



**DESTEK VEKTÖR MAKİNELERİ PARAMETRELERİNİN META SEZGİSEL
YÖNTEMLER İLE OPTİMİZASYONU VE PARKİNSON HASTALIĞI VERİ
SETİ ÜZERİNDE UYGULANMASI**

ZÜBEYİR ŞÜKRÜ ÖZKORUCU

**YÜKSEK LİSANS TEZİ
MEKATRONİK MÜHENDİSLİĞİ**

Doç. DR. TURGUT ÖZSEVEN

Kasım-2021

Her hakkı saklıdır.

T.C.
TOKAT GAZİOSMANPAŞA ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
MEKATRONİK MÜHENDİSLİĞİ

YÜKSEK LİSANS TEZİ

DESTEK VEKTÖR MAKİNELERİ PARAMETRELERİNİN META SEZGİSEL
YÖNTEMLER İLE OPTİMİZASYONU VE PARKİNSON HASTALIĞI VERİ SETİ
ÜZERİNDE UYGULANMASI

ZÜBEYİR ŞÜKRÜ ÖZKORUCU

TOKAT

Kasım - 2021

Her hakkı saklıdır.

TEZ BEYANI

Tez yazım kurallarına uygun olarak hazırlanan bu tezin yazılmasında bilimsel ahlak kurallarına uyulduğunu, başkalarının eserlerinden yararlanılması durumunda bilimsel normlara uygun olarak atıfta bulunulduğunu, tezin içerdığı yenilik ve sonuçların başka bir yerden alınmadığını, kullanılan verilerde herhangi bir tahrifat yapılmadığını, tezin herhangi bir kısmının bu üniversite veya başka bir üniversitedeki başka bir tez çalışması olarak sunulmadığını beyan ederim.

ZÜBEYİR ŞÜKRÜ ÖZKORUCU

26 Kasım 2021

ÖZET

DESTEK VEKTÖR MAKİNELERİ PARAMETRELERİNİN META SEZGİSEL YÖNTEMLER İLE OPTİMİZASYONU VE PARKİNSON HASTALIĞI VERİ SETİ ÜZERİNDE UYGULANMASI

Zübeyir Şükrü ÖZKORUCU

Yüksek Lisans, Mekatronik Mühendisliği Anabilim Dalı

Tez Danışmanı: Doç. Dr. Turgut ÖZSEVEN

Kasım 2021, 104 sayfa

Dopamin hücrelerinin zamanla azalması ve yetersiz kalması sonucunda parkinson hastalığı ortaya çıkar. Bu azalma yaşa bağlı olarak değişir. Dünya nüfusunun gittikçe yaşlandığı gerçeği dikkate alındığında bu hastalık ilerleyen yıllarda artabilir. Bu hastalık için kesin bir teşhis yöntemi olmamakla birlikte hasta uzun bir süre takip altında tutulur ve sonrasında parkinson hastalığı tanısı konulabilir. Bu tez çalışmasında parkinson hastalarının tespit edilebilmesi için Destek Vektör Makineleri (DVM) ile sınıflandırma yapılmıştır. DVM’de bulunan parametrelerin seçimi oldukça önemlidir. Hatalı parametre seçimi DVM’nin sınıflandırma başarısını etkilemektedir. Bu yüzden son yıllarda literatürde meta sezgisel yöntemler yoğun bir şekilde kullanılmış ve başarılı sonuçlar elde edilmiştir. Bu çalışmada Yarasa Algoritması (YA), İyileştirilmiş Kaotik Parçacık Sürü Optimizasyonu (İKPSO), İyileştirilmiş Genetik Algoritma (İGA) ve Armoni Arama Algoritması (AAA) kullanılarak DVM optimizasyon modelleri oluşturulmuştur. Çalışmadaki deneyler UCI (Machine Learning Repository of University of California at Irvine) veri tabanından alınan iki farklı parkinson hastalığı veri seti üzerinde yapılmıştır ve bu veri setleri Parkinson 1 ve Parkinson 2 şeklinde isimlendirilmiştir. Elde edilen sonuçlar doğruluk, duyarlılık, seçicilik, kesinlik ve F1 skor değerlendirme ölçütleri kullanılarak karşılaştırılmıştır. DVM çekirdek fonksiyonlarından RBF, lineer ve polinom çekirdek fonksiyonu kullanılmıştır. İki veri setinde de genel olarak RBF çekirdek fonksiyonu en başarılı performansa sahiptir. Parkinson 1 ve Parkinson 2 veri setlerinde en iyi doğruluk sonuçları sırasıyla %88,75 ile İKPSO-DVM ve %95,422 ile YA-DVM modellerine aittir. Literatür karşılaştırmaları önerilen modellerin bazı çalışmalardan daha iyi, bazı çalışmalar ile de rekabet edebilecek seviyede olduklarını göstermiştir.

ANAHTAR KELİMELER: Destek Vektör Makineleri, Meta Sezgisel Yöntemler, Parametre Optimizasyonu, Sınıflandırma Doğruluğu, Parkinson Hastalığı.

ABSTRACT

OPTIMIZATION OF SUPPORT VECTOR MACHINES BY META HEURISTIC METHODS AND APPLYING ON PARKINSON'S DISEASE DATASET

Zübeyir Şükrü ÖZKORUCU

Master's Thesis, Divisions of Mechatronics Engineering

Advisor: Assoc. Prof. Dr. Turgut ÖZSEVEN

November 2021, 104 pages

Parkinson's disease occurs as a result of the decrease and insufficiency of dopamine cells over the time. This decrease varies with age. Considering the fact that the world population is getting older, this disease may increase in the coming years. Although there is no definitive diagnosis method for this disease, the patient is kept under follow-up for a long time and then parkinson's disease can be diagnosed. In this thesis study, classification was made with Support Vector Machine (SVM) to detect parkinson's patients. The selection of parameters in SVM is very important. Incorrect parameter selection affects the classification success of SVM. Therefore, meta heuristic methods have been used extensively in the literature in recent years and successful results have been obtained. In this study, SVM optimization models were created using Bat Algorithm (BA), Improved Chaotic Particle Swarm Optimization (ICPSO), Improved Genetic Algorithm (IGA) and Harmony Search Algorithm (HSA). Experiments in the study were conducted on two different parkinson's disease datasets taken from the UCI (Machine Learning Repository of University of California at Irvine) database and these datasets were named as Parkinson 1 and Parkinson 2. Obtained results were compared using accuracy, sensitivity, specificity, precision and F1 score evaluation criteria. Among DVM kernel functions, RBF, linear and polynomial kernel functions were used. In general, RBF kernel function has the most successful performance in both datasets. The best accuracy results in Parkinson 1 and Parkinson 2 datasets belong to ICPSO-SVM model with 88.75% and BA-DVM model 95.422%, respectively. Literature comparisons have shown that the proposed models are better than some studies and can compete with some studies.

KEYWORDS: Classification Accuracy, Meta Heuristic Methods, Parameter Optimization, Parkinson Disease, Support Vector Machines.

TEŞEKKÜR

Yüksek lisans tezi olan bu çalışmanın planlanmasında ve hazırlanmasında beni yönlendiren, bana zamanını ayıran, ilgi ve desteğini esirgemeyen danışman hocam Sayın Doç. Dr. Turgut ÖZSEVEN'e teşekkürlerimi sunarım.

Tüm eğitim hayatım boyunca desteklerini esirgemeyen ve bugünlere gelmemde büyük emekleri olan aileme teşekkür ederim.

Zübeyir Şükrü ÖZKORUCU

Kasım,2021

İÇİNDEKİLER

Sayfa

TEZ BEYANI	i
ÖZET	ii
ABSTRACT.....	iii
TEŞEKKÜR.....	iv
ŞEKİL LİSTESİ.....	vii
ÇİZELGE LİSTESİ.....	x
SİMGELER VE KISALTMALAR.....	xi
1. GİRİŞ.....	1
2. LİTERATÜR ÖZETLERİ	4
2.1 Literatür Taraması Değerlendirmesi	13
3. OPTİMİZASYON	14
3.1 Meta Sezgisel Yöntemler	15
3.2 Yarasa Algoritması (YA)	16
3.3 İyileştirilmiş Kaotik Parçacık Sürü Optimizasyonu (İKPSO).....	19
3.3.1 PSO'nun matematiksel modeli.....	20
3.3.2 PSO'nun yapısı.....	21
3.3.3 Uyarlanabilir eylemsizlik ağırlık faktörü (Adaptive inertia weight factor)	22
3.3.4. Kaotik yerel arama.....	23
3.4 İyileştirilmiş Genetik Algoritma (İGA)	25
3.4.1. GA'nın temel kavramları	26
3.4.2 GA'nın adımları	27
3.4.3 Çaprazlama ve mutasyon olasılığı modeli	35
3.5 Armoni Arama Algoritması (AAA).....	36
3.5.1 AAA'nın diğer meta sezgisel yöntemlerden farklılıkları	38
3.5.2 AAA'nın sahip olduğu avantajlar.....	38
3.5.3 AAA'nın yapısı	39
4. DESTEK VEKTÖR MAKİNELERİ (DVM)	42
4.1 İstatistiksel Öğrenme Teorisi ve Sınıflandırma.....	42
4.2 Doğrusal Ayrılabilen Verilerde DVM	43

	<u>Sayfa</u>
4.3 Doğrusal Ayrılamayan Verilerde DVM.....	47
5. DVM PARAMETRELERİNİN OPTİMİZASYONU	53
5.1 Veri Setleri.....	55
5.2 DVM Modellerinin Performans Ölçüm Kriterleri	55
5.3 Parkinson 1 Veri Seti Deneyleri	58
5.3.1 YA-DVM modeli ile sınıflandırma	59
5.3.2 İKPSO-DVM ile yapılan sınıflandırma	62
5.3.3 İGA-DVM ile yapılan sınıflandırma	65
5.3.4 AAA-DVM ile yapılan sınıflandırma	68
5.3.5 Sınıflandırma modellerinin karşılaştırılması.....	73
5.4 Parkinson 2 Veri Seti Deneyleri	76
5.4.1. YA-DVM ile yapılan sınıflandırma.....	77
5.4.2 İKPSO ile yapılan sınıflandırma	80
5.4.3 İGA-DVM ile yapılan sınıflandırma	82
5.4.4 AAA-DVM ile yapılan sınıflandırma	84
5.4.5 Sınıflandırma modellerinin karşılaştırılması.....	90
6. SONUÇ ve ÖNERİLER	93
KAYNAKLAR	95
ÖZGEÇMİŞ	104

ŞEKİL LİSTESİ

Sayfa

Şekil 3.1: YA'nın sözde kodu.....	18
Şekil 3.2: Bir parçacığın hareketi.....	20
Şekil 3.3: Sürünün iterasyonlar sonucunda konumu.....	22
Şekil 3.4: İkili kodlama ile temsil edilen iki farklı kromozom.....	27
Şekil 3.5: Değer kodlama örnekleri.....	28
Şekil 3.6: Permütasyon kodlama örnekleri.....	28
Şekil 3.7: Rulet çemberi yöntemi.....	29
Şekil 3.8: Tek noktalı çaprazlama örneği.....	31
Şekil 3.9: Üç noktalı çaprazlama örneği.....	31
Şekil 3.10: Tekdüze çaprazlama örneği.....	32
Şekil 3.11: İlk çocuk için sıralı çaprazlama.....	32
Şekil 3.12: İkinci çocuk için sıralı çaprazlama.....	33
Şekil 3.13: Karşılaştırmalı çaprazlamanın ilk adımı.....	33
Şekil 3.14: Karşılaştırmalı çaprazlamanın ikinci adımı.....	34
Şekil 3.15: Mutasyon tekniklerine örnekler.....	35
Şekil 3.16: Estetik melodiyi elde etme süreci ile global çözüme ulaşma süreci arasındaki ilişki.....	37
Şekil 3.17: Armoni belleği ve armonilere karşılık gelen amaç fonksiyonu değerleri.....	40
Şekil 4.1: Düzlemler ile sınıflandırma yapılması.....	43
Şekil 4.2: Olası hiper düzlemler.....	44
Şekil 4.3: En uygun hiper düzlemin belirlenmesi.....	45
Şekil 4.4: Verilerin doğrusal olarak ayrılamama durumu.....	47
Şekil 4.5: C parametresinin hiper düzleme etkisi.....	49
Şekil 4.6: Doğrusal olarak ayrılamayan verilerin daha yüksek boyuta dönüştürülmesi....	50
Şekil 5.1: YA-DVM, İKPSO-DVM, İGA-DVM ve AAA-DVM modelleri akış şeması.....	54
Şekil 5.2: Parkinson 1 veri seti için yarasa sayısının sınıflandırma doğruluğuna etkisi (RBF).....	60
Şekil 5.3: Parkinson 1 veri seti için yarasa sayısının sınıflandırma doğruluğuna etkisi (Lineer fonksiyon).....	61

Şekil 5.4: Parkinson 1 veri seti için yarasa sayısının sınıflandırma doğruluğuna etkisi (Polinom fonksiyon).....	61
Şekil 5.5: Parkinson 1 veri seti için İKPSO'da popülasyon büyüklüğünün sınıflandırma doğruluğuna etkisi (RBF).....	63
Şekil 5.6: Parkinson 1 veri seti için İKPSO'da popülasyon büyüklüğünün sınıflandırma doğruluğuna etkisi (Lineer fonksiyon).....	64
Şekil 5.7: Parkinson 1 veri seti için İKPSO'da popülasyon büyüklüğünün sınıflandırma doğruluğuna etkisi (Polinom fonksiyon).....	64
Şekil 5.8: Parkinson 1 veri seti için İGA'da popülasyon büyüklüğünün sınıflandırma doğruluğuna etkisi (RBF).....	66
Şekil 5.9: Parkinson 1 veri seti için İGA'da popülasyon büyüklüğünün sınıflandırma doğruluğuna etkisi (Lineer fonksiyon).....	66
Şekil 5.10: Parkinson 1 veri seti için İGA'da popülasyon büyüklüğünün sınıflandırma doğruluğuna etkisi (Polinom fonksiyon).....	67
Şekil 5.11: Parkinson 1 veri seti için AAA'da HMS'nin sınıflandırma doğruluğuna etkisi (RBF).....	68
Şekil 5.12: Parkinson 1 veri seti için AAA'da HMS'nin sınıflandırma doğruluğuna etkisi (Lineer fonksiyon).....	69
Şekil 5.13: Parkinson 1 veri seti için AAA'da HMS'nin sınıflandırma doğruluğuna etkisi (Polinom fonksiyon).....	69
Şekil 5.14: Parkinson 1 veri seti için AAA'da HMCR'nin sınıflandırma doğruluğuna etkisi (RBF).....	70
Şekil 5.15: Parkinson 1 veri seti için AAA'da HMCR'nin sınıflandırma doğruluğuna etkisi (Lineer fonksiyon).....	70
Şekil 5.16: Parkinson 1 veri seti için AAA'da HMCR'nin sınıflandırma doğruluğuna etkisi (Polinom fonksiyon).....	71
Şekil 5.17: Parkinson 1 veri seti için AAA'da PAR'ın sınıflandırma doğruluğuna etkisi (RBF).....	71
Şekil 5.18: Parkinson 1 veri seti için AAA'da PAR'ın sınıflandırma doğruluğuna etkisi (Lineer fonksiyon).....	72
Şekil 5.19: Parkinson 1 veri seti için AAA'da PAR'ın sınıflandırma doğruluğuna etkisi (Polinom fonksiyon).....	72
Şekil 5.20: Parkinson 2 veri seti için yarasa sayısının sınıflandırma doğruluğuna etkisi (RBF).....	77
Şekil 5.21: Parkinson 2 veri seti için yarasa sayısının sınıflandırma doğruluğuna etkisi (Lineer fonksiyon).....	78

Şekil 5.22: Parkinson 2 veri seti için yarasa sayısının sınıflandırma doğruluğuna etkisi (Polinom fonksiyon).....	78
Şekil 5.23: Parkinson 2 veri seti için İKPSO'da popülasyon büyüklüğünün sınıflandırma doğruluğuna etkisi (RBF).....	80
Şekil 5.24: Parkinson 2 veri seti için İKPSO'da popülasyon büyüklüğünün sınıflandırma doğruluğuna etkisi (Lineer fonksiyon).....	81
Şekil 5.25: Parkinson 2 veri seti için İKPSO'da popülasyon büyüklüğünün sınıflandırma doğruluğuna etkisi (Polinom fonksiyon).....	81
Şekil 5.26: Parkinson 2 veri seti için İGA'da popülasyon büyüklüğünün sınıflandırma doğruluğuna etkisi (RBF).....	83
Şekil 5.27: Parkinson 2 veri seti için İGA'da popülasyon büyüklüğünün doğruluğa etkisi (Lineer fonksiyon).....	83
Şekil 5.28: Parkinson 2 veri seti için İGA'da popülasyon büyüklüğünün doğruluğa etkisi (Polinom fonksiyon).....	83
Şekil 5.29: Parkinson 2 veri seti için AAA'da HMS'nin sınıflandırma doğruluğuna etkisi (RBF).....	85
Şekil 5.30: Parkinson 2 veri seti için AAA'da HMS'nin sınıflandırma doğruluğuna etkisi (Lineer fonksiyon).....	85
Şekil 5.31: Parkinson 2 veri seti için AAA'da HMS'nin sınıflandırma doğruluğuna etkisi (Polinom fonksiyon).....	86
Şekil 5.32: Parkinson 2 veri seti için AAA'da HMCR'nin sınıflandırma doğruluğuna etkisi (RBF).....	86
Şekil 5.33: Parkinson 2 veri seti için AAA'da HMCR'nin sınıflandırma doğruluğuna etkisi (Lineer fonksiyon).....	87
Şekil 5.34: Parkinson 2 veri seti için AAA'da HMCR'nin sınıflandırma doğruluğuna etkisi (Polinom fonksiyon).....	87
Şekil 5.35: Parkinson 2 veri seti için AAA'da PAR'ın sınıflandırma doğruluğuna etkisi (RBF).....	88
Şekil 5.36: Parkinson 2 veri seti için AAA'da PAR'ın sınıflandırma doğruluğuna etkisi (Lineer fonksiyon).....	88
Şekil 5.37: Parkinson 2 veri seti için AAA'da PAR'ın sınıflandırma doğruluğuna etkisi (Polinom fonksiyon).....	89

