel evrim algoritmasına (DE) dayalı iki tür hibrit optimizasyon algoritması önermişlerdir. Yerleşim tasarım alanını global olarak aramak için önerdikleri hibrit algoritmanın ana çerçevesinin DE olduğunu, yerel yararlanma kapasitesini ve algoritmanın sağlamlığını geliştirmek için de gradyan tabanlı bir yöntem olan sıralı ikinci dereceden programlamayı (SQP) kullanmışlardır.

İlk hibrit algoritmanın DESQP, SQP'nin DE'nin yineleme işlemi bittiğinde gerçekleştirildiği ve amacının en umut verici alanı bulmak olan SQP'nin başlangıç noktasının sadece DE'nin nihai çözümünü kullandığı algoritmadır. İkinci hibrit algoritmada

(DESPDE), SQP'nin DE'nin belirli bir yinelemesinde gerekleřtirildiđi ve mevcut neslin popülasyonun tüm bireylerinin amacının evrim sürecini hızlandırmak olan başlangı noktalarını kullandıđı algoritmadır.

Önerdikleri hibrit algoritmaların etkinliđini ve sađlamlıđını DE ile karřılařtırmıřlardır. Sonuları 14 ve 40 bileřenli iki üç boyutlu uydu yerleřim durumunda dođrulamıřlardır (Chen ve ark. 2018).

Verma ve Parouha, küçük ve büyük ölekli mühendislik tasarım problemlerinin çözümlü için DE ve PSO'yu kullanarak oluřturdukları hibrit bir meta sezgisel algoritma önermiřlerdir. Önerdikleri algoritmada erken yakınsamayı önlemek için yeni bir mutasyon, aprazlama ve seim stratejisini uygulamıřlardır. Önerdikleri hibrit algoritmayı 23 kısıtsız performans fonksiyonu ile dođrulamıřlardır.

Beř küçük yapı mühendisliđi ve bir büyük ölekli mühendislik tasarım problemi olan ekonomik yük dađıtım optimizasyon probleminin çözümlünde önerdikleri hibrit algoritmayı kullanmıřlardır. Analiz sonularına göre önerdikleri algoritmanın birok teknolojik algoritmadan üstün olduđunu belirtmiřlerdir (Verma ve Parouha 2021).

Khuat ve Le, modern yazılım geliřtirme süreçlerinde önemli bir rolü olan yazılım efor tahmini probleminin çözümlü için yapay arı kolonisi ve paracık süre optimizasyonu algoritmalarını kullanarak hibrit bir algoritma önermiřlerdir. Önerdikleri algoritmanın efor tahmini problemini çözümlü diđer alıřmalardaki yöntemlerden daha iyi performans gösterdiđi sonucuna varmıřlardır (Khuat ve Le 2018).

Yelghi ve arkadaşlarının önerdiđi optimizasyon algoritmaları ateř böceđi algoritmasını modifiye ederek git-gel yaklařımı ile yerel minimum problemini çözümlütedir. Diđer alıřmalarında ise, inřaat alanındaki kırmızıizgi problemini optimizasyon algoritmalarını kullanarak çözümlüştür (Yelghi ve Köse 2018), (Asherlou ve ark. 2022), (Yelghi ve ark. 2020).

2. ZİHİNSEL ARAMA TEMELLİ PARACIK SÜRÜ OPTİMİZASYONU (HMS-PSO) ALGORİTMASI

2.1. Zihinsel Arama Temelli Paracık Sürü Optimizasyonu Algoritması (HMS-PSO) Yaklařımı

İnsan Zihinsel Arama Tabanlı Paracık Sürü Optimizasyonu (HMS-PSO) yaklařımı, Paracık Sürü Optimizasyonu (PSO) ve İnsan Zihinsel Arama (HMS) popülasyon tabanlı meta-sezgisel algoritmalarının birleřtirilmesiyle oluřturulmuřtur. Önerilen HMS-PSO, insan

davranışını taklit eden insan zihinsel arama operatörü ile birlikte PSO keşif ve sömürü tekniklerini kullanır.

Geleneksel PSO algoritması, problemin boyutuna ve optimizasyon zorluğuna bağlı olarak değişken bir keşif ve yararlanma stratejileri kombinasyonu kullanabilir. Sosyal katsayı keşif ile, bilişsel katsayı ise sömürüyle ilgilidir. Bu katsayıların seçimi, parçacığın belleğinde tutulan en iyi çözüm ile genel olarak en iyi çözüm arasındaki dengeyi yansıtır. Eylemsizlik katsayısı, parçacığın genel ideal çözüme yönelik eğilimini belirler.

Denklem 1' de, parçacığın hızının nasıl değişeceğini belirlemek için kullanılır. Burada v parçacığın hızını, w eylemsizlik ağırlıklarını, c_1 ve c_2 bilişsel ve sosyal katsayılarını ve r_1 ve r_2 parçacığın toplam hızı üzerindeki bu iki faktörün stokastik etkisini kontrol eden rastgele vektörlerini gösterir. P_{best} , her parçacık için yerel en iyi çözümün minimum değeridir ve G_{best} , küresel en iyi çözüm için küresel minimum değeridir.

$$v = w * v + c_1 * r_1 * (P_{best} - x) + c_2 * r_2 * (G_{best} - x) \quad (1)$$

Denklem 1' de c_1 , c_2 ve r_1 , r_2 rastgele seçilmiş iki sayıdır, w ise eylemsizlik ağırlığını temsil eder. Atalet katsayısı yüksek olan bir parçacık daha hızlı hareket edebilir, ancak aynı zamanda sürüden uzaklaşmasına da neden olabilir. Bilişsel katsayı seçimi, parçacığın yerel olarak optimal çözümünde takılıp kalmasına neden olabilir. Herhangi bir alternatif veya üstün küresel çözüm bulmadan, seçilen sosyal katsayı, onu en iyi küresel çözümü kopyalamaya zorlayabilir.

Önerilen HMS-PSO yaklaşımı, parçacığın zihinsel arama operatörünü kullanmasına izin vererek kendi başına en iyi çözümü bulmasına yardımcı olur. Normal dağılım (veya "d"), verilerdeki her bir değer için olasılık dağılımlarını kullanarak verileri temsil eden bir formdur. Rastgele oluşturulan MC sayısı, denklem 2' deki geleneksel normal dağılımı oluşturur. Verilerin çoğu ortalamanın etrafında gezinme eğiliminde olduğundan, düzenleme simetriktir.

$$d = \frac{1}{\sqrt{2\pi e^{-\frac{mc^2}{2}}}} \quad (2)$$

HMS tekniği, beta'nın 0,3 ile 1,99 arasında bir aralığa sahip olduğunu ve rastgele eşit olarak dağıtıldığını belirtir. Aşağıdaki örnekteki denklem 3, zihinsel arama katsayısını veya sigma'yı hesaplamak için kullanılır.

$$Sigma = \sin\left(\frac{\pi Beta}{2}\right) \quad (3)$$

S, bir aramadaki her bir kavramın ürettiği ardışık değerlerin miktarını ifade eder. Levy uçuşuna dayalı bir öneri, bu aşamadaki birkaç yeni fikrin odak noktasıdır. Her teklif için ek yeni tekliflerin sayısı, üst ve alt sınırlamalar arasında rastgele bir tam sayı ile belirlenir. Levy Flight, Levy dağılımının adım boyutunu kontrol ettiği özel bir rastgele yürüyüş türüdür. Rastgele bir yürüyüşte, zincirdeki mevcut konum, bir sonraki hedefi belirleyen tek faktördür. Levy uçuşu birkaç kısa geziden ve birçok küçük aşamadan oluşur.

Bir başka deyişle Levy Flight, hem yoğunlaştırmanın kalitesini hem de çeşitlendirmeyi aynı anda iyileştiriyor. Belirsiz bölgelerde gezinmek için Levy uçuşunun Brownian hareketinden daha üstün olduğunu belirtmek çok önemlidir (Rahkar Farshi 2021). S, denklem 4'den üretilir, burada I parçacık sayısıdır, xi her parçacığın başlangıçtaki tekdüze rastgele konumudur ve 0.01, Levy dağılım katsayısı sayısıdır (Mousavirad ve Ebrahimpour 2017). U ve V, 0 ile 1 arasında rastgele normal dağılım sayılarıdır ve I parçacık sayısıdır.

$$S = (d * 0.01 * \frac{(u * \sigma)}{1} * x^i) \quad (4)$$

Zihinsel arama operatörü, daha iyi sonuçlar elde etmek için Levy uçuş dağılımına göre çeşitli şekillerde ayarlanır. Parçacık yerel en iyi çözüm tarafından yakalanmaz. Denklem 5, zihinsel aramanın sonucu, parçacığın mevcut konumunun Lbest, yerel minimumun Pbest ve S'nin bulunan yer olduğunu gösterir.

Diğer bir deyişle, uygunluk fonksiyonu tarafından belirlenen parçacıkların yerel minimum değeri, zihinsel aramanın minimum değerinden yüksekse, zihinsel arama sonucunun değerini parçacıkların yerel minimum değerine uygular (P en iyi = S). P en iyi = L en iyi bir alternatiftir; bunun yokluğunda, parçacığın bellek değerini yerel minimum değerle karşılaştırır.

$$If L_{best} < S \text{ then } P_{best} = L_{best}, If S < L_{best} \text{ then } P_{best} = S \quad (5)$$

Beta, 0,3 ile 1,99 arasında değişen dağılım endeksini belirtirken, dağıtım ölçüğü faktörünü belirtir. Önerilen HMS-PSO algoritmasının kaba kodu aşağıda Şekil 3'te gösterilmiştir (Kaya ve Yılmaz 2022).

```

1. Initialize particle population
2. for t = 1: maximum generation
3.   Initialize global and local best particles( $p_b$  and  $p_g$ )
4.   for i = 1: population size
5.      $v_i(t+1) = w(t) * v_i(t) + c_1 * r_1 * (p_b - x_i(t)) + c_2 * r_2 * (p_g - x_i(t));$ 
6.     if  $v_i(t+1) > v_{max}$  then  $v_i(t+1) = v_{max};$ 
7.     else if  $v_i(t+1) < v_{min}$  then  $v_i(t+1) = v_{min};$ 
8.     end
9.      $x_i(t+1) = x_i(t) + v_i(t+1);$ 
10.    if  $x_i(t+1) > x_{max}$  then  $x_i(t+1) = x_{max};$ 
11.    else if  $x_i(t+1) < x_{min}$  then  $x_i(t+1) = x_{min};$ 
12.    end
13.  end
14. Initialize the mental search for each particle
15. for i = 1: population size
16.    $S = d * 0.01 * \frac{(u * \sigma)}{(v * \beta)} * \chi^i$ 
17.    $x_s = S$ 
18.   if  $f(x_i(t)) < f(p_b(t))$  then  $p_b(t) = x_i(t)$ 
19.   else if  $f(x_s(t)) < f(p_b(t))$  then  $p_b(t) = x_s(t)$ 
20.   end
21. end
22.  $f(p_g(t)) < \min_i (f(p_b(t)));$ 
23.  $w(t) = \frac{t_{max}-t}{t_{max}} (w_{max} - w_{min}) + w_{min};$ 
24. end

```

Şekil 3. HMS-PSO Algoritmasının Kaba Kodu

2.2. HMS-PSO Algoritmasının İspatı

Meta-sezgisel algoritmaların matematiksel anlamda ispatları yoktur. Bunun yerine meta-sezgisel algoritmaların benchmark fonksiyonları kullanılarak yakınsayıp yakınsamadıklarına göre algoritmanın etkinliği ortaya konmaktadır. Bu bölümde HMS-PSO algoritmasının etkinliğini gösterebilmek için performans ölçütü olarak benchmark fonksiyonlarından yararlanılmıştır.

HMS-PSO, PSO ve HMS algoritmaları, Jupyter Notebook ortamında; Python programlama dili kullanılarak kodlanmıştır. Üç algoritmaya ait test fonksiyonları kullanılarak yapılan performans ölçümlerinde, Eröz ve Tanyıldız'ın yapmış olduğu çalışmadan yararlanılmıştır (Eröz ve Tanyıldız 2018). Tablo 1'de tek modlu kalite testi fonksiyonları, Tablo 2'de çok modlu kalite testi fonksiyonları; Tablo 3'de sabit boyutlu çok modlu kalite testi fonksiyonları görülmektedir.

Tablo 1. Tek Modlu Kalite Testi Fonksiyonları

Fonksiyon Adı	Fonksiyon	V _{no}	Sınır	F _{min}
Hyper Sphere	$F_1(x) = \sum_{i=1}^n x_i^2$	30	[-100, 100]	0
Shifted Schwefel's Problem 1.2	$F_2(x) = \sum_{i=1}^n x_i^2 x_i + \prod_{i=1}^n x_i $	30	[-10, 10]	0
Schwefel 1.2	$F_3(x) = \sum_{i=1}^n (\sum_{j=1}^i x_j)^2$	30	[-100, 100]	0
Schwefel 2.21	$F_4(x) = \max\{ x_i , 1 \leq i \leq n\}$	30	[-100, 100]	0
Rosenbrock	$F_5(x) = \sum_{i=1}^{n-1} [100(x_{i+1} - x_i^2)^2 + (x_i - 1)^2]$	30	[-30, 30]	0
Step2	$F_6(x) = \sum_{i=1}^n ([x_i + 0.5])^2$	30	[-100, 100]	0
Quartic	$F_7(x) = \sum_{i=1}^n ix_i^4 + \text{random}[0,1]$	30	[-1.28, 1.28]	0

Tablo 2. Çok Modlu Kalite Testi Fonksiyonları

Fonksiyon Adı	Fonksiyon	V _{no}	Sınır	F _{min}
Schwefel	$F_8(x) = \sum_{i=1}^n -x_i \sin(\sqrt{ x_i })$	30	[-500, 500]	-418.9829 x 5
Rastrigin	$F_9(x) = \sum_{i=1}^n [x_i^2 - 10\cos(2\pi x_i) + 10]$	30	[-5.12, 5.12]	0
Ackley	$F_{10}(x) = -20 \exp\left(-0.2 \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2}\right) - \exp\left(\frac{1}{n} \sum_{i=1}^n \cos(2\pi x_i)\right) + 20 + e$	30	[-32, 32]	0
Griewank	$F_{11}(x) = \frac{1}{4000} \sum_{i=1}^n x_i^2 - \prod_{i=1}^n \cos\left(\frac{x_i}{i}\right) + 1$	30	[-600, 600]	0

Tablo 3. Sabit Boyutlu Çok Modlu Kalite Testi Fonksiyonları

Fonksiyon Adı	Fonksiyon	V _{no}	Sınır	F _{min}
Six Hump	$F_{16}(x) = 4x_1^2 - 2.1x_1^4 + \frac{1}{3}x_1^6 + x_1x_2 - 4x_2^2 + 4x_2^4$	2	[-5, 5]	-1.0316
Branin	$F_{17}(x) = (x_2 - \frac{5.1}{4\pi^2} x_1^2 - 6)^2 + 10 \left(1 - \frac{1}{8\pi}\right) \cos x_1 + 10$	2	[-5, 5]	0.398
Gold Stein and Price	$F_{18}(x) = [1 + (x_1 + x_2 + 1)^2(19 - 14x_1 + 3x_1^2 - 14x_2 + 6x_1x_2 + 3x_2^2)] \times [30 + (2x_1 - 3x_2)^2 \times (18 - 32x_1 + 12x_1^2 + 48x_2 - 36x_1x_2 + 27x_2^2)]$	2	[-2, 2]	3

2.3. HMS-PSO Algoritmasının Kalite Testi Fonksiyonları Kullanılarak PSO ve HMS Algoritmaları ile Karşılaştırılması

Tablo 4 'de HMS-PSO, PSO ve HMS algoritmalarının tek modlu kalite testi fonksiyonları kullanılarak elde edilen sonuçlar görülmektedir.

HMS-PSO algoritmasının performansını PSO ve HMS algoritmaları ile karşılaştırmak için kalite test fonksiyonlarına göre 30 boyut ve 2 boyutta algoritmaların her biri 30 kez çalıştırılmıştır.

HMS-PSO ve PSO için parçacık sayısı 50, MaxIter=100, W=0.729, C1=1.49, C2=1.49 olarak seçilmiştir. HMS algoritması için maxIter=100, ML=2, MH=10, UB=1.99, LB=0,3, N_var=30, Npop=50, cluster = 5 olarak seçilmiştir. Tablolarda koyu renk ile gösterilenler en iyi sonuçları veren algoritmalara ait sonuçlardır. Süre birimi olarak saniye alınmıştır.

Tablo 4. HMS-PSO, PSO ve HMS' ye Ait Tek Modlu Kalite Testi Fonksiyonları Sonuçları

Rosenbrock	HMS-PSO		PSO		HMS				
Ort	0,000162		1,835E-06		0,01722				
En iyi	0,000161		1,835E-05		0,01721				
En kötü	0,000163		1,835E-04		0,01723				
Süre	Program	Executed	in	Program	Executed	in	Program	Executed	in
		1.7299999854003545e-05			1.69999999971169e-05		1.6899999991437653e-05		
Hyper_Sphere	HMS-PSO		PSO		HMS				
Ort	3,977380		140,754818		4,696785				
En iyi	3,977381		140,754817		4,696784				
En kötü	3,977383		140,754819		4,696786				
Süre	Program	Executed	in	Program	Executed	in	Program	Executed	in
		1.6400000276917126e-05			1.8299999965165625e-05		1.640000004954345e-05		
Schwefel_12	HMS-PSO		PSO		HMS				
Ort	3,536302		140,754818		4,666853				
En iyi	3,536301		140,754817		4,666851				
En kötü	3,536303		140,754819		4,666854				

Süre	Program	Executed	in	Program	Executed	in	Program	Executed	in
	1.739999970595818e-05			1.790000032997341e-05			1.7800000023271423e-05		
Schwefel	HMS-PSO			PSO			HMS		
_21									
Ort	4,670017			24,224892			0,926157		
En iyi	4,670016			24,224891			0,926156		
En kötü	4,670018			24,224893			0,926158		
Süre	Program	Executed	in	Program	Executed	in	Program	Executed	in
	1.700000029813964e-05			1.8799999452312477e-05			1.720000000204891e-05		
Step2	HMS-PSO			PSO			HMS		
Ort	0,0000002			0,000003			0,002		
En iyi	0,0000001			0,000002			0,001		
En kötü	0,0000003			0,000005			0,003		
Süre	Program	Executed	in	Program	Executed	in	Program	Executed	in
	1.7500000467407517e-05			1.7999999727180693e-05			1.790000000312375e-05		
Quartic	HMS-PSO			PSO			HMS		
Ort	0,000002			1,000002			4,80E-40		
En iyi	0,000001			1,000001			4,80E-40		
En kötü	0,000003			1,000003			4,80E-40		
Süre	Program	Executed	in	Program	Executed	in	Program	Executed	in
	1.720000000204891e-05			2.080000012938399e-05			1.8000000181928044e-05		

Tablo 5’de HMS-PSO, PSO ve HMS algoritmalarına ait çok modlu kalite testi fonksiyonlarına ait sonuçlar görülmektedir.

Tablo 5. PSO_HMS, PSO ve HMS’ ye Ait Çok Modlu Kalite Testi Fonksiyonları Sonuçları

Schwefel	HMS-PSO	PSO	HMS
Ort.	-32569,4894	10492,4038	-4,00E+196
En iyi	-32569,4895	10492,4036	-4,00E+195
En kötü	-32569,4896	10492,4039	-4,00E+197
Süre	Program Executed in 1.680000059423037e-05	Program Executed in 2.1800000467919745e-05	Program Executed in 1.69999999971169e-05
Rastrigin	HMS-PSO	PSO	HMS
Ort.	133,681573	115,558462	132,650093
En iyi	133,681571	115,558461	132,650090
En kötü	133,681574	115,558463	132,650095
Süre	Program Executed in 1.6600000890321098e-05	Program Executed in 1.8200000340584666e-05	Program Executed in 1.8000000068241206e-05
Ackley	HMS-PSO	PSO	HMS
Ort.	0,105814	4,014728	3,633894
En iyi	0,105811	4,014725	3,633891
En kötü	0,105816	4,014729	3,633895
Süre	Program Executed in 1.590000101714395e-05	Program Executed in 1.739999970595818e-05	Program Executed in 2.0500000005085894e-05
Griewank	HMS-PSO	PSO	HMS
Ort.	1,564497	2,266796	0,230447
En iyi	1,564495	2,266793	0,230444
En kötü	1,564499	2,266798	0,230449
Süre	Program Executed in 1.7099999240599573e-05	Program Executed in 1.739999970595818e-05	Program Executed in 1.8299999965165625e-05

Tablo 6’da HMS-PSO, PSO ve HMS algoritmalarına ait sabit boyutlu çok modlu kalite testi fonksiyonlarına ait sonuçlar görülmektedir.

Tablo 6. HMS-PSO, PSO ve HMS’ ye Ait Sabit Boyutlu Çok Modlu Kalite Testi Fonksiyonları Sonuçları

Branin	HMS-PSO	PSO	HMS
Ort	0,397887	0,397888	0,416598
En iyi	0,397883	0,397887	0,416597
En kötü	0,397889	0,397890	0,416599
Süre	Program Executed in 1.880000127130188e-05	Program Executed in 3.370000013092067e-05	Program Executed in 1.990000009755022e-05
Six_Hump_Camel	HMS-PSO	PSO	HMS
Ort	-1,031624	-1,031626	-1,029027
En iyi	-1,031622	-1,031625	-1,029025
En kötü	-1,031628	-1,031629	-1,029028
Süre	Program Executed in 1.680000059423037e-05	Program Executed in 1.739999970595818e-05	Program Executed in 1.919999996999395e-05
Goldstein Price	HMS-PSO	PSO	HMS
Ort	3,0000000000187	3,000000000014	3,0000000000054
En iyi	3,0000000000184	3,000000000012	3,0000000000050
En kötü	3,0000000000189	3,000000000015	3,0000000000056
Süre	Program Executed in 1.680000059423037e-05	Program Executed in 1.7300000763498247e-05	Program Executed in 1.6599999980826396e-05
Dejong	HMS-PSO	PSO	HMS
Ort	0,001442	0,005425	11,718696
En iyi	0,001441	0,005422	11,718694
En kötü	0,001444	0,005428	11,718699
Süre	Program Executed in 1.6599999071331695e-05	Program Executed in 1.720000000204891e-05	Program Executed in 3.889999999273641e-05

Tablo 7’de diğer kalite test fonksiyonlarına ait algoritmaların sonuçları görülmektedir (Mathworks Erişim Tarihi 2021), (Simon Fraser Üniversitesi Erişim Tarihi 2021).

Tablo 7. Diğer Kalite Test Fonksiyonlarında HMS-PSO, PSO ve HMS’ ye Ait Kalite Testi Sonuçları

Schubert	HMS-PSO	PSO	HMS
Ort	-186,73093	-186,73095	-185,49704
En iyi	-186,73090	-186,73090	-185,49702
En kötü	-186,73098	-186,73098	-185,49706
Süre	Program Executed in 1.7000002117129043e- 05	Program Executed in 1.8700000509852543e- 05	Program Executed in 1.6799999912109342e-05
Whitley	HMS-PSO	PSO	HMS
Ort	0,0425055	0,000355	0,355125
En iyi	0,0425053	0,000351	0,355121
En kötü	0,0425058	0,000358	0,355128
Süre	Program Executed in 1.6599999071331695e- 05	Program Executed in 1.6899999991437653e- 05	Program Executed in 1.670000000331129e-05
Matyas	HMS-PSO	PSO	HMS
Ort	17358,878924	232,867334	4,99E-19
En iyi	17358,878921	232,867331	4,99E-17
En kötü	17358,878929	232,867339	4,99E-18
Süre	Program Executed in 1.6599999071331695e- 05	Program Executed in 2.009999980145949e-05	Program Executed in 1.5999999959603883e-05
Zakharov	HMS-PSO	PSO	HMS
Ort	0,050945	0,050947	0,051647
En iyi	0,050943	0,050945	0,051645
En kötü	0,050949	0,050950	0,051649
Süre	Program Executed in 2.0799998310394585e- 05	Program Executed in 1.7500000467407517e- 05	Program Executed in 1.700000070765964e-05
McCormick	HMS-PSO	PSO	HMS
Ort	-148,672346	-105,566926	-2,736718
En iyi	-148,672344	-105,566924	-2,736716
En kötü	-148,672348	-105,566928	-2,736719
Süre	Program Executed in 1.6600002709310502e- 05	Program Executed in 1.7300000308750896e- 05	Program Executed in 1.7100000150094274e-05
Bohachevsky	HMS-PSO	PSO	HMS
Ort	2734013,571094	3925114,233636	0,0006644
En iyi	2734013,571092	3925114,233634	0,0006642
En kötü	2734013,571096	3925114,233638	0,0006646

Süre	Program Executed in 1.6500001947861165e- 05	Program Executed in 1.7700000171316788e- 05	Program Executed in 2.1000000060666935e-05
Michalewicz	HMS-PSO	PSO	HMS
Ort	-1,919884	-1,9198844	-0,99991
En iyi	-1,919882	-1,9198842	-0,99999
En kötü	-1,919886	-1,9198846	-0,99996
Süre	Program Executed in 1.6900001355679706e- 05	Program Executed in 1.969999938893598e- 05	Program Executed in 1.760000000672335e-05

Önerilen hibrit HMS-PSO algoritması, PSO algoritmasının sömürme ve keşif özelliklerine sahip olup, HMS algoritmasının zihinsel arama özelliğini kullanarak parçacıkları kendi özelinde yerel en iyi çözümde takılı kalmasını engelleyerek, global en iyi çözüme daha çok yaklaşımlarını sağlamak için ortaya konulmuştur.

Zihinsel arama operatöründeki sigma katsayısı her bir parçacığın Levy uçuş dağılımında hareket etmesini sağlar. HMS-PSO algoritmasının performansını PSO ve HMS algoritmaları ile karşılaştırmak için kalite test fonksiyonları kullanılmıştır. Kalite test fonksiyonlarına göre 30 boyut ve 2 boyutta algoritmaların her biri 30 kez çalıştırılmıştır. Bazı uygunluk fonksiyonlarında HMS-PSO ve PSO birbirine yakın sonuçlar vermiştir.

Önerilen HMS-PSO algoritması, PSO ve HMS algoritmalarına göre daha iyi sonuçlar verdiği kalite testi fonksiyonları ile yapılan performans değerlendirmelerinde görülmektedir. Ackley, Griewank, De jong, Schwefel_21, Hyper_Sphere ve Mc Cormick benchmark fonksiyonlarında HMS-PSO diğer algoritmalara göre daha iyi yakınsadığı görülmektedir.

Bununla birlikte HMS-PSO algoritmasının bazı benchmark fonksiyonlarında ise diğerlerine yakın ya da aynı yakınsama değerlerini verdiği görülmektedir. “**No Free Lunch**” teoremine göre meta-sezgisel algoritmaların tüm problemleri çözmesi beklenmez (Wolpert ve Macready 1997).

Bununla birlikte tüm benchmark fonksiyonlarında da iyi sonuç vermeleri beklenmemektedir. Problemin boyutu arttıkça HMS-PSO algoritmasının performansının PSO ve HMS’ ye göre belirgin bir şekilde daha iyi olduğu görülmüştür. Ancak önerilen algoritmanın daha iyi çalışabilmesi için katsayıların düzenlenmesi ve ayarlanması gerekmektedir.

ÜÇÜNCÜ BÖLÜM

YAPAY SİNİR AĞLARI VE DERİN SİNİR AĞLARI

1. YAPAY SİNİR AĞLARI

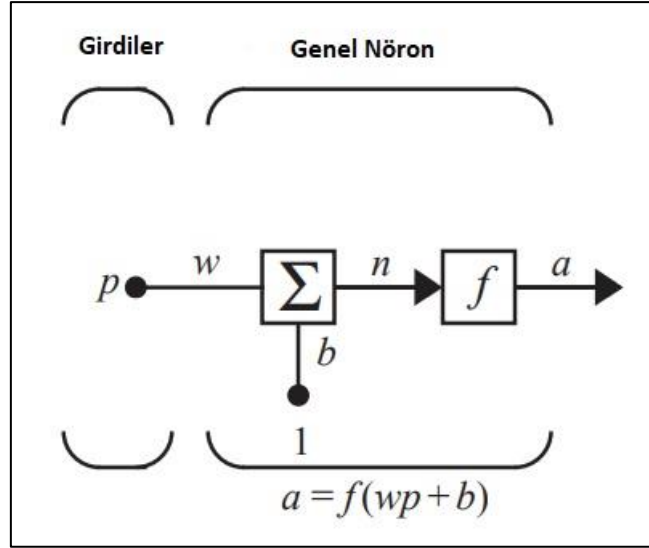
1.1. Yapay Sinir Ağları ve Kullanım Alanları

Yapay sinir ağları, makinelerin insanlara benzer şekilde akıl yürütmesine ve karar vermesine izin veren tekniklerden türetilen matematiksel modeller kullanarak sinir hücrelerinin biyolojik özelliklerini simüle eden yapay zekâ teknikleridir. Bu yapıların çalışma mantığı, insan beyninin paralel ve dağıtılmış işleme yeteneklerine dayanmaktadır ve bu yapıların her biri, kendi bellek işleme parçalarının ağırlıkları ile sınırlandırılmıştır.

Yapay sinir ağları, çeşitli alanlarda karmaşık sorunları ele almak için kullanılmıştır. Örneklerden veri toplayarak ve geçmişte öğrendikleri bilgilere dayanarak çıkarım ve karar verebilen bir yapı inşa ederek genelleme yaparlar. Giriş, gizli katman ve çıkış katmanlarında bu nöronları kullanan model yapılar, onları nöronların temel bileşenleri olarak kullanan yapay sinir ağlarını oluşturur. Girdi-gizli-çıkış katmanı, aktivasyon fonksiyonu, yanlılık ağırlık değerleri ve öğrenme ve eğitim teknikleri bir YSA'nın parçalarıdır.

Şekil 4'te tek girişli bir nöron gösterilmektedir. Aktarılan terimlerden biri de skaler girdinin skaler ağırlıkla çarpılmasıyla oluşmaktadır. Toplam, bir yanlılık değeri ile çarpıldıktan sonra diğer girdiyi almaktadır.

Skaler nöron çıktısı, net girdi olarak da bilinen toplam çıktısını kullanan bir transfer fonksiyonu tarafından oluşturulmaktadır. Bu model eğer bir biyolojik bir nörona uygulanırsa, ağırlık sinapsın gücüne, toplama ve transfer fonksiyonları hücre gövdesine ve nöron çıktısı da aksondaki sinyale benzediği görülmektedir (Hagan ve ark. 2014).



Şekil 4. Tek Girdili Nöron

Nöron çıktısı aşağıdaki şekilde denklem 6' da hesaplanır;


$$a = f(wp + b) \quad (6)$$

Eğer $w=5$, $p=4$ ve $b=1$ olarak alınırsa sonuç,

$$a=f(5(4)+1)=f(21)$$

Böylece seçilen özel transfer fonksiyonunun nihai sonucu belirleyeceği bilinmektedir. 1 sabit girişi dışında, sapmanın bir ağırlığa benzediği söylenebilir. Ancak belirli bir nöronda yanlılık olması istenmiyorsa, bu atlanılabilmektedir. Her ikisinin de değiştirilebilen nöronun skaler parametreleri olduğu bilinmektedir.

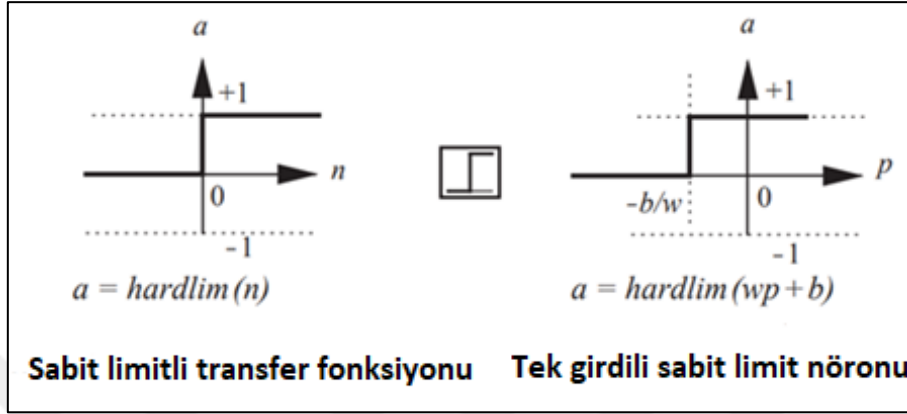
Nöronlar arasındaki girdi ile çıktı ilişkisinin belirli bir amaca ulaşmasını sağlamak için, parametreler herhangi bir öğrenme kuralı tarafından güncellenmeden önce transfer fonksiyonu seçilir. Şekil 5' te transfer lineer ve lineer olmayan transfer fonksiyonu görülmektedir (Abdali ve ark. 2018).



Şekil 5. Lineer ve Lineer Olmayan Transfer Fonksiyonu

Nöronun çözmeye çalıştığı sorunun bazı gereksinimlerini karşılamak için özel bir transfer fonksiyonu seçilmektedir.

Şekil 6’da görülen sabit limit transfer fonksiyonu tarafından 0 ya da fonksiyon argümanı 0’dan büyük veya 0’a eşitse 1 olarak ayarlanmaktadır. Bu özellik nöronları oluşturmak için kullanılmaktadır.



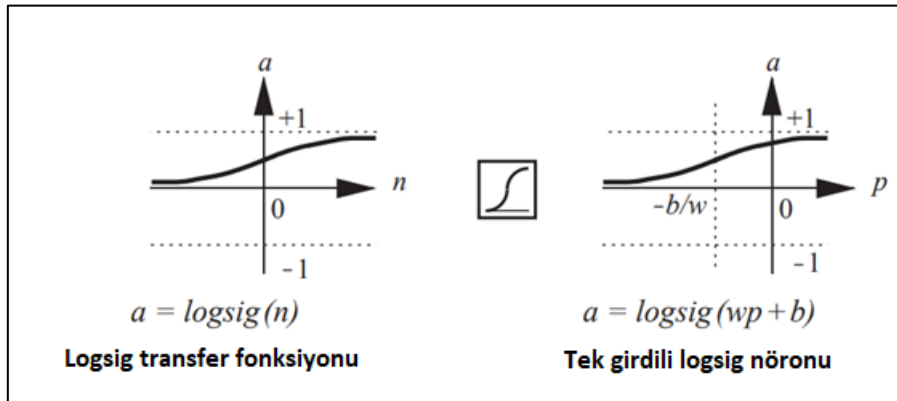
Şekil 6. Sabit Limitli Tek Girdili Sabit Limitli Nöronu

Doğrusal transfer fonksiyonunun çıktısı, denklem 7’de görüldüğü gibi girdisine eşittir:

$$a = n \quad (7)$$

Şekil 7’de ki transfer fonksiyonu girdiyi artı ve eksi sonsuz arasında herhangi bir değere göre, alır ve denklem 8’ e göre çıktıyı 0 ile 1 aralığına indirgemektedir:

$$a = \frac{1}{1 + e^{-n}} \quad (8)$$

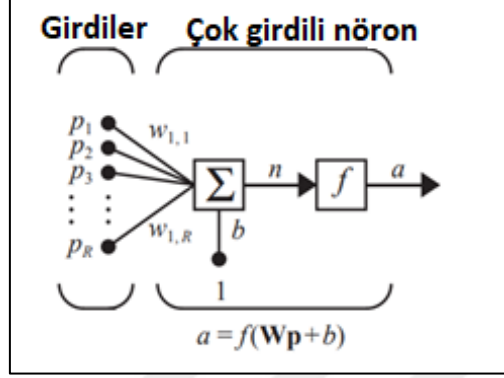


Şekil 7. Logsig transfer fonksiyonu

Logsig transfer fonksiyonu türevlenebilir olması nedeniyle, geriye yayılım algoritması kullanılarak eğitilmiş çok katmanlı ağlarda yaygın olarak kullanılmaktadır. Logsig transfer fonksiyonu denklem 8’ de görülmekte olup, hiperbolik tanjant sigmoid fonksiyonu denklem 9’ da görülmektedir.

$$a = \frac{e^n - e^{-n}}{e^n + e^{-n}} \quad (9)$$

Genellikle, nöronun birden fazla girdisi bulunmaktadır. R girdili bir nöron için her bir girdi p_1, p_2, \dots, p_R olmak üzere, $w_{1,1}, w_{1,2}, \dots, w_{1,R}$ ağırlık matrisi olan W 'nun elemanları ise çok girdili nöron Şekil 8'de görülmektedir.



Şekil 8. Çok Girdili Nöron

Nöron, ağırlıklı girdi ile toplanan bias olan b yanlılık değerine sahiptir. Bununla birlikte net girdi olan n denklem 10'da görülmektedir:

$$n = w_{1,1}p_1 + w_{1,2}p_2 + \dots + w_{1,R}p_R + b \quad (10)$$

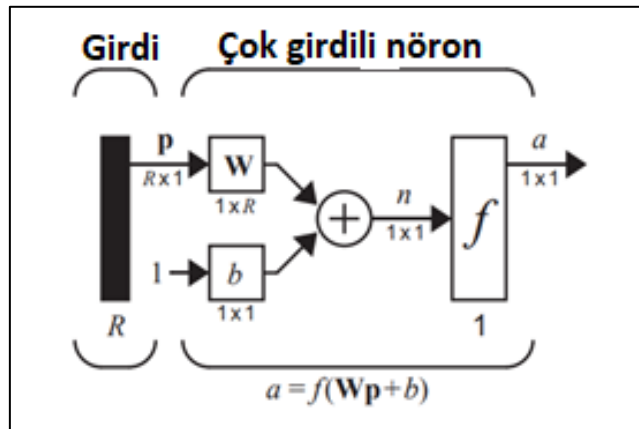
Bu ifade matris formunda yazılırsa denklem 11 ortaya çıkmaktadır:

$$n = W_p + b \quad (11)$$

Nöron çıktısı denklem 12'de görülmektedir;

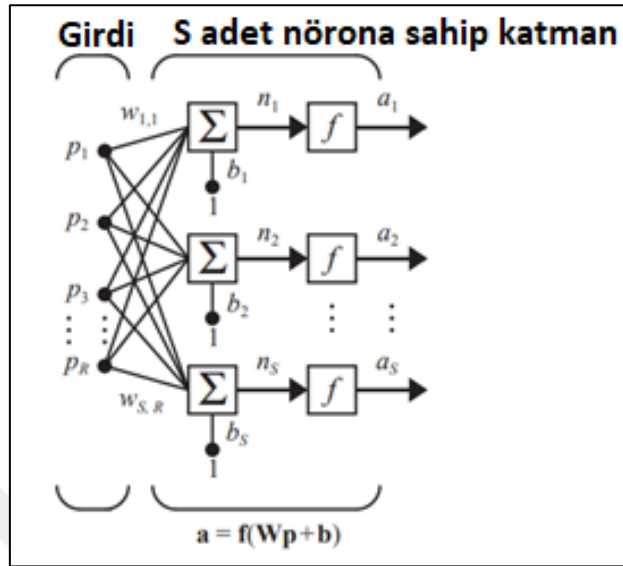
$$a = f(W_p + b) \quad (12)$$

R girdili nörona ait ağırlık ve bias yanlılık değeri toplamı Şekil 9'da görülmektedir.



Şekil 9. Çok Girdili Nöron İle Ağırlık ve Bias Yanlılık Toplamı

Bir katmanda genellikle birden fazla nöron olduğu bilindiğinden, S adet nörona ait bir katman Şekil 10’da görülmektedir.

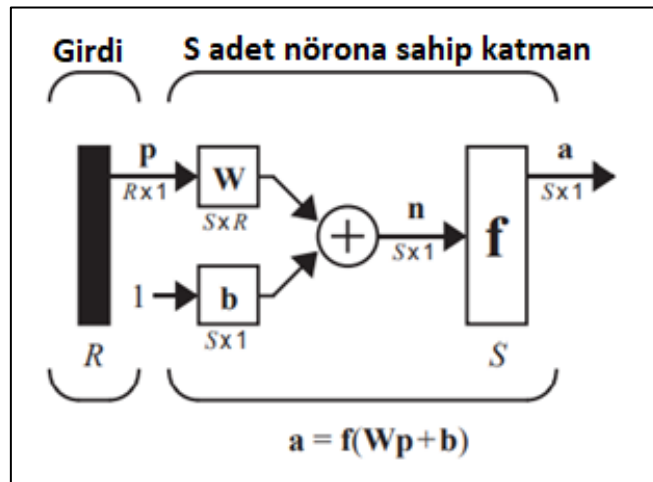


Şekil 10. S Adet Nöronlu Katman

Girdi vektörünün ağırlıklarına ait ağırlık matrisi W denklem 13’ de görülmektedir.

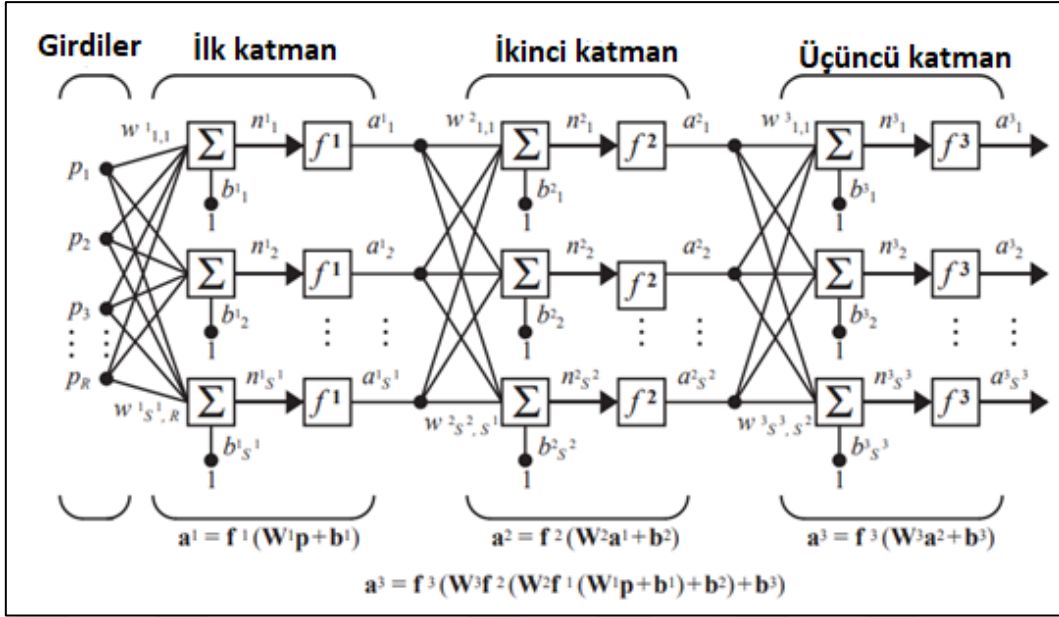
$$W = \begin{bmatrix} w_{1,1} & w_{1,2} & \dots & w_{1,R} \\ w_{2,1} & w_{2,2} & \dots & w_{2,R} \\ \vdots & \vdots & \ddots & \vdots \\ w_{S,1} & w_{S,2} & \dots & w_{S,R} \end{bmatrix} \quad (13)$$

S adet nörona sahip katman ile ağırlık ve bias toplamları Şekil 11’de görülmektedir.



Şekil 11. Girdileri Ağırlıklandırılmış S Nöronlu Katman

Buna göre 3 katmanlı bir ağ yapısı oluşturulmak istenirse, Şekil 12’de görülmektedir.



Şekil 12. 3 Katmanlı Ağ Yapısı

Perceptron kuralını, tek nöronlu bir perceptron ağırlık matrisinin güncellenmesi çok nöronlu bir perceptron için genelleştirilirse denklem 14 ve denklem 15' ten yararlanılmaktadır.

$$i^{w^{yeni}} = i^{w^{eski}} + e_i p \quad (14)$$

Bias yanlılık vektörünün i ' nci elemanı güncellenirse,

$$b_i^{yeni} = b_i^{eski} + e_i \quad (15)$$

Perceptron kuralı matris notasyonu kullanılarak yazıldığında denklem 16 elde edilir,

$$w^{yeni} = w^{eski} + e p^T \quad (16)$$

Hatanın hesaplanmasında denklem 17 kullanılmaktadır,

$$e = t_1 - a \quad (17)$$

Hebb öğrenme kuralına göre, bir A hücresinin aksonu, onu uyarmak ve sık sık veya sürekli olarak ateşlenmesine katılmak için bir B hücrelerine yeterince yakın olduğunda bir veya her iki hücrede bir büyüme süreci veya metabolik değişiklik meydana gelir. Bu, B'yi ateşleyen hücrelerden biri olarak A'nın verimliliğini artırır. Hebb öğrenme kuralında denklem 18, denklem 19 ve denklem 20 kullanılmaktadır.

$$w_{ij}^{yeni} = w_{ij}^{eski} + t_q p_{qj} \quad (18)$$

$$W = t_1 p_1^T + t_2 p_2^T + \dots + t_q p_q^T \quad (19)$$

$$W = [t_1 t_2 \dots t_Q] \begin{bmatrix} p_1^T \\ p_2^T \\ \vdots \\ p_Q^T \end{bmatrix} = TP^T \quad (20)$$

Hebb öğrenme kuralının bir versiyonu olan delta kuralı denklem 21' de görülmektedir.

$$W^{yeni} = W^{eski} + \alpha(t_q - a_q)p_q^T \quad (21)$$

Ağın ortalama karesel hatasının hesaplanabilmesi için denklem 22, denklem 23 ve denklem 24 kullanılmaktadır. Denklem 16' da p ağın girdilerini ve t ağın hedef çıktılarını temsil etmektedir.

$$\{p_1, t_1\}, \{p_2, t_2\}, \dots, \{p_Q, t_Q\} \quad (22)$$

Tek bir vektör içerisinde bias içeren parametreler ayarlanmak istenirse, x

$$x = \begin{bmatrix} 1^w \\ b \end{bmatrix} \quad (23)$$

$$z = \begin{bmatrix} p \\ 1 \end{bmatrix} \quad (24)$$

Ağın çıktısı olan a denklem 25' de görülmektedir.

$$a = 1^w p + b, \quad a = x^T z \quad (25)$$

Hatanın karesi denklem 26 ile hesaplanmaktadır.

$$M(x) = E[e^2] = E[(t - a)^2] = E[(t - x^T z)^2] \quad (26)$$

N ağdaki katman sayısı olmak üzere, n=0,1,...,N-1, çok katmanlı bir ağın ileri yayılımı tek bir katmanın çıktısı denklem 27' de görülmektedir.

$$a^{n+1} = f^{n+1}(W^{n+1}a^n + b^{n+1}), \quad a^0 = p, \quad a = a^M \quad (27)$$

İki bağımsız algorithmadan oluşan bu ağ yapısı, ağın, ağın nasıl çalıştığını ve kalıpları nasıl koruduğunu açıklayan gelişmiş bir besleme ve denetimli eğitim yaklaşımının, girdilerden istenen çıktıyı tahmin edip edemediğini test eder.