ÇİZELGE LİSTESİ

Sayfa

Çizelge 4. 1: DVM’de bulunan bazı çekirdek fonksiyonları	51
Çizelge 5. 1: Çalışmada kullanılan veri setleri	55
Çizelge 5. 2: Hata matrisi	56
Çizelge 5. 3: Parkinson 1 veri setinin öznitelikleri	59
Çizelge 5. 4: Parkinson 1 veri setinin YA-DVM ile sınıflandırma sonuçları.....	62
Çizelge 5. 5: Parkinson 1 veri setinin İKPSO-DVM ile sınıflandırma sonuçları	65
Çizelge 5. 6: Parkinson 1 veri setinin İGA-DVM ile sınıflandırma sonuçları	67
Çizelge 5. 7: Parkinson 1 veri setinin AAA-DVM ile sınıflandırma sonuçları.....	73
Çizelge 5. 8: Önerilen modellerin Parkinson 1 veri setindeki sınıflandırma sonuçları...	74
Çizelge 5. 9: Önerilen modellerin literatürdeki diğer çalışmalarla sınıflandırma doğruluğu karşılaştırması	75
Çizelge 5. 10: Parkinson 2 veri setinin öznitelikleri	76
Çizelge 5. 11: Parkinson 2 veri setinin YA-DVM ile sınıflandırma sonuçları.....	79
Çizelge 5. 12: Parkinson 2 veri setinin İKPSO-DVM ile sınıflandırma sonuçları	82
Çizelge 5. 13: Parkinson 2 veri setinin İGA-DVM ile sınıflandırma sonuçları	84
Çizelge 5. 14: Parkinson 2 veri setinin AAA-DVM ile sınıflandırma sonuçları.....	89
Çizelge 5. 15: Önerilen modellerin Parkinson 2 veri setindeki sınıflandırma sonuçları.90	
Çizelge 5. 16: Önerilen modellerin literatürdeki diğer çalışmalarla doğruluk karşılaştırması	91

SİMGELER VE KISALTMALAR

Simgeler

A_i	:	i. yarasanın ses şiddeti
c_1	:	Hız sabiti
c_2	:	Hız sabiti
cx_i	:	i. kaotik değişken
C	:	Ceza parametresi
d	:	Derece parametresi
$f(x^i)$	:	x^i vektörünün amaç fonksiyonundaki değeri
f_i	:	i. yarasanın frekansı
f_{max}	:	Maksimum frekans değeri
f_{min}	:	Minimum frekans değeri
Fit_{max}	:	Mevcut popülasyondaki maksimum uygunluk değeri
Fit_{min}	:	Mevcut popülasyondaki minimum uygunluk değeri
$HMCR$	:	Armoni belleğini dikkate alma oranı
HMS	:	Armoni belleği boyutu
p_{best}	:	Uygunluk değeri en iyi olan parçacığın uygunluk değeri
P_c	:	Çaprazlama olasılığı
P_{cmax}	:	Maksimum çaprazlama olasılığı
P_{cmin}	:	Minimum çaprazlama olasılığı
P_m	:	Mutasyon olasılığı
P_{mmax}	:	Maksimum mutasyon olasılığı
P_{mmin}	:	Minimum mutasyon olasılığı
PAR	:	Ton ayarlama oranı
r_i	:	i. yarasanın sinyal yayma oranı
v_i	:	i. yarasanın hızı
w	:	Eylemsizlik katsayısı
x_i	:	i. yarasanın konumu
x_i^j	:	j. armoni vektöründe yer alan i. karar değişkeni
γ	:	Gamma parametresi

Kısaltmalar

AAA	:	Armoni Arama Algoritması
ABC	:	Yapay Arı Koloni
ACO	:	Karınca Koloni Optimizasyonu
ACOr	:	Sürekli Alan için Karınca Koloni Optimizasyonu
ACROA	:	Yapay Kimyasal Reaksiyon Optimizasyon Algoritması
BSA	:	Geriye Dönük Arama
CMAES	:	Kovaryans Matris Adaptasyonu Gelişim Stratejisi
CS	:	Guguk Kuşu Algoritması
DEA	:	Diferansiyel Evrim Algoritması
DFO	:	Dağıtıcı Sinek Optimizasyonu
DL&S	:	Dağıtılmış Öğrenme ve Arama
DN	:	Doğru Negatifler
DP	:	Doğru Pozitifler
DVM	:	Destek Vektör Makinesi
EHO	:	Fil Sürüsü Algoritması
GA	:	Genetik Algoritma
GS	:	Izgara Arama
GWO	:	Gri Kurt Optimizasyonu
İGA	:	İyileştirilmiş Genetik Algoritma
İKPSO	:	İyileştirilmiş Kaotik Parçacık Sürü Optimizasyonu
KAA	:	Karga Arama Algoritması
KPSO	:	Kaotik Parçacık Sürü Optimizasyonu
MPSO	:	Modifiye Edilmiş Parçacık Sürü Optimizasyonu
PSO	:	Parçacık Sürü Optimizasyonu
QPSO	:	Kuantum Parçacık Sürü Optimizasyonu
RBF	:	Radyal Tabanlı Fonksiyon
SA	:	Benzetimli Tavlama
SSA	:	Salp Sürüsü Algoritması
SSE	:	Statik Güvenlik Ölçümü
UCI	:	Machine Learning Repository of University of California at Irvine

WOA	:	Balina Optimizasyonu
YA	:	Yarasa Algoritması
YN	:	Yanlış Negatifler
YP	:	Yanlış Pozitif



1. GİRİŞ

İlk kez 1817 yılında titrek felç olarak tanımlanan parkinson hastalığı, insan beyinde üretilen dopamin hücrelerinin zamanla yüksek miktarda azalması sonucu dopamin üretiminin yetersiz kalması ile ortaya çıkan bir hastalıktır. Dopamin hücreleri kişilerin hareketlerini kontrol etmesi için beyin bölgeleri arasındaki iletişime yardımcı olur (Güneş, 2021).

Konuşmanın bozulması, hareketlerde yavaşlama, denge bozukluğu ve titreme parkinson hastalığının başlıca belirtileridir. Hastalık ilerledikçe uyku düzensizliği, yürüme, konuşma, çiğneme ve yutmada zorlanma yaşanabilir. Hastalık başlangıçta depresyon, eklem hastalıkları ve yaşlanma ile ilişkilendirilerek yanlış tanı konulabilmektedir (Güneş, 2021). Hastalığın bahsedilen bu belirtilerinin yanı sıra parkinson hastalarının yaklaşık %90'ında konuşma bozukluğu bulunmaktadır (Juste ve ark., 2018).

İstatiksel verilere göre ABD'de yaklaşık 1 milyon insan parkinson hastalığı ile yaşıyor ve bu rakamın 2030 yılına kadar 1.2 milyona çıkması bekleniyor. Dünya üzerinde ise 10 milyondan fazla insan parkinson hastalığı ile yaşamaktadır (Marras ve ark., 2018).

Parkinson hastalığının teşhisinde kişilerin yürüme ve ses kayıtları analizi kullanılır. Görüntüleme veya tahlil sonuçlarıyla bu hastalığın teşhisi konulamaz. Teşhis konulurken hasta uzun bir süre gözlem altında tutulur. Bu hastalığı tamamen ortadan kaldıracak bir tedavi yöntemi olmamakla birlikte hastalığın ilk evrelerinde görülen belirtileri azaltmak için ilaç tedavisi uygulanır. Bu yüzden hastalığın erken tanısı oldukça önemlidir. Erken tanı sayesinde hastalığın ilerlemesi yavaşlatılabilir (Kaya, 2019; Narin, 2020).

Erken tanıya destek olması amacıyla kişilerin hasta olup olmadıklarını tahmin eden makine öğrenmesi algoritmaları bulunmaktadır. Makine Öğrenmesi (MÖ) algoritmalarından biri de Destek Vektör Makineleridir (DVM). DVM; istatiksel öğrenme teorisine ve yapısal risk minimizasyonuna dayanan, örüntü tanıma ve sınıflandırma problemlerinin çözümünde kullanılmakta olan etkili bir yöntemdir. Literatürde DVM

kullanılarak parkinson hastalarını tespit eden uygulamalar geliştirilmiştir (Kaya, 2019; Narin, 2020).

DVM'ler doğrusal olarak ayrılabilen veriler üzerinde iyi sonuçlar verirken, lineer olarak ayrılamayan veriler üzerinde etkili sonuçlar veremezler. Bu problemi çözmek için çekirdek fonksiyonları kullanılır. Çekirdek fonksiyonları, verileri çok boyutlu uzaya haritalar ve lineer olarak ayrılabilir hale getirir. Çekirdek fonksiyonları parametrelere sahiptir ve bu parametrelerin değerleri DVM'nin performansına ciddi şekilde etki etmektedir. Bu değerler doğru bir şekilde ayarlanmazsa başarısız sınıflandırma sonuçları elde edilir. Bu değerlerin doğru bir şekilde ayarlanabilmesi için optimizasyon algoritmalarına ihtiyaç duyulmuştur.

Meta sezgisel optimizasyon algoritmaları başarılı sonuçlar verdiği için son 20 yılda literatürde hızla ilerlemiştir (Yang, 2010b). Karınca koloni algoritması (Dorigo ve ark., 2005), parçacık sürü optimizasyonu (Kennedy ve Eberhart, 1995) ve karga arama algoritması (Askarzadeh, 2016) literatürde bulunan meta sezgisel algoritmalarından bazılarıdır. Meta sezgisel yöntemler, doğadan esinlenerek önerilen, geleneksel optimizasyon yöntemleri kabul edilemez çözümler ürettiğinde etkin ve uygun çözümler üreten algoritmalarlardır. Meta sezgisel yöntemler yüksek kalitede çözümler elde etmek için alt seviye sezgisellere rehberlik eden bir süreçtir (Voß ve Fink, 1999). Bu yöntemler basit yerel arama yöntemlerinden karmaşık öğrenme işlemlerine kadar geniş bir alanı oluşturmaktadır. Bu yöntemler probleme özgü değildir, karmaşık matematiksel işlemler gerektirmez ve lokal optimuma nadiren takılır. Bu yüzden meta sezgisel yöntemler geniş kullanım alanına sahiptirler.

Bu tez çalışmasında Yarasa Algoritması (Yang, 2010a), İyileştirilmiş Kaotik Parçacık Sürüsü Optimizasyonu (Liu ve ark., 2005), İyileştirilmiş Genetik Algoritma (Wu, 2019) ve Armoni Arama Algoritması (Geem ve ark., 2001) kullanılarak parametre optimizasyonu yapılmış 4 farklı DVM modeli önerilmiştir. Önerilen bu modellerin başarısı UCI (Machine Learning Repository of University of California at Irvine) veri tabanından alınan iki farklı parkinson hastalığı veri seti (Little ve ark., 2007; Naranjo ve ark., 2016) üzerinde deneylerle test edilmiştir ve parkinson hastalarının tespit edilmesi

sağlanmıştır. Böylece parkinson hastalığının erken teşhisine katkıda bulunulması amaçlanmıştır.

Bu tez çalışması altı bölümden oluşmaktadır. İkinci bölümde literatür taraması, üçüncü bölümde YA, İKPSO, İGA ve AAA algoritmaları, dördüncü bölümde DVM, beşinci bölümde sınıflandırma sonuçları, altıncı bölümde sonuçlar ve öneriler sunulmuştur.



2. LİTERATÜR ÖZETLERİ

Zhang ve ark. (2010) Göğüs Kanseri, Diyabet, Kalp, Tiroit ve Titanik veri setlerini Karınca Koloni Optimizasyonu (ACO) yöntemi ile parametre optimizasyonu yapılmış DVM sınıflandırıcı ile sınıflandırmışlardır. Kullanılan DVM modeli uygun sonuçlar vermiştir.

Yan ve ark. (2010) Kuantum Parçacık Sürü Optimizasyonu (QPSO) ve Benzetimli Tavlama (SA) yöntemlerinin birlikte kullanıldığı hibrit bir yöntem önermişlerdir (QPSO-SA-DVM). QPSO, klasik PSO yöntemi ile kuantum fiziği düşüncesinin birleştirilmiş halidir. Bu yöntem PSO algoritmasının tüm avantajlı özelliklerini taşımaktadır. Fakat PSO yöntemi global bir optimizasyon değildir ve en uygun çözüme yakınsamayı garanti etmez. QPSO ise global yakınsamayı garanti eder. Önerilen model sadece QPSO yöntemi ile parametre optimizasyonu yapılmış DVM (QPSO-DVM) modeli ile karşılaştırılmıştır. İki modelinde sınıflandırma doğruluğu ve sınıflandırıcının genelleme yeteneğine katkısının aynı olduğu gözlemlenmiştir. Fakat QPSO-SA-DVM modeli daha iyi yakınsama hızına sahiptir.

EEG işaret verilerinin sınıflandırılmasında kullanılan DVM'nin parametreleri Parçacık Sürü Optimizasyonu (PSO) yöntemi ile optimize edilmeye çalışılmıştır. Bu çalışmada kullanılan veri seti Bonn Üniversitesi Epileptoloji bölümünden alınmıştır. DVM'de lineer, polinom ve RBF (Radyal Tabanlı Fonksiyon) çekirdek fonksiyonları kullanılmıştır. RBF çekirdek fonksiyonunda en iyi sınıflandırma başarısı elde edilmiştir. PSO yöntemi ile parametrelerin en uygun şekilde seçildiği ve sınıflandırma süresini kısalttığı sonucuna varılmış (Özbeyaz ve ark., 2011).

PSO'nun kolayca yerel optimuma düşme problemini çözmek, yakınsama hızını arttırmak ve algoritmanın hassasiyetini geliştirmek için Kaotik Parçacık Sürü Optimizasyonu (KPSO) kullanılmış (Han ve Houjun, 2011). PSO yöntemine kaos işlemi dahil edilmiştir. Bu yöntem PSO ve Genetik Algoritma (GA) ile karşılaştırılmış ve KPSO daha iyi sonuçlar vermiştir.

PSO'nun erken yakınsama, yerel optimuma düşme problemlerini çözmek, PSO'nun global arama kabiliyetini geliştirmek için KPSO kullanılmış (Wang ve ark., 2011). PSO yöntemine göre daha başarılı sonuçlar elde edilmiştir.

Hiçbir kasını hareket ettiremeyen ve dış dünyaya istediklerini anlatamayan hastalar için beyin bilgisayar arayüzü geliştirilmiştir. Bu arayüz insan beyni ile dış bir cihaz arasında iletişim kurulmasını sağlar. DVM parametre optimizasyonu için GA kullanılmıştır. (Wang ve ark., 2011). Optimizasyon işleminin DVM'nin performansını iyileştirdiği gözlemlenmiştir.

Bir başka çalışmada DVM parametre optimizasyonunda PSO, GA ve Izgara Arama (GS) yöntemleri karşılaştırılmıştır. PSO yöntemine dayalı DVM modeli hem sınıflandırma süresi hem de sınıflandırma doğruluğu açısından daha iyi sonuçlar vermiştir (Hric ve ark., 2011).

Li ve Ding (2012) hiperspektral sınıflandırma için kullanılan DVM'de parametre optimizasyonu için PSO yöntemini kullanmışlardır. PSO yöntemi hem sınıflandırma doğruluğunu arttırmış hem de zaman maliyetini azaltmıştır.

SA yöntemine dayalı DVM sınıflandırıcı önerilmiştir (Wang, 2012). Önerilen model, genetik algoritmaya dayalı DVM ve parametre optimizasyonu yapılmamış DVM ile karşılaştırılmıştır. Önerilen model daha iyi sonuçlar vermiştir.

Xue ve ark. (2013) hiperspektral görüntü sınıflandırması için DVM kullanmışlar ve parametre optimizasyonunu PSO ile yapmışlardır. Önerilen yöntemi çapraz onaylama ve GA ile karşılaştırmışlardır. PSO'ya dayalı modelin daha başarılı olduğu gözlemlenmiştir. Li ve ark. (2013) DVM parametrelerinin optimizasyonu için ateş böceği algoritmasını kullanmışlardır. Önerilen model ile yapılan sınıflandırma sonuçlarına göre daha az hata oranına, daha istikrarlı ve daha doğru sonuçlara ulaşılmıştır.

Diferansiyel Evrim Algoritması (DEA), popülasyon evrimine dayanan bir tür gerçek sayı kodlama optimizasyon algoritmasıdır. Şu anki popülasyondan farklı bilgiler çıkarabilir ve ilerideki araştırmaya rehberlik edebilir. Ayrıca algoritma kontrol parametreleri

nispeten daha azdır ve global arama yeteneği çok daha güçlüdür. DEA yöntemi kullanılarak parametre optimizasyonu yapılan DEA-DVM modelinin performansını test etmek için UCI'deki 15 veri seti üzerinde denemeler yapılmıştır (Jun ve ark., 2013). DEA-DVM'nin performansı parametre optimizasyonu yapılmamış DVM'ye göre daha iyi olduğu gözlemlenmiştir.