Geri yayılım sırasında ağın çıktılarını istenen çıktı değerleriyle karşılaştırarak hatalar hesaplanır. Hatayı düşürmeye çalışmak için, sinir ağının giriş eşiği ve ağırlık parametreleri, tahmin edilen hata değerleri kullanılarak değiştirilir. Geri yayılım hesaplaması, n = N-1, ..., 2, 1 olmak üzere, denklem 28 ve denklem 29' da görülmektedir.

$$s^N = -2F^N(n^N)(t - a), \quad s^n = F^n(n^n)(W^{n+1})^T s^{n+1} \quad (28)$$

$$F^n(n^n) = \begin{bmatrix} f^n(n_1^n) & 0 & \dots & 0 \\ 0 & f^n(n_2^n) & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & \dots & \dots & f^n(n_s^n) \end{bmatrix}, f^n(n_j^n) = \frac{\partial f^n(n_j^n)}{\partial n_j^n} \quad (29)$$

Ağırlık güncellemesi için yaklaşık adım azaltma kullanılırsa denklem 30' da ki gibi hesaplanır.

$$W^n(k+1) = W^n(k) - \alpha s^n (a^{m-1})^T, b^n(k+1) = b^n(k) - \alpha s^n \quad (30)$$

Kullanımda olan çok sayıda sinir ağı mimarisi vardır. Standartlaştırılmış geri yayılım algoritması ile uygulanan çok katmanlı algılayıcı, bunlar arasında en yaygın ve yaygın olarak kullanılan mimaridir. Bir gradyan iniş arama stratejisi kullanan bu algoritmanın, eğer başlangıç ağırlıkları uygun şekilde seçilmezse, yerel optimum çözümlerde takılıp kalması çok olasıdır.

Bununla birlikte, hesaplamalar yavaş ilerleyebilir ve hatta optimumun ötesine geçebilir veya arasında gidip gelebilir. Bu kısıtlamalar, akademisyenleri ideal çözüme daha etkin bir şekilde ulaşmaya, kontrol sisteminin yakınsamasını sağlamaya ve öğrenmeyi hızlandırmaya yardımcı olabilecek daha güçlü optimizasyon stratejileri aramaya yöneltti.

En iyi YSA parametrelerini elde etmek için PSO tekniği önerilmektedir. Bu teknik popülerdir, çünkü birkaç yinelemeyle yakınsak sonuçlar üretir ve hesaplamaları nispeten hızlı hale getirir. PSO, sürü üyeleri arasındaki işbirliği ve rekabetin ürettiği sürü zekâsından yararlanan popülasyon temelli bir yöntemdir. Çok çeşitli arama ve optimizasyon sorunlarını çözmek için başarıyla geliştirilmiştir.

1.2. Yapay Sinir Ağlarının Optimizasyonunda Kullanılan Metasezgisel Algoritmalar

Meta-sezgisel yöntemlerin yapay sinir ağlarının optimizasyonunda kullanıldığı birçok çalışma bulunmaktadır. Deneme yanılma ya da grid araması kullanılarak belirlenen gizli katman yapısı ve nöron sayısı nedeniyle arka planında sabit öğrenme oranıyla çalışan geri yayılım algoritmasına sahip ileri beslemeli sinir ağları yerel minimuma takılı kalma, aşırı öğrenme, yetersiz eğitim ve global minimuma ulaşamama gibi birçok problemle karşı karşıya kalabilmektedir. Bunun sebebi başlangıç ağırlıklarının seçiminde yapılan hatalardır.

Meta-sezgisel algoritmaların ağırlıklarının başlatılmasında kullanılması bu soruna bir çözüm getirmektedir. Barkat ve ark. Başlangıç ağırlıklarının seçimi için Tavuk Sürüsü Optimizasyonu algoritmasını önermişlerdir. Önerdikleri algoritmayı geri yayımlı sinir ağı, yapay arı kolonisi geri yayılımı ve genetik algoritmalı yapay sinir ağı ile karşılaştırmışlardır. Önerdikleri algoritmanın doğruluk ve ortalama karesel hata bakımından diğer algoritmalarından daha iyi sonuç verdiğini ifade etmişlerdir (Barkat ve ark. 2021).

Kawam ve Mansour, denetimli öğrenmede sinir ağlarının eğitiminin etkinliğini arttırmak için optimizasyon problemlerinin çözümünde kullanılan meta-sezgisel algoritmalarından Guguk Kuşu Araması algoritmasını çok katmanlı ileri beslemeli yapay sinir ağına kullanmışlardır. Sınıflandırma problemlerinin çözümünde bu eğittikleri ağı kullanarak ağı doğruluk performansını değerlendirmişlerdir. Elde ettikleri sonuçları Parçacık Sürü Optimizasyonu ve Garantili Yakınsama Parçacık Sürü Optimizasyonu algoritmalarının sonuçları ile karşılaştırmışlardır. 4 farklı sınıflandırma probleminde de önerdikleri yöntemin diğerlerinden daha iyi sonuçlar elde ettiğini ifade etmişlerdir (Kawam ve Mansour 2012).

Irmak ve Gülcü yapay sinir ağının eğitiminde ağırlık ve bias değerlerini optimize etmek için kelebeklerin davranışlarının modellenmesiyle oluşturulan Kelebek Optimizasyon Algoritmasını kullanmışlardır. Önerdikleri modeli Yarasa algoritmalı yapay sinir ağı modeli,

Maddenin Halleri Arama algoritmalı yapay sinir ağı ve geri yayımlı yapay sinir ağı ile karşılaştırmışlardır. Xor, balon, meme kanseri ve kalp veri setlerine uyguladıkları öğrenme modellerinin sonuçlarına göre önerdikleri modelin diğerlerinden daha üstün bir başarı gösterdiğini söylemişlerdir (Irmak ve Gülcü 2021).

Shi ve Li, konut binalarının performansını değerlendirmek için karınca kolonisi optimizasyonu yapay sinir ağlarını kullanmışlardır (Shi ve Li 2009).

Sivagaminathan ve S. Ramakrishnan, Sinir ağları ve karınca kolonisi optimizasyonu kullanarak özellik alt kümesi seçimi için hibrit bir yaklaşım önermişlerdir (Sivagaminathan ve Ramakrishnan 2007).

Socha ve Blum İleri beslemeli sinir ağının eğitiminde Karınca Kolonisi Optimizasyonu algoritmasını kullanmışlardır (Socha ve Blum 2007).

Bunun gibi birçok optimizasyon probleminin çözümünde kullanılan Karınca Kolonisi Optimizasyonu Dorigo ve ark. tarafından geliştirilmiştir (Dorigo, Maniezzo, Colomi 1996).

Beheshti ve Shamsuddin, Newton'un hareket yasalarını temelli PSO'yu Hızlandırılmış Merkezi Parçacık Yerçekimi optimizasyonu ile birleştirerek Merkezci Hızlandırılmış Parçacık sürüsü optimizasyon yöntemini oluşturmuşlardır. Yükseltmiş PSO olarak düşündükleri bu tekniğin, yapay sinir ağının yakınsama ve öğrenme hızını arttırdığını belirtmişlerdir. Tıbbi durumların teşhisinde yapay sinir ağı ile birlikte önerdikleri yöntemi kullanmışlardır (Beheshti ve Shamsuddin 2014).

Mirjalili çok katmanlı algılayıcının eğitiminde Gri Kurt algoritmasını kullanmıştır (Mirjalili 2015).

Brajevic ve Tuba, ileri beslemeli yapay sinir ağının eğitimi için ateş böceği algoritmasını önermişlerdir (Brajevic ve Tuba 2013).

Nandy ve ark. Geri yayımlı yapay sinir ağının eğitimi için doğadan ilham alan ateş böceği algoritmasını önermişlerdir (Nandy ve ark. 2012).

Kovalski ve Lukasik, yapay sinir ağı eğitiminde Krill Sürüsü algoritmasını kullanmışlardır (Kovalski ve Lukasik 2016).

Devikanniga ve Raj, kemik erimesi sınıflandırması için Hükümdar Kelebek Optimizasyonu temelli bir yapay sinir ağı modeli önermişlerdir (Devikanniga ve Raj 2018).

Jaddi ve ark. Değiştirilmiş Yarasadan İlham alan Algoritmayı yapay sinir ağının optimizasyonunda kullanmışlardır (Jaddi ve ark. 2013).

Yaghini ve ark. Meta sezgisel ve açgözlü gradyan tabanlı algoritmaların yeteneklerini bir arada kullanarak momentum koşullu karşıt-tabanlı parçacık sürü optimizasyonu ile hibrit bir geri yayılım algoritması oluşturmuşlardır.

Zamanla değişen parametrenin kullanılmasının standart PSO'nun arama yeteneğini geliştirdiğini ve kısıtlama faktörünün parçacıkların yakınsamasını garanti ettiğini belirtmişlerdir (Yaghini ve ark. 2013).

Alweshah, zaman serisi problemini çözmek için Ateş Böceği Algoritmaları Yapay Sinir Ağı'nı kullanmıştır (Alweshah 2014).

Karaboğa ve Öztürk, örüntü sınıflandırmak için kullandıkları yapay sinir ağını Yapay Arı Kolonisi Algoritması ile eğitmişlerdir (Karaboğa ve Öztürk 2009).

Leung ve ark. Yapay Sinir Ağı'nın yapısının ve parametrelerinin ayarlanması için gelişmiş bir genetik algoritma önermişlerdir (Leung ve ark. 2003).

Yang ve Kao yapay sinir ağının eğitimi için güçlü bir evrimsel algoritma geliştirmişlerdir (Yang ve Kao 2001).

Mirjalili ve arkadaşları Yer Çekimsel Arama ve Parçacık Sürü Optimizasyonu algoritmasını birleştirerek, yapay sinir ağının eğitiminde kullanılmak üzere hibrit bir algoritma önermişlerdir (Mirjalili ve ark. 2012).

Donate ve ark. zaman serisi tahmini için genetik algoritma, diferansiyel evrim ve dağılım tahmini algoritmasını kullanarak evrimleşmiş bir yapay sinir ağı modeli önermişlerdir (Donate ve ark. 2013).

Da ve Xiurun, Benzetimli Tavlama yöntemi ile geliştirilmiş parçacık sürü optimizasyonu temelli bir yapay sinir ağını önermişlerdir (Da ve Xiurun 2005).

Khan ve Sahai e-öğrenme içerikleri için geliştirdikleri ileri beslemeli yapay sinir ağı modelinin eğitiminde Genetik Algoritma ve PSO ile Geri Yayılım algoritmalarını diğer algoritmalar ile karşılaştırmışlardır (Khan ve Sahai 2012).

Parsian ve ark. melanom tespiti için Yapay Sinir Ağı' nı Gri Kurt Optimizasyon Algoritması ile optimize ederek hibrit bir yapay sinir ağı modeli önermişlerdir. Önerdikleri yöntemin Çok Katmanlı Algılayıcı 'nın performansını arttırdığını söylemişlerdir (Parsian ve ark. 2017).

Yelghi ve diğerleri, meta-sezgisel temelli ateşböceği algoritmasının değiştirilmiş bir modelini önermişlerdir. Kümeleme algoritmasının parametrelerinin ayarlanması, ANFIS (Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi), sinir ağları gibi karmaşık problemleri çözmeye çalışan (Yelghi ve Köse 2018), (Yelghi ve ark. 2020), (Kumar ve ark. 2022), (Tavangari ve Yelghi 2022) Finans ve yazılım mühendisliği alanında, karmaşık problemleri (NP sınıfı) çözmek için optimizasyon algoritmaları (Yelghi, Yelghi ve Shahkar 2021), (Yelghi 2011), (Yelghi 2012), (Yelghi ve ark. 2021) uygulamaya çalışmışlardır.

Sonuç olarak, bu problemlerin çözülmesi, diğer gerçek problemlerin uygulanmasında yeni adımlara yol açacaktır.

2. DERİN SİNİR AĞLARI

2.1. Derin Sinir Ağları ve Kullanım Alanları

Makine öğrenmesi yöntemlerinden olan yapay sinir ağlarının ağda birden çok katman kullanılarak doğrusal olmayan problemlerin çözümü için geliştirilen derin öğrenme, farklı ağ mimarilerine sahiptir.

Derin öğrenme yöntemlerinde kullanılan katmanların eğitilebilme, anlaşılabilirlik ve verimlilik anlamında heterojen bir yapıya sahip olmalarına ihtiyaç duyulur. Birden çok katmana ihtiyaç duyulmasının nedeni, ham verilerden yapılacak olan bilgi ve özellik çıkarımının kademeli olarak yapılabilmesini sağlamak içindir (Deng ve Yu 2014).

Kenarları tanımak için alt katmanlar kullanılırken, rakam, harf ve yüz gibi insana ait özellikleri tanımak için daha yüksek katmanlar görüntü işleme uygulamalarında kullanılabilir.

Derin İleri Beslemeli Ağlar(DFFN), Yinelemeli Sinir Ağı(RNN), Uzun Kısa Süreli Bellek(LSTM), Oto-Kodlayıcı(AE), Derin İnanç Ağı(DBN) ve Derin Evrişimli Sinir Ağı(CNN) bunlardan bazılarıdır.

Bu mimariler, bilgisayar ile görü, ses tanıma, doğal dil işleme, makine çevirisi, biyo-informatik ve ilaç tasarlama gibi birçok alanda kullanılmaktadır. Bu yapılar, tıbbi görüntülerin analizi, iklim bilimi, malzeme inceleme ve oyunlarda insanların performansları ile karşılaştırıldığında, onlardan daha iyi sonuç üretebildikleri görülmüştür (Ciresan ve ark. 2012), (Khrizhevsky ve ark. 2012), (TechCrunch 2017).

Günümüzde derin öğrenme yöntemlerinin çoğu Evrişimli Sinir Ağı mimarilerinden oluşmaktadır (Bengio 2009). Derin öğrenmede her bir seviye, girdideki verilerin soyut ve birlikte temsiline dönüştürülmesini öğrenmektedir.

Derin öğrenme yöntemlerinin, görüntü tanıma uygulamasındaki süreçleri ve özelliklerin hangi seviyeye daha uygun olacak şekilde belirlenebileceğini kendi kendine öğrenebilmesi beklenir. Eğer, ham girdiler piksellerden oluşan bir matris olarak tanımlanırsa, ilk temsili katmanın pikselleri soyutlayabilmesi ve kenarları kodlayabilmesi, ikinci katmanın kenar düzenlemeleri oluşturabilmesi, üçüncü katmanın da göz ya da burun gibi özellikleri kodlayabilmesi ve dördüncü katmanın eldeki görüntüde bir yüz olduğunu fark edebilmesi beklenmektedir.

Bu yöntemler, kendi kendine öğrenme süreçlerini içerse de katman sayısı ya da katman boyutu gibi farklı seviyelerde soyutlama sağlayabilen durumlarda el ile ayarlanmaya ihtiyaç duymaktadırlar (Bengio ve ark. 2013), (LeCun, Bengio ve Hinton 2015).

Derin Sinir Ağı'nın derinliği için gizli katmanların sayısı ve çıktı katmanı dahil olmak üzere, iki gizli katmana sahip bir ağ için derinlik 3 olarak ifade edilmektedir. Derinlik

potansiyeli sınırsız olan Tekrarlayan Sinir Ağlarında, katman boyunca bir sinyal birden fazla yayılabilmektedir (Schmidhuber 2015).

Derin öğrenmeyi diğerlerinden ayırabilmek için derinliğin ikiden daha yüksek olması konusunda fikir birliğine varılmıştır (Schigekei 2019). Çok fazla sayıda katmanın olması ağıın fonksiyon yaklaşımına katkıda bulunacağı anlamına gelmemektedir. Derin öğrenme yöntemlerinin sığ yöntemlere göre daha iyi özellikleri çıkarabilmesi ve bu özellikleri öğrenebilmesi bu ekstra katmanlar sayesinde yapılabilmektedir.

Derin Öğrenme mimarileri oluşturulurken açgözlü bir katmanın oluşturulması (Bengio ve ark. 2007), soyutlamanın çözülebilmesine ve performansı iyileştirmede hangi özelliklerin yarar sağlayacağını belirlemede faydalı olur (Bengio ve ark. 2013).

Denetimli öğrenmede kullanılan Derin Öğrenme yöntemleri, verilerin temsilindeki gereksiz olan kısımları ortadan kaldıracı katmanlı yapılar oluştururken, verileri temel bileşenlere benzeyen kompakt ara temsillere dönüştürerek özellik mühendisliğine olan ihtiyacı ortadan kaldırır.

Denetimsiz öğrenmeye uygulanan Derin Öğrenme algoritmalarından Derin İnanç Ağları, etiketlenmemiş verilerden özellik çıkarımını denetimsiz olarak eğitilebilmesi sayesinde gerçekleştirerek bunu bir avantaja dönüştürebilmektedir (Bengio ve ark. 2013), (Hinton 2009).

Bilinen evrensel yaklaşım, sürekli olan fonksiyonlara yaklaşabilmek için sonlu boyutta tek bir gizli katmana sahip olan ileri beslemeli sinir ağıının kapasitesine dayalıdır (Cybenko 1989), (Hornik 1991), (Haykin 1999), (Hassoun 1995).

Cybenko tarafından ortaya konan sigmoid aktivasyon fonksiyonu yaklaşımı Hornik tarafından ileri beslemeli çok katmanlı mimarilerin kullanılmasıyla daha genelleştirilmiştir (Cybenko 1989), (Hornik 1991).

Rosenblatt' ın ise günümüzde kullanılan derin öğrenme yöntemlerinin bütün temel bileşenlerini geliştirdiği kabul edilir (Tappert 2019).

Birden fazla gizli katmana sahip bir Yapay Sinir Ağı, Derin Sinir Ağı olarak bilinmektedir (Bengio 2009), (Schmidhuber 2015).

Tüm sinir ağıları insan beynine benzer şekilde çalışan ve diğer makine öğrenmesi yöntemleri gibi eğitilebilen, nöronlar, nöronlar arasındaki iletişimi sağlayan sinapslar, ağırlıklar, bias ve aktivasyon fonksiyonlarından oluşur (Serokell Erişim Tarihi 2022).

Derin Sinir Ağları, ekstra katmanlar yardımıyla alt katmanlardan gelen özellikleri birleştirerek karmaşık verilerin, sığ bir ağdan daha az birim kullanarak modellenmesini nesneye ait birleşik modeller üreterek sağlayabilmektedir (Bengio 2009), (Szegedy ve ark. 2013).

Bu Derin Sinir Ağlarının karmaşık ve doğrusal olmayan ilişkileri modelleyebildiğini göstermektedir. Derin Sinir Ağlarının bu performansı, seyrek çok değişkenli polinomlarda kanıtlanmıştır (Rolnick ve Tegmark 2018).

Derin ağ mimarileri birden fazla temel yaklaşımın farklı yapılarını barındırır. Aynı veri setleri kullanılmadıkça farklı mimarilerin performanslarının karşılaştırılabilmesi mümkün olmamaktadır.

Derin Sinir Ağları, girdi verilerinin çıktı verilerine geri döngü olmaksızın aktarıldığı ileri beslemeli ağlardır. Başlangıçta bu ağlar, yapay nöronların bir haritasını meydana getirir ve aralarındaki bağlantılara rastgele değişkenler ya da başka bir ifade ile ağırlıklar atar.

Girdilerin ve ağırlıkların çarpılması 0 ve 1 arasında bir çıktının oluşmasını sağlar. Ağın doğru bir şekilde modeli tanıması için ağırlıkların ayarlanması gerekir (Hof 2019). Ağırlıkların ayarlanması, belirli değişkenlerin daha etkin bir hale gelmesiyle verilerin tam olarak işlenmesi için gereken matematiksel uydurma sağlanana kadar devam eder.

Dil modelleme gibi uygulamalar için verilerin herhangi bir yönde akmasına imkân tanıyan Tekrarlayan Sinir Ağları literatürdeki çalışmalarda kullanılmıştır (Gers ve ark. 2001), (Sutskever ve ark. 2014), (Jozefowicz ve ark. 2016), (Gillick ve ark. 2015), (Mikolov 2010).

Uzun Kısa Süreli Bellek kullanımının da bu alanda etkili olduğu söylenebilmektedir (Hochreiter ve Schmidhuber 1997), (Gers ve ark. 2002).

Bilgisayar görüşünde literatürde sıkça kullanıldığı bilinen Derin Evrişimli Sinir Ağlarının akustik modelleme kullanarak otomatik konuşmada kullanıldığı bilinmektedir (LeCun 1998), (Sainath ve ark. 2013).

2.2. Derin Sinir Ağı Mimarileri

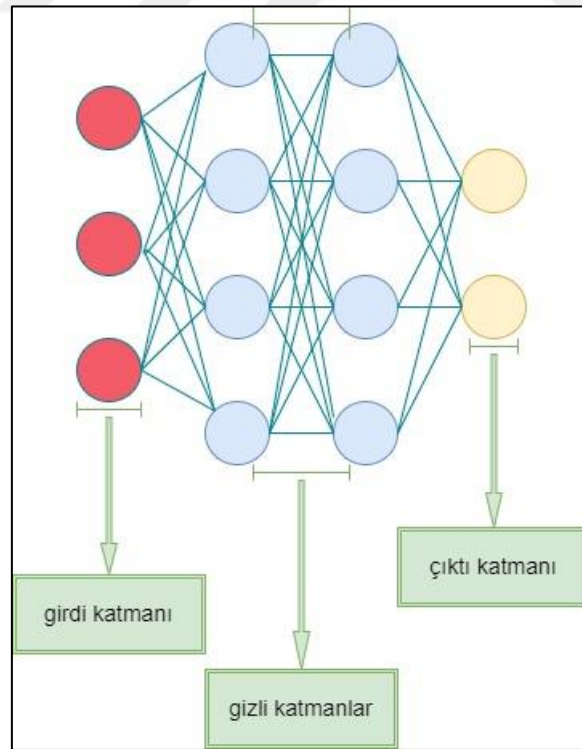
2.2.1. Derin İleri Beslemeli Sinir Ağı

Derin İleri Beslemeli Sinir Ağları(DFFN), verilerin girdi katmanından çıktı katmanına kadar ileriye doğru işlendiği, en az iki gizli katmandan oluşan, tek başına katmanların bir bağlantısının olmadığı, iki art arda gelen katmanın birbiriyle bağlı olduğu ağlardır.

Verilen girdinin bilinen çıktıyı tahmin etmesi ya da sınıflandırmasına dayalı denetimli öğrenmede Derin İleri Beslemeli Sinir Ağları kullanılmaktadır. Hatanın geri yayılımı girdi verisi ile çıktı verisinin karşılaştırılması veya toplam karesel hata (MSE) gibi performans değerlendirme ölçütleri kullanılarak yapılmaktadır.

Gizli katmanlarda yeteri kadar nöron olması, girdi ve çıktı verileri arasında ilişkinin modellenmesine olanak sağlar. Derin İleri Beslemeli Sinir Ağları, diğer ağ mimarileri ile birlikte kullanılarak yeni ağ modellerinin oluşturulmasına imkân tanır (Rosenblatt 1958).

Şekil 13'te derin İleri Beslemeli Sinir Ağı mimarisi görülmektedir. Bu mimari, girdi katmanı, iki gizli katman ve çıktı katmanından oluşmaktadır (Asimov Enstitüsü Erişim Tarihi 2022).



Şekil 13. Derin İleri Beslemeli Sinir Ağı Mimarisi

2.2.2. Yinelemeli Sinir Ağları

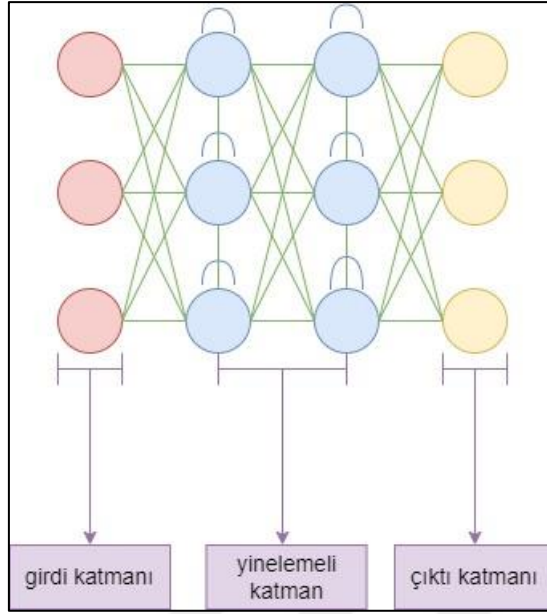
Yinelemeli Sinir Ağları (RNN), durumsuz olmayan, zaman bükülmesine sahip, zaman içerisinde geçişler arasında bağlantıların olduğu, bir önceki geçiş katmanından da bilgi alabilen Derin İleri Beslemeli Sinir Ağlarıdır. Ağın eğitiminin ve girdinin beslenmesinin sırası bu ağ mimarileri için önemlidir. Ağa tek seferde verilen girdi ile ard arda verilen girdiden elde edilen sonuçlar farklı olabilmektedir.

Çok derin bir ağ yapısına sahip Derin İleri Beslemeli Ağların bilgi kaybına benzer şekilde RNN mimarileri de, kullanılan aktivasyon fonksiyonları nedeniyle bilginin zaman içerisinde kaybolması gibi bir patlayan gradyan problemi ile karşı karşıya kalabilmektedir. Bunların yalnızca ağırlıklar olduğu dikkate alındığında ve bu ağırlıkların zaman içerisinde geçmişten gelen bilgilerin depolandığı yerler olmaları sezgisel olarak bir problem ifade etmese de ağırlığın 0 ya da 1000 gibi bir değere ulaşması önceki durumu belirlemede pek bir şey ifade etmemektedir.

Ses ya da video verisi olmayan herhangi bir zaman çizelgesine sahip olmayan birçok veri biçimi bir dizi ile temsil edilebilmektedir. Bu da RNN'lerin birçok alanda kullanılabilmesine olanak sağlamaktadır.

Resim ya da metin dizisi, her defasında bir piksel ya da karakterin beslenmesiyle zamana bağlı ağırlıkların, gerçekte herhangi bir saniyede olmayıp, dizide daha önce gelenler için kullanılabilmesine olanak sağlamaktadır. Otomatik tamamlama gibi bilgileri geliştirmek ya da bilgileri tamamlamak için kullanıldıklarında iyi sonuçlar vermektedirler (Elman 1990).

Şekil 14'te standart bir RNN mimarisi görülmektedir. Bu ağ mimarisi, girdi katmanı, çıktı katmanı ve yinelemeli gizli katmanlardan oluşan bir mimariye sahiptir.



Şekil 14. Yinelemeli Sinir Ağı Mimarisi


2.2.3. Uzun Kısa Süreli Bellek

Uzun Kısa Süreli Bellek (LSTM) Ağı mimarileri, açık bir şekilde tanımlanan bir bellek hücresi kullanan ve geçitlerden oluşan bir yapı kullanırlar. Bu ağlar, genellikle biyoloji yerine elektrik devrelerinden ilham alan yapılardır ve patlayan gradyan problemini çözmeye çalışırlar.

Girdi, çıktı ve unutma kapısı olmak üzere her bir nöronun üç kapısı ve bir hafızaya sahip hücresi bulunmaktadır. Bu kapılar, bilginin akışını durdurmaya ya da bilginin akışına izin vererek bilginin korunmasını sağlarlar. Girdi kapısı, bir önceki katmandan gelen bilgilerin ne kadarının depolanacağına karar verir. Çıktı katmanı, bir sonraki katmanın bu hücrenin durumu ile ilgili sahip olacağı bilgi miktarının belirlenmesine karar verir. Unutma kapısı, ağın önceki bölümünde unutulması gereken bilgileri unutulmasını sağlar.

LSTM'ler müzik bestesi ya da şiir yazımı gibi karmaşık dizilerin öğrenilmesinin gerektiği alanlarda başarı sağlamıştır. Bu mimarilerin çalıştırılabilmesi için çok fazla kaynağa ihtiyaç duyulmaktadır. Bunun nedeni ise, kapıların her birinin bir önceki nörondaki hücreye göre bir ağırlığa sahip olmasıdır (Hochreiter ve Schmidhuber 1997).

Şekil 15'de standart bir LSTM ağı mimarisi görülmektedir. Bu mimari, girdi katmanı, çıktı katmanı ve yinelemeli hafıza katmanlarından oluşmaktadır.



Şekil 15. Uzun Kısa Süreli Bellek Ağ Mimarisi

2.2.4. Oto-Kodlayıcı


Oto-Kodlayıcı(AE) ağ mimarileri, Derin İleri Beslemeli Sinir Ağları'nın farklı kullanım şekline benzer ağ yapıları olarak bilinmektedirler. AE'lerin temel düşüncesi, bilgilerin sıkıştırılmasında olduğu gibi otomatik olarak kodlanmasıdır.

Ağ mimarisi, girdi ve çıktı katmanlarındaki nöron sayısı dikkate alındığında bunlardan daha az nörona sahip gizli katmanlardan oluşmakta ve kum saatini andıran bir şekle benzemektedir.

Tek ya da çift katman sayısına bağlı olarak orta katmanları etrafında simetrik bir yapıya sahip olan AE'lerde bilgi, en çok orta katman olarak ifade edilen küçük katmanlarda sıkıştırılmaktadır. Bu orta katmanlar ağın geçiş noktalarını ifade etmektedirler. Orta kısma kadar olanlar kodlama kısmı, orta kısımdan sonraki olanlar da kod çözme ve orta kod olarak adlandırılmaktadır.

AE'leri eğitmek için girdinin beslenmesi ve girdi ile çıktı arasındaki farkın hata olarak ayarlanması, hatanın geri yayılımının sağlanması ile mümkündür. Ağırlıkların simetrik olacak şekilde oluşturulması kodlama ağırlıklarının kod çözme ağırlıkları ile aynı sayıda olmasına olanak sağlamaktadır (Bourlard ve Kamp 1988).

Şekil 16’da standart bir AE ağ mimarisi görülmektedir. Bu mimari girdi katmanı, gizli katman ve hatanın geri yayılımını sağlayan girdi ve çıktının karşılaştırıldığı girdi-çıkıtı karşılaştırma katmanlarından oluşmaktadır.



Şekil 16. Oto-Kodlayıcı Ağ Mimarisi

2.2.5. Derin İnanç Ağları

Derin İnanç Ağları (DBN), genellikle Kısıtlı Boltzman Makinesi(RBM) ya da Varyasyonel Oto-Kodlayıcılardan (VAE) meydana gelen yığın mimarilerdir. Yığınlar şeklinde etkili olarak eğitilebilen ve ağgözlü öğrenme yöntemine dayalı oluşturulan DBN’ler, AE ya da RBM’nin sadece bir önceki ağı kodlamayı öğrenmesine göre çalışmaktadır.

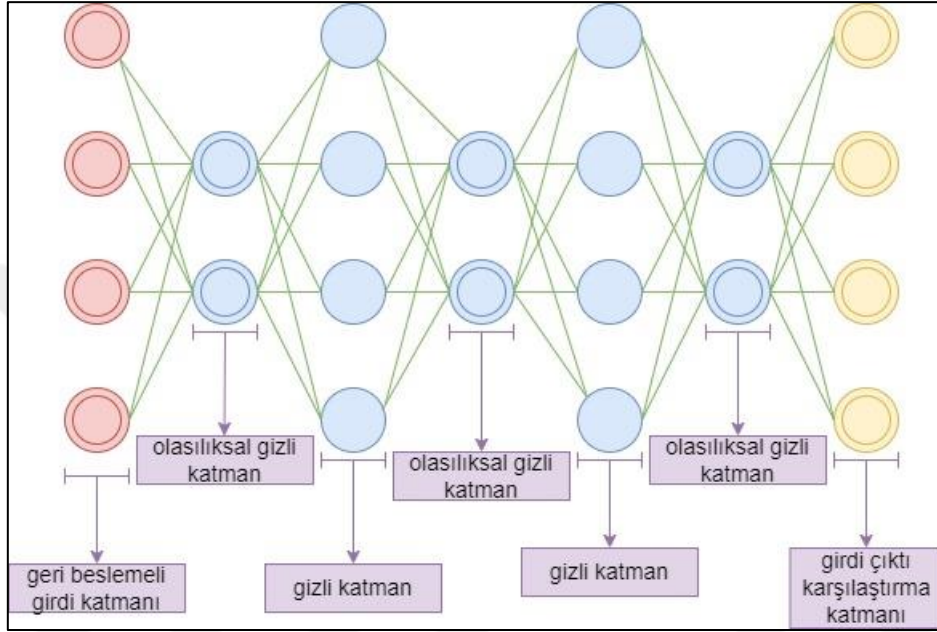
Buradaki öğrenme stratejisi, kabul edilebilir fakat en uygun olmayan bir cevaba ulaşmak için yerel en uygun çözümlerin bulunmasını ifade eder.

Verileri RBM’ler ya da VAE’ler gibi olasılıksal bir model şeklinde temsil etmeyi öğrenme yeteneğine sahip olan DBN’ler, geri yayılım ya da karşılaştırılmalı uzaksama ya da yakınsama ile eğitilebilirler.

Modelin bir kez denetimsiz öğrenme yöntemi kullanılarak eğitilmesi ya da kararlı bir duruma yaklaşması yeni verilerin elde edilmesine olanak sağlayabilmektedir.

Kontrast kullanılarak ıraksama yöntemiyle eğitilen bu mimariler nöronların farklı özellikleri aramasını öğrenmesiyle eldeki mevcut verilerin dahi sınıflandırılabilmesine imkân sağlayabilmektedirler (Bengio 2007).

Şekil 17’de standart bir DBN mimarisi görülmektedir. Bu mimari, geri beslemeli girdi katmanı, girdi-çıkı karşılaştırma katmanı, gizli katmanlar ve olasılıksal gizli katmanlardan oluşmaktadır.



Şekil 17. Derin İnanç Ağı Mimarisi

2.2.6. Derin Evrişimli Sinir Ağı

Derin Evrişimli Sinir Ağları (CNN), görüntü işlemede daha sık kullanılan, bununla birlikte ses vb. diğer veri türlerinde de kullanılabilen Derin İleri Beslemeli Ağlar gibi diğer ağlardan çok farklı ağ mimarisine sahip yapılardır.

CNN, ağın görüntüler ile beslendiği ve ağın verileri sınıflandırdığı yer olarak kullanım durumuna göre ifade edilebilmektedir. Hayvan resimlerinin kendi türlerine göre sınıflandırılabilmesine olanak sağlarlar. Eldeki girdi görüntüsünün sınıfına göre bir çıktı sınıfı elde etmeye imkân tanıyan mimarilerdir.

CNN mimarileri, eğitim verilerinin tamamını tek seferde ayrıştırma hedefinde olmayan bir giriş ile başlatılır. Örnek vermek gerekirse, 100x100 piksel boyutlarındaki bir görüntü verisinin işlenebilmesi için 10000 düğümden oluşan bir katmana ihtiyaç duyulmaz.

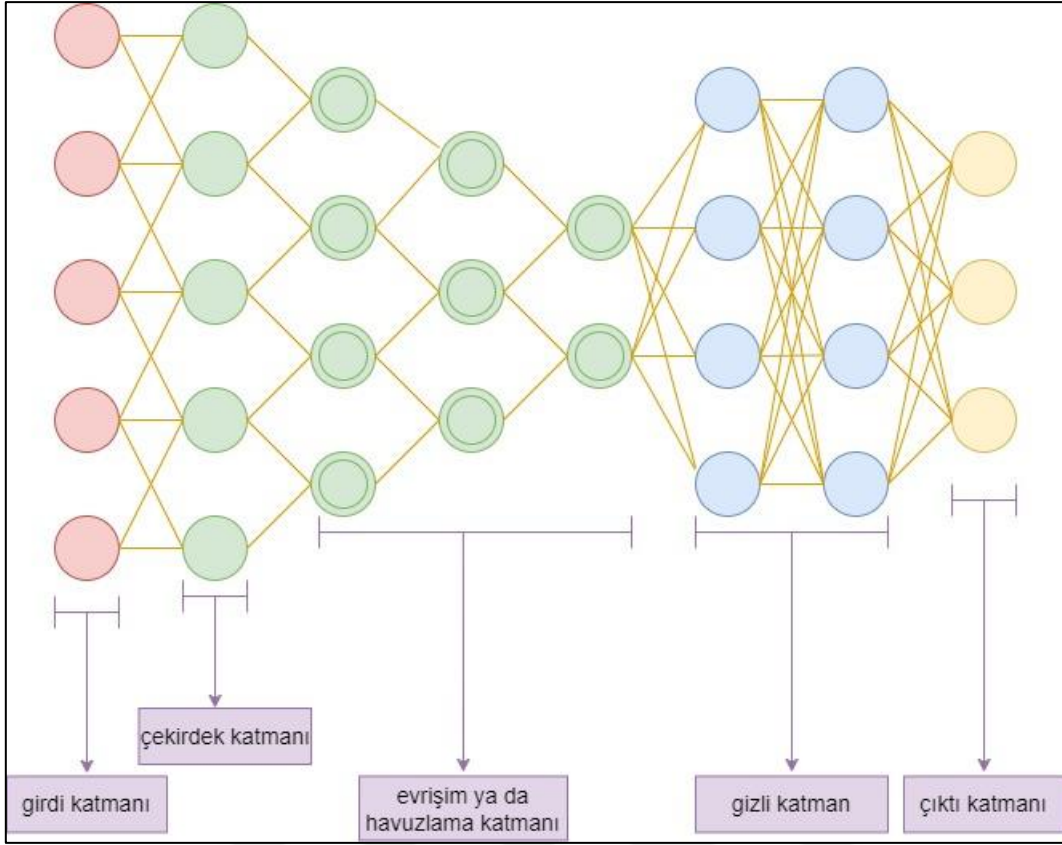
Görüntünün tamamının tek seferde aktarılması yerine, sol üst köşeden başlanarak ilk 10x10 piksellik bir görüntü verisi alınarak 10x10 boyutunda bir tarayıcı girdi katmanı oluşturulur.

Giriş geçildikten sonra, bir diğer 10x10 piksellik görüntü verisi ile giriş katmanı beslenir. Tarayıcı katmana aktarılacak verilerin sağlanması için filtre(tarayıcı) bir piksel sağa kaydırılır. Tarayıcı genişliği ne olursa olsun giriş 20 pikselin üzerinde taşınmaz. Görüntü üzerinde gezinilmesi ile elde edilen girdi verileri tam bağlantılı katmanlar yerine evrişimli katmanlar kullanılarak beslenir.

Her bir düğüm, sadece kendisine komşu olan hücreler ile bağlantılıdır. Bunlar genellikle birkaç taneden fazla değildir. Evrişimli katmanlar girdinin basitçe bölünebilen faktörlerinden dolayı derinleşmesi ile küçülme eğilimi gösterir. Tanımı gereği, 64, 32, 16, 8, 4, 2, 1 şeklinde tam bölünebilme için ikinin kuvvetleri yaygın olarak burada kullanılmaktadır. Evrişim katmanlarının dışında, birleştirme katmanları da bulunmaktadır. Havuzlama işlemi ayrıntıların bir süzgeçten geçirilerek filtrelenmesini sağlar. Maksimum havuzlama tekniği, 2x2 piksellik bir veride en fazla yeşil pikselin iletilmesini gerektiren bir tekniktir.

Ses tanımada CNN mimarilerinin kullanımı temel olarak girdinin verilerin uzunluğu boyunca, parça parça ses dalgaları ile beslenmesiyle gerçekleştirilmektedir. Gerçek dünya problemlerinin çözümünde kullanılan CNN mimarilerinde verilerin daha fazla işlenebilmesi ve doğrusal olmayan bir soyutlama yapılabilmesi için çıktı katmanından önce bir DFFN ağı mimariye eklenir (LeCun 1998).

Şekil 18'de standart bir CNN mimarisi görülmektedir. Bu mimari, girdi katmanı, çıktı katmanı, çekirdek katman, evrişim ya da havuzlama katmanı ve gizli katmanlardan oluşmaktadır.



Şekil 18. Derin Evrişimli Sinir Ağı Mimarisi

DÖRDÜNCÜ BÖLÜM

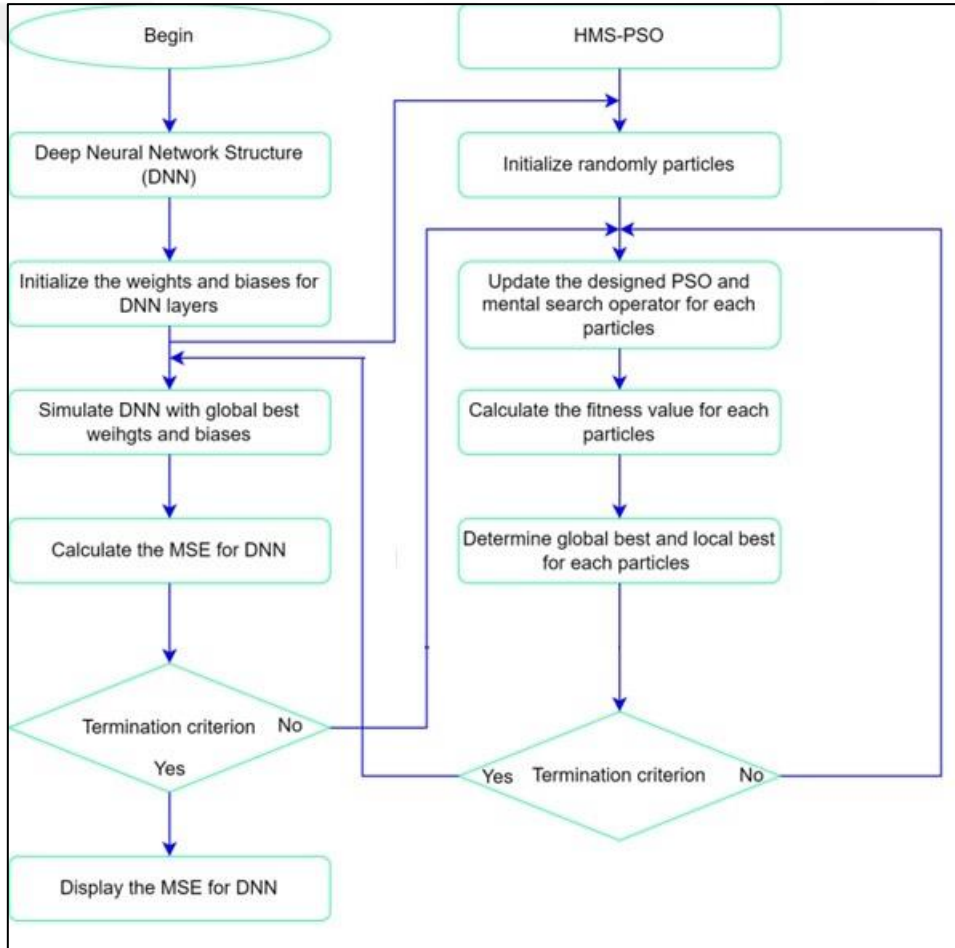
ÖNERİLEN DERİN SİNİR AĞI MODELİ VE DEĞERLENDİRİLMESİ

1. ÖNERİLEN DERİN SİNİR AĞI MODELİ

1.1. Önerilen Derin Sinir Ağı Modelinin Oluşturulması

HMS-PSO algoritması, Sepsis hastalığı tahmini için Sinir Ağı yapılarının ağırlıklarını ve önyargılarını optimize etmek için kullanılır ve bu çalışmada HMS-PSO-DNN olarak adlandırılmıştır.

Şekil 19, HMS-PSO tarafından optimize edilmiş bir Sinir Ağının akış şemasını göstermektedir.



Şekil 19. HMS-PSO Tarafından Optimize Edilmiş DNN Akış Şeması

Sepsis tahmin modeli için 25 alternatif ağ mimarisi değerlendirildi. Model, 1200 satır ve 500 yinelemeden oluşan bir örnek Sepsis veri kümesinde sigmoid aktivasyon fonksiyonu kullanılarak eğitildi.

Ortalama karesel hata (MSE) kriterine göre, en iyi ağ yapısı olarak "24-18-9-3-2" ağ modeli seçilmiştir. Aşağıdaki Tablo 8' de bunu göstermektedir.