Xiao-Cong (2014) seramik tüp yüzeyi hatalarının algılanması için seramik tüp görüntülerini sınıflandırmış. DVM parametreleri QPSO yöntemi ile optimize edilmiş. Çalışmada 5 farklı çeşit seramik tüp hatası her birinden 100 görüntü olacak şekilde toplam 500 görüntüden oluşan bir veri seti kullanılmış. Önerilen model standart PSO yöntemine dayalı DVM ve parametre optimizasyonu yapılmamış DVM ile karşılaştırılmış ve önerilen modelde daha başarılı sonuçlar elde edilmiştir.

Heyelan kayma oranı tahmini üzerine yapılan bir çalışmada sınıflandırma için kullanılan DVM'nin çekirdek fonksiyonu parametrelerini optimize etmek için GA kullanılmıştır. Yapılan testler sonucunda optimizasyonun DVM'nin sınıflandırma doğruluğu oranını arttırdığı sonucuna varılmıştır (Li ve Kong, 2014).

Çekiş konvertöründe inverterin hatalarını sınıflandırmak için kullanılan DVM'nin parametreleri GS, GA ve PSO ile optimize edilmiştir (Jin ve ark., 2014). Üç yöntemde de DVM'nin yüksek sınıflandırma doğruluğu oranlarına ulaştığı fakat en iyi sonucun GS'de olduğu tespit edilmiştir. Bunun sebebinin GS'nin diğer yönteme göre daha geniş parametre arama kapsamına sahip olması ve diğer iki yöntemdeki rastgele başlatılan parametre dezavantajının olmadığı şeklinde açıklanmış.

Bir başka çalışmada su altı hedef sınıflandırma konusu üzerinde durulmuştur. Dört akustik sınıfın hedeflerinin ayırt edilebilmesi için DVM sınıflandırıcı kullanılmıştır (Sherin ve Supriya, 2015). Parametre optimizasyonu için GA kullanılmıştır. Yapılan testlerde GA'nın iyi sonuçlar verdiği gözlemlenmiştir.

Rulman yatak arızalarının teşhisinde kullanılan Yapay Kimyasal Reaksiyon Optimizasyon Algoritması'na dayalı bir model önerilmiştir (ACROA-DVM). ACROA

daha az parametre kullanır ve güçlü bir algoritmadır. Yöntemin performansı UCI'den alınan Tiroit, Iris ve Seed veri setlerinde test edilmiştir. Ayrıca önerilen model GA-DVM ve PSO-DVM ile karşılaştırılmıştır. Önerilen yöntemin hem test hata değeri daha düşüktür, hem de çalışma süresi daha kısadır (Ao ve ark., 2015).

Syarif ve ark. yaptıkları çalışmada DVM çekirdek fonksiyonu parametreleri optimizasyonu için GS ve GA yöntemlerini kullanmışlardır. Yapılan testler sonucunda GS'nin düşük boyutlu veri setlerinde güvenilir olduğu ve oldukça yavaş kaldığı sonucuna varılmıştır. GA yönteminin GS'ye göre ortalama 16 kat daha hızlı çalıştığı ve sınıflandırma başarısı açısından daha iyi sonuçlar verdiği gözlemlenmiştir (Syarif ve ark., 2016).

Ceylan ve Taşkın (2016a) hiperspektral görüntü sınıflandırma için DVM kullanmışlar ve DVM parametrelerini Armoni Arama Algoritması (AAA) ile optimize etmişlerdir. Önerilen AAA-DVM modeli GA-DVM ve GS-DVM ile karşılaştırılmış. Önerilen model daha başarılı sınıflandırma yapmıştır ve zaman maliyeti daha azdır.

Ceylan ve Taşkın (2016b) bir başka çalışmalarında yine hiperpektral görüntü sınıflandırması yapmışlar ve bu sefer AAA, DEA ve GS yöntemleri ile DVM parametre optimizasyonu yapmışlardır. AAA ve DEA'nın başarılı ve birbirine benzer sonuçlar verdiğini ve AAA'nın hesaplama maliyetinin en az olduğu sonucuna varmışlardır.

Statik güvenlik ölçümü (SSE), güç sistemlerindeki en önemli çalışmalardan biridir. SSE probleminin çözümü için kullanılan DVM sınıflandırıcının parametreleri çeşitli optimizasyon teknikleriyle (modifiye edilmiş PSO (MPSO), sürekli alan için karınca koloni optimizasyonu (ACOr), DEA ve AAA) optimize edilerek performansları karşılaştırıldı (Rastgoufard ve Charalampidis, 2016). SSE problemi 2 sınıflı, 3 sınıflı ve 4 sınıflı olmak üzere farklı şekillerde denendi. Sınıf sayısı değiştikçe başarılı olan optimizasyon yöntemi değişmektedir. Fakat denemelerin hepsinde AAA-DVM modelinin eğitim zamanı daha kısa sürmüştür.

Song ve ark. (2016) DVM parametre optimizasyonu için Yerçekimi Arama Algoritması'nı (GSA) kullanmışlardır. GSA hem kodlaması kolay ve basit hem de daha güçlü global arama yeteneği var. GSA, PSO ve GA ile karşılaştırılmış ve GSA'da daha başarılı sonuçlar elde edilmiştir.

Güç dağıtım şebekelerindeki hata tiplerini sınıflandırmak için kullanılan DVM'nin parametre optimizasyonu için PSO kullanılmıştır (Cho ve Hoang, 2017). Hem sınıflandırma başarısının arttığı hem de eğitim zamanının kısaldığı görülmüştür.

PSO algoritması hızlı bir hesaplama hızına sahip ancak bu yöntemin yerel optimuma düşmesi kolaydır ve erken yakınsama problemi vardır. Bu yüzden çözüm uzayında en iyi çözümü bulması zordur. He ve ark. (2017) yaptıkları çalışmada PSO algoritmasının performansını geliştirmek için PSO'ya mutasyon işlemini eklemişlerdir (M-PSO). Yapılan testler göstermiştir ki önerilen bu yöntem PSO'nun yerel optimuma düşme ve erken yakınsama problemlerini çözmüştür. Ayrıca bu yöntem geleneksel PSO yöntemi ve GS yöntemi ile karşılaştırılmıştır. Hem sınıflandırma doğruluğu açısından hem de eğitim sürecinin zamanı açısından önerilen yöntem daha iyi sonuçlar vermiştir.

Tharwat ve ark. (2017) DVM'de sınıflandırma hatasının düşürülmesi için Yarasa Algoritması'nı (YA) kullanmışlardır. Literatürde sıklıkla kullanılan UCI'den alınan 9 farklı veri seti üzerinde denemeler yapılmıştır. İlk olarak YA-DVM modeli ile GS-DVM modeli karşılaştırılmış. YA-DVM modeli hem sınıflandırmada daha başarılı olmuş hem de daha kısa sürede sınıflandırmayı yapmıştır. Deneyler DVM'nin RBF ve polinom çekirdek fonksiyonları üzerinde yapılmıştır. RBF çekirdek fonksiyonu polinom çekirdek fonksiyonuna göre daha başarılı sonuçlar vermiştir. Daha sonra literatürde daha önce önerilmiş olan PSO-DVM (Lin ve ark., 2008) ve GA-DVM (Huang ve Wang, 2006) modelleri ile YA-DVM yöntemi karşılaştırılmıştır. Tüm veri setlerinde YA-DVM, PSO-DVM'den daha başarılı sonuçlar vermiştir. Ayrıca birçok veri setinde de YA-DVM, GA-DVM'ye göre daha başarılıdır.

Tuba ve Stanimirovic (2017) DVM parametre optimizasyonu için Fil Sürüşü Algoritması'nı (EHO) kullanmışlardır. 5 farklı veri setinde denemeler yapmışlar ve EHO

yöntemini GS ve GA ile karşılaştırmışlardır. 5 veri setinin biri dışında diğerlerinde EHO yöntemi daha yüksek sınıflandırma doğruluğa ulaşmıştır. Ayrıca 5 farklı veri seti için bulunan optimal DVM parametre değerleri birbirinden farklı çıkmıştır. Bu da şunu göstermektedir ki her veri seti için DVM parametrelerinin ayarlanması gereklidir.

Sürücü yorgunluğu trafik kazalarında önemli bir faktördür. Eğer sürücü yorgunluğu erken tespit edilebilirse bu faktöre bağlı trafik kazaları önlenebilir. Xie ve ark. (2017) sürücü yorgunluk tespiti için kullandıkları DVM'nin parametre optimizasyonu için Dağıtılmış Öğrenme ve Arama (DL&S) yöntemini uygulamışlardır. Önerilen bu yöntem GS ile karşılaştırılmıştır. Gerçek dünyadan elde edilen sürücü verileri üzerinde yapılan testler sonucunda DL&S yöntemi ile GS yöntemi sınıflandırma başarıları benzer çıkmıştır. Fakat DL&S yöntemi hesaplama karmaşıklığını %92.5 düşürmüştür.

DVM çekirdek fonksiyonu parametrelerini optimize etmek ve dengesiz veri seti üzerinde sınıflandırıcının performansını geliştirmek için sürü zekası temelli bir yöntem olan Dağıtıcı Sinek Optimizasyonu (DFO) önerilmiş (Alhakbani ve al-Rifaie, 2017). UCI'den alınan literatürde çeşitli yöntemlerin performansını karşılaştırmak için kullanılan 8 farklı veri seti çalışmada kullanılmıştır. Önerilen yöntem PSO ve GS yöntemleriyle karşılaştırılmıştır. DFO yöntemi daha iyi bir sonuç vermiştir. Ayrıca yapılan deneylerde PSO ve GS yöntemleri veri setleri üzerinde performans yönünden dalgalanmalar göstermesine rağmen önerilen yöntem tüm veri setlerinde istikrarlı bir performans göstermiştir.

Kömür yatağı gaz kuyularındaki kuyu dibi akış basıncını tahmin etmek için kullanılan DVM sınıflandırıcının parametrelerini optimize etmek için GA kullanılmıştır (Xiangdong ve Shaoqing, 2018). Ayrıca önerilen model PSO-DVM ile karşılaştırılmıştır. GA-DVM modelinin parametre öğrenme ve genelleme yeteneğinin daha iyi olduğu gözlemlenmiştir. PSO'nun düşük arama hassasiyeti ve erken yakınsama problemlerinden dolayı mutasyon işlemi PSO'ya dahil edilmiştir (Can ve ark., 2018). Bu işlem yinelemeli süreçte arama alanını genişletebilir ve yerel optimum değerden dışarı atlamaya yardımcı olabilir. Deneyler sonucunda önerilen modelin tahmin oranı PSO'dan daha iyi çıkmıştır.

Tezcan (2018) hazırladığı tez çalışmasında DVM parametre optimizasyonu için Karga Arama Algoritması (KAA) ve Salp Sürüsü Algoritması'nı (SSA) kullanmış. UCI veri tabanında bulunan Wisconsin Göğüs Kanseri, Pima Kızılderilileri Diyabet, Parkinson, Sonar, Şarap, Cam ve Ünlü Harf veri setleri üzerinde deneyler yapılmıştır. KAA algoritmasının genel olarak daha başarılı olduğu görülmüştür. Ayrıca KAA ve SSA yöntemleri aynı veri setleri üzerinde farklı algoritmalar ile yapılan çalışmalar ile karşılaştırılmıştır. KAA ve SSA'nın diğer algoritmalarla yakın seviyelerde sonuçlar verdiği gözlemlenmiştir.

Klasik PSO algoritmasında yerel minimaya sıkışıp kalmaktan kaynaklanan bir sıkıntı vardır. Chen ve ark. (2019) bu sorunun üstesinden gelebilmek için klasik PSO'da bir modifikasyon yapmışlar ve mutant PSO yöntemini önermişlerdir. Kullanılan DVM sınıflandırıcı metal oksit dalgalanmasının teşhisi için kullanılmıştır. Önerilen yöntem klasik PSO yöntemi, GA ve çapraz onaylama (cross validation) ile karşılaştırılmıştır. Mutant PSO yöntemi ile yapılan sınıflandırmada test doğruluğu oranı daha yüksek çıkmış ve eğitim zamanı da kısalmıştır.

PSO kolayca yerel optimuma düşmektedir. Bu nedenle PSO algoritmasına T operatörü uygulanmıştır (Yang ve ark., 2019). Önerilen model hem sınıflandırma başarısı hem de hesaplama süresi açısından başarılı sonuçlar vermiştir.

Tao ve ark. (2019) hastane yatış masraflarını sınıflandırma üzerine bir çalışma yapmışlardır. Masraflar düşük ve yüksek maliyetli şeklinde iki sınıfa ayırmışlardır. Parametre optimizasyonu için kullanılan genetik algoritma hastane yatış masrafları modelini kurmadaki uygun özellikleri ve parametreleri bulur. GA yöntemi PSO ile karşılaştırılmıştır. Sınıflandırma doğruluğu oranları benzer çıkmasına rağmen çalışma zamanı GA'da daha kısa sürmüştür.

GA'da çaprazlama olasılığı ve mutasyon olasılığı genellikle sabit değerlerdir. Bu sabit olasılıklı model, popülasyondaki değişikliklere uyum sağlamada başarısız olur. Bu yüzden Wu (2019) GA için yeni bir çaprazlama ve mutasyon olasılığı modeli önermiş ve

bunu DVM parametre optimizasyonunda kullanmıştır. Deneyler 3 farklı veri seti üzerinde yapılmıştır ve başarılı sonuçlar elde edilmiştir.

Yang ve Xu (2019) göğüs kanserinin erken teşhisi için DVM tabanlı teşhis sistemi geliştirmişlerdir. DVM parametrelerinin optimizasyonu için diferansiyel evrim (DE) algoritması kullanılmıştır. DEA, GA, PSO ve Karınca Koloni Optimizasyonu (ACO) yöntemlerine göre daha az ayarlanacak parametreye sahiptir. DEA, PSO ve GA ile karşılaştırılmıştır. DEA hem daha kısa sürede sınıflandırma yapmış hem de daha iyi bir sınıflandırma başarısına sahiptir.

Kaya (2019) parkinson hastalığının tahmini için DVM sınıflandırıcı kullanılmıştır. DVM parametre optimizasyonu için hibrit bir yöntem önerilmiştir (CS-PSO-DVM). CS-PSO yöntemi guguk kuşu algoritması (CS) ve PSO yöntemlerinin birlikte kullanıldığı hibrit bir yöntemdir. Parkinson hastalığı veri seti UCI'den temin edilmiştir. CS-PSO-DVM modeli CS-DVM ve PSO-DVM yöntemleri ile karşılaştırılmıştır. CS-PSO-DVM modelinin sınıflandırma başarısı daha yüksektir. Bu çalışmanın neticesinde farklı optimizasyon algoritmalarının iyi özellikleri alınarak oluşturulan hibrit bir algoritma aracılığıyla sınıflandırma başarısının artırılabilceği sonucuna varılmıştır.

Saini ve ark. (2019) Yapay Arı Koloni (ABC) ve GA yöntemleri ile DMV parametrelerini optimize etmişlerdir. Çekirdek fonksiyonu olarak RBF, polinom ve lineer seçilmiş. İki farklı veri setinde yapılan deneyler sonucunda ortalama sonuçlar üzerinden yapılan değerlendirmede optimizasyon yöntemleri arasından ABC yönteminin ve seçilen çekirdek fonksiyonları arasında polinom çekirdek fonksiyonunun daha başarılı olduğu gözlemlenmiştir.

Thai ve ark. (2019) UCI'den alınan 3 veri setinde (Tiroit, Tohum, Escherichia Coli) Geriye Dönük Arama (BSA) yöntemi (Civicioglu, 2013), PSO (Cervantes ve ark., 2017), GA (Huang ve ark., 2017) ve Kovaryans Matris Adaptasyonu Gelişim Stratejisi (CMAES) (Jafrasteh ve Fathianpour, 2017) yöntemleri ile parametre optimizasyonu yaparak sonuçları karşılaştırmışlardır. Üç veri setinde de BSA yöntemine dayalı DVM'nin sınıflandırma hatası oranını daha düşük ve zaman maliyeti daha kısadır. Ayrıca

Thai ve ark. (2019) BSA yöntemine dayalı DVM sınıflandırıcıyı dişli arızalarını tespit etmek için de kullanmışlardır.

Saldırganlar kötü amaçlı yazılımları kullanarak birçok zararlı alan adları üretmekte ve kullanıcıların internet güvenliğini tehlikeye sokmaktadırlar. Bu alan adlarını tespit etmek için DVM yöntemine dayalı bir sınıflandırıcı kullanılmış (Huang ve ark., 2019). Kullanılan veri seti 50.000 alan adından oluşmaktadır. %97.49 sınıflandırma doğruluğu oranına ulaşılmış. Parametre optimizasyonu yapılmamış DVM'ye göre %3.46 oranında daha yüksek bir sonuca ulaşılmıştır.

Rajalaxmi ve Vidhya (2019) SSA'nın keşif kapasitesini geliştirmek için mutasyon işlemini SSA'ya dahil etmişler ve bu yöntemin standart SSA'ya göre daha iyi sonuçlar verdiğini gözlemişlerdir.

Cezayir'deki Tilesdit barajının su kalitesini sınıflandırmak için DVM kullanılmıştır (Ladjal ve ark., 2020). DVM'nin daha yüksek bir doğruluk oranıyla tahmin yapabilmesi DVM parametre optimizasyonunda PSO kullanılmış. Sınıflandırma başarısı %92'ye ulaşmış.