Tablo 8. Ağ modelleri

Girdi katmanı nöron sayısı	Gizli katmandaki nöron sayısı	Çıktı katmanındaki nöron sayısı	MSE
24	40-40-20-10-3	2	0,1791
24	20-40-9-6-3	2	0,1791
24	10-40-9-3	2	0,1791
24	10-20-30-5-2	2	0,1791
24	40-40-90-30	2	0,0791
24	50-15-18-3	2	0,1041
24	10-30-10-30	2	0,1041
24	70-35-30-7	2	0,1583
24	10-40-10-5	2	0,1375
24	30-25-10-3	2	0,0875
24	25-15-10-2	2	0,1416
24	21-10-5-3	2	0,175
24	20-20-30-50-50	2	0,0833
24	30-30-70-10	2	0,1791
24	3-15-9-2	2	0,125
24	21-12-9-3	2	0,1291
24	18-9-3	2	0,0791
24	18-12-6	2	0,1333
24	30-50-6-3	2	0,1791
24	15-18-12-3	2	0,1791
24	7-15-9-3	2	0,1416
24	18-12-6-3	2	0,1125
24	9-15-8-3	2	0,1041
24	12-18-9-3	2	0,1541
24	16-8-5-2	2	0,1791

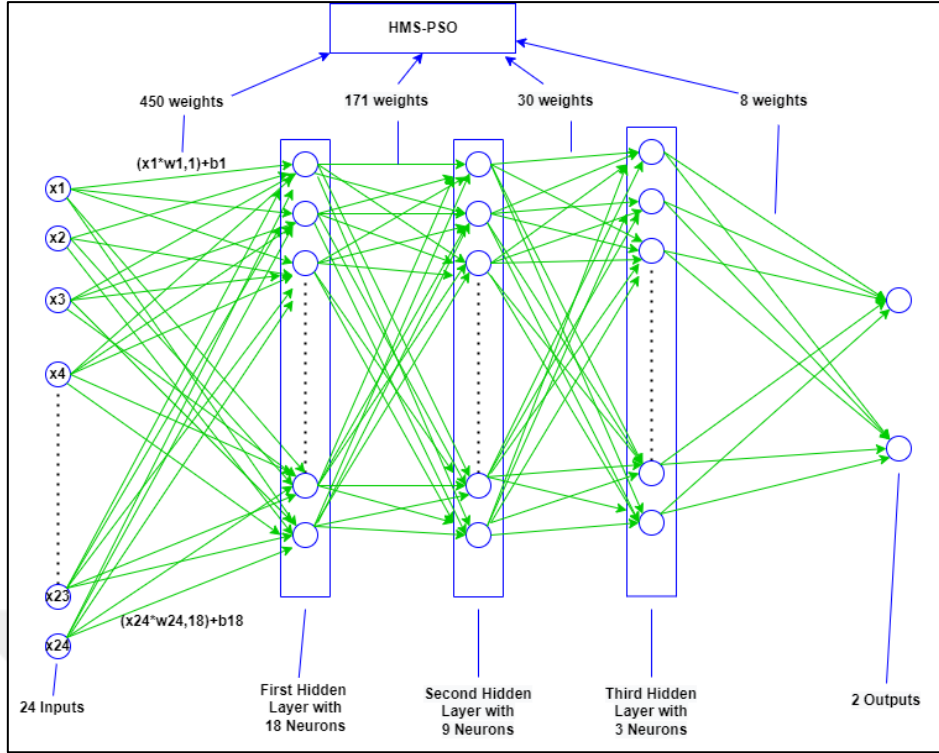
Ortalama karesel hata denklem 31 (Agahian ve Akan 2021), (Rahkar Farshi 2021) ile hesaplanır.

$$MSE = \frac{1}{U} \sum_{U=1}^U (y_u - y_u^l)^2 \quad (31)$$

Ayarlanabilir parametre sayısı denklem 32 ile hesaplanır.

$$(N_i + 1)x|h_1| + (h_1 + 1)x|h_2| + (h_2 + 1)x|h_3| + (h_3 + 1)xN_0 \quad (32)$$

Sonuç olarak 659 ayarlanabilir ağırlık vardır. Şekil 20, HMS-PSO tarafından ağırlıkları optimize edilen Derin Sinir Ağlarının modelini göstermektedir.



Şekil 20. HMS-PSO Algoritması İle Ağırlıkları Optimize Edilmiş Derin Sinir Ağı Mimarisi(HMS-PSO-DNN)

2. VERİ SETİ

2.1. Veri Setinin Oluşturulması

Çalışmanın veri setinde yaşları 18 ile 60 arasında değişen 640 hastanın yaşamsal kayıtları yer aldı. Yoğun bakım ünitesindeki doktorların yönlendirmesiyle veri setini oluşturmak için gerekli parametreler oluşturuldu. Yoğun bakımda geçirilen saat sayısı parametre süresi ile hesaplandı.

Hastanın cinsiyeti ve boyu ile birlikte RR, LYM, LYM100, wbc, neu ve neu y kalış süreleri de dikkate alındı. Hayati işlevler ve kan seviyeleri ayrıca hgb, plt, crp, Procalcitonin, HR, spo2, Temp, BPSYS, bpDias, bpMean, Apache2_ilk, Sofa_ilk ve Apache2_Mort parametreleriyle temsil edilir.

1 saatlik ortalama değerleri temsil eden bu istatistikler, her hasta için 12 saatlik bir veri seti oluşturmak üzere girdi parametreleri olarak kullanıldı. Hasta verileri toplamda 24 giriş parametresini oluşturur. Acil durum ve Sepsis Çıkış parametreleri Sepsis parametrelerini içerir. Veri setindeki eksik değerlerin bıraktığı boşlukları doldurmak için her bir sütunun ortalamaları tahsis edilmiştir. Veri seti 0'dan 1'e normalize edildi. Çıkış değerlerine de sıcak kodlama ve sayısallaştırma uygulanmıştır.

3. BULGULAR VE TARTIŞMA

3.1. Performans Kriterleri

Bu bölümde çalışmanın sonuçlarını ifade etmek için kullanılan performans kriterleri açıklanmıştır. Sınıflandırma, modelin belirli bir girdi verisinin etiketini doğru tahmin etmeye çalıştığı denetim makine öğrenmesi yöntemi olarak bilinmektedir.

Sınıflandırmada model, eğitim verilerini kullanarak eğitilir ve tahmin için de test verileri üzerinde değerlendirilir. Regresyon, bağımsız değişkenler ile bağımlı değişkenler arasındaki ilişkiyi belirlemek için kullanılan bir yöntemdir. Sürekli sonuçları tahmin etmek için makine öğreniminde kullanılmaktadır.

3.1.1. Doğruluk(Accuracy)

Doğruluk, doğru tahmin sayısının toplam tahmin sayısına bölünmesiyle elde edilen bir performans kriteridir. Doğruluk değeri 0 ile 1 arasındadır. Doğruluk hesaplaması, denklem 33' de gösterilmektedir.

$$\text{Doğruluk} = \frac{\text{Doğru Tahminler}}{\text{Tüm Tahminler}} \quad (33)$$

Doğruluk performans kriteri bir sınıfın diğerinden daha büyük olduğu dengesiz veri setlerinde, tek başına model performansını ifade etmek için kullanılırsa yanıltıcı olabilmektedir.

3.1.2. Ortalama Mutlak Hata (MAE)

Ortalama Mutlak Hata, tahmin edilen değerler ile gerçek değerler arasındaki fark olarak bilinmektedir. Bir veri setindeki gerçek değerler ile tahmin edilen değerler arasındaki her bir farkın mutlak değerinin ortalamasıdır.

Denklem 34' te y gerçek değerleri ve y^{\wedge} ise tahmin edilen değerleri göstermek üzere MAE aşağıdaki şekilde hesaplanır.

$$MAE = \frac{1}{N} \sum_{i=0}^n |y_i - y^{\wedge}_i| \quad (34)$$

3.1.3. Ortalama Karesel Hata (MSE)

Ortalama Karesel Hata, tüm veri setinde her bir örnek için ortalama kare kaybıdır. MSE, her bir örnek için olan karesel kayıpların toplanıp örnek sayısına bölünmesiyle hesaplanmaktadır.

Denklem 35' de x tahmin edilen özelliği, tahmin(x) x özelliğine göre tahmin edilen değeri, y gerçek değeri ve N örnek sayısını ifade etmek üzere MSE hesaplaması aşağıdaki şekildedir.

$$MSE = \frac{1}{N} \sum_{(x,y) \in D} (y - tahmin(x))^2 \quad (35)$$

3.1.4. Kök Ortalama Karesel Hata (RMSE)

Hatanın karekökü olan RMSE, tahmin hatalarının standart sapmasıdır. Hatalar, veri noktalarının regresyon doğrusuna olan uzaklığının ölçütüdür. RMSE, hataların ne kadar dağıldığını ölçmek için kullanılır. Verilerin en uygun doğru etrafında ne kadar yoğunlaştığını ifade etmemize yarar.

Denklem 36' da f tahminleri ve o da gözlemlenen değerleri ifade etmek üzere RMSE hesaplaması aşağıdaki şekilde yapılır.

$$RMSE = \sqrt{(f - o)^2} \quad (36)$$

3.1.5. Karmaşıklık Matrisi (CM)

Karmaşıklık Matrisi (CM), modelin hangi yönden doğru veya yanlış olduğu kısımları gözlemek için kullanılan bir performans kriteridir. Her sınıf için doğru ve yanlış tahmin sayısını karşılaştırır.

Bu matriste bulunan unsurlar;

Doğru Pozitif (TP), modelin pozitif olarak doğru tahminleridir.

Yanlış Pozitif(FP), modelin pozitif olarak yanlış tahmin ettiği negatiflerdir.

Doğru Negatif(TN), modelin doğru yaptığı negatif tahminlerdir.

Yanlış Negatif(FN), modelin yanlış olarak tahmin ettiği pozitiflerdir. Şekil 21'de Karmaşıklık Matrisi görülmektedir.

		Actual Values	
		Positive (1)	Negative (0)
Predicted Values	Positive (1)	TP	FP
	Negative (0)	FN	TN

Şekil 21. Karmaşıklık Matrisi

3.1.6. Kesinlik (Precision)

Kesinlik, modelin pozitif sınıfı doğru bir şekilde tanımlamada ne kadar iyi olup olmadığını ölçmektir. Pozitif tahminlerden kaçının doğru olduğunu bulmak için kullanılır. Bir modeli optimize etmek için bu metrik kullanıldığında modeldeki yanlış pozitiflerin sayısı azaltılmış olur.

Doğruluk Denklem 37’de ki gibi hesaplanır.

$$Precision = \frac{TP}{(TP+FP)} \quad (37)$$

3.1.7. Duyarlılık(Recall)

Modelin veri kümesindeki tüm olumlu gözlemleri doğru bir şekilde tahmin etmede ne kadar iyi olduğunu bulmamıza yarar. Ancak yanlış pozitifler hakkında bilgi vermez.

Duyarlılık hesaplaması denklem 38’de görülmektedir.

$$Recall = \frac{TP}{(TP+FN)} \quad (38)$$

Genel anlamda kesinlik ve duyarlılık model performansının değerlendirilmesi için birlikte gözlemlenmesi gereken performans metrikleridir.

3.1.8. F1 Puanı(F1-Score)

Kesinlik ve duyarlılığın harmonik ortalaması olan F1 puanı, 0 ile 1 arasında bir değerdir. F1 puanının 1 olması mükemmel şekilde kesinlik ve duyarlılığı ifade etmektedir. F1 puanının 0 olması ise kesinliğin ya da duyarlılığın 0 olduğu anlamına gelmektedir.

F1 puanı denklem 39’da ki gibi hesaplanmaktadır.

$$F1 = 2 * \frac{(precision*recall)}{(precision+recall)} \quad (39)$$

3.1.9. Destek(Support)

Destek, her bir hedef değer sınıfında yer alan gerçek yanıtın örnek sayısı olarak tanımlanabilmektedir.

3.1.10. R-Kare (R-Squared)

R-Kare, belirleme katsayısı olarak da bilinir ve verilerin yerleştirildiği regresyon doğrusuna ne kadar yakın olduğunun istatistiksel bir ölçüsüdür. Aynı veri setindeki yüksek R-Kare değeri gözlemlenen veriler ile uyarlanan değerler arasındaki daha küçük farkları ifade etmektedir.

R-Kare, bir regresyon modelinin verilere yeterli uyum sağlayıp sağlamadığını göstermektedir. İyi bir model düşük bir R-Kare değerine sahip olabilirken, yanlış bir model de yüksek bir R-Kare değerine sahip olabilir.

R-Kare denklem 40'da ki gibi hesaplanır.

$$R^2 = 1 - \frac{\text{Belirlenen Değişken}}{\text{Toplam Değişken}} \quad (40)$$

3.1.11. Alıcı Çalışma Karakteristik Eğrisi (ROC)

Alıcı Çalışma Karakteristik Eğrisi, modelin tüm sınıflandırma eşiklerindeki performansının yani doğru pozitif ve yanlış pozitif oranının grafiği şeklinde ifade edilmektedir. Farklı sınıflandırma algoritmalarını karşılaştırmak ve değerlendirmek için kullanılırlar. Dengesiz veri seti olan uygulamalarda daha sık kullanılmaktadırlar.

3.1.12. Eğri Altında Kalan Alan(AUC)

Eğri Altında Kalan Alan (AUC), eğrinin altındaki tüm iki boyutlu alanın ölçümü olup, bu yüzden modelin tüm olası sınıflandırma eşiklerindeki performansının ölçüsünü gösterir. AUC ne kadar yüksek olursa, modelin sınıflar arasında ayırım yapma performansı o kadar başarılı olur.

Genel olarak 0.5 değere sahip bir AUC, modelin ayırım yapamadığını gösterirken, 0.7'nin üzerindeki bir AUC değeri modelin kullanabilir modeli ifade etmektedir.

3.1.13. Standart Sapma

Bir olasılık dağılımı ya da rassal bir değişkenin veri değerlerini özetlemek için kullanılan bir ölçüttür. Standart sapmanın varyansın kare kökü olduğu bilinmektedir. Standart sapma niceliksel ölçekli sayılar için en çok kullanılan verilerin ortalamaya göre yayılmasını gösterir.

Denklem 42’de $E(x)$ x için beklenen değer ve $Var(x)$ x için varyans değerini ifade ettiği bilindiğinden, standart sapma aşağıdaki gibi hesaplanmaktadır.

$$\text{Standart Sapma} = \sqrt{E(x^2) - (E(x))^2} = \sqrt{Var(x)} \quad (42)$$

3.1.14. Varyans

Mümkün olan tüm değerlerin beklenen değer ya da ortalamadan uzaklıklarının karelerinin ortalaması şeklinde bulunan bir ölçüttür. Ortalama bir dağılımın merkezi konum noktasını bulmaya çalışırken, varyans değerlerin hangi ölçekte ya da ne kadar yaygın olduklarını tanımlamaya odaklanır. Gerçek değişkenin biriminin karesi varyans için ölçüm birimini ifade etmektedir.

Değişkenin beklenen değeri $E(x)$ olmak üzere, varyans aşağıdaki denklem 43 ile hesaplanır.

$$Var(x) = E((x - E(x))^2) \quad (43)$$

3.2. Benchmark Veri Setleri Sonuçları

Benchmark veri setleri olan kalp yetmezliği (Chicco ve Jurman 2020), kriyoterapi, immunoterapi (Khozeimeh ve ark. 2017), (Khozeimeh ve ark. 2017) ve diyabet (Bendi ve ark. 2011), (Bendi ve ark. 2012) veri setleri de HMS-PSO-DNN algoritmasının etkinliğini göstermek için kullanılmıştır.

Yapılan çalışmalarda her bir algoritma için 15 bağımsız çalışma kullanılarak test edilmiştir. Tablo 9, Tablo 10, Tablo 11, Tablo 12, Tablo 13, Tablo 14, Tablo 15 ve Tablo 16,

HMS-PSO-DNN ve diğer algoritmaların performans karşılaştırma sonuçlarını göstermektedirler.

Tablolarda koyu renkli olarak gösterilen sonuçlar algoritmaların en iyi performansı vurgulamaktadır. Tablo 9’da kalp yetmezliği veri setindeki HMS-PSO-DNN algoritmasının 15 bağımsız çalışmasındaki performansı görülmektedir.

Tablo 9. HMS-PSO-DNN Kalp Yetmezliği Veri Setindeki Performansı

HMS-PSO-DNN	MAE	MSE	RMSE	precision-0	precision-1	recall-0	recall-1	f1-score-0	f1-score-1	AUC
1	0,2166	0,2166	0,4654	0,76	0,83	0,91	0,6	0,83	0,7	0,7571
2	0,2333	0,2333	0,483	0,74	0,82	0,91	0,56	0,82	0,67	0,7371
3	0,2166	0,2166	0,46547	0,79	0,77	0,86	0,68	0,82	0,72	0,7685
4	0,2166	0,2166	0,4654	0,74	0,93	0,97	0,52	0,84	0,67	0,7457
5	0,25	0,25	0,5	0,73	0,81	0,91	0,52	0,81	0,63	0,7171
6	0,2166	0,2166	0,4654	0,75	0,88	0,94	0,56	0,84	0,68	0,7514
7	0,2333	0,2333	0,48304	0,73	0,87	0,94	0,52	0,83	0,65	0,7314
8	0,25	0,25	0,5	0,75	0,75	0,86	0,6	0,8	0,67	0,7285
9	0,2	0,2	0,4472	0,77	0,88	0,94	0,6	0,85	0,71	0,7714
10	0,25	0,25	0,5	0,73	0,81	0,91	0,52	0,81	0,63	0,7171
11	0,2166	0,2166	0,4654	0,81	0,75	0,83	0,72	0,82	0,73	0,7742
12	0,183	0,183	0,4281	0,77	0,94	0,97	0,6	0,86	0,73	0,7857
13	0,2333	0,2333	0,48304	0,76	0,79	0,89	0,6	0,82	0,68	0,7428
14	0,2	0,2	0,4472	0,79	0,81	0,89	0,68	0,84	0,74	0,7828
15	0,2166	0,2166	0,4654	0,76	0,83	0,91	0,6	0,83	0,7	0,7571

Adam, Adadelta, SGD ve RMS-PROP, Derin Sinir Ağlarının ağırlıklarının optimizasyonunda kullanılan gradyan temelli ve türevlenebilir algoritmalarıdır. Bu algoritmaların literatürde birçok kullanımı mevcuttur.

Tablo 10’da HMS-PSO-DNN algoritması ve diğer algoritmaların kalp yetmezliği veri setindeki ortalama performansları görülmektedir.

Tablo 10. Algoritmaların Kalp Yetmezliği Veri Setindeki Performansları

	mse_ort	rmse_ort	pre-0_ort	pre-1_ort	recall-0_ort	recall-1_ort	f1-0_ort	f1-1_ort	auc_ort
Adam	0,41666	0,64549	0,58	0	1	0	0,74	0	0,5
Adadelta	0,460817	0,676407	0,425333	0,112	0,733333	0,266667	0,542667	0,157333	0,5
HMS	0,4166	0,645	0,58	0	1	0	0,74	0	0,5
HMS-PSO-DNN	0,222167	0,470937	0,758667	0,831333	0,90933333	0,592	0,828	0,687333	0,751193
PSO	0,35861	0,59623	0,62800	0,38733	0,97067	0,17867	0,76467	0,23933	0,57503
RMS_PROP	0,246493	0,495579	0,753333	0,708	0,907333	0,484	0,824	0,570667	0,696
SGD	0,333	0,5773	0	0,67	0	1	0	0,8	0,5

Tablo 11’de HMS-PSO-DNN algoritmasının diyabet veri setindeki 15 bağısız çalışmasındaki performansı görülmektedir.

Tablo 11. HMS-PSO-DNN Algoritmasının Diyabet Veri Seti Performansı

HMS-PSO-DNN	MAE	MSE	RMSE	precision-0	precision-1	recall-0	recall-1	f1-score-0	f1-score-1	AUC
1	0,2714	0,2714	0,5209	0,66	0,85	0,88	0,59	0,75	0,7	0,7366
2	0,25714	0,25714	0,507	0,67	0,85	0,88	0,62	0,76	0,72	0,7502
3	0,2714	0,2714	0,5209	0,69	0,76	0,76	0,7	0,72	0,73	0,7301
4	0,2714	0,2714	0,5209	0,65	0,88	0,91	0,57	0,76	0,69	0,7383
5	0,2714	0,2714	0,5209	0,68	0,8	0,82	0,65	0,74	0,72	0,7334
6	0,2285	0,2285	0,478	0,7	0,89	0,91	0,65	0,79	0,75	0,7788
7	0,2571	0,2571	0,507	0,67	0,85	0,88	0,62	0,76	0,72	0,7502
8	0,2714	0,2714	0,5209	0,64	0,95	0,97	0,51	0,77	0,67	0,7416
9	0,2714	0,2714	0,5209	0,67	0,82	0,85	0,62	0,75	0,71	0,735
10	0,2857	0,2857	0,5345	0,64	0,84	0,88	0,57	0,74	0,68	0,7231
11	0,2714	0,2714	0,5209	0,68	0,8	0,82	0,65	0,74	0,72	0,7334
12	0,2714	0,2714	0,5209	0,65	0,88	0,91	0,57	0,76	0,69	0,7383
13	0,2428	0,2428	0,4928	0,68	0,88	0,91	0,62	0,78	0,73	0,7653
14	0,2857	0,2857	0,5345	0,7	0,73	0,7	0,73	0,7	0,73	0,7133
15	0,2571	0,2571	0,507	0,67	0,85	0,88	0,62	0,76	0,72	0,7502

Tablo 12’de algoritmaların diyabet veri setindeki performanslarının ortalamaları görülmektedir.

Tablo 12. Algoritmaların Diyabet Veri Seti Performans Ortalaması

	mse_ort	rmse_ort	pre-0_ort	pre-1_ort	recall-0_ort	recall-1_ort	f1-0_ort	f1-1_ort	auc_ort
Adam	0,3914	0,62028	0,276	0,636	0,318	0,868	0,292667	0,703333	0,594
Adadelta	0,5	0,707	0,5	0	1	0	0,67	0	0,5
HMS	0,5285	0,727	0,47	0	1	0	0,64	0	0,5
HMS-PSO-DNN	0,265683	0,5152	0,67	0,842	0,864	0,619333333	0,752	0,712	0,741187
PSO	0,31424	0,55931	0,63467	0,76600	0,78800	0,59600	0,70067	0,66867	0,69107
RMS_PROP	0,38662	0,614687	0,476	0,555333	0,526667	0,7	0,477333	0,608	0,612
SGD	0,533287	0,729093	0,078	0,388667	0,2	0,8	0,112667	0,522	0,5

Tablo 13’de HMS-PSO-DNN algoritmasının kriyoterapi veri setinde 15 bağımsız çalışmasındaki performans sonuçları görülmektedir.

Tablo 13. HMS-PSO-DNN Algoritmasının Kriyoterapi Veri Seti Performansı

HMS-PSO-DNN	MAE	MSE	RMSE	precision-0	precision-1	recall-0	recall-1	f1-score-0	f1-score-1	AUC
1	0,16	0,16	0,408	0,8	0,88	0,89	0,79	0,84	0,82	0,833
2	0,16	0,16	0,408	0,75	1	1	0,67	0,86	0,8	0,833
3	0,11	0,11	0,33	0,89	0,89	0,89	0,89	0,89	0,89	0,888
4	0,16	0,16	0,408	0,75	1	1	0,67	0,86	0,8	0,833
5	0,16	0,16	0,408	0,75	1	1	0,67	0,86	0,8	0,833
6	0,11	0,11	0,33	0,82	1	1	0,78	0,9	0,88	0,888
7	0,11	0,11	0,33	0,82	1	1	0,78	0,9	0,88	0,888
8	0,16	0,16	0,408	0,8	0,88	0,89	0,78	0,84	0,82	0,833
9	0,16	0,16	0,408	0,8	0,88	0,89	0,78	0,84	0,82	0,833
10	0,11	0,11	0,33	0,82	1	1	0,78	0,9	0,88	0,888
11	0,16	0,16	0,408	0,8	0,88	0,89	0,78	0,84	0,82	0,833
12	0,11	0,11	0,33	0,82	1	1	0,78	0,9	0,88	0,888
13	0,11	0,11	0,33	0,82	1	1	0,78	0,9	0,88	0,888
14	0,11	0,11	0,33	0,82	1	1	0,78	0,9	0,88	0,888
15	0,05	0,05	0,235	0,9	1	1	0,89	0,95	0,94	0,944

Tablo 14’de algoritmaların kriyoterapi veri seti performans ortalamaları görülmektedir.

Tablo 14. Algoritmaların Kriyoterapi Veri Seti Performans Ortalamaları

	mse_ort	rmse_ort	pre-0_ort	pre-1_ort	recall-0_ort	recall-1_ort	f1-0_ort	f1-1_ort	auc_ort
Adam	0,164	0,412227	0,752	0,982667	0,985333	0,677333	0,854667	0,798	0,826667
Adadelta	0,77	0,88	0,22	0	1	0	0,36	0	0,5
HMS	0,5	0,707	0,5	0	1	0	0,67	0	0,5
HMS-PSO-DNN	0,129333	0,360067	0,810667	0,960667	0,963333333	0,773333333	0,878667	0,852667	0,866067
PSO	0,20711	0,45127	0,75600	0,85400	0,85267	0,72867	0,79600	0,77800	0,78833
RMS_PROP	0,222733	0,466533	0,764667	0,79	0,764667	0,807333	0,746667	0,786	0,786
SGD	0,486667	0,694933	0,018667	0,492	0,066667	0,933333	0,028667	0,642667	0,5

Tablo 15’de HMS-PSO-DNN algoritmasının immunoterapi veri setinde 15 bağımsız çalışmasındaki performans sonuçları görülmektedir.

Tablo 15. HMS-PSO-DNN Algoritmasının İmmunoterapi Veri Seti Performans Sonuçları

HMS-PSO-DNN	MA E	MS E	RMS E	precision-0	precision-1	recall-0	recall-1	f1-score-0	f1-score-1	AU C
1	0,22	0,22	0,471	0,67	0,8	0,4	0,92	0,5	0,86	0,66
2	0,11	0,11	0,33	1	0,87	0,6	1	0,75	0,93	0,8
3	0,22	0,22	0,471	0,67	0,8	0,4	0,92	0,5	0,86	0,66
4	0,16	0,16	0,408	1	0,81	0,4	1	0,57	0,9	0,7
5	0,16	0,16	0,408	1	0,81	0,4	1	0,57	0,9	0,7
6	0,16	0,16	0,408	1	0,81	0,4	1	0,57	0,9	0,7
7	0,16	0,16	0,408	0,75	0,86	0,6	0,92	0,67	0,89	0,76
8	0,22	0,22	0,471	1	0,76	0,2	1	0,33	0,87	0,6
9	0,22	0,22	0,471	1	0,76	0,2	1	0,33	0,87	0,6
10	0,22	0,22	0,471	1	0,76	0,2	1	0,33	0,87	0,6
11	0,22	0,22	0,471	0,67	0,8	0,4	0,92	0,5	0,86	0,66
12	0,16	0,16	0,408	0,75	0,86	0,6	0,92	0,67	0,89	0,76
13	0,22	0,22	0,471	0,6	0,85	0,6	0,85	0,6	0,85	0,72
14	0,22	0,22	0,471	0,6	0,85	0,6	0,85	0,6	0,85	0,72
15	0,22	0,22	0,471	1	0,76	0,2	1	0,33	0,87	0,6

Tablo 16’ da algoritmaların immunoterapi veri setindeki performans sonuçlarının ortalamaları görülmektedir.

Tablo 16. Algoritmaların immunoterapi veri seti performans ortalamaları

	mse_ort	rmse_ort	pre-0_ort	pre-1_ort	recall-0_ort	recall-1_ort	f1-0_ort	f1-1_ort	auc_ort
Adam	0,27	0,527	0,4	0,776	0,32	0,88	0,352	0,816	0,596
Adadelta	0,22	0,471	0	0,78	0	1	0	0,88	0,5
HMS	0,72	0,849	0,28	0	1	0	0,43	0	0,5
HMS-PSO-DNN	0,192667	0,4406	0,847333	0,810667	0,41333333	0,95333333	0,521333	0,878	0,682667
PSO	0,23600	0,48747	0,59933	0,77400	0,28000	0,94333	0,35933	0,85133	0,61067
RMS_PROP	0,326	0,5704	0,189333	0,725333	0,12	0,879333	0,146	0,793333	0,496
SGD	0,27	0,527	0	0,72	0	1	0	0,84	0,5

4. SEPSİS TAHMİNİ SONUÇLARI

4.1. Sepsis Tahmininde Kullanılan Algoritmaların Performans Sonuçları

12 saatlik Sepsis veri seti kullanılarak HMS-PSO-DNN, HMS, PSO, Adadelta, SGD, RMS-PROP ve Adam optimizasyon algoritmalarının performansı MSE kriterine göre karşılaştırılmıştır.

Tablo 17, Sepsis tahmini için optimizasyon algoritmalarının MSE performans sonuçlarını gösterir.

Tablo 17. Sepsis tahmini için kullanılan optimizasyon algoritmalarının MSE performansı

Çalışma	HMS- PSO-DNN	HMS	PSO	Adadelta	Sgd	Rmsprop	Adam
1	0,22005	0,35807	0,35807	0,33073	0,33789	0,27018	0,27604
2	0,24218	0,35807	0,35807	0,67122	0,33854	0,27604	0,28125
3	0,25716	0,35807	0,32552	0,34115	0,36003	0,27474	0,28125
4	0,23567	0,35807	0,35807	0,32617	0,35026	0,29232	0,25065
5	0,27018	0,35807	0,35807	0,66471	0,35352	0,28385	0,25781
6	0,25651	0,35807	0,35807	0,31966	0,33659	0,27279	0,28255
7	0,22851	0,35807	0,35807	0,33854	0,34831	0,26953	0,29102
8	0,24153	0,35807	0,35221	0,33659	0,35286	0,27539	0,29167
9	0,23046	0,35807	0,35807	0,35482	0,33073	0,28776	0,35417
10	0,24479	0,35807	0,29492	0,35417	0,34701	0,28385	0,26302
11	0,24869	0,35807	0,35807	0,34049	0,33398	0,27083	0,29818
12	0,27539	0,35807	0,35807	0,64648	0,33268	0,29622	0,27148
13	0,22721	0,35807	0,35807	0,35352	0,34245	0,27865	0,29818
14	0,24414	0,35807	0,35807	0,32617	0,33203	0,27995	0,26172
15	0,24544	0,35807	0,32552	0,34896	0,33789	0,25977	0,27018
16	0,26888	0,35807	0,35807	0,65820	0,32617	0,27279	0,35091
17	0,25911	0,35807	0,30013	0,34635	0,33594	0,26888	0,27409
18	0,24544	0,35807	0,30664	0,32682	0,31836	0,29753	0,27344
19	0,25000	0,35807	0,30078	0,34049	0,32813	0,28125	0,23177
20	0,26758	0,35807	0,27409	0,33529	0,33919	0,27344	0,26953
21	0,27214	0,35807	0,30859	0,34635	0,33073	0,27474	0,27995
22	0,23958	0,35807	0,35807	0,34245	0,33854	0,28125	0,26758
23	0,24674	0,35807	0,35807	0,34115	0,34180	0,28451	0,28125
24	0,26107	0,35807	0,35807	0,32227	0,33919	0,28776	0,35221
25	0,26172	0,35807	0,35807	0,35352	0,33398	0,26823	0,35286
26	0,26107	0,35807	0,35807	0,33268	0,35482	0,26497	0,33464
27	0,25326	0,35807	0,35807	0,68294	0,33529	0,27734	0,26953
28	0,26758	0,35807	0,35807	0,33659	0,32552	0,28255	0,29167
29	0,23112	0,35807	0,35807	0,33138	0,34896	0,27865	0,28385
30	0,27995	0,35807	0,35807	0,34375	0,33464	0,29167	0,26042

12 saatlik Sepsis veri setinin tahmininde kullanılan optimizasyon algoritmaları için RMSE değerleri Tablo 18' de gösterilmektedir.

Tablo 18. Sepsis Tahmini İçin Kullanılan Optimizasyon Algoritmalarının RMSE Performansı

Çalışma	HMS_PSO-DNN	HMS	PSO	Grad	Adadelta	Sgd	Rmsprop	Adam
1	0,46910	0,59839	0,59839	0,77356	0,87952	0,93783	0,96842	0,98408
2	0,49213	0,59839	0,59839	0,77356	0,87952	0,93783	0,96842	0,98408
3	0,50711	0,59839	0,57054	0,75534	0,86911	0,93226	0,96554	0,98262
4	0,48547	0,59839	0,59839	0,77356	0,87952	0,93783	0,96842	0,98408
5	0,51979	0,59839	0,59839	0,77356	0,87952	0,93783	0,96842	0,98408
6	0,50647	0,59839	0,59839	0,77356	0,87952	0,93783	0,96842	0,98408
7	0,47803	0,59839	0,59839	0,77356	0,87952	0,93783	0,96842	0,98408
8	0,49146	0,59839	0,59348	0,77037	0,87771	0,93686	0,96792	0,98383
9	0,48007	0,59839	0,59839	0,77356	0,87952	0,93783	0,96842	0,98408
10	0,49476	0,59839	0,54307	0,73693	0,85845	0,92652	0,96256	0,98110
11	0,49870	0,59839	0,59839	0,77356	0,87952	0,93783	0,96842	0,98408
12	0,52478	0,59839	0,59839	0,77356	0,87952	0,93783	0,96842	0,98408
13	0,47667	0,59839	0,59839	0,77356	0,87952	0,93783	0,96842	0,98408
14	0,49411	0,59839	0,59839	0,77356	0,87952	0,93783	0,96842	0,98408
15	0,49542	0,59839	0,57054	0,75534	0,86911	0,93226	0,96554	0,98262
16	0,51854	0,59839	0,59839	0,77356	0,87952	0,93783	0,96842	0,98408
17	0,50903	0,59839	0,54784	0,74016	0,86033	0,92754	0,96309	0,98137
18	0,49542	0,59839	0,55375	0,74415	0,86264	0,92878	0,96373	0,98170
19	0,50000	0,59839	0,54844	0,74056	0,86056	0,92766	0,96315	0,98140
20	0,51728	0,59839	0,52353	0,72356	0,85062	0,92229	0,96036	0,97998
21	0,52167	0,59839	0,55551	0,74533	0,86332	0,92915	0,96393	0,98180
22	0,48947	0,59839	0,59839	0,77356	0,87952	0,93783	0,96842	0,98408
23	0,49673	0,59839	0,59839	0,77356	0,87952	0,93783	0,96842	0,98408
24	0,51095	0,59839	0,59839	0,77356	0,87952	0,93783	0,96842	0,98408
25	0,51158	0,59839	0,59839	0,77356	0,87952	0,93783	0,96842	0,98408
26	0,51095	0,59839	0,59839	0,77356	0,87952	0,93783	0,96842	0,98408
27	0,50324	0,59839	0,59839	0,77356	0,87952	0,93783	0,96842	0,98408
28	0,51728	0,59839	0,59839	0,77356	0,87952	0,93783	0,96842	0,98408
29	0,48075	0,59839	0,59839	0,77356	0,87952	0,93783	0,96842	0,98408
30	0,52910	0,59839	0,59839	0,77356	0,87952	0,93783	0,96842	0,98408


Tablo 19, 12 saatlik Sepsis veri seti kullanılarak yapılan tahminde optimizasyon algoritmaları için MSE performans ölçümlerini gösterir.

Tablo 19. Optimizasyon Algoritmalarının Sepsis Tahminindeki MSE Performans Ölçümleri

Optimizasyon algoritması	MSE(ort)	MSE(maks)	MSE(min)	MSE(standart sapma)	MSE(varyans)
HMS-PSO-DNN	0,25111	0,27995	0,22005	0,01567	0,00025
HMS	0,35807	0,35807	0,35807	0,00000	0,00000
PSO	0,34360	0,35807	0,27409	0,02535	0,00064
Grad	0,46931	0,64193	0,35742	0,13833	0,01914
Adadelta	0,39312	0,68294	0,31966	0,12399	0,01537
Sgd	0,33887	0,36003	0,31836	0,00966	0,00009
Rmsprop	0,27858	0,29753	0,25977	0,00913	0,00008
Adam	0,28676	0,35417	0,23177	0,03166	0,00100

12 saatlik Sepsis veri setinde Sepsis hastalığının tahmininde kullanılan optimizasyon algoritmalarının MSE' nin şematik performansı Şekil 22' de gösterilmektedir.

Her bir şekil için, MSE ve bağımsız çalışma sayısını göstermektedir. Her bir şekilde, her bir algoritma 30 bağımsız çalışma sayısında çalıştırılarak MSE performansları elde edilmiştir.



Şekil 22. Sepsis Veri Seti Optimizasyon Algoritmaları MSE Performansı


12 saatlik Sepsis veri setindeki Sepsis tahmini için kullanılan optimizasyon algoritmalarının RMSE performansı Tablo 20' de gösterilmektedir.

Tablo 20. Optimizasyon Algoritmalarının Sepsis Tahminindeki RMSE Performans Ölçümleri

Optimizasyon algoritması	RMSE(ort)	RMSE(mak)	RMSE(min)	RMSE(standart sapma)	RMSE(varyans)
HMS-PSO-DNN	0,50087	0,52910	0,46910	0,01567	0,00025
HMS	0,59839	0,59839	0,59839	0,00000	0,00000
PSO	0,58577	0,59839	0,52354	0,02224	0,00049
Grad	0,67813	0,80120	0,59785	0,09892	0,00979
Adadelta	0,62088	0,82640	0,56539	0,08883	0,00789
Sgd	0,58207	0,60002	0,56423	0,00829	0,00007
Rmsprop	0,52774	0,54546	0,50967	0,00863	0,00007
Adam	0,53475	0,59512	0,48143	0,02888	0,00083

Şekil 23, 12 saatlik Sepsis veri setindeki Sepsis tahmininde kullanılan optimizasyon algoritmalarının 30 bağımsız çalışma sayısında elde edilen RMSE sonuçlarını göstermektedir.

Her bir şekil için RMSE ve 30 bağımsız çalışma sayısı görülmektedir.



Şekil 23. Sepsis Veri Seti Optimizasyon Algoritmaları RMSE Performansı

Tablo 21’de 2000 iterasyon ve 30 bağımsız çalışma sayısındaki 226 Sepsis değil ve 216 Sepsis olacak şekilde veri seti dengelenmiş olup yapılan deneysel çalışmanın sonuçlarına göre HMS-PSO-DNN algoritmasının performansı görülmektedir.

Tablo 21. HMS-PSO-DNN Algoritması Dengeli Veri Seti Sonuçları

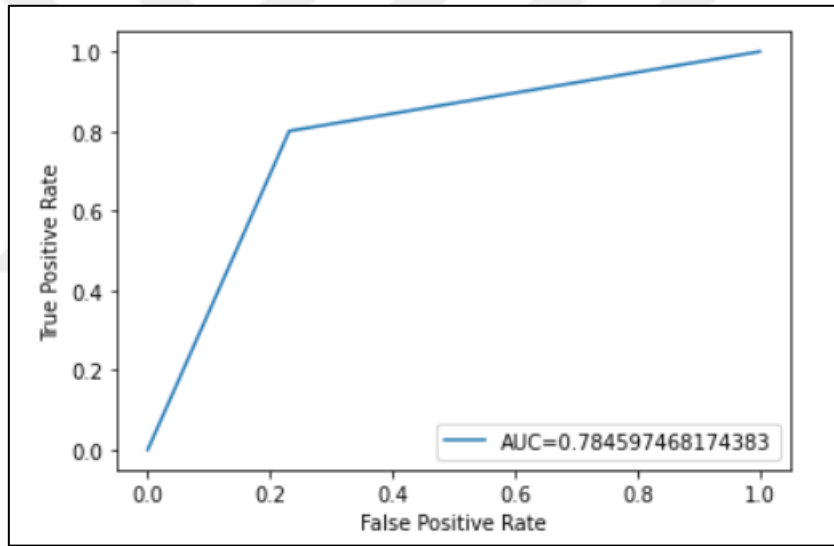
HMS-PSO-DNN	MSE	RMSE	precision-0	precision-1	recall-0	recall-1	f1-score-0	f1-score-1	AUC
1	0,26201	0,51187	0,78	0,71	0,69	0,79	0,73	0,75	0,7393
2	0,27049	0,52009	0,72	0,74	0,78	0,68	0,75	0,71	0,72818
3	0,24505	0,49502	0,79	0,73	0,72	0,8	0,75	0,76	0,75605
4	0,27521	0,5246	0,73	0,72	0,73	0,72	0,73	0,72	0,72463
5	0,24882	0,49882	0,74	0,76	0,79	0,71	0,77	0,73	0,74996
6	0,23091	0,48053	0,78	0,75	0,76	0,78	0,77	0,77	0,76935
7	0,27521	0,5246	0,72	0,73	0,76	0,68	0,74	0,71	0,7237
8	0,22525	0,47461	0,77	0,78	0,79	0,76	0,78	0,77	0,77423
9	0,23468	0,48444	0,76	0,77	0,8	0,73	0,78	0,75	0,76439
10	0,24033	0,49024	0,79	0,73	0,72	0,8	0,76	0,76	0,76069
11	0,25447	0,50445	0,77	0,72	0,72	0,77	0,74	0,75	0,74615
12	0,24033	0,49024	0,77	0,75	0,76	0,76	0,76	0,76	0,75976
13	0,24787	0,49787	0,79	0,72	0,7	0,81	0,74	0,76	0,75355
14	0,25353	0,50352	0,75	0,74	0,76	0,73	0,76	0,74	0,74599
15	0,24787	0,49787	0,77	0,74	0,75	0,76	0,76	0,75	0,75227
16	0,21583	0,46457	0,8	0,77	0,77	0,8	0,79	0,78	0,78459
17	0,2507	0,5007	0,74	0,76	0,78	0,71	0,76	0,73	0,74833
18	0,24882	0,49882	0,79	0,72	0,7	0,81	0,74	0,76	0,75269
19	0,26672	0,51645	0,73	0,74	0,77	0,69	0,75	0,72	0,73222
20	0,24033	0,49024	0,8	0,72	0,7	0,82	0,75	0,77	0,7612
21	0,23279	0,48249	0,77	0,76	0,77	0,76	0,77	0,76	0,7671
22	0,24128	0,4912	0,77	0,74	0,75	0,77	0,76	0,76	0,75895
23	0,23751	0,48735	0,79	0,73	0,72	0,8	0,76	0,77	0,76354
24	0,23939	0,48928	0,76	0,76	0,78	0,74	0,77	0,75	0,76011
25	0,2262	0,4756	0,78	0,77	0,79	0,76	0,78	0,77	0,77347
26	0,25353	0,50352	0,76	0,73	0,74	0,76	0,75	0,74	0,74671
27	0,22525	0,47461	0,77	0,78	0,8	0,75	0,78	0,76	0,77408
28	0,2573	0,50725	0,76	0,73	0,74	0,75	0,75	0,74	0,74288
29	0,24882	0,49882	0,76	0,74	0,76	0,74	0,76	0,74	0,75099
30	0,22997	0,47955	0,8	0,74	0,74	0,8	0,77	0,77	0,77093

Tablo 22’ de HMS-PSO-DNN algoritması ve diğer algoritmaların dengeli veri seti performanslarının 2000 iterasyon ve 30 bağımsız çalışma süresindeki performans kriterlerine göre ortalamaları görülmektedir.

Tablo 22. Algoritmaların Sepsis Tahmini Performansının Karşılaştırılması

Algoritma	Mse(ort)	Rmse(ort)	pre-0(ort)	pre-1(ort)	recall-0(ort)	recall-1(ort)	f1-0(ort)	f1-1(ort)	Auc(ort)
Adam	0,321578	0,5618	0,692	0,545	0,779	0,5716	0,7183	0,5586	0,6756
Adadelta	0,47596	0,6899	0,52	0	1	0	0,69	0	0,5
HMS	0,48633	0,6973	0,51	0	1	0	0,68	0	0,5
PSO	0,37986	0,6137	0,62600	0,4836	0,7663	0,4653	0,6733	0,4680	0,6156
RMS_PROP	0,293177	0,5411	0,716333	0,6993	0,7086	0,705	0,7106	0,7026	0,7066
SGD	0,49198	0,70141	0,51	0	1	0	0,67	0	0,5
HMS-PSO-DNN	0,245549	0,4953	0,767	0,7426	0,7513	0,758	0,7586	0,7503	0,7545

Şekil 24’de HMS-PSO-DNN algoritmasının dengeli veri setindeki AUC grafiğine ait en iyi sonuçlar için doğru pozitifler ve yanlış pozitiflerin oranı görülmektedir.

**Şekil 24. HMS-PSO-DNN Dengeli Veri Seti AUC Sonucu**

Tablo 23’de HMS-PSO-DNN algoritmasının ilk 6 saatlik veriler ile eğitilmesi sonucunda 15 bağımsız çalışma süresindeki performansları ve Tablo 24’de HMS-PSO-DNN algoritmasının 15 bağımsız çalışma süresindeki performans ortalamaları görülmektedir.