Singh ve Bansal (2020) göğüs kanseri hastalığının tahmini için kullanılan DVM sınıflandırıcının parametrelerini Gri Kurt Optimizasyonu ve Balina Optimizasyonu'nun birleşiminden oluşan hibrit bir yöntemle optimize etmişlerdir (GWWOA-DVM). Önerilen bu modeli GWO-DVM ve WOA-DVM ile karşılaştırmışlar ve önerilen modelin daha başarılı olduğunu gözlemlemişlerdir. Ayrıca aynı göğüs kanseri veri seti üzerinde sınıflandırma yapılan PSO-DVM (Alhakbani ve ark., 2017), WOA-DVM (Wang ve ark., 2020), Ayarlanmış Yarası Algoritması'na dayalı DVM (Tuba ve ark., 2016) ve DVM (Kamel ve ark., 2019) modelleri ile önerilen model sınıflandırma doğruluğu yönünden karşılaştırılmış ve %97.721 ile önerilen model en başarılı sonucu vermiştir.

Ağa izinsiz girişleri algılamak için PSOGWO-DVM modeli önerilmiş (Chen ve ark., 2021). Bu modelde ilk olarak GWO'nun optimizasyon yeteneğini ve yakınsama hızını iyileştirmek için PSO kullanılmış. Daha sonra DVM'nin parametrelerini optimize etmek

iin PSOGWO algoritması kullanılmış. nerilen model GWO-DVM ve parametre optimizasyonu yapılmamış DVM ile karşılaştırılmıştır. nerilen model daha başarılı sonuçlar vermiştir.

2.1 Literatr Taraması Deęerlendirmesi

Literatr taraması gstermektedir ki DVM’de parametrelerin optimizasyonu sınıflandırma performansına ciddi bir şekilde etki etmektedir. Optimizasyon iřlemi iin karınca koloni optimizasyonu, paracık srs optimizasyonu, genetik algoritma, yarasal algoritması gibi birok meta sezgisel yntem kullanılmış ve başarılı sonuçlar elde edilmiştir. Fakat kullanılan optimizasyon yntemlerinin başarısı veri setlerine gre farklılık gstermektedir. Bu yzden DVM’de parametre optimizasyonu iin en başarılı yntem kesin olarak belirlenememektedir. Literatrde bu konu ile ilgili alıřmalar hl devam etmektedir.

Bu tez alıřmasında DVM parametre optimizasyonu iin 4 farklı yntem seilmiştir. Bunlar Yarasal Algoritması, İyileřtirilmiş Kaotik Paracık Sr Optimizasyonu (Liu ve ark., 2005), İyileřtirilmiş Genetik Algoritma (Wu, 2019) ve Armoni Arama Algoritması’dır.

AAA ynteminde hesaplama sresi olduka kısadır ve başarılı sonuçlar elde edilmiştir (Ceylan ve Tařkın, 2016a). PSO ve GA literatrde yoęun olarak kullanılan iki yntemdir. Fakat PSO’da yerel optimuma kolayca dřme, erken yakınsama gibi problemler var iken GA’da sabit aprazlama ve mutasyon olasılıęından kaynaklanan sıkıntılar vardır. Bu problemlerin stesinden gelebilmek iin literatrde İyileřtirilmiş Kaotik Paracık Sr Optimizasyonu (Liu ve ark., 2005) ve İyileřtirilmiş Genetik Algoritma (Wu, 2019) geliřtirilmiştir. YA ise literatrde sıklıkla kullanılan 9 veri seti zerinde yapılan sınıflandırmada başarılı bir performans gstermiştir (Tharwat ve ark., 2017)

3. OPTİMİZASYON

Bir sistemden belirli kısıtlar altında en uygun sonucu alabilmek için yapılan çalışmalara optimizasyon denir. Diğer bir deyişle, hedef fonksiyonu minimize veya maksimize etmek amacıyla problemin değişkenlerinin en uygun değerlerinin belirlenmesi işlemine optimizasyon denir. Optimizasyon problemlerinde bulunan en iyi çözüm aslında en iyi çözüm değil, çözümler arasında diğerlerinden üstün olanı ifade etmektedir. Optimizasyon problemleri birkaç adımdan oluşmaktadır. Optimizasyon işleminde yapılacak ilk iş karar parametreleri olan parametreleri belirlemektir. Daha sonra parametrelerin alamayacağı değerleri tanımlayan sınırlama fonksiyonları, parametrelere bağlı olarak minimize edilecek bir maliyet fonksiyonu veya maksimize edilecek bir kar fonksiyonu tanımlamaktadır.

$x = (x_1, x_2, x_3, \dots, x_n)$ vektörü tanımlanmış olsun. Bu vektör parametrelerin değerlerini ifade etmektedir. Buna bağlı olarak maliyet fonksiyonu $f(x) = f(x_1, x_2, x_3, \dots, x_n)$ şeklinde tanımlanır.

$$h_j(x) = h_j(x_1, x_2, \dots, x_n) = 0, \quad 1 \leq j \leq p \quad (3.1)$$

$$g_i(x) = g_i(x_1, x_2, \dots, x_n) \leq 0, \quad 1 \leq i \leq m \quad (3.2)$$

$h_j(x)$ ve $g_i(x)$ fonksiyonları sınırlama fonksiyonlarını ifade etmektedir. $f(x)$ fonksiyonu Eşitlik 3.1'de tanımlandığı gibi p tane eşitlik sınırlamalarına veya Eşitlik 3.2'de tanımlandığı gibi m tane eşitsizlik sınırlamalarına sahip olabilir. Maliyet fonksiyonu değerlerinin oluşturduğu uzay çözüm uzayı, karar değişkenleri yani x_i 'lerin oluşturduğu uzaya ise arama uzayı denir (Karaboğa, 2011).

Optimizasyon problemleri tek amaçlı ve çok amaçlı olarak ikiye ayrılır. Bazı problemlerde birden fazla maliyet fonksiyonu bulunabilir. Eğer böyle bir durum varsa bu problemler çok amaçlı optimizasyon problemi olarak adlandırılır. Gerçek hayattaki optimizasyon problemlerinin birçoğu çok amaçlıdır.

Optimizasyon problemleri amaçlarına göre sınıflandırılabilirdiği gibi sınırlamalarına göre de sınıflandırılabilir. $f(x)$ maliyet fonksiyonunda x ile ilgili herhangi bir kısıt yoksa buna kısıtsız optimizasyon problemi, x ile ilgili sınırlama veya sınırlamalar varsa bu optimizasyon problemi kısıtlı optimizasyon problemi olur.

Kısıtlamaları sağlayan tüm çözümlerin oluşturmuş olduğu bölge uygun çözüm bölgesidir. Optimizasyon problemlerinde bulunması amaçlanan en uygun (optimum) çözüm, minimize edilecek problem olması halinde uygun bölgede en düşük maliyet değerine sahip çözümken, maksimize edilecek problem olması halinde ise uygun bölgede en büyük maliyet fonksiyonu değerine sahip çözümdür (Karaboğa, 2011).

3.1 Meta Sezgisel Yöntemler

Meta sezgisel kelimesi üst seviye sezgisel şeklinde ifade edilmektedir. Meta sezgisel yöntemler, doğadan esinlenerek önerilen, geleneksel optimizasyon yöntemleri kabul edilemez çözümler ürettiğinde etkin ve uygun çözümler üreten algoritmalarlardır. Meta sezgisel yöntemler arama uzayını etkin ve verimli bir şekilde inceleyerek, stokastik bir şekilde çözüm araştırması yaparlar. Her iterasyonda oluşturulmuş olan çözüm kümesinden yola çıkarlar ve yeni çözümler üretirler. Fakat global optimum çözümü bulmayı garanti etmezler (Onan, 2013; Yetkin ve Berber, 2014; Yetkin, 2016;). Her meta sezgisel algoritmanın esinlendiği yapıya uygun olarak bulunan parametreleri vardır.

Meta sezgisel yöntemler yüksek kalitede çözümler elde etmek için alt seviye sezgisellere rehberlik eden bir süreçtir (Voß ve Fink, 1999). Bu yöntemler basit yerel arama yöntemlerinden karmaşık öğrenme işlemlerine kadar geniş bir alanı oluşturmaktadır. Bu yöntemler probleme özgü değildir, karmaşık matematiksel işlemler gerektirmez, aşırı derecede hesaplama zamanına ihtiyaç duymazlar, dönüşümleri kolaydır ve lokal optimuma nadiren takılır. Bu yüzden meta sezgisel yöntemler geniş kullanım alanına sahiptirler.

Meta sezgisel yöntemler; fizik tabanlı (ısıt işlem algoritması, parçacık çarpışma algoritması), biyolojik tabanlı (karınca kolonisi algoritması, evrimsel algoritmalar), sürü tabanlı (parçacık sürü optimizasyonu, arı koloni optimizasyonu), sosyal tabanlı (tabu araştırma algoritması, parlamenter optimizasyon algoritması), müzik tabanlı (armoni arama), spor tabanlı (lig şampiyonası algoritması) ve kimya tabanlı yöntemler olmak üzere yedi farklı grupta değerlendirilir (Akyol ve Alataş, 2016). Ayrıca birden fazla meta sezgisel yöntemin bir arada kullanıldığı hibrit modeller de geliştirilmiştir (Kaya, 2019; Yan ve ark., 2010).

Meta sezgisel yöntemler yalnızca esinlendikleri kaynağa göre sınıflandırılmazlar. Aynı zamanda arama yaptıkları uzaya göre tek noktalı ve çok noktalı arama yapan yöntemler, amaç fonksiyonlarına göre sabit ve değişken amaç fonksiyonlu yöntemler, komşuluklarına göre tek komşulu ve değişken komşulu, hafızalarına göre hafızalı ve hafızasız olarak da sınıflandırılabilirler (Akyol ve Alataş, 2012).

Bu çalışmada kullanılan armoni arama algoritması müzik tabanlı, genetik algoritma biyolojik tabanlı, parçacık sürüsü optimizasyonu ve yarasa algoritması sürü tabanlı yöntemlerdir.

3.2 Yarasa Algoritması (YA)

YA, yarasaların ekolokasyon olarak isimlendirilen sesin yankılanmasından faydalanarak cismin bulunduğu yönü ve uzaklığı belirleme davranışından esinlenerek oluşturulmuş popülasyon tabanlı bir optimizasyon algoritmasıdır (Kamal, 2018). YA, 2010 yılında Xin-She Yang (Yang, 2010a) tarafından geliştirilmiştir ve sürü zekası temelli bir yöntemdir.

Birçok yarasa türü, farklı böcekleri tanımak, iletişim kurmak, hedefledikleri avların konumlarını tespit etmek, onlarla olan mesafelerini hissetmek, karanlıkta da gündüz gibi engellere çarpmadan hareket etmek için ekolokasyon adı verilen bir tür sonar kullanırlar

(Fenton, 2004; Yılmaz, 2014). Yarasaların gözleri görmesine rağmen ekolokasyon ile yönlerini bulur ve hareket ederler (Demir, 2015).

Yarasalar etrafa sinyaller yayarlar ve bu sinyaller çevredeki nesnelere ve avlarına çarpar. Böylece yankı oluşur. Yarasalar bu yankıyı dinledikten sonra yankıdaki kodları analiz eder. Daha sonra etrafındaki nesneleri tespit edip sınıflandırır ve onların yerini belirler (Schnitzler ve Kalko, 2001; Yılmaz, 2014).

YA aşağıda tanımlanan üç kurala dayalıdır (Yang, 2010a):

1. Tüm yarasalar çevrelerindeki avları, nesneleri, engelleri vb. tespit etmek ve onlarla aralarındaki mesafeyi belirlemek için ekolokasyon kullanır.
2. Yarasalar çevrelerindeki nesneleri bulmak için x_i konumunda, v_i hızında, f_{min} sabit frekansta, λ dalga boyunda ve A_0 ses şiddetinde rastgele uçarlar. Yaymış oldukları sinyallerin frekansını otomatik olarak ayarlayabilirler ve hedeflerinin yakınlığına bağlı olarak sinyal yayma oranlarını $r \in [0,1]$ olarak düzenleyebilirler.
3. Yaymış oldukları ses şiddetinin büyüklüğü minimum değer A_{min} ' den büyük değer A_0 'a kadar değişkenlik gösterir.

YA beş parametreye sahiptir. Bu parametrelerin özellikleri şu şekildedir (Tharwat ve ark. 2017):

- Yarasaların konumları (x_i): Arama uzayında koordinatlar ile temsil edilir. Algoritmanın başlangıcında rastgele belirlenir.
- Yarasaların hızları (v_i): Yarasaların arama uzayında en uygun çözüme doğru hareket etmesi için kullanılır.
- Sinyal yayma oranı (r_i): Yarasalar etrafa ses gönderirler ve bu ses yansır. Yansıyan bu sesi yarasalar avına olan mesafeyi ölçmek için yararlı bilgiye dönüştürür. Eğer yeni çözümlerde iyileşme varsa sinyal yayma oranı $r_i^{t+1} = r_i^0 [1 - \exp(-\gamma t)]$ denkleminde güncellenir ($\gamma > 0$ ve sabittir. t değeri şu anki iterasyon sayısını temsil eder.)
- Frekans (f_i): Yarasaların hızını kontrol etmek için kullanılan bir parametredir. Bu değer yüksek olursa yarasanın hızı yüksek olur. Frekans değeri başlangıçta $[f_{min}, f_{max}]$ aralığında rastgele atanır.

- Ses şiddeti (A_i): Yarasa avını bulana kadar $A_i^{t+1} = \alpha A_i^t$ denklemine göre ses şiddeti genellikle azalır. $\alpha = 0.7$ ile 0.99 arasında seçilir (Yang,2014). Ses şiddeti ve sinyal yayma oranının güncellenme işlemi sadece yeni üretilen çözümler ile iyileşme sağlanıyorsa yapılmalıdır. Daha iyi çözümler üretiliyorsa, yarasalar en uygun çözüme doğru hareket ediyor demektir. Yarasa avını bulduğunda ses şiddeti genellikle azalmasına rağmen, sinyal yayma oranı artmaktadır (Yang, 2010a).

YA'nın sözde kodu Şekil 3.1'de gösterilmiştir.

```

Her bir yarasanın başlangıç konumlarını, ses şiddetini, sinyal yayma oranlarını ve başlangıç
frekanslarını belirle. Her bir yarasanın uygunluk değerini ( $F(x_i)$ ) belirle.
While (t < maksimum iterasyon sayısı)
    Frekans, hız ve konum değerlerini güncelle.
    if (rand(0,1) >  $r_i$ )
        En iyi çözümün etrafında yerel bir çözüm üret.
    end if
    if (rand <  $A_i$  &  $F(x_i) < F(yeni)$  )
        Yeni üretilen çözümü kabul et.
         $r_i$  değerini arttır ve  $A_i$  değerini azalt.
    end if
    Popülasyondaki yarasaları sırala ve en iyi çözümü bul.
end while
En iyi çözümü göster.

```

Şekil 3.1: YA'nın sözde kodu (Kamal, 2018)

Popülasyonda bulunan her yarasa, f_i frekansında, popülasyondaki diğer yarasalar içerisinde en iyi bireyin sahip olduğu x_* çözüm değerine göre üretilen v_i^t hız değeri ile bir sonraki pozisyonlarını belirlemektedir (Yılmaz, 2014). x_i^t konum değeri ve v_i^t hız değerinin güncellenme işleminin yapıldığı denklemler Eşitlik 3.3, 3.4 ve 3.5'de verilmiştir (Yang ve He,2013).

$$f_i = f_{min} + (f_{max} - f_{min})\beta \quad (3.3)$$

$$v_i^t = v_i^{t-1} + (x_i^{t-1} - x_*) f_i \quad (3.4)$$

$$x_i^t = x_i^{t-1} + v_i^t \quad (3.5)$$

β , 0 ile 1 aralığında rastgele bir değeri, x_* popülasyondaki yarasalar arasında o anki en iyi konumu ifade etmektedir. Algoritmada daha iyi sonuçlar çıktıkça x_* değeri güncellenmektedir. f_i değeri her problem için farklılık gösterebilir çünkü bu değeri etkileyen $[f_{min}, f_{max}]$ değerleri vardır. Her yarasa uygunluk değerinin kalitesine göre bir başka çözüm seçip o çözümün etrafında yeni kaynak aramaktadır (Kamal, 2018). En iyi çözümün etrafında yerel çözüm üretme işlemi Eşitlik 3.6 ile yapılır.

$$x_{new} = x_{old} + \varepsilon A^t \quad (3.6)$$


ε değeri $[-1,1]$ aralığında rastgele bir sayıdır. A^t , t anındaki tüm yarasaların ortalama ses şiddetidir.

3.3 İyileştirilmiş Kaotik Parçacık Sürü Optimizasyonu (İKPSO)

Parçacık Sürü Optimizasyonu (PSO), 1995 yılında Russell Eberhart ve James Kennedy tarafından yiyecek bulmaya çalışan kuş sürülerinin davranışlarından esinlenerek oluşturulmuş bir optimizasyon algoritmasıdır (Kennedy ve Eberhart, 1995). Kuş, balık gibi hayvan sürülerinin avcılardan kaçma, zengin yiyecek kaynağı bulma gibi süreçlerde birbirleriyle haberleşmesi doğruyu bulma ihtimallerini ve hızlarını arttırmaktadır. Sürüdeki her bir bireye parçacık denir ve parçacıklar popülasyonu yani sürüyü oluşturmaktadır. Bu bireylerin her biri aday çözümdür. Bu yöntemde her bir parçacık konumunu önceki tecrübelerinden ve sürüdeki en iyi konuma sahip bireyden yararlanarak en iyi konuma doğru ayarlar. Genelde parçacıklar bir sonraki konumlarında önceki konumlarına göre daha iyi bir konuma gelirler. Bu süreç hedefe ulaşana kadar devam eder.