Tablo 23. HMS-PSO-DNN İlk 6 Saatlik Veriler İle Tahmin Sonucu

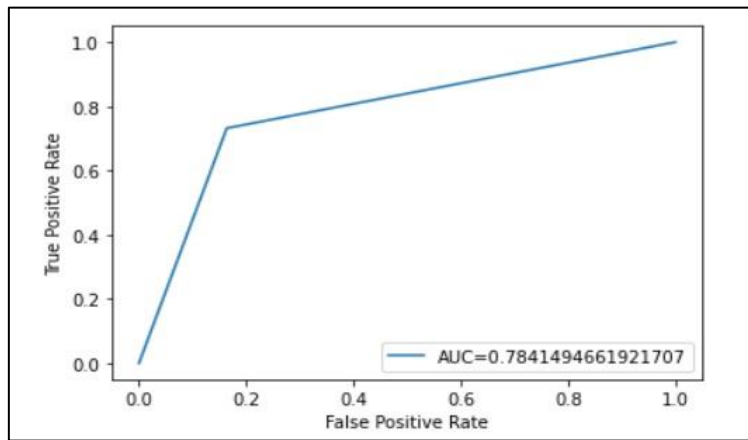
HMS-PSO-DNN	MAE	MSE	RMSE	precision-0	precision-1	recall-0	recall-1	f1-score-0	f1-score-1	AUC
1	0,25235	0,25235	0,50234	0,77	0,72	0,74	0,76	0,76	0,74	0,7481
2	0,24482	0,24482	0,49479	0,76	0,75	0,78	0,73	0,77	0,74	0,75367
3	0,25423	0,25423	0,50421	0,77	0,72	0,74	0,75	0,76	0,73	0,74588
4	0,23728	0,23728	0,48712	0,75	0,79	0,84	0,68	0,79	0,73	0,75814
5	0,2128	0,2128	0,4613	0,78	0,8	0,84	0,73	0,81	0,76	0,78414
6	0,24105	0,24105	0,49097	0,8	0,72	0,73	0,79	0,76	0,76	0,76076
7	0,24482	0,24482	0,49479	0,77	0,74	0,77	0,74	0,77	0,74	0,75456
8	0,23352	0,23352	0,48324	0,74	0,81	0,86	0,66	0,8	0,73	0,76082
9	0,24293	0,24293	0,49288	0,78	0,74	0,76	0,76	0,77	0,75	0,757
10	0,24105	0,24105	0,49097	0,78	0,73	0,75	0,77	0,77	0,75	0,75944
11	0,25235	0,25235	0,50234	0,74	0,76	0,81	0,68	0,77	0,72	0,74391
12	0,22598	0,22598	0,47538	0,79	0,76	0,79	0,76	0,79	0,76	0,77323
13	0,2354	0,2354	0,48518	0,79	0,74	0,75	0,78	0,77	0,76	0,76544
14	0,23917	0,23917	0,48905	0,78	0,74	0,77	0,75	0,77	0,75	0,76034
15	0,22975	0,22975	0,47932	0,78	0,76	0,78	0,76	0,76	0,77	0,76945

Tablo 24. HMS-PSO-DNN İlk 6 Saatlik Veriler İle Tahmin Sonucu Ortalaması

mse_ort	rmse_ort	pre-0_ort	pre-1_ort	recall-0_ort	recall-1_ort	f1-0_ort	f1-1_ort	auc_ort
0,239167	0,488925	0,772	0,752	0,78066667	0,74	0,774667	0,746	0,759659

HMS-PSO-DNN, ilk 6 saatlik Sepsis veri seti kullanılarak yapılan Sepsis hastalığının tahmininde tahmin doğruluğu olarak Nemati ve arkadaşlarının yaptığı çalışmadan (Nemati ve ark. 2017) daha iyi sonuç vermiştir.


Şekil 25’de HMS-PSO-DNN algoritmasının 20 parçacık kullanılarak yapılan ilk 6 saatteki çalışmasında doğru pozitif ve yanlış pozitif oranları ile en iyi AUC sonucu görülmektedir.

**Şekil 25. HMS-PSO-DNN İlk 6 Saatlik Verilerdeki En İyi AUC**

İlk 6 saatlik Sepsis verileri için doğrulama veri seti kullanıldığında doğruluk ve kesinlik sonuçları Şekil 26 ve Şekil 27’de görülmektedir.

	precision	recall	f1-score	support
0	0.81	0.79	0.80	281
1	0.77	0.80	0.78	250
accuracy			0.79	531
macro avg	0.79	0.79	0.79	531
weighted avg	0.79	0.79	0.79	531
0.7909604519774012				

Şekil 26. HMS-PSO-DNN algoritması Doğrulama veri seti doğruluk ve kesinlik



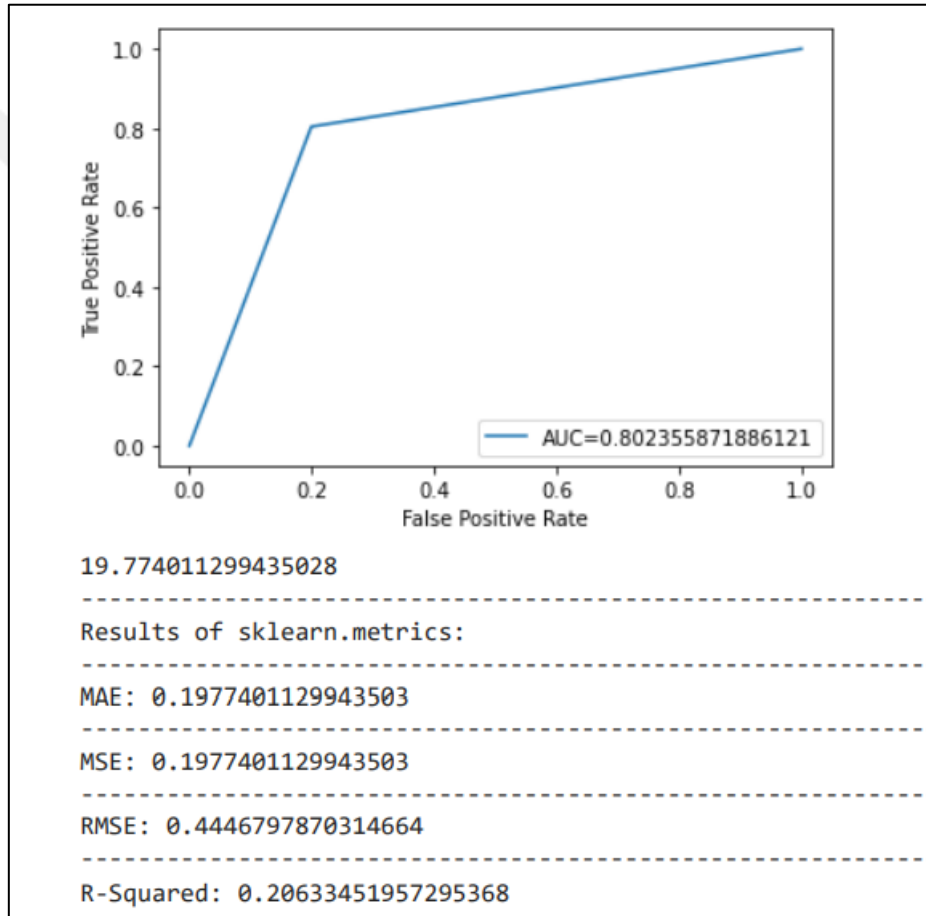
Şekil 27. HMS-PSO-DNN Algoritması Doğrulama Veri Seti AUC Ve MSE Sonuçları

HMS-PSO-DNN algoritmasının ilk 6 saatlik verilerin 500 parçacık kullanılarak elde ettiği en iyi sonuçlar Şekil 28 ve Şekil 29’da görülmektedir.

Elde edilen sonuçlar Shashikumar ve arkadaşlarının (Supreeth ve ark. 2017) yaptığı çalışmadan daha iyi AUC sonucu elde ettiği görülmektedir.

	precision	recall	f1-score	support
0	0.82	0.80	0.81	281
1	0.78	0.80	0.79	250
accuracy			0.80	531
macro avg	0.80	0.80	0.80	531
weighted avg	0.80	0.80	0.80	531
0.8022598870056498				

Şekil 28. HMS-PSO-DNN Doğruluk Ve Kesinlik Performansı Sonuçları



Şekil 29. HMS-PSO-DNN Algoritması En İyi MSE Ve AUC Sonucu

SONUÇ VE ÖNERİLER

Bu çalışmada, Sepsis hastalığı tahmini için kullanılan Derin Sinir Ağı' nın ağırlık ve yanlılık parametreleri, yeni bir hibrit meta-sezgisel algoritma olan HMS-PSO kullanılarak ayarlanmıştır.

Önerilen hibrit algoritma, İnsan Zihinsel Arama algoritmasının zihinsel arama operatörünü kullanarak parçacık sürüsü optimizasyon algoritmasındaki parçacıkların en iyi yerel minimum çözümünü arar. Sonuç olarak, PSO algoritmasının parçacıkları, yerel minimum değerinde takılıp kalmaktan ziyade küresel en iyi çözüme doğru ilham alır.

Gradyan tabanlı optimizasyon algoritmaları kullanılarak Yapay Sinir Ağlarının ağırlıkları ayarlanırken yerel minimuma takılıp kalma, aşırı öğrenme, yetersiz öğrenme gibi sorunlarla da karşılaşmaktadır.

HMS-PSO-DNN, zihinsel aramaya dayalı parçacık hareketleriyle bunlardan kaçınmaya çalışır. Önerilen Derin Sinir Ağı modeli için örnek veri setini tahmin etmek için 26 farklı ağ yapısı kullanılmıştır.

Sepsis hastalığını tahmin etmek için örnek Sepsis veri setinin tahmininde en düşük MSE değerine sahip ağ modeli belirlenmiştir. İlk olarak, diyabet, kalp yetmezliği, kriyoterapi ve immunoterapi veri setleri dâhil olmak üzere HMS-PSO-DNN' nin performansı için kıyaslamada benchmark veri setler kullanılarak, Metasezgisel ve gradyan tabanlı optimizasyon algoritmalarıyla karşılaştırıldı.

Sonuçlar, HMS-PSO-DNN ile diğer algoritmaların rekabet edebilecek düzeyde olmadıklarını göstermektedir. Sepsis veri setindeki performans değerlendirmeleri, gradyan tabanlı algoritmaların yeterince öğrenemediğini ve yerel minimumda sıkışıp kaldığını da ortaya koyuyor.

Sonuç olarak, Sepsis şüphesi olan hastaların ilk 12 saatlik verilerini kullanarak, HMS-PSO-DNN Sepsis hastalığını tahmin etmede daha başarılı oldu. Bununla birlikte veri seti dengelendiğinde doğruluk, kesinlik gibi performans değerleri artmış ve MSE hata değeri azalmıştır.

İlk 6 saatlik veriler ile yapılan deneysel çalışmalarda ise önerilen HMS-PSO algoritması literatürdeki Nemati ve arkadaşları ile Shashikumar ve arkadaşlarının elde ettiği sonuçlardan daha iyi sonuçlar vermiştir. HMS-PSO algoritmasının performansı, onu hastalık yerine ölüm oranını tahmin etmek için kullanacak olan gelecek araştırmalarda geliştirilecektir.

KAYNAKÇA

- A Guide to Deep Learning and Neural Networks, <https://serokell.io/blog/deep-learning-and-neural-network-guide>, Erişim Tarihi: 26.12.2022.
- Abdali, A., Mazlumi, K., Noroozian, R. (2018). A Precise Fault Location Scheme For Low-Voltage Dc Microgrids Systems Using Multi-Layer Perceptron Neural Network. 36. 821-834.
- Adetiba, E., Olugbara, O.O. Lung Cancer Prediction Using Neural Network Ensemble with Histogram of Oriented Gradient Genomic Features. The Scientific World Journal, 2015.
- Agahian, S., Akan, T., 2021. Battle royale optimizer for training multi-layer perceptron. Evolving Systems. 10.1007/s12530-021-09401-5.
- Ahmed, F.S. et al. A statistically rigorous deep neural network approach to predict mortality in trauma patients admitted to the intensive care unit. J Trauma Acute Care Surg. 2020 Oct;89(4):736-742. doi: 10.1097/TA.0000000000002888. PMID: 32773672.
- Alweshah, M. "Firefly algorithm with artificial neural network for time series problems," Res. J. Appl. Sci. Eng. Technol. vol. 7, no. 19, pp. 3978–3982, 2014.
- Angus, D.C., Linde-Zwirble, W.T., Lidicer, J. et al (2001) Epidemiology of severe Sepsis in the United States: analysis of incidence, outcome, and associated costs of care. Crit. Care Med 29, 2001, 1303–1310.
- Asherlou, S., Yelghi, A., Pancar, E. B., Oruç, Ş. 2022. An optimization approach for highway alignment using metaheuristic algorithms. Meta-heuristic Optimization Techniques: Applications in Engineering, 10, 11.
- Askarzadeh, A., Rashedi, E. 2017. Harmony Search Algorithm. 10.4018/978-1-5225-2322-2.ch001.
- Atashpaz-Gargari, E., Lucas, C. 2007. Imperialist Competitive Algorithm: An Algorithm for Optimization Inspired by Imperialistic Competition", IEEE Congress on Evolutionary Computation, 4661-4667.

- Aydın, G. Sepsis ve Septik Şok, Akılcı Antibiyotik Kullanımı ve Erişkinde Toplumdan Edinilmiş Enfeksiyonlar, Sempozyum Dizisi No: 31, Kasım 2002, 131-140.
- Baldini, F., Giannetti, A., Trono, C., Bolzoni, L., Porro, G. The CAI instrument: A novel optical device for Sepsis analysis for POCT applications, 2011 International Quantum Electronics Conference (IQEC) and Conference on Lasers and Electro-Optics (CLEO) Pacific Rim incorporating the Australasian Conference on Optics, Lasers and Spectroscopy and the Australian Conference on Optical Fiber Technology, Sydney, NSW, 2011, 693-694.
- Barkat, A., Saima, A. L., Wareesa et al. An Efficient Learning Weight of Elman Neural Network with Chicken Swarm Optimization Algorithm, *Procedia Computer Science*, Volume 192, 2021, Pages 3060-3069.
- Bedoya, A.D. et al. Machine learning for early detection of Sepsis: an internal and temporal validation study. *JAMIA Open*. 2020 Apr 11;3(2):252-260. doi: 10.1093/jamiaopen/ooaa006. PMID: 32734166; PMCID: PMC7382639.
- Beheshti, Z., Shamsuddin, S.M.H. "CAPSO: centripetal accelerated particle swarm optimization," *Inf. Sci. (Ny)*. vol. 258, pp. 54–79, 2014.
- Bendi, V.R. et al. A Critical Comparative Study of Liver Patients from USA and INDIA: An Exploratory Analysis, *International Journal of Computer Science Issues*, ISSN :1694-0784, May 2012.
- Bendi, V.R. et al. A Critical Study of Selected Classification Algorithms for Liver Disease Diagnosis, *International Journal of Database Management Systems (IJDMS)*, Vol.3, No.2, ISSN : 0975-5705, PP 101-114, May 2011.
- Bengio, Y. (2009) "Learning Deep Architectures for AI," *Foundations and Trends in Machine Learning*, 2(1):1-127. Doi: 10.1561/22000000006.
- Bengio, Y. et al. "Greedy layer-wise training of deep networks." *Advances in neural information processing systems* 19 (2007): 153.
- Bengio, Y., Courville, A., Vincent, P. (2013). "Representation Learning: A Review and New Perspectives". *IEEE Transactions on Pattern Analysis and Machine*

- Bengio, Y., Lamblin, P., Popovici, D., Larochelle, H., (2007). “Greedy layer-wise training of deep networks”. *Advances in neural information processing systems*. pp. 153–160.
- Bone, R.C., Balk, R.A., Cerra, F.B. et al. Definitions for Sepsis and organ failure and guidelines for the use of innovative therapies in Sepsis, *Chest* 101, no. 6 (1992): 1644-55. <http://journal.publications.chestnet.org>.
- Bourlard, H., Kamp, Y. “Auto-association by multilayer perceptrons and singular value decomposition.” *Biological cybernetics* 59.4-5 (1988): 291-294.
- Brajevic, I., Tuba, M. “Training feed-forward neural networks using firefly algorithm,” *Recent Adv. Knowl. Eng. Syst. Sci.* 2013.
- Bratton, D., Kennedy, J. 2007. Defining a Standard for Particle Swarm Optimization (PDF). *Proceedings of the 2007 IEEE Swarm Intelligence Symposium*, 120–127. doi:10.1109/SIS.2007.368035. ISBN 978-1-4244-0708-8. S2CID 6217309
- Bui T. et al. Remote patient monitoring for improving outpatient care of patients at risk for Sepsis, 2016 IEEE Systems and Information Engineering Design Symposium (SIEDS), Charlottesville, VA, 2016, 136-141.
- Büke, Ç. *Yeni Rehberler Eşliğinde Sepsis, Türk Klinik Mikrobiyoloji ve Enfeksiyon Hastalıkları Derneği, Ege Üniversitesi Tıp Fakültesi*, 2015.
- Calvert, J.S. et al. A computational approach to early Sepsis detection, *Computers in Biology and Medicine*, Volume 74, 1 July 2016, 69-73, ISSN 0010-4825, Science direct.
- Carcillo, J.A. Fields AI (2002) Clinical practice parameters for hemodynamic support of pediatric and neonatal patients in septic shock. *Crit. Care Med* 30: 1365–1378.
- Chen, X. Et al. 2018. The Hybrid Algorithm Based on Differential Evolution for Satellite Layout Optimization Design, 2018 IEEE Congress on Evolutionary Computation (CEC), 1-8, doi: 10.1109/CEC.2018.8477969.

- Chicco, D., Jurman, G. "Machine learning can predict survival of patients with heart failure from serum creatinine and ejection fraction alone". *BMC Medical Informatics and Decision Making* 20, 16 (2020)
- Ciresan, D., Meier, U., Schmidhuber, J. (2012) "Multi-column deep neural networks for image classification," 2012 IEEE Conference on Computer Vision and Pattern Recognition, pp. 3642-3649, arXiv: 1202.2745. doi: 10.1109/cvpr.2012. ISBN 978-1-4673-1228-8. S2CID 2161592.
- Cybenko (1989). "Approximations by superpositions of sigmoidal functions, " *Mathematics of Control, Signals, and Systems*, 2 (4):303–314. doi:10.1007/bf02551274. S2CID 3958369.
- Da, Y., Xiurun, G. "An improved PSO-based ANN with simulated annealing techniques," *Neurocomputing*, vol. 63, no. 0, pp. 527 – 533, Jan 2005.
- Danner, O.K., Hendren, S., Santiago, E., Nye, B., Abraham, P. Physiologically-based, predictive analytics using the heart-rate-to-Systolic-Ratio significantly improves the timeliness and accuracy of Sepsis prediction compared to SIRS, *The American Journal of Surgery*, Volume 213, Issue 4, April 2017, 617-621, ISSN 0002-9610, Science-direct.
- Deng, L., Yu, D. (2014) "Deep Learning Methods and Applications," *Foundations and Trends in Signal Processing*, 7(3-4): 1-99. Doi:10.1561/20000000039.
- Devikanniga, D., Raj, R.J.S. "Classification of osteoporosis by artificial neural network based on monarch butterfly optimization algorithm," *Healthc. Technol. Lett.* vol. 5, no. 2, pp. 70–75, 2018.
- Donate, J.P., Li, X., Sanchez, G.G., De Miguel, A.S. "Time series forecasting by evolving artificial neural networks with genetic algorithms, differential evolution and estimation of distribution algorithm," *Neural Comput. Appl.* vol. 22, no. 1, pp. 11–20, Jan 2013.
- Dorigo, M., Maniezzo, V., Coloni, A. "Ant system: optimization by a colony of cooperating agents," *IEEE Trans. Syst. Man, Cybern. Part B*, vol. 26, no. 1, pp. 29–41, 1996.

- Du, K., Swamy, M.N.S. 2016. Search and Optimization by Metaheuristics: Techniques and Algorithms Inspired by Nature (1st. ed.). Birkhäuser Basel.
- Elman, J.L. "Finding structure in time." *Cognitive science* 14.2 (1990): 179-211.
- Eröz, E., Tanyıldız, E. 2018. Güncel Metasezgisel Optimizasyon Algoritmaları nın Performans Karşılaştırması. 1-16. 10.1109/IDAP.2018.8620764.
- Gers, F., Schraudolph, N., Schmidhuber, J. (2002). Learning Precise Timing with LSTM Recurrent Networks. *Journal of Machine Learning Research*. 3. 115-143. 10.1162/153244303768966139.
- Gers, F.A., Schmidhuber, J. (2001). "LSTM Recurrent Networks Learn Simple Context Free and Context Sensitive Languages". *IEEE Transactions on Neural Networks*. 12 (6): 1333–1340. doi:10.1109/72.963769.
- Ghalwash, M., Radosavljevic, V., Obradovic, Z. Early Diagnosis and Its Benefits in Sepsis Blood Purification Treatment, 2013 IEEE International Conference on Healthcare Informatics, Philadelphia, PA, 2013, 523-528.
- Ghasemi, P., Raoufy, M.R. Prediction of mortality in patients with Sepsis using Detrended fluctuation analysis of Heart Rate Variability, 2016 23rd Iranian Conference on Biomedical Engineering and 2016 1st International Iranian Conference on Biomedical Engineering (ICBME), Tehran, 2016, 150-154.
- Ghodrati, A., Lotfi, S. 2012. A Hybrid CS/PSO Algorithm for Global Optimization. In: Pan JS. Chen SM., Nguyen N.T. (eds) *Intelligent Information and Database Systems. ACIIDS 2012. Lecture Notes in Computer Science*, vol 7198. Springer, Berlin, Heidelberg. https://doi.org/10.1007/978-3-642-28493-9_11
- Gillick, D., Brunk, C., Vinyals, O., Subramanya, A. (2015). "Multilingual Language Processing from Bytes". arXiv:1512.00103.
- Guillen J. et al. Predictive models for severe Sepsis in adult ICU patients, 2015 Systems and Information Engineering Design Symposium, Charlottesville, VA, 2015, 182-187.
- Gunnarsdottir, K., Sadashivaiah, V., Kerr, M., Santaniello, S., Sarma, S.V. Using demographic and time series physiological features to classify Sepsis in the intensive

- care unit, 2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), Orlando, FL, 2016, 778-782.
- Gültepe, E., Nguyen, H., Albertson, T., Tagkopoulos, I. A Bayesian network for early diagnosis of Sepsis patients: a basis for a clinical decision support system, 2012 IEEE 2nd International Conference on Computational Advances in Bio and Medical Sciences (ICCABS), Las Vegas, NV, 2012, 1-5.
- Hagan, M.T., Demuth, H.B., Beale, M.H., De Jesús, O. Neural Network Design, 2nd Edition, Martin Hagan, 2014, 0971732116, 9780971732117.
- Hassoun, Mohamad H. (1995). Fundamentals of Artificial Neural Networks. MIT Press. p. 48. ISBN 978-0-262-08239-6.
- Haykin, S. (1999). Neural Networks: A Comprehensive Foundation. Prentice Hall. ISBN 978-0-13-273350-2.
- Hinton, G. (2009) "Deep belief networks," Scholarpedia, 4(5):5947, doi:10.4249/scholarpedia.5947.
- Hochreiter, S., Schmidhuber, J. (1997) "Long Short-Term Memory," Neural Computation, 9 (8):1735–1780. doi:10.1162/neco.1997.9.8.1735. ISSN 0899-7667. PMID 9377276.
- Hochreiter, S., Schmidhuber, J. "Long short-term memory." Neural computation 9.8 (1997): 1735-1780.
- Hof, R. D. "Is Artificial Intelligence Finally Coming into Its Own?". MIT Technology Review. Archived from the original on 31 March 2019.
- Hornik, K. (1991) "Approximation Capabilities of Multilayer Feedforward Networks," Neural Networks, 4 (2): 251–257, doi:10.1016/0893-6080(91)90009-t.
- <https://www.asimovinstitute.org/author/fjodorvanveen/>, Erişim tarihi 23.12.2022.
- https://www.mathworks.com/matlabcentral/mlc-downloads/downloads/f4d6be8c-ddaa-4aa4-93b6-07ff656cc94b/f630b041-ae4e-44fb-90a9-21c636968b69/previews/Test_Functions.m/index.html. Erişim tarihi 30.12.2021.

<https://www.sfu.ca/~ssurjano/shubert.html>. Erişim tarihi 30.12.2021.

Irmak, B., Gülcü, Ş. (2021). Training of the feed-forward artificial neural networks using butterfly optimization algorithm. *MANAS Journal of Engineering*, 9 (2) , 160-168.

Jaddi, N.S., Abdullah, S., Hamdan, A.R. “Optimization of neural network model using modified bat-inspired algorithm,” *Appl. Soft Comput.* vol. 37, pp. 71–86, 2015.

Jiang, Y., Tan, P., Song, H., Wan, B., Hosseini, M., Sha, L. A Self-Adaptively Evolutionary Screening Approach for Sepsis Patient, 2016 IEEE 29th International Symposium on Computer-Based Medical Systems (CBMS), Dublin, 2016, 60-65.

Jozefowicz, R., Vinyals, O., Schuster, M., Shazeer, N., Wu, Y. (2016). "Exploring the Limits of Language Modeling". arXiv:1602.02410.

Kamal, S.A., Yin, C., Qian, B., Zhang, P. An interpretable risk prediction model for healthcare with pattern attention. *BMC Med Inform Decis Mak.* 2020 Dec 30;20(Suppl 11):307. doi: 10.1186/s12911-020-01331-7. PMID: 33380322; PMCID: PMC7772928.

Karaboğa, D., Öztürk, C. “Neural networks training by artificial bee colony algorithm on pattern classification,” *Neural Netw. World*, vol. 19, no. 3, p. 279, 2009.

Kawam, A.A., Mansour, N. *International Journal of Computer and Information Technology* (ISSN: 2279 – 0764) Volume 01– Issue 02, November 2012. Page 156-161.

Kaya U, Yılmaz, A. (2022) A Hybrid Metaheuristic Algorithm Based on Mental Search: HMS-PSO, *International Conference on Science, Engineering Management and Information Technology 2022*, ppt. 44.

Kennedy, J., Eberhart, R. C. 1995. Particle swarm optimization. In *Proceedings of the International Conference on Neural Networks*; Institute of Electrical and Electronics Engineers. Vol. 4, 1942–1948. DOI: 10.1109/ICNN.1995.488968

Khan, K., Sahai, A. “A comparison of BA, GA, PSO, BP and LM for training feed forward neural networks in e-learning context,” *Int. J. Intell. Syst. Appl.* vol. 4, no. 7, p. 23, 2012.

- Khozeimeh, F. et al. "An Expert system for selecting wart Treatment method," *Computers in Biology and Medicine*, vol. 81, pp. 167-175, 2,1,2017.
- Khozeimeh, F., Jabbari, F. et al. "Intralesional immunotherapy compared to cryotherapy in the Treatment of warts," *International Journal of Dermatology*, 2017, DOI:10.1111/ijd.13535
- Khuat, T.T., Le, M.H. 2018. A Novel Hybrid ABC-PSO Algorithm for Effort Estimation of Software Projects Using Agile Methodologies, *Journal of Intelligent Systems*, vol. 27, no. 3, 489-506. <https://doi.org/10.1515/jisys-2016-0294>
- Kowalski, P.A., Łukasik, S. "Training neural networks with krill herd algorithm," *Neural Process. Lett.* vol. 44, no. 1, pp. 5–17, 2016.
- Krizhevsky, A., Sutskever, I., Hinton, G., (2012). "ImageNet Classification with Deep Convolutional Neural Networks," *NIPS 2012: Neural Information Processing Systems*, Lake Tahoe, Nevada.
- Kumar, A., Pant, S., Ram, M. & Yadav, O. (Eds.). (2022). *Meta-heuristic Optimization Techniques: Applications in Engineering (Vol. 10)*. Walter de Gruyter GmbH & Co KG.
- LeCun, Y. et al. "Gradient-based learning applied to document recognition." *Proceedings of the IEEE* 86.11 (1998): 2278-2324.
- LeCun, Y. et al. (1998) "Gradient-based learning applied to document recognition," *Proceedings of the IEEE*, 86 (11):2278–2324, doi:10.1109/5.726791.
- LeCun, Y., Bengio, Y., Hinton, G. (2015). "Deep learning". *Nature*. 521 (7553): 436–444. Bibcode:2015Natur.521..436L. doi:10.1038/nature14539. PMID 26017442. S2CID 3074096.
- Leung, F.H.F., Lam, H., Ling, S., Tam, P.-S. "Tuning of the structure and parameters of a neural network using an improved genetic algorithm," *IEEE Trans. Neural Netw.* vol. 14, no. 1, pp.79–88, Jan 2003.

- Liu, J., Tang, Z.H., Zeng, F., Li, Z., Zhou, L. Artificial neural network models for prediction of cardiovascular autonomic dysfunction in general Chinese population, *BMC Medical Informatics and Decision Making*, 2013, 13: 80.
- Marshall, A.H., Payne, K., Cairns, K.J., Craig, S., McCall, E. Modelling the development of late onset Sepsis and length of stay using discrete conditional survival models with a classification tree component, 2012 25th IEEE International Symposium on Computer-Based Medical Systems (CBMS), Rome, 2012, 1-6.
- Meiring, C. et al. Optimal intensive care outcome prediction over time using machine learning. *PLoS One*. 2018 Nov 14;13(11):e0206862. doi: 10.1371/journal.pone.0206862. PMID: 30427913; PMCID: PMC6241126.
- Mikolov, T. et al. (2010). "Recurrent neural network based language model," *Interspeech*: 1045–1048. doi:10.21437/Interspeech.2010-343.
- Mirjalili, S. "How effective is the Grey Wolf optimizer in training multi-layer perceptrons," *Appl. Intell.* vol. 43, no. 1, pp. 150–161, 2015.
- Mirjalili, S., Mohd Hashim, S.Z., Moradian Sardroudi, H. "Training feed-forward neural networks using hybrid particle swarm optimization and gravitational search algorithm," *Appl. Math. Comput.* vol. 218, no. 22, pp. 11 125–11 137, Jul 2012.
- Mitchell S. et al. Optimization of Sepsis risk assessment for ward patients, 2016 IEEE Systems and Information Engineering Design Symposium (SIEDS), Charlottesville, VA, 2016, 107-112.
- Morales, C., Ribas, V., Vellido, A. Applying Conditional Independence Maps to Improve Sepsis Prognosis, 2016 IEEE 16th International Conference on Data Mining Workshops (ICDMW), Barcelona, 2016, 254-260.
- Mousavirad, S.J., Ebrahimpour-Komleh, H. 2017. Human mental search: a new population-based metaheuristic optimization algorithm. *Applied Intelligence*. 47. 10.1007/s10489-017-0903-6.

- Moutzouri, A.G., Athanassiou, G.A., Dimitropoulou, D., Skoutelis, A.T., Gogos, C.A. Severe Sepsis and diabetes mellitus have additive effects on red blood cell deformability, (2008) *Journal of Infection*, 57 (2) , 147-151.
- Nanda, S., Panda, G. (2014). A survey on nature inspired metaheuristic algorithms for partitional clustering. *Swarm and Evolutionary Computation*. 16. 10.1016/j.swevo.2013.11.003.
- Nandy, S., Sarkar, P.P., Das, A. “Analysis of a nature inspired firefly algorithm based back-propagation neural network training,” *arXiv Prepr. arXiv1206.5360*, 2012.
- Nemati, S., Holder, A. et al. (2017). An Interpretable Machine Learning Model for Accurate Prediction of Sepsis in the ICU. *Critical Care Medicine*. 46. 1. 10.1097/CCM.0000000000002936.
- Ongena, F., Dhaene, T., De Turck, F., Benoit, D., Decruyenaere, J. Design of a probabilistic ontology-based clinical decision support system for classifying temporal patterns in the ICU: A Sepsis case study, 2010 IEEE 23rd International Symposium on Computer-Based Medical Systems (CBMS), Perth, WA, 2010, 389-394.
- Parente, J.D., Lee, D., Lin, J., Chase, J.G., Shaw, G.M. A fast and accurate diagnostic test for severe Sepsis using kernel classifiers, *UKACC International Conference on Control 2010*, Coventry, 2010, 1-6.
- Parreco, J.P., Hidalgo, A.E., Badilla, A.D., Ilyas, O., Rattan, R. Predicting central line-associated bloodstream infections and mortality using supervised machine learning. *J Crit Care*. 2018 Jun;45:156-162. doi: 10.1016/j.jcrc.2018.02.010. Epub 2018 Feb 21. PMID: 29486341.
- Parsian, A., Ramezani, M., Ghadimi, N. (2017). A hybrid neural network-gray wolf optimization algorithm for melanoma detection. *Biomedical Research-tokyo*, 28, 3408-3411.
- Perng, J.W., Kao, I.H., Kung, C.T., Hung, S.C., Lai, Y.H., Su, C.M. Mortality Prediction of Septic Patients in the Emergency Department Based on Machine Learning. *J Clin Med*. 2019 Nov 7;8(11):1906. doi: 10.3390/jcm8111906. PMID: 31703390; PMCID: PMC6912277.

- Radicchi, F., Baronchelli, A. 2012. Evolution of optimal Levy-flight strategies in human mental searches. *Phys Rev E* 85(6):061121.
- Radicchi, F., Baronchelli, A., Amaral, L.A., 2012. Rationality, irrationality and escalating behavior in lowest unique bid auctions. *PloS one* 7(1):e29910
- Rafiei, A., Rezaee, A., Hajati, F., Gheisari, S., Golzan, M. SSP: Early prediction of Sepsis using fully connected LSTM-CNN model. *Comput Biol Med.* 2021 Jan;128:104110. doi: 10.1016/j.combiomed.2020.104110. Epub 2020 Nov 10. PMID: 33227577.
- Rahkar Farshi, T. 2021. Battle royale optimization algorithm. *Neural Comput & Applic* 33, 1139–1157. <https://doi.org/10.1007/s00521-020-05004-4>.
- Rahkar Farshi, T. 2021. Battle royale optimization algorithm. *Neural Comput & Applic* 33, 1139–1157. <https://doi.org/10.1007/s00521-020-05004-4>.
- Rao, S. S. (2009). *Engineering Optimization: Theory and Practice: Fourth Edition*. John Wiley and Sons. <https://doi.org/10.1002/9780470549124>.
- Rodríguez, A., Mendoza, D., Ascuntar, J., Jaimes, F. Supervised classification techniques for prediction of mortality in adult patients with Sepsis. *Am J Emerg Med.* 2020 Sep 12:S0735-6757(20)30807-X. doi: 10.1016/j.ajem.2020.09.013. Epub ahead of print. PMID: 33036848.
- Rolnick, D., Tegmark, M. (2018). "The power of deeper networks for expressing natural functions". *International Conference on Learning Representations. ICLR 2018*.
- Rosenblatt, F. "The perceptron: a probabilistic model for information storage and organization in the brain." *Psychological review* 65.6 (1958): 386.
- Rosendo, M., Pozo, A. 2010, A Hybrid Particle Swarm Optimization algorithm for combinatorial optimization problems, *IEEE Congress on Evolutionary Computation*, 1-8, doi: 10.1109/CEC.2010.5586178.
- Sainath, T.N., Mohamed, A.-R., Kingsbury, B., Ramabhadran, B. (2013) "Deep convolutional neural networks for LVCSR," 2013 *IEEE International Conference on Acoustics, Speech and Signal Processing*, pp. 8614–8618, doi:10.1109/icassp.2013.6639347.

- Saqib, M., Sha, Y., Wang, M.D. Early Prediction of Sepsis in EMR Records Using Traditional ML Techniques and Deep Learning LSTM Networks. *Annu Int Conf IEEE Eng Med Biol Soc.* 2018 Jul;2018:4038-4041. doi: 10.1109/EMBC.2018.8513254. PMID: 30441243.
- Saraiva, J.P. et al. Integrating classifiers across datasets improves consistency of biomarker predictions for Sepsis, *IFAC-Papers On-Line*, Volume 49, Issue 26, 2016, 95- 102, ISSN 2405-8963, Science-direct.
- Schmidhuber, J. (2015). "Deep Learning in Neural Networks: An Overview". *Neural Networks*. 61:85117.arXiv:1404.7828. doi:10.1016/j.neunet.2014.09.003. PMID 2546 2637. S2CID 11715509.
- Schuh, C.J. Sepsis and Septic Shock Analysis using Neural Networks, *NAFIPS 2007 - 2007 Annual Meeting of the North American Fuzzy Information Processing Society*, San Diego, CA, 2007, 650-654.
- Shashikumar, S.P., Josef, C.S., Sharma, A., Nemati, S. DeepAISE - An interpretable and recurrent neural survival model for early prediction of Sepsis. *Artif Intell Med.* 2021 Mar;113:102036. doi: 10.1016/j.artmed.2021.102036. Epub 2021 Feb 13. PMID: 33685592; PMCID: PMC8029104.
- Shi, H., Li, W. "Artificial neural networks with ant colony optimization for assessing performance of residential buildings," in *2009 International Conference on Future BioMedical Information Engineering (FBIE)*, 2009, pp. 379–382.
- Shigeki, S. (2019) "Human Behavior and Another Kind in Consciousness: Emerging Research and Opportunities", IGI Global. ISBN 978-1-5225-8218-2.
- Singer, M. et al. The Third International Consensus Definitions for Sepsis and Septic Shock (Sepsis-3), *Consensus Definitions for Sepsis and Septic Shock*, American Medical Association, *JAMA*, 2016, Volume 315, Number 8: 762-775. Copyright 2016 American Medical Association. (JAMA. 2016; 315(8):801-810. doi:10.1001/jama.2016.0287.)
- Singh, N., Singh, S.B. 2017. Hybrid Algorithm of Particle Swarm Optimization and Grey Wolf Optimizer for Improving Convergence Performance, *Journal of Applied*

- Sivagaminathan, R.K., Ramakrishnan, S. "A hybrid approach for feature subset selection using neural networks and ant colony optimization," *Expert Syst. Appl.* vol. 33, no. 1, pp. 49–60, 2007.
- Socha, K., Blum, C. "An ant colony optimization algorithm for continuous optimization: application to feed-forward neural network training," *Neural Comput. Appl.* vol. 16, no. 3, pp. 235–247, 2007.
- Stanculescu, I., Williams, C.K.I., Freer, Y. Autoregressive Hidden Markov Models for the Early Detection of Neonatal Sepsis, in *IEEE Journal of Biomedical and Health Informatics*, Sept. 2014, vol. 18, no. 5, 1560-1570.
- Supreeth, P. et al. "Early sepsis detection in critical care patients using multiscale blood pressure and heart rate dynamics", *Journal of Electrocardiology*, Volume 50, Issue 6, 2017, Pages 739-743, ISSN 0022-0736, <https://doi.org/10.1016/j.jelectrocard.2017.08.013>.
- Sutskever, L., Vinyals, O., Le, Q. (2014). "Sequence to Sequence Learning with Neural Networks" (PDF). *Proc. NIPS*. arXiv:1409.3215. Bibcode:2014arXiv1409.3215S.
- Szegedy, C., Toshev, A., Erhan, D. (2013). "Deep neural networks for object detection". *Advances in Neural Information Processing Systems*: 2553–2561.
- Tang, C.Q., Li, J.Q., Xu, D.Y., Liu, X.B., Hou, W.J., Lyu, K.Y., Xiao, S.C., Xia, Z.F. Comparison of machine learning method and logistic regression model in prediction of acute kidney injury in severely burned patients. *Zhonghua Shao Shang Za Zhi*. 2018 Jun 20;34(6):343-348. Chinese. doi: 10.3760/cma. j.issn.1009-2587.2018.06.006. PMID: 29961290.
- Tappert, Charles C. (2019). "Who Is the Father of Deep Learning?". 2019 International Conference on Computational Science and Computational Intelligence (CSCI). IEEE. pp. 343–348. doi:10.1109/CSCI49370.2019.00067. ISBN 978-1-7281-5584-5.

- Tavangari, S.H., Yelghi, A. Features of metaheuristic algorithm for integration with ANFIS model. Authorea. April 18, 2022.
- Tech Crunch. "Google's AlphaGo AI wins three-match series against the world's best Go player". 25 May 2017.
- Verma, P., Parouha, R.P. 2021, An advanced hybrid meta-heuristic algorithm for solving small- and large-scale engineering design optimization problems. *Journal of Electrical Systems and Inf Technol* 8, 10. <https://doi.org/10.1186/s43067-021-00032-z>
- Vieira, S.M., Mendonça, L.F., Farinha, G.J., Sousa, J.M.C. Meta-heuristics for feature selection: Application to Sepsis outcome prediction, 2012 IEEE Congress on Evolutionary Computation, Brisbane, QLD, 2012, 1-8.
- Ward, L., Paul, M., Andreassen, S. Automatic learning of mortality in a CPN model of the systemic inflammatory response syndrome, *Mathematical Biosciences*, Volume 284, February 2017, 12-20, ISSN 0025-5564, Science direct.
- Wernly, B., Mamandipoor, B., Baldia, P., Jung, C., Osmani, V. Machine learning predicts mortality in septic patients using only routinely available ABG variables: a multi-centre evaluation. *Int J Med Inform.* 2021 Jan;145:104312. doi: 10.1016/j.ijmedinf.2020.104312. Epub 2020 Oct 24. PMID: 33126059.
- Wickramaratne, S.D., Shaad Mahmud, M.D. Bi-Directional Gated Recurrent Unit Based Ensemble Model for the Early Detection of Sepsis. *Annu Int Conf IEEE Eng Med Biol Soc.* 2020 Jul;2020:70-73. doi: 10.1109/EMBC44109.2020.9175223. PMID: 33017933.
- Wolpert, D.H., Macready, W.G. "No free lunch theorems for optimization," in *IEEE Transactions on Evolutionary Computation*, vol. 1, no. 1, pp. 67-82, April 1997, doi: 10.1109/4235.585893.
- Xue, Y., Aouari, A., Mansour, R. F., Su, S. 2021. A Hybrid Algorithm Based on PSO and GA for Feature Selection. *Journal of Cyber Security*, 3(2), 117–124.

- Yaghini, M., Khoshraftar, M.M., Fallahi, M. "A hybrid algorithm for artificial neural network training", *Engineering Applications of Artificial Intelligence*, Volume 26, Issue 1, 2013, Pages 293-301.
- Yanes, J.M.D.M., Bailón, M.M., García R.J., Barrera, V.H., Farinós, N.P., Andrés, A.L.D. Trends in Sepsis incidence and outcomes among people with or without type 2 diabetes mellitus in Spain (2008–2012), *Diabetes Research and Clinical Practice*, Volume 110, Issue 3, 2015, 266-275, ISSN 0168-8227, Science-direct.
- Yang, J.-M., Kao, C.-Y. "A robust evolutionary algorithm for training neural networks," *Neural Comput. Appl.* vol. 10, no. 3, pp. 214–230, Dec 2001.
- Yang, Y. H., Wang, Y. 2010. A Hybrid Algorithm Based on PSO and DE and Its Application in Complexity System. In *Applied Mechanics and Materials* (Vols. 26–28, pp. 1155–1158). Trans Tech Publications, Ltd. <https://doi.org/10.4028/www.scientific.net/amm.26-28.1155>
- Yelghi, A. A new strategy reverse engineering of business process from BPEL to formal specification (in Persian), 2nd national conference Soft Computing and IT, 2011 (6).
- Yelghi, A. Investigate clustering and association rules and provide customers' favorite products, 1nd National Conference Mathematics and Its Applications in Engineering Sciences, 2012,11805.
- Yelghi, A., Köse, C, Yelghi, A., Shahkar, A., S. 2020. Automatic fuzzy-DBSCAN algorithm for morphological and overlapping datasets. *Journal of Systems Engineering and Electronics*, 31(6), 1245-1253.
- Yelghi, A., Köse, C. (2018). A modified firefly algorithm for global minimum optimization. *Applied Soft Computing*, 62, 29-44.
- Yelghi, A., Köse, C. 2018. A modified firefly algorithm for global minimum optimization. *Applied Soft Computing*, 62, 29-44.
- Yelghi, A., Köse, C., Yelghi, A., Shahkar, A. "Automatic fuzzy-DBSCAN algorithm for morphological and overlapping datasets," in *Journal of Systems Engineering and*

Electronics, vol. 31, no. 6, pp. 1245-1253, Dec. 2020, doi: 10.23919/JSEE.2020.000095.

Yelghi, A., Yelghi, A.S., Shahkar, A. 5th international research congress on social sciences. Kur, Enflasyon ve Faiz Yapay Sinir Ağlar İle Üçgen İlişkisinin Tahmini, Feb 26,2021.

Yelghi, A.S., Gürsoy, M., Yelghi, A. bankacılık piyasasında kredi türüne göre belirlenen faiz oranlarının enflasyon ve döviz kuru ilişkisi. journal of empirical economics and social sciences, 3(1), 21-42.6.

Zhang, D., Yin, C., Hunold, K.M., Jiang, X., Caterino, J.M., Zhang, P. An interpretable deep-learning model for early prediction of Sepsis in the emergency department. Patterns (N Y). 2021 Jan 19;2(2):100196. doi: 10.1016/j.patter.2020.100196. PMID: 33659912; PMCID: PMC7892361.

Zhang, Y. 2015. Parçacık Sürü Optimizasyon Algoritması ve Uygulamaları Üzerine Kapsamlı Bir Araştırma, Mühendislikte Matematiksel Problemler, 931256

Zhang, Y., Wu, L. 2011. A Hybrid TS-PSO optimization algorithm, Journal of Convergence Information Technology. 6. 169-174. 10.4156/jcit.vol6.issue5.18.

Zhang, Z., Pan, Q., Ge, H., Xing, L., Hong, Y., Chen, P. Deep learning-based clustering robustly identified two classes of Sepsis with both prognostic and predictive values. EBioMedicine. 2020 Dec;62:103081. doi: 10.1016/j.ebiom.2020.103081. Epub 2020 Nov 10. PMID: 33181462; PMCID: PMC7658497.