PSO algoritmasında her parçacık bir çözüm sunar ve tüm parçacıkların uygunluk fonksiyonu ile bulunan bir uygunluk değeri vardır. Ayrıca parçacıklar hız bilgisine benzer bir bilgiye sahiptir. Parçacıkların hareket şekli Şekil 3.2’de gösterilmiştir. Parçacıklar

belirli bir miktar kendi en iyi yaklaşımları yönünde, belirli bir miktar bir önceki hareketleri yönünde ve belirli bir miktar da sürü en iyi yaklaşımı yönünde hareket ederler.



Şekil 3.2: Bir parçacığın hareketi (Bryson ve ark., 2016)

3.3.1 PSO'nun matematiksel modeli

$x_i = (x_{i1}, x_{i2}, x_{i3}, \dots, x_{iD})$, D boyutlu bir uzayda i 'inci parçacığı ifade etsin. $p_i = (p_{i1}, p_{i2}, p_{i3}, \dots, p_{iD})$, i 'inci parçacığın bir önceki eni iyi pozisyonu ifade etmektedir. Bu ifade en iyi uygunluk değerini göstermektedir ve ayrıca p_{best} olarak ifade edilir. Tüm parçacıklar arasından seçilen en iyi uygunluk değerleri (p_{best}) g indeksi ile ifade edilirse, P_g 'nin pozisyonu g_{best} 'tir. $v_i = (v_{i1}, v_{i2}, v_{i3}, \dots, v_{iD})$ i . parçacığın hız vektörü olsun. PSO'da her bir parçacığın hız ve konumu, parçacığın p_{best} ve g_{best} durumlarına göre değişir. Parçacıkların hızlarının ve konumlarının değişimi Eşitlik 3.7 ve 3.8'de gösterilmiştir (Guo ve ark., 2008).

$$v_{id} = w * v_{id} + c_1 rand_1 (p_{id} - x_{id}) + c_2 rand_2 (p_{gd} - x_{id}) \quad (3.7)$$

$$x_{id} = x_{id} + v_{id} \quad (3.8)$$

w değeri eylemsizlik katsayısıdır ve bu değer ne kadar büyük olursa v_{id} hız değeri de o kadar büyük olacaktır. c_1 ve c_2 değerleri hız sabitleridir ve hızlanma ağırlıklarını belirler. Hızlanma ağırlığı parçacıkların en iyi duruma doğru uçarken kullandıkları hız anlamına gelir. Eğer c_1 değeri sıfır olursa, parçacık sadece kendi tecrübesi ile hareket eder ve yerel optimuma düşmesi daha kolay olur. Eğer c_2 değeri sıfır olursa, parçacık sadece sosyal deneyime sahip olur ve her parçacık kendi kendine hareket eder. Bu yüzden çözümün bulunma olasılığı düşer. Eğer hem c_1 hem de c_2 değeri sıfır olursa parçacık hiçbir deneyime sahip olmaz. Bu yüzden sürüdeki tüm parçacıklar sistemli ve düzenli olmaz (Yuan ve Chu, 2007). $rand_1$ ve $rand_2$, $[0,1]$ aralığında eşit oranda dağıtılmış rastgele bağımsız değerlerdir. PSO'da Eşitlik 3.7'de görüldüğü gibi parçacığın bir önceki hızı, o parçacığın şu ana kadarki en iyi konumu ve komşu parçacıklardan en iyi konuma sahip olanın parçacık dikkate alınarak parçacığın bir sonraki hızı hesaplanır. Bu hesaplanan değere göre de Eşitlik 3.8'deki gibi parçacığın yeni konumu hesaplanır.


3.3.2 PSO'nun yapısı

PSO algoritması temel olarak şu basamaklardan oluşur:

1. Sürüdeki parçacıkların başlangıç konumları ve hızları rastgele bir şekilde üretilir.
 2. Sürüdeki tüm parçacıkların uygunluk değeri hesaplanır.
 3. Her bir parçacık için mevcut jenerasyondan yerel en iyi (p_{best}) parçacık bulunur.
 4. Mevcut jenerasyondaki yerel en iyi parçacıklar içinden en iyi parçacık seçilir ve global en iyi (g_{best}) parçacık olarak kabul edilir.
 5. Parçacıkların hızları ve konumları Denklem 37 ve 38'deki matematiksel işlemlerle güncellenir.
 6. Durdurma kriteri sağlanana kadar 2, 3, 4 ve 5 adımları tekrar edilir.
- Durdurma kriteri, iterasyon sayısı olabileceği gibi arama süresi, probleme özel başarı değerleri de olabilir.

PSO'nun örnek bir iterasyonu Şekil 3.2'de gösterilmiştir. İlk iterasyonda tüm parçacıklar yayılır. Daha sonra sürüdeki parçacıkların uygunluk değerleri hesaplanır ve en iyi çözümler bulunarak tüm parçacıklar için kişisel ve global en iyi parçacıklar güncellenir. En iyi çözüm üretilene kadar iterasyon devam eder. Şekil 3.3'de görüldüğü gibi problem

75.iterasyonda sonlanmıştır. Problemin boyutu ve karmaşıklığı arttıkça iterasyon sayısı ve parçacık sayısı arttırılmalıdır (Wahab ve ark., 2015).



Şekil 3.3: Sürünün iterasyonlar sonucunda konumu (Wahab ve ark., 2015)

3.3.3 Uyarlanabilir eylemsizlik ağırlık faktörü (Adaptive inertia weight factor)

PSO'nun performansı parametrelerine göre değişkenlik gösterir. Eşitlik 3.7'de hız güncelleme formülünde kullanılan, w ile ifade edilen eylemsizlik ağırlığı PSO yönteminde oldukça önemli bir yere sahiptir. Bu değer kontrolü en uygun çözümü doğru bir şekilde belirlemede önemli bir yer tutmaktadır. Eylemsizlik ağırlığı, parçacığın eski hızının yeni hıza güncellemesindeki etkiyi belirler (Gao ve ark., 2012). Bu değer büyük olması yerel minimumdan atlamak için uygundur. Küçük olması ise algoritmanın yakınsaması için faydalıdır. İşte burada bir denge kurulmalıdır. Bunun için de eylemsizlik ağırlığı değerini düzenleyecek olan bir denklem önerilmiş ve PSO'ya iyileştirme yapılmıştır (Liu ve ark., 2005; Cheng ve ark., 2010). Bu denklem şu şekildedir:

$$w = \begin{cases} w_{min} + \frac{(w_{max} - w_{min})(f - f_{min})}{f_{ort} - f_{min}}, & f \leq f_{ort}, \\ w_{max}, & f > f_{ort}, \end{cases} \quad (3.9)$$

w_{min} ve w_{max} sırasıyla w değerinin minimum ve maksimum değerlerini göstermektedir. f , parçacığın mevcut uygunluk değeridir. f_{ort} , tüm parçacıkların ortalama uygunluk değerini, f_{min} ise tüm parçacıklar içinde en küçük uygunluk değerine sahip parçacığın uygunluk değerini göstermektedir. Bu denklem ile parçacık çeşitliliği ve iyi yakınsama kapasitesi sürdürülmeye çalışılır.

3.3.4. Kaotik yerel arama

PSO yöntemi kodlaması kolay olmasına rağmen yerel arama kapasitesi zayıftır ve kolayca yerel optimuma takılabilir (Han ve Houjun, 2011). PSO'nun erken yakınsamanın engellenmesi, global aramasının iyileştirilmesi ve yerel optimuma takılmasını önlemek için PSO algoritmasına kaos işlemi dahil edilir. En meşhur kaos eşitliklerinden biri lojistik eşitliktir (logistic equation) ve denklemi şu şekildedir (May, 1976):

$$x_{n+1} = \mu \cdot x_n(1 - x_n), \quad 0 \leq x_0 \leq 1 \quad (3.10)$$

μ kontrol parametresi, x bir değişken ve $n = 0, 1, 2, \dots$ 'dir. Bu denklem deterministik olmasına rağmen $\mu = 4$ ve $x_0 \notin \{0, 0.25, 0.5, 0.75, 1\}$ olduğunda kaotik dinamikler sergilemektedir (Liu ve ark., 2005).

Kaos hareketi başlangıç koşullarına duyarlıdır, rastgelelik, ergodiklik özelliklerine sahiptir. Bu yüzden kaos işlemi PSO'ya dahil etmek popülasyon çeşitliliğini, parçacık arama ergodikliğini iyileştirebilir ve böylece yerel optimuma takılma sorunun üstesinden gelinebilir. Ayrıca algoritmanın yakınsama hızı ve hassasiyeti iyileştirilebilir (Han ve Houjun, 2011).

Kaotik yerel arama süreci şu denklemle tanımlanabilir (Liu ve ark., 2005):

$$cx_i^{(k+1)} = 4cx_i^{(k)} (1 - cx_i^{(k)}), \quad i = 1, 2, \dots, n \quad (3.11)$$

cx_i , i. kaotik değişken, k iterasyon sayısını ifade etmektedir.

Kaotik yerel arama işleminin adımları şu şekildedir (Liu ve ark., 2005):

1. $(x_{min,i}, x_{max,i})$ aralığında bulunan karar değişkenleri $x_i^{(k)}, i = 1, 2, \dots, n$ Eşitlik 3.12 kullanılarak kaotik değişkenlere haritalanır.

$$cx_i^{(k)} = \frac{x_i^{(k)} - x_{min,i}}{x_{max,i} - x_{min,i}}, \quad i = 1, 2, \dots, n \quad (3.12)$$

2. Eşitlik 3.11 kullanılarak bir sonraki iterasyon için $cx_i^{(k+1)}$ kaotik değişkenleri belirlenir.

3. Eşitlik 3.13 kullanılarak $cx_i^{(k+1)}$ kaotik değişkenleri $x_i^{(k+1)}$ değişkenlerine dönüştürülür.

$$x_i^{(k+1)} = x_{min,i} + cx_i^{(k+1)}(x_{max,i} - x_{min,i}), \quad i = 1, 2, \dots, n \quad (3.13)$$

4. Karar değişkenleri $x_i^{(k+1)}$ ile yeni çözümleri değerlendirir.

5. Eğer yeni çözüm küresel en iyi çözümden (g_{best}) daha iyiye ya da tanımlanan maksimum iterasyona ulaşılmışsa kaotik yerel arama işlemini sonlanır, değilse k değerini bir artırır ve birinci adıma dön.

Kaotik Parçacık Sürü Optimizasyonu'nun adımları şu şekilde özetlenebilir:

1. Sürüdeki parçacıkların başlangıç konumları ve hızları rastgele bir şekilde üretilir.
2. Sürüdeki tüm parçacıkların uygunluk değeri hesaplanır.
3. Tüm parçacıkların yerel en iyi çözümleri başlangıç konumlarına ait uygunluk değerleri olarak kabul edilir.
4. Mevcut popülasyondaki parçacıklar arasından en iyi uygunluk değerine sahip parçacık global en iyi çözüm kabul edilir.
5. Parçacıkların hızları ve konumları Eşitlik 3.7 ve 3.8'deki matematiksel işlemlerle güncellenir.
6. Yeni konum değerleriyle parçacıkların yeni uygunluk değerleri hesaplanır.

7. Hesaplanan uygunluk değeri parçacığın yerel en iyi çözümünden daha iyiye parçacığın yerel en iyi çözümü güncellenir. Ayrıca hesaplanan uygunluk değeri global en iyi çözümünden daha iyiye global en iyi çözüm de güncellenir.

8. N popülasyon sayısı olmak üzere en iyi $N/5$ parçacığı bul.

9. Global en iyi parçacık için kaotik yerel arama işlemini uygula.

9.1 Eşitlik 3.12'deki ile karar değişkenlerini kaotik değişkenlere haritala.

9.2 Eşitlik 3.11'i kullanarak bir sonraki iterasyon için kaotik değişkenleri belirle.

9.3 Eşitlik 3.13 ile kaotik değişkenleri karar değişkenlerine dönüştür.

9.4 Yeni çözümü değerlendir. Eğer yeni çözüm küresel en iyi çözümünden (g_{best}) daha iyiye ya da tanımlanan maksimum iterasyona ulaşılmışsa kaotik yerel arama işlemini sonlandır, küresel en iyi parçacığı güncelle ve 10.adıma geç, değilse 9.1'e dön.

10. Arama uzayını Eşitlik 3.14 ve 3.15 ile daralt.

$$x_{min,i} = \max(x_{min,i}, x_{gbest} - rand * (x_{max,i} - x_{min,i})) \quad (3.14)$$

$$x_{max,i} = \min(x_{max,i}, x_{gbest} + rand * (x_{max,i} - x_{min,i})) \quad (3.15)$$

11. Daraltılmış arama uzayında rastgele $4N/5$ yeni parçacık üret ve uygunluk değerlerini bul.

12. 11. adımda üretilen $4N/5$ parçacık ile kaotik yerel arama sonucu değiştirilen küresel en iyi parçacığın dahil olduğu eski en iyi $N/5$ parçacığı birleştir.

13. 5.adıma geri dön ve durdurma kriteri sağlanıncaya kadar devam et.

3.4 İyileştirilmiş Genetik Algoritma (İGA)

Genetik algoritma (GA), temelleri 1970'li yılında John Holland tarafından ortaya atılmış, geleneksel yöntemlerle çözümü zor olan problemlerde kullanılan evrimsel yaklaşımlardan biridir (Holland, 1975). Bu yöntemde Darwin'in evrim teorisinden esinlenilmiştir (Dawid, 1999).

GA, iyi nesillerin yaşamlarını koruması ve kötü nesillerin yok olması ilkesine dayanır. Anne ve babadan doğan yeni bireyler, onlardan iyi genleri almış olabileceği gibi kötü genleri de almış olabilir. Bu durumda kötü genlere sahip olan bireyler varlıklarını sürdüremeyecektir (Elmas, 2016).

3.4.1. GA'nın temel kavramları

Gen

Genler, GA'da çözümün bir özelliğini temsil eder. Gen bir kromozomdaki tek bir özelliktir. Gen yapıları programcının tanımlamasına bağlıdır (Elmas ve Yiğit, 2007).

Kromozom (Birey)

Genetik aloritmada problem gen yapısında kodlanmakta ve genler bir araya gelerek kromozomu oluşturmaktadır. Her bir kromozom problem için olası çözümleri temsil eder ve kromozomlardaki her bir kısım genleri oluşturmaktadır (Elmas, 2016; Okur ve Atlas, 2020).

Popülasyon

Kromozomların bir araya gelmesiyle popülasyon oluşmaktadır. Popülasyon büyüklüğü çok önemlidir çünkü fazla sayıda kromozom yığını problemin çözümünü uzatabilirken, az sayıda kromozom yığını ise çözüm değerlerine ulaşlamamasına ya da sistemin belirli bir çözüm uzayında takılarak çözümü iyileştirememesine neden olabilir (Elmas, 2016). Popülasyon büyüklüğü için kesin bir değerden söz edilemez. Probleme göre bu değer değişkenlik gösterebilir.

Genetik Operatörler

GA'da üç çeşit genetik operatör vardır: seçim, çaprazlama ve mutasyon. Bu kavramlar ileride detaylı şekilde açıklanacaktır.

Diğer Kavramlar

Allel, bir genin alabileceği değerler, lokus genin kromozom içinde bulunduğu konum genotip kromozom yapısı, fenotip ise genotipin fiziksel açıklamasıdır. Uygunluk değeri, her bir kromozomun amaç fonksiyonunda almış olduğu değerdir. Bu değere göre bireylerin iyi ya da kötü olduğu belirlenir ve sonraki nesillere aktarılıp aktarılmayacağına karar verilir. GA'da popülasyondaki iyi özelliklere sahip bireylerin bir sonraki nesile aktarılması amaçlanır.

3.4.2 GA'nın adımları

İlk adım kromozomların kodlanmasıdır. Bir problemin GA ile çözümüne başlanabilmesi için ilk olarak probleme ait veriler algoritmanın anlayacağı dile çevrilmelidir yani kodlanmalıdır. GA'da genel olarak kullanılan kodlama sistemleri ikili kodlama, sıralı (permütasyon) kodlama ve değer kodlamadır.

İkili (binary) kodlama, GA'da en eski ve en yaygın kullanılan kodlama türlerinden biridir. Her kromozom 0 veya 1 değerlerinden oluşur. Sabit bir dizi uzunluğu belirlenmelidir. İkili kodlama ile temsil edilen iki kromozom örneği Şekil 3.4'de gösterilmiştir (Çakar, 2009).

KROMOZOM A	10110010110010101110
KROMOZOM B	11111110000011000001

Şekil 3.4: İkili kodlama ile temsil edilen iki farklı kromozom (Arıcı, 2021)

Değer kodlamada problemin gerçek değerleri kullanılmaktadır. Kodlanan karakterler tam sayı, ondalık sayı, harf ya da sözcüklerden oluşabilir. Şekil 3.5'de değer kodlama ile kodlanmış örnek kromozomlar gösterilmiştir (Sivanandam ve Deepa, 2008).

KROMOZOM A	ADBHNJMKLERTY
KROMOZOM B	(1,234),(5,678),(4,678)
KROMOZOM C	(ön),(sağ),(ön),(arka)

Şekil 3.5: Değer kodlama örnekleri (Arıcı, 2021)

Sıralı (permütasyon) kodlama, Özellikle araç rotalama ya da gezgin satıcı problemleri gibi ikili kodlama ile gösterimi zor olan problemlerde tercih edilen kodlama çeşididir. Kromozomda bulunan her gen, gidilecek noktayı gösterir (Taşkın ve Emel, 2009). Sıralamanın önemli olduğu problemlerde bu yöntem tercih edilir. Şekil 3.6’da permütasyon kodlama örneği gösterilmiştir (Dursun, 2009).

KROMOZOM A	135792468
KROMOZOM B	123498765

Şekil 3.6: Permütasyon kodlama örnekleri (Arıcı, 2021)

İkinci adım başlangıç popülasyonunun oluşturulmasıdır. Algoritmada kullanılacak bireyler (kromozomlar) oluşturulur. Başlangıç popülasyonu genellikle rastgele belirlenir. Kromozom sayısı programcı tarafından belirlenir. Popülasyon büyüklüğü GA’nın performansını etkiler. Popülasyonun büyük olması çözüm uzayında daha geniş bir bölümde arama yapılmasını sağlar fakat çalışma süresini uzatır. Popülasyonun küçük olması ise çalışma zamanı kısaltırken arama dar bir uzayda gerçekleştirileceği için en iyi çözüme ulaşılma olasılığını azaltır.


Üçüncü adım, uygunluk fonksiyonunun belirlenmesi ve uygunluk değerinin hesaplanmasıdır. Uygunluk fonksiyonu ile popülasyondaki kromozomların uygunluk değeri hesaplanır. Hesaplanan uygunluk değeri ile bireyler hayatta kalıp kalmayacağına karar verilir (Dursun, 2009). İyi bireyler hayatta kalıp bir sonraki nesile özellikleri aktarılır.

Dördüncü adım seçim işlemidir. Uygunluk değeri hesaplandıktan sonra mevcut popülasyondan bir sonraki jenerasyon oluşturulmalıdır. Bunun için de seçim işlemi yapılır. Seçim işleminde popülasyondan bireyler seçilir ve bunlar ebeveyn olarak isimlendirilir. Seçim işleminin amacı mevcut popülasyondaki uygunluk değeri yüksek olan bireyleri çoğaltmaktır (Ayhan, 2021).

Seçim işleminde dengenin gözetilmesi gerekir. Çok güçlü bir seçimin yapılması çözüme giden çeşitliliğin azalmasına sebep olabilirken, çok zayıf bir seçim ise geniş bir alanın taranmasından dolayı evrimin yavaşlamasına sebep olabilir (Bolat ve ark., 2005; Okur ve Atlas 2020).

Seçim işlemi için farklı teknikler mevcuttur. En sık kullanılan yöntemler, rulet çemberi tekniği, sıralı seçim yöntemi, turnuva yöntemidir.

Rulet çemberi yönteminde toplumdaki tüm bireylerin uygunluk değerlerin toplanmasıyla toplumun uygunluk değeri bulunur. Her bir bireyin uygunluğu değeri bireylerin toplam uygunluk değerine bölünür ve bireylerin seçilme olasılıkları bulunur (Dursun, 2009). Şekil 3.7’de görüldüğü gibi uygunluk değeri yüksek olan bireylerin rulet çarkında kapladığı alan daha fazla olur. Bu yüzden rulet çarkı çevrildiğinde uygunluk değeri yüksek bireylerin seçilme olasılığı da artar (Kahraman ve Özdağlar, 2004).



Şekil 3.7: Rulet çemberi yöntemi (Arıcı, 2021)

Bir bireyin rulet çemberi yöntemine göre seçilme olasılığı şu denklemle hesaplanır:

$$P_s(c_i) = \frac{f_i}{\sum_{i=1}^N f_i} \quad (3.16)$$


$P_s(c_i)$ i. bireyin seçilme olasılığı, $f_i \geq 0$ olmak üzere i. bireyin uygunluk değeri ve N popülasyon büyüklüğünü gösterir (Satman, 2016).

Turnuva yönteminde rastgele seçilen iki bireyin uygunluk değerlerinin karşılaştırılıp uygunluk değeri daha iyi olan bireyin seçilmesine dayalı olan bir seçim yöntemidir.

Sıralı seçim yönteminde bireyler uygunluk değerlerine göre en iyiden en kötüye doğru sıralanır ve uygunluk değerleri ile orantılı olarak bireylere değerler atanır (Liang ve Wang, 2020). Seçim yapılırken rassal sayı ataması kullanılır (Vural, 2005). Uygunluk değeri yüksek olan bireyin seçilme ihtimali daha fazla iken uygunluk değeri düşük olan bireyin seçilme ihtimali daha düşüktür (Ayhan, 2021).


GA'nın beşinci adımı çaprazlama işlemidir. Seçilen ebeveynlerin çeşitli kurallar ile birleştirilmesiyle yeni bireyler üretmeye çaprazlama denir (Ayhan, 2021). Çaprazlama işleminde seçilen iki bireye ait özellikler çocuğa aktarılır ve yeni jenerasyon meydana gelir. İyi özelliklere sahip bireylerin çaprazlanmasıyla iyi genlerin aktarılması sağlanır (Vural, 2005). Çaprazlama oranına göre ebeveyn çiftleri arasında çaprazlama olup olmayacağı belirlenir. Çaprazlama olasılığı 0 ile 1 arasında bir değerdir. Rastgele bir sayı üretilip bu sayının çaprazlama olasılığından küçük olup olmadığına bakılır. Eğer küçükse ebeveyn çiftleri arasında çaprazlama yapılır. Eğer büyük ya da eşitse ebeveyn çiftleri arasında çaprazlama işlemi uygulanmaz. Çaprazlama işlemi için en çok kullanılan teknikler tek noktalı çaprazlama, çok noktalı çaprazlama, karşılaştırmalı çaprazlama, tekdüze çaprazlama ve sıralı çaprazlamadır.

Tek noktalı çaprazlama tekniğinde ebeveyn dizileri üzerinde rastgele tek bir nokta belirlenir ve bu noktadan bölme yapılır. Bölünen genler çapraz şekilde birleşir ve Şekil 3.8’de görüldüğü gibi iki yeni çocuk meydana gelir (Özalp ve Alp, 2020).




Şekil 3.8: Tek noktalı çaprazlama örneği (Arıcı, 2021)

Çok noktalı çaprazlamada birden fazla çaprazlama noktası rastgele seçilir. Bireyler belirlenen bu çaprazlama noktalarından çaprazlanır. Kromozom uzunluğuna göre çaprazlama noktasının kaç tane olacağı belirlenir. Şekil 3.9’da üç noktalı çaprazlama örneği gösterilmiştir (Vural, 2005).




Şekil 3.9: Üç noktalı çaprazlama örneği (Arıcı, 2021)

Tekdüze (uniform) çaprazlama tekniğinde çaprazlama noktası seçilmez. Ebeveynlerin genleri sırasıyla çocuğa kopyalanır. Kopyalamada her bir gen anlık bir $X_i \in [0,1]$ ($i = 1, \dots, n$) olasılığına göre ebeveynlerin birisinden gelmektedir. Örnek olarak $X_i < 0.5$ ise i. gen birinci ebeveynden birinci çocuğa ikinci ebeveynden ikinci çocuğa, $X_i \geq 0.5$ ise i. gen birinci ebeveynden ikinci çocuğa ikinci ebeveynden birinci çocuğa aktarılır (Özalp ve Alp, 2020). Şekil 3.10’da tekdüze çaprazlama örneği gösterilmiştir.




Şekil 3.10: Tekdüze çaprazlama örneği (Arıcı, 2021)

Sıralı çaprazlamada genler, kromozomlarda sıralamaya göre dizilir. Birinci ebeveynden bazı genler çocuğa kopyalanır, kalan genler ise ikinci ebeveynde görülen sıraya göre çocuklara kopyalanır. İki ebeveyn kromozom üzerinde rastgele iki kesme noktası seçilir. Şekil 3.11’de görüldüğü gibi birinci ebeveynin iki kesme noktası arasındaki genler (5-4-6-7) birinci çocuğa kopyalanır (Kumar ve Pannerselvam, 2017). Daha sonra genlerin geri kalanı ikinci kesim noktasından itibaren ikinci ebeveyndeki sırayla kopyalanır. Kromozomlarda gen tekrarı oluşursa bu genlerin yerine soldan sağa doğru tekrarlanmayan genler kopyalanır (Cheng ve ark., 1999).




Şekil 3.11: İlk çocuk için sıralı çaprazlama (Arıcı, 2021)

İkinci çocuk için yapılacak sıralı çaprazlamada Şekil 3.12’de olduğu gibi ebeveynler yer değiştirilir ve aynı kurallar uygulanır (Kumar ve Pannerselvam, 2017).




Şekil 3.12: İkinci çocuk için sıralı çaprazlama (Arıcı, 2021)

Karşılaştırmalı çaprazlamada rastgele iki kromozom seçilir ve bu iki kromozomun genleri eşit olacak şekilde rastgele karıştırılır. Daha sonra çaprazlama noktası belirlenip tek noktali çaprazlama yöntemi uygulanır (Özalp ve Alp, 2020). Şekil 3.13’de ebeveynlerin genleri karıştırılmış, Şekil 3.14’de çaprazlama noktası belirlenip tek noktali çaprazlama uygulanmıştır.



Şekil 3.13: Karşılaştırmalı çaprazlamanın ilk adımı (Arıcı, 2021)




Şekil 3.14: Karşılaştırmalı çaprazlamanın ikinci adımı (Arıcı, 2021)

GA'nın altıncı adımı mutasyon işlemidir. Mutasyon işlemi, popülasyondaki çeşitliliği arttırmak ve korumak amacıyla uygulanan bir işlemdir (Çolak,2010). Bu işlem önceki adımlarda kaybedilen yararlı genlerin kurtarılması için kullanılır. Mutasyon olasılığına göre kromozomdaki değer değiştirilir (Chen ve Chen, 1997). Mutasyon işlemi tüm kromozomlara uygulanmaz. Sadece üretilen çocukların belli bir yüzdesine uygulanır ki bu yüzdeye mutasyon olasılığı ismi verilmektedir. Bu olasılık probleme başlarken belirlenir ve genel olarak 0.01 gibi çok küçük değerlerden oluşur. Eğer mutasyon olasılığı değeri büyük olursa gereğinden fazla değişiklik olur ve en uygun çözüme ulaşmak zorlaşabilir (Kırda, 2013; Okur ve Atlas, 2020).

Mutasyon işlemi için farklı teknikler mevcuttur. Bunlardan bazıları şu şekildedir (Liu, 2014):

- Karşılıklı değişim mutasyonu: Kromozom üzerinde rastgele iki farklı konum belirlenir ve bu konumdaki genler karşılıklı olarak değiştirilir.
- Ekleme mutasyonu: Kromozomdan rastgele bir gen çıkarılır ve yine rastgele seçilen bir konuma eklenir.
- Ter çevirme mutasyonu: Rastgele iki pozisyon seçilir ve bu iki pozisyon arasındaki genler ters çevrilir.
- Yer değiştirme mutasyonu: Kromozomdan rastgele iki konum seçilir, seçilen iki yer arasındaki genler kaldırılır ve kromozomda rastgele belirlenen yerlere eklenir.

Şekil 3.15'de bu mutasyon tekniklerinin örnekleri gösterilmiştir (Liu, 2014).



Şekil 3.15: Mutasyon tekniklerine örnekler (Arıcı, 2021)

3.4.3 Çaprazlama ve mutasyon olasılığı modeli

GA'da çaprazlama ve mutasyon olasılığı genellikle sabit değerlerdir. Bu sabit olasılıklı model, popülasyondaki değişikliklere uyum sağlamada başarısız olur. Ayrıca çaprazlama ve mutasyon olasılığı GA'nın yakınsamasında ve sınıflandırma doğruluğunda önemli bir etkiye sahiptir (Wu, 2019). Çaprazlama oranının yüksek olması arama uzayının çok hızlı bir şekilde araştırılmasına neden olur ve diğer bireylere göre daha iyi olan bireyler üreme işleminden sonra hızlı bir şekilde bozulur. Düşük çaprazlama oranında ise üreme sonucunda oluşan yeni nesile az sayıda yeni bireylerin girmesine sebep olur ve arama uzayı yeterince taranamaz. Mutasyon olasılığında ise olasılık değeri yüksek olursa araştırmaya aşırı bir rastgelelik kazandırılmış olunur ve ıraksama hızlanır. Mutasyon olasılığı düşük bir değer olursa ıraksama yavaşlar ve arama uzayı tamamen taranamaz. Bu yüzden erken yakınsama problemi ortaya çıkar (Kalınlı ve Aksu, 2011). Bu sorunları çözmek için Wu 2019'da popülasyondaki bireylerin değişen uygunluk değerlerine göre değişkenlik gösteren yani sabit kalmayan çaprazlama ve mutasyon olasılığı modeli önermiştir. Bu modele göre çaprazlama olasılığı Eşitlik 3.17'de gösterilmiştir (Wu, 2019).

$$P_c = \left(\frac{\frac{Fit_{min} \cdot P_{cmax}}{Fit_{max}} + (P_{cmin} \cdot \frac{c}{t} + P_{cmax} \cdot \frac{t-c}{t} P_{cmax})}{2} \right) \quad (3.17)$$

Bu denklemde P_c çaprazlama olasılığını, Fit_{min} algoritma çalışırken mevcut popülasyondaki minimum uygunluk değerini, P_{cmin} minimum çaprazlama olasılığını, P_{cmax} maksimum çaprazlama olasılığını, t değeri toplam jenerasyon sayısını, c değeri algoritmanın çalışması esnasındaki mevcut popülasyonun jenerasyon sayısını ve Fit_{max} algoritma çalışırken mevcut popülasyondaki maksimum uygunluk değerini ifade eder.

Önerilen yeni mutasyon olasılığı ise şu şekildedir (Wu,2019):

$$P_m = P_{mmin} \cdot \frac{c}{t} + P_{mmax} \cdot \frac{t-c}{t} \quad (3.18)$$

Bu denklemde P_m mutasyon olasılığını, P_{mmin} minimum mutasyon olasılığını, P_{mmax} maksimum mutasyon olasılığını, c değeri algoritmanın çalışması esnasındaki mevcut popülasyonun jenerasyon sayısını ve t değeri toplam jenerasyon sayısını ifade eder.


Bu tez çalışmasında GA yöntemini kodlarken önerilen bu çaprazlama ve mutasyon olasılığı modeli kullanılmıştır.

3.5 Armoni Arama Algoritması (AAA)

Armoni Arama Algoritması (AAA) 2001 yılında Geem, Kim ve Jonathan tarafından geliştirilmiştir. Bu algorithmada jazz müzikteki en iyi armoniye ulaşma süreci benimsenmiştir. Bu yöntemde orkestra elemanları birlikte daha fazla çalarlarsa en iyi armoniyi elde edebilir. Bu süreç optimizasyon problemine uyarlandığında ise daha fazla denemeye en iyi sonuca ulaşılabilir (Geem ve ark., 2001).

AAA'da en estetik melodi ancak tüm orkestra elemanlarının armonik açıdan birbirleri ile uyumlu şekilde çalışmaları ile elde edilebilir. Bu durumu optimizasyon problemlerine

uyarlarsak optimizasyon problemlerinde amaç fonksiyonunun global çözüme yaklaşması ile en iyi çözüm elde edilebilir. Orkestranın en estetik melodiye ulaşma süreçleriyle optimizasyon problemlerindeki global çözüme ulaşma arasındaki ilişki Şekil 3.16’da gösterilmiştir (Ayvaz ve ark., 2007b).



Şekil 3.16: Estetik melodiye elde etme süreci ile global çözüme ulaşma süreci arasındaki ilişki (Ayvaz ve ark., 2007b)

Şekil 3.16’da görüldüğü gibi orkestrada üç farklı müzisyen bulunmakta ve her müzisyenin hafızasında üçer tane nota bulunmaktadır. Birinci müzisyenin hafızasında (Do, Re, Mi), ikinci müzisyenin hafızasında (Fa, Mi, Sol) ve üçüncü müzisyenin hafızasında (La, Si, Sol) notaları bulunmaktadır. Şekil 3.16’da görüldüğü gibi birinci müzisyen (Do), ikinci müzisyen (Mi), üçüncü müzisyen (Sol) notasını çalmıştır ve (Do, Mi, Sol) şeklinde bir armoni oluşmuştur. Oluşan bu armoni, müzisyenlerin hafızalarındaki en kötü armoniden daha iyi olması durumunda hafızaya girer ve en kötü armoni hafızadan çıkarılır. Bu işlem en estetik melodi elde edilinceye kadar devam eder. Bu süreci optimizasyon problemine uyarlarsak Şekil 3.16’da görüldüğü gibi X_1 , X_2 , X_3 üç farklı karar değişkeni olsun. Bu karar değişkenlerinin hafızalarındaki değerler $X_1 = (1.0, 2.2, 2.6)$, $X_2 = (3.2, 2.6, 1.5)$, $X_3 = (1.7, 2.4, 2.2)$ olsun. Örnek olarak karar değişkenlerinin hafızalarından 1.0, 2.6 ve 2.2 seçilmiş olsun. Bu durumda yeni bir çözüm

kümesi (1.0, 2.6, 2.2) olur. Bu çözüm kümesi hafızadaki en kötü çözümden daha iyi ise bu çözüm kümesi hafızaya alınır ve en kötü çözüm hafızadan çıkarılır. Bu işlem en iyi çözüm kümesi elde edilene kadar devam eder (Ayvaz ve ark., 2007b).

AAA, tek bir çözümle ilgilenen diğer algoritmaların aksine aynı anda birden çok çözümle ilgilenir. Bu yüzden yerel optimumlara yakalanma olasılığı, tek çözümle ilgilenen algoritmalara göre daha azdır (Omran ve Mahdavi, 2008).

3.5.1 AAA'nın diğer meta sezgisel yöntemlerden farklılıkları

AAA'nın diğer meta sezgisel yöntemlerden farklılıkları şu şekildedir (Geem ve ark., 2001; Ayvaz ve ark., 2007b; Alia ve Mandava, 2011):

- GA'da yeni bir nesil oluşturulurken popülasyondan seçilen iki birey göz önünde bulundurulur ve bu yüzden sadece seçilen bu bireylerin özellikleri yeni nesile aktarılabilir. AAA'da ise yeni armoni oluşturulurken bellekte bulunan tüm armoniler göz önünde bulundurulur. Ayrıca AAA'da yeni armoni oluşturulurken sadece bellekteki armonilerden değil, armoni belleğini dikkate alma oranı ve ton ayarlama oranı gibi AAA'nın parametreleri sayesinde bellekten olmayan alternatiflerden de yararlanılabilir.
- AAA'nın çalışma zamanı GA'ya göre oldukça kısadır.
- Her armonide bulunan her karar değişkeni birbirinden bağımsız olarak değerlendirilir.
- Üretmek için karmaşık türev bilgisine ihtiyaç duymaz.

3.5.2 AAA'nın sahip olduğu avantajlar

AAA'nın sahip olduğu avantajlar şu şekildedir (Ayvaz, 2007a; Hong-Qi ve ark, 2008; Fesanghary ve ark., 2009):

- Algoritmanın matematiksel tanımları oldukça kolaydır ve kolay bir şekilde kodlanabilmektedir.
- Karar değişkenleri için özel bir başlangıç çözümü tanımlamaya gerek yoktur.

- Birden çok çözümle optimizasyon işlemi devam eder. Bu yüzden birden çok yönde global optimum çözüm aranır ve böylece lokal optimum çözümlerden kurtulmaktadır.
- Arama uzayındaki hiç taranmamış alanları da arama kabiliyeti vardır.

3.5.3 AAA'nın yapısı


Bu algoritma beş temel adımdan oluşmaktadır. Birinci adım problemin kurulması ve çözüm parametrelerinin ayarlanmasıdır. $f(x)$ minimize edilecek amaç fonksiyonu, x_i karar değişkenleri, X_i i. karar değişkeni için kullanılan çözüm uzayı, N toplam karar değişkeni sayısı olmak üzere optimizasyon problemi şu şekilde tanımlanır (Ayvaz ve ark., 2007b):

$$z = \min\{f(x)\} \quad x_i \in X_i \quad i = 1, 2, 3, \dots, N \quad (3.19)$$

AAA yöntemine ait çözüm parametreleri şunlardır: Armoni Belleği Boyutu (HMS: Harmony Memory Search), Armoni Belleğini Dikkate Alma Oranı (HMCR: Harmony Memory Considering Rate), Ton Ayarlama Oranı (PAR: Pitch Adjusting Rate).

HMS, algoritma çalışırken her bir iterasyonda bellekte tutulacak en iyi sonuca sahip çözüm sayısıdır. HMCR, yeni armoni oluştururken armoni hafızasının hangi oranda dikkate alınacağını belirtir. PAR, bellekten seçilmiş olan değerlere hangi oranda ton ayarlama işlemi yapılacağını gösterir (Güngör, 2015).

İkinci adım armoni belleğinin oluşturulmasıdır. Belirlenen HMS değeri kadar armoni rastgele üretilir. Üretilen armoniler ile armoni belleği oluşturulmuş olur. Her bir armoninin değeri amaç fonksiyonunda hesaplanır ve armoniler minimizasyon problemlerinde küçükten büyüğe, maksimizasyon problemlerinde büyükten küçüğe sıralanır (Güngör, 2015). Şekil 3.17'de armoni belleği ve armonilere karşılık gelen amaç fonksiyonu değerleri gösterilmiştir.



Şekil 3.17: Armoni belleği ve armonilere karşılık gelen amaç fonksiyonu değerleri (Ayvaz ve ark., 2007b)

Şekil 3.17’de $i = 1, 2, 3, \dots, N$ ve $j = 1, 2, 3, \dots, HMS$ olmak üzere x_i^j , j. armoni vektöründe yer alan i. karar değişkeninin ifade etmektedir. $f(x^i)$ ise x^i vektörünün amaç fonksiyonundaki değeridir.

Üçüncü adım yeni armoni oluşturulmasıdır. Bu adımda $x' = (x'_1, x'_2, x'_3, \dots, x'_N)$ yeni armoni vektörü üretilmektedir. HMCR değeri, yeni üretilecek bu armoni vektörünün mevcut armoni belleğinden mi, yoksa mevcut çözüm uzayı içerisinde rastgele mi seçileceğini belirler. x' vektöründeki her bir değişken için ayrı ayrı bu işlem tekrarlanır. HMCR 0 ile 1 arasında değer olduğu için HMCR değeri yeni oluşturulacak armoni vektöründeki karar değişkeninin mevcut armoni hafızasından seçilmesini, $(1-HMCR)$ değeri ise mevcut çözüm uzayı içinden rastgele seçileceğini gösterir (Ayvaz ve ark., 2007b; Güngör, 2015). Seçim işleminin nasıl yapıldığı Eşitlik 3.20’de gösterilmiştir (Ayvaz ve ark., 2007b).

$$x'_i = \begin{cases} x'_i \in \{x_i^1, x_i^2, x_i^3, \dots, x_i^{HMS}\} & \text{HMCR olasılığı durumu} \\ x'_i \in X_i & (1 - HMCR) \text{olasılığı durumu} \end{cases} \quad (3.20)$$

Seçim işlemi yapıldıktan sonra her karar değişkeni için ton ayarlamasının yapılmasına gerek olup olmadığına karar verilir. Bunun için de PAR parametresi kullanılır. Bu işlemin matematiksel tanımı Eşitlik 3.21’de yapılmıştır (Ayvaz ve ark., 2007b).

$$x'_i = \begin{cases} x'_i \pm Rnd(0,1) * bw, & \text{PAR olasılığı durumu} \\ x'_i, & (1 - PAR) \text{olasılığı durumu} \end{cases} \quad (3.21)$$

bw değeri rastgele seçilmiş band genişliğini, $Rnd(0,1)$ 0 ile 1 arasında üretilmiş rastgele bir sayıyı gösterir. PAR parametresi de 0 ile 1 arasında bir değerdir. Eşitlik 3.21’de

görüldüğü gibi PAR olasılığı durumunda karar değişkenine $Rnd(0,1) * bw$ değeri eklenir. (1-PAR) durumunda ise karar değişkenine hiçbir değişiklik yapılmaz (Ayvaz ve ark., 2007b).

AAA'nın dördüncü adımı armoni belleğinin güncellenmesidir. Üretilen $x' = (x'_1, x'_2, x'_3, \dots, x'_N)$ armoni vektörünün amaç fonksiyonunda değeri hesaplanır. Sonuç, hafızadaki en kötü armoninin amaç fonksiyonu değeri ile karşılaştırılır. Eğer yeni üretilen armoni vektörünün sonucu daha iyi ise en kötü armoni vektörü hafızadan çıkarılır ve yeni armoni vektörü eklenir.

Beşinci adım durma koşulunun kontrolüdür. Durma koşullarının sağlanıp sağlanmadığı kontrol edilir. Durma koşulu sağlanıyorsa algoritma sonlandırılır. Durma koşulu sağlanmadıysa 3.adıma dönülür ve 3.adımdan itibaren olan işlemler tekrarlanır. Durma koşulu genellikle problemin başına belirlenen iterasyon sayısıdır. Bunun yanı sıra kabul edilebilir bir amaç fonksiyonu değerine ulaşma, belirli bir çalışma süresine ulaşma da durma koşulu olabilir (Güngör, 2015).

4. DESTEK VEKTÖR MAKİNELERİ (DVM)


DVM, çalışmaları 1960'lı yılların sonlarında başlayıp 1990'lı yıllara doğru son halini alan, 1995 yılında Vapnik tarafından ilk kez bir sınıflandırma probleminin çözümünde kullanılan bir makine öğrenmesi algoritmasıdır (Mountrakis ve ark., 2011; Kaya, 2016). DVM; istatistiksel öğrenme teorisine ve yapısal risk minimizasyonuna dayanan, örüntü tanıma ve sınıflandırma problemlerinin çözümünde kullanılmakta olan etkili bir yöntemdir. DVM'ler sınıflandırma problemlerinin çözümünde en başarılı yöntemlerden birisidir ve diğer makine öğrenmesi yöntemlerine göre daha iyi genelleme yeteneğine sahiptir. Sınıflandırma problemlerini lokal minimaya takılmadan çözebilmektedirler (İplikçi, 2009; Uçak, 2012). DVM başlangıçta iki sınıflı doğrusal verilerin sınıflandırılması amacıyla tasarlanmış, daha sonra ikiden fazla sınıflı ve doğrusal olmayan verilerin sınıflandırılması için genelleştirilmiştir.

DVM'lerin çalışma mantığının anlaşılabilmesi için ilk olarak İstatistiksel Öğrenme Teorisi ve Sınıflandırma kavramları anlatılacaktır.

4.1 İstatistiksel Öğrenme Teorisi ve Sınıflandırma

Veri setinde bulunan verilere göre o verileri sınıflandırmak için kullanılacak olan tahmin fonksiyonunu bulma işine istatistiksel öğrenme teorisi denir (Uçak, 2012; Kaya, 2016). Bu işlemde birçok tahmin fonksiyonu üretilebilir. İstatistiksel öğrenme teorisinin amacı bu tahmin fonksiyonlarından en ideal olanını bulmaktır. Sınıflandırma problemlerinde veriler etiketlere ayrılarak sınıflandırılır. Etiketli verilere sağlıklı insanlar ile hasta insanlar, kırmızı noktalar ile mavi noktalar, zenginler ile fakirler gibi örnekler verilebilir. Örnek olarak Şekil 4.1'de Iris veri tabanında bulunan Versicolor ve Virginica yaprak çeşitlerinin sınıflandırılması gösterilmektedir. Yaprakların uzunluğu ve genişliği özniteliklerine göre sınıflandırma yapılmaktadır. Düzlem 1, Düzlem 2 ve Düzlem 3 olarak isimlendirilen doğruların hepsi hiper düzlem olarak adlandırılmazdır. Şekilde de görüldüğü gibi Düzlem 3 iki sınıfı birbirinden ayıramamasına rağmen Düzlem 1 ve Düzlem 2 iki sınıfı birbirinden ayırabilmektedir (Metlek ve Kayaalp, 2020). İşte istatistiksel

öğrenme teorisinin amacı sınıflandırma yapılırken oluşabilecek sınıflandırma hatasını minimuma indirmektir.




Şekil 4.1: Düzlemler ile sınıflandırma yapılması (Metlek ve Kayaalp, 2020)

DVM’lerde kullanılan verilerin birbirinden doğrusal olarak ayrılıp ayrılmaması, verileri sınıflandırmak amacıyla kullanılacak düzlemlerin kaç adet ve nasıl olacağını etkilemektedir. DVM’lerde kullanılan yöntemler, doğrusal ayrılabilen veriler ve doğrusal ayrılamayan veriler için olmak üzere ikiye ayrılmaktadır.

4.2 Doğrusal Ayrılabilen Verilerde DVM

Sınıflandırma probleminde öncelikle iki sınıfın birbirinden ayrılması ele alınacaktır. Bu, daha fazla sınıf için geliştirilebilir. DVM’de temel fikir, N özellik sayısı olmak üzere N boyutlu bir uzaydaki veriler içerisinde bulunan en yakın vektörlerin arasını maksimum yaparak verileri birbirinden uygun şekilde ayıracak bir hiper düzlem belirlemektir (Cortes ve Vapnik, 1995).

Şekil 4.2’de görüldüğü gibi iki sınıfı birbirinden ayıran sonsuz sayıda doğru bulunmaktadır. Fakat marjini maksimize eden sadece bir tane doğru vardır. Marjin, iki sınıfın arasındaki maksimum uzaklığa verilen isimdir. Marjini maksimize eden doğru da hiper düzlem olarak adlandırılmaktadır. Hiper düzlemin boyutu özellik sayısına göre değişiklik göstermektedir. Örneğin özellik sayısı iki ise hiper düzlem bir çizgi iken, özellik sayısı üç olduğunda hiper düzlem iki boyutlu bir düzlem haline gelmektedir.




Şekil 4.2: Olası hiper düzlemler (Özseven ve ark., 2012)

Doğrusal olarak sınıflandırılabilen bir sınıflandırma probleminde eğitim verisinin $\{x_n, y_n\}$, $n = 1, 2, \dots, k$ olduğunu kabul edelim. Bu durumda en uygun hiper düzleme ait eşitsizlikler şu şekildedir:

$$w \cdot x_n + b \geq +1 \quad \text{her } y = +1 \text{ için} \quad (4.1)$$

$$w \cdot x_n + b \leq -1 \quad \text{her } y = -1 \text{ için} \quad (4.2)$$

Bu eşitsizliklerde $x \in R^n$ ve N boyutlu bir uzayı temsil eder. $y \in \{-1, +1\}$, sınıf etiketlerini, w ağırlık vektörünü (hiper düzlemin normali) ve b eğilim değerini göstermektedir (Osuna ve ark., 1997). Optimum hiper düzlemin belirlenebilmesi için bu düzleme paralel ve sınırlarını oluşturacak şekilde iki hiper düzlemin belirlenmesi gereklidir (Şekil 4.3). Bu iki hiper düzlemleri oluşturan noktalara destek vektörleri denir.



Şekil 4.3: En uygun hiper düzlemin belirlenmesi (Kavzoğlu ve Çölkesen, 2010)

DVM'nin amacı $w \cdot x_i + b = +1$ ve $w \cdot x_i + b = -1$ şeklinde ifade edilen iki düzlem arasındaki uzaklığı en büyük olan düzlemi bulmaktır. Bu uzaklığa geometrik marjin ismi verilmektedir ve Eşitlik 4.3'de formülü gösterilmiştir (Uçak, 2012):

$$m = \frac{1}{||w||} \quad (4.3)$$

Optimum hiper düzlemin bulunması şu şekilde ifade edilir:

$$\min \left[\frac{1}{2} ||w||^2 \right] \quad (4.4)$$

Kısıtlamalar ise şu şekildedir (Vapnik, 1999; Kavzoğlu ve Çölkesen, 2010):

$$y_i(w \cdot x_i + b) - 1 \geq 0 \text{ ve } y_i \in \{-1, +1\} \quad (4.5)$$

Bu optimizasyon problemi Lagrange çarpanları yöntemi ile çözülebilmektedir. Amaç fonksiyonu ve kısıtlamalar kullanılarak Lagrange fonksiyonu şu şekilde oluşturulabilir:

$$L(w, b, \alpha) = \frac{1}{2} ||w||^2 - \sum_{i=1}^N \alpha_i [y_i (w \cdot x_i + b) - 1] \quad (4.6)$$

$L(w, b, \alpha)$ Lagrange fonksiyonunu, α_i Lagrange çarpanlarını ifade etmektedir. Fonksiyonun w ve b değerlerine göre türevi alınır ve şu denklemler elde edilir:

$$\frac{\partial L(w, b, \alpha)}{\partial w} = w - \sum_{i=1}^N (y_i \alpha_i x_i) = 0 \quad (4.7)$$

$$\frac{\partial L(w, b, \alpha)}{\partial b} = \sum_{i=1}^N (y_i \alpha_i) = 0 \quad (4.8)$$

Bu adımdan sonra Eşitlik 4.7 ve 4.8'deki ifadeler Eşitlik 4.6'da yerine konulursa, dual amaç fonksiyonu elde edilir. Artık çözülmesi gereken optimizasyon problemi dual kuadratik optimizasyon problemi olduğu için problemdeki amaç fonksiyonu minimize edilmeye dönüşür (Kaya,2016).

$$Max : \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i,j=1}^N \alpha_i \alpha_j y_i y_j x_i x_j \quad (4.9)$$

$$Kısıt: \sum_{i=1}^N (y_i \alpha_i) = 0 \quad (4.10)$$

$$\alpha_i \geq 0, i = 1, 2, 3, \dots, N \quad (4.11)$$

Lagrange fonksiyonu ile en uygun hiper düzlem bulunup eğitim verisi eğitildikten sonra yapılması gereken yeni gelen verilerin hangi sınıfa dahil olduğunu bulmaktır. Bunun için de yeni verilerin en uygun hiper düzlemin hangi tarafına düştüğüne bakılır. Yeni gelen


veri hiper düzlem fonksiyonuna sokulup verinin hangi tarafta kaldığına bakılır. Bu işlem Eşitlik 4.12 veya 4.13 ile yapılır.

$$f(x) = \text{sign}(w^*x + b^*) \quad (4.12)$$

$$f(x) = \text{sign}(\sum_{i=1}^N (\alpha_i y_i x_i x + b) \quad (4.13)$$

4.3 Doğrusal Ayrılamayan Verilerde DVM

Bir önceki bölümde doğrusal ayrılabilen veriler için DVM'nin sınıflandırma yapması anlatıldı. Fakat gerçek hayattaki birçok veri setinde veriler doğrusal olarak ayrılamazlar (Şekil 4.4). Bu tip veriler doğrusal olarak sınıflandırılmaya çalışılırsa başarılı bir sınıflandırma sonucu ortaya çıkmayabilir. Doğrusal olarak ayrılamayan veri setleri için sınıflandırma yaparken optimal hiper düzlemi bulmak için bazı hatalara tolerans gösterilmelidir. Bu veri setlerinde negatif olmayan gevşetici değişkenler kullanılarak DVM bir miktar ceza ve hataya müsaade edecek şekilde yeniden tasarlanır (Duman, 2010; Kaya, 2016).



Şekil 4.4: Verilerin doğrusal olarak ayrılamama durumu (Özseven ve ark., 2012)


Doğrusal olarak ayrılabilen veriler için kullanılan DVM modelindeki eşitsizlikler δ_i değişkenleri aracılığıyla aşağıdaki gibi gevşetilebilir.

$$w.x_i + b \geq +1 - \delta_i \quad \text{her } y = +1 \text{ için} \quad \delta_i \geq 0 \quad (4.14)$$

$$w.x_i + b \leq -1 + \delta_i \quad \text{her } y = -1 \text{ için} \quad \delta_i \geq 0 \quad (4.15)$$

δ_i eğer sıfıra eşitse doğru sınıflandırma yapılmıştır. $0 < \delta_i < 1$ ise (x_i, y_i) noktası doğru sınıflandırılmıştır ancak (x_i, y_i) noktası ayırma yüzeyinin doğru tarafında değil, belirlenen marjinin içindedir. $\delta_i \geq 1$ ise sınıflandırma yanlış yapılmıştır (Kaya, 2016).

Doğrusal olmayan verileri ayırmak için kullanılacak DVM modelinde amaç hatalı sınıflandırmalara izin vererek marj uzaklığını maksimize etmektir. Bunun için de amaç fonksiyonuna hataları en küçükleyecek olan ceza parametresi (C) eklenir. C değeri yanlış sınıflandırma ile marjın genişliği arasındaki dengeyi ayarlamayı sağlar. Bu değer sınıflandırma doğruluğu ve destek vektörlerinin sayısını kontrol eder. Diğer bir deyişle küçük C değeri kısıtlamaların kolayca göz ardı edilmesini kolaylaştırırken büyük C değeri kısıtlamaların göz ardı edilmesini zorlaştırır (Wang, 2005). C değeri küçük olduğunda yanlış sınıflandırma sayısı artar ve marjini büyük bir hiper düzlem seçilir. C değeri büyük olduğunda ise birçok örneği doğru bir şekilde sınıflandırmaya çalışan daha küçük marjinli hiper düzlem seçilir. Sadece C değerinin büyük olması ile bu sorun çözülemez. Bu yüzden problemdeki örnek veri için uygun bir C değeri bulmak önemlidir. Böylece eğitim modeli örnek veri ve eğitim hatası arasında bir denge kurabilir. C parametresinin hiper düzleme olan etkisi Şekil 4.5’de gösterilmiştir. Şekil 4.5’de soldaki sınıflandırmada C değeri 0.001 ve sağdaki sınıflandırmada C değeri 1’dir. Kırmızı noktalar yanlış sınıflandırma sonuçlarını göstermektedir. Mavi çizgi hiper düzlemi temsil etmektedir. Soldaki sınıflandırmada C değeri daha düşük olduğu için sağdaki sınıflandırmaya göre yanlış sınıflandırma sayısı daha fazla ve marjin daha geniştir. Bu tezin konusu olan DVM’de optimize edilmesi gereken parametrelerden biri C parametresidir.



Şekil 4.5: C parametresinin hiper düzleme etkisi (Tharwat ve Hassanien, 2019)

Ceza parametresi eklenerek optimizasyon problemi şu hale dönüşür:

$$\min \left[\frac{1}{2} ||w||^2 \right] + C \sum_{i=1}^N \delta_i \quad (4.16)$$

$$\text{Kısıtlar: } y_i(w \cdot x_i + b) \geq +1 - \delta_i, \quad \delta_i \geq 0 \quad (4.17)$$

Bu problem de Lagrange fonksiyonu ile çözülebilir. Bu problem için Lagrange fonksiyonu şu şekildedir (Kaya, 2016):

$$L(w, b, \delta, \alpha, \beta) = \frac{1}{2} ||w||^2 + C \sum_{i=1}^N \delta_i - \sum_{i=1}^N \alpha_i [y_i(w \cdot x_i + b) - 1 + \delta_i] - \sum_{i=1}^N \delta_i \beta_i \quad (4.18)$$

Eşitlik 4.18’de α ve β Lagrange çarpanlarını ifade etmektedir. Eşitlik 4.18’e gerekli türev işlemleri uygulanıp sıfıra eşitlenir ve şu denklemler elde edilir (Kaya, 2016):

$$\frac{\partial L(w, b, \delta, \alpha, \beta)}{\partial w} = w - \sum_{i=1}^N (y_i \alpha_i x_i) = 0 \quad (4.19)$$

$$\frac{\partial L(w, b, \delta, \alpha, \beta)}{\partial b} = \sum_{i=1}^N (y_i \alpha_i) = 0 \quad (4.20)$$

$$\frac{\partial L(w,b,\delta,\alpha,\beta)}{\partial \delta} = C - \alpha_i + \beta_i = 0 \quad (4.21)$$

Dual problem ise şu şekildedir (Kaya, 2016):


$$Max : \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i,j=1}^N \alpha_i \alpha_j y_i y_j x_i x_j \quad (4.22)$$

$$Kısıt: \sum_{i=1}^N (y_i \alpha_i) = 0 \quad (4.23)$$

$$Kısıt: 0 \leq \alpha_i \leq C \quad i = 1, 2, 3, \dots, N \quad (4.24)$$

Çekirdek Fonksiyonları

Doğrusal olarak ayırlamayan veriler yüksek boyutlu bir uzay taşınarak yani haritalandırarak doğrusallaştırılabilirler (Şekil 4.6).



Şekil 4.6: Doğrusal olarak ayırlamayan verilerin daha yüksek boyuta dönüştürülmesi (Kavzoğlu ve Çölkesen, 2010)

Doğrusal olmayan verilerin yüksek boyutlu uzaya taşınması işlemi çekirdek fonksiyonlar aracılığıyla yapılmaktadır. Çekirdek fonksiyonların genel denklemi şu şekildedir:

$$K(x_i, x_j) = \phi(x_i) \cdot \phi(x_j) \quad (4.25)$$

Çekirdek fonksiyonu dahil edilerek doğrusal ayrılamayan DVM’lerde dual problem şu şekildedir:

$$Max: \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i,j=1}^N \alpha_i \alpha_j y_i y_j K(x_i, x_j) \quad (4.26)$$

$$Kısıt: \sum_{i=1}^N (y_i \alpha_i) = 0 \quad (4.27)$$

$$Kısıt: 0 \leq \alpha_i \leq C \quad i = 1, 2, 3, \dots, N \quad (4.28)$$

Hiper düzlemin denklemi ise şu şekildedir:

$$f(x) = \text{sign}(\sum_{i=1}^N \alpha_i y_i K(x_i, x_j) + b) \quad (4.29)$$

DVM ile sınıflandırma yaparken çekirdek fonksiyonunun seçimi oldukça önemlidir çünkü çekirdek fonksiyonu sınıflandırma başarısını etkilemektedir. Her problem için başarılı denilebilecek kesin bir çekirdek fonksiyonu yoktur. Çekirdek fonksiyonlarının başarısı problemden probleme değişkenlik gösterebilir. Literatürde kullanılan bazı çekirdek fonksiyonları ve onların parametreleri Çizelge 1’de gösterilmiştir.

Çizelge 4. 1: DVM’de bulunan bazı çekirdek fonksiyonları

Çekirdek Fonksiyonu	Fonksiyon Formülü	Fonksiyon Parametreleri
Lineer	$K(x, x_i) = x \cdot x^T$	-
RBF	$K(x, x_i) = e^{-\gamma \cdot \ x_i - x_j\ ^2}$	γ
Polinom	$K(x_i, x_j) = (1 + x \cdot x_i^T)^d$	d

Çizelge 4.1’de görüldüğü gibi her çekirdek fonksiyonun formülü ve parametreleri farklıdır. Literatürde sıklıkla RBF tercih edilmiştir (Özbeyaz ve ark., 2011; Tharwat ve ark., 2017; Saini ve ark., 2019). Sınıflandırma yapılırken kullanılacak çekirdek fonksiyonunun parametrelerinin optimize edilmesi sınıflandırma başarısını arttırmaktadır. Bu tezde de amaç ceza parametresi C ile seçilen çekirdek fonksiyonunun parametrelerinin optimize edilerek sınıflandırma başarısının artırılmasıdır.



5. DVM PARAMETRELERİNİN OPTİMİZASYONU

Bu çalışmada meta sezgisel algoritmalar kullanılarak DVM çekirdek fonksiyonu parametrelerinin optimizasyonu yapılmıştır. Kullanılan algoritmalar Yarasa Algoritması (YA), İyileştirilmiş Genetik Algoritma (İGA), İyileştirilmiş Kaotik Parçacık Sürü Optimizasyonu (İKPSO) ve Armoni Arama Algoritması'dır (AAA).


DVM'de birçok çekirdek fonksiyonu bulunmaktadır. Bu çalışmada RBF, polinom ve lineer çekirdek fonksiyonları kullanılmıştır. Bir problemi optimize etmek için meta sezgisel algoritmalar kullanılırken dikkat edilmesi gereken iki faktör vardır: popülasyon temsili ve uygunluk fonksiyonu. Popülasyon temsiliinde hangi karar değişkenlerinin bireyi temsil edeceği belirlenmelidir. Bu çalışmada karar değişkeni iki adettir. Bunlardan biri ceza parametresidir (C). Diğer karar değişkeni ise çekirdek fonksiyonu parametresidir. Bu parametre çekirdek fonksiyonuna göre değişkenlik göstermektedir. Çünkü her bir çekirdek fonksiyonunun farklı parametreleri bulunmaktadır. RBF çekirdek fonksiyonu için γ (gamma), polinom çekirdek fonksiyonu için d (derece) parametresi karar değişkeni olarak kullanılmıştır. Lineer fonksiyonun parametresi bulunmadığı için karar değişkeni yoktur. Sonuç olarak RBF çekirdek fonksiyonu için yapılan optimizasyonda C ve γ , polinom fonksiyonda C ve d ve lineer fonksiyonda sadece C parametresi optimize edilmiş ve karar değişkeni olarak kullanılmıştır.

Makine öğrenmesi yöntemlerinde performans değerlendirmesi yapabilmek için veri kümesi eğitim ve test kümeleri olarak ayrılmaktadır. Ayırma işlemi farklı şekillerde yapılabilir. Bunlardan biri k katmanlı çapraz onaylama yöntemidir. Bu yöntemde öncelikle k değeri seçilir ve k değeri veri kümesinin kaç parçaya ayrılacağını belirler. Veri seti k adet parçaya ayrıldıktan sonra her adımda bölünen parçalardan birisi test kümesi kalan k-1 adet parça ise eğitim kümesi olarak kullanılır. Bu yöntem k değeri kadar tekrarlanır ve elde edilen sınıflandırma sonuçlarının ortalaması genel sınıflandırma doğruluğu olarak kabul edilir. Bu tez çalışmasında k değeri 5 seçilmiştir.

Popülasyondaki her bir bireyin kalitesini belirlemek için uygunluk fonksiyonu oluşturulmuştur. Eşitlik 5.1'de uygunluk fonksiyonu gösterilmiştir.

$$\text{Ortalama Doğruluk} = (\sum_{i=1}^k (\text{Test Doğruluğu}) / k \quad (5.1)$$

Önerilen DVM modellerinin akış şeması Şekil 5.1’de verilmiştir.



Şekil 5.1: YA-DVM, İKPSO-DVM, İGA-DVM ve AAA-DVM modelleri akış şeması

5.1 Veri Setleri

Bu çalışmada önerilen DVM modellerinin performansını değerlendirmek için 2 farklı parkinson hastalığı veri seti kullanılmıştır. Bu veri setleri UCI (Machine Learning Repository of University of California at Irvine) veri tabanından alınmıştır. Karışıklığa sebep olmaması için bundan sonra bu veri setleri Parkinson 1 ve Parkinson 2 olarak isimlendirilecektir. Bu veri setlerinin sınıf, öznitelik ve örnek sayıları Çizelge 5.1’de gösterilmiştir.

Çizelge 5. 1: Çalışmada kullanılan veri setleri

Veri Seti No	Veri Seti Adı	Örnek Sayısı	Sınıf Sayısı	Öznitelik Sayısı
1	Parkinson 1	240	2	46
2	Parkinson 2	195	2	22

Önerilen DVM modellerinin uygulaması Matlab ortamında gerçekleştirilmiştir. DVM için Matlab ortamında kod yazılmıştır. Önerilen modelin veri setleri üzerinde denemeleri Intel Core i7 – 7700 HQ, 2.80 GHz, 16 GB RAM, Windows 10 işletim sistemi özelliklerini taşıyan bilgisayarda yapılmıştır.

5.2 DVM Modellerinin Performans Ölçüm Kriterleri

Sınıflandırma modellerinin performansını değerlendirmek için hata matrisi (confusion matrix) kullanılır. Bu matrisde tahminlerin ve gerçek değerlerin karşılaştırması yapılır. Bu matrisde dört farklı değer bulunur: doğru pozitifler, doğru negatifler, yanlış pozitifler, yanlış negatifler. Bu kavramlar bir insanın hasta olup olmadığının sınıflandırılması örneği üzerinden aşağıda tanımlanmıştır.

Doğru pozitifler (DP), sınıflandırıcının hasta olarak tahmin ettiği ve gerçek sonucunda hasta olduğu durumdur. Doğru negatifler (DN), sınıflandırıcının hasta değil olarak tahmin ettiği ve gerçek sonucunda hasta olmadığı durumdur. Yanlış pozitifler (YP), sınıflandırıcının hasta olarak tahmin ettiği fakat gerçek sonucun hasta olmadığı

durumdur. Yanlış negatifler (YN), sınıflandırıcının hasta değil olarak tahmin ettiği fakat gerçek sonucun hasta olduğu durumdur.

Bir veri setindeki sınıf etiketi sayısı k ise hata matrisi $k \times k$ boyutundadır. Bu çalışmada kullanılan iki veri setinde de sınıf sayısı 2 olduğu için hata matrisi 2×2 boyutunda olacaktır. 2×2 'lik bir hata matrisi Çizelge 5.2'de gösterilmiştir.

Çizelge 5. 2: Hata matrisi

		Tahmin	
		Pozitif Durumlar	Negatif Durumlar
Gerçek	Pozitif	DP	YN
	Negatif	YP	DN

Hata matrisini kullanarak yapılan performans değerlendirmesinde beş farklı değer kullanılmıştır. Bunlar, doğruluk, duyarlılık, seçicilik, kesinlik ve F1 skor değerleridir. Bu değerlerin hata matrisine göre formülleri Eşitlik 5.2, 5.3, 5.4, 5.5 ve 5.6'da gösterilmiştir.

$$Doğruluk = \frac{DP+DN}{DP+DN+YP+YN} \quad (5.2)$$

$$Duyarlılık = \frac{DP}{DP+YN} \quad (5.3)$$

$$Seçicilik = \frac{DN}{DN+YP} \quad (5.4)$$

$$Kesinlik = \frac{DP}{DP+YP} \quad (5.5)$$

$$F1 \text{ Skor} = 2 * \frac{Duyarlılık * Kesinlik}{Duyarlılık + Kesinlik} \quad (5.6)$$

Doğruluk, sınıflandırma modelinde doğru olarak sınıflandırılmış örnek sayısının toplam örnek sayısına oranıdır. Doğruluk değeri ile performans değerlendirilirken veri setinin

dengeleli dağılıması önemli bir faktördür. Eğer veri seti dengelesiz dağılımıssa doğruluk değeri oranının yüksek çıkması sınıflandırma modelinin başarısı hakkında yanıltıcı olabilir.

Duyarlılık, sınıflandırma modelinin doğruları bilme konusundaki etkinliğini ifade eder. Hastalık örneğinden yola çıkılacak olursak veri kümesinde hasta olarak tanımlanan örneklerin ne kadarının hasta olarak tahmin edilebildiğini belirler. Hata matrisinde değerinin yüksek çıkmasının istenmediği en kritik alan, özellikle tıpla ilgili veri setlerinde YN değeridir. Çünkü YN’de gerçekte hasta olan birisi hasta değil olarak sınıflandırılmıştır ve bu durumda hasta, yanlış sınıflandırma sonucundan dolayı hasta olmadığını zannederek tedavi olmayacak ve hastalık ilerleyecektir. Bu da endişe verici bir durumdur. Tıp haricinde başka alandaki veri setleri ile yapılan sınıflandırmalarda veri setinin türüne göre hata matrisinde değerinin yüksek çıkmasının istenmediği en kritik alan YP değeri olabilir. YN’nin YP’nin önüne geçtiği durumlarda duyarlılık değeri faydalı bir performans değerlendirme ölçütüdür.

Seçicilik, sınıflandırma modelinde yoku tahmin etme olasılığıdır. Yine hastalık örneğine göre değerlendirilirse veri kümesinde hasta değil olarak tanımlanan örneklerin ne kadarının hasta değil olarak tahmin edildiğini belirler.

Kesinlik, sınıflandırma modelinin pozitif olarak tahmin ettiği örneklerin gerçekte ne kadarının doğru bir şekilde tahmin edildiğini belirleyen ölçüttür. Doğru olarak sınıflandırılan hasta sayısını bulmak isteniyorsa kesinlik ölçütü kullanmak daha doğru bir yaklaşım olacaktır.

F1 skor, kesinlik ve duyarlılığın harmonik ortalamasıdır. Özellikle dengelesiz veri setlerinin daha net bir şekilde performansının belirlenebilmesi için F1 skor kullanılabilir.

5.3 Parkinson 1 Veri Seti Deneyleri

Bu veri setinde sağlıklı insanlarla parkinson hastaları birbirinden ayırt edilmeye çalışılmıştır. Bu veri seti UCI veri tabanında bulunan, Naranjo ve arkadaşlarının literatüre iki adet çalışma sundukları bir veri setidir (Naranjo ve ark., 2016,2017). Veriler, 2019 yılında sisteme sunulmuştur. Bu yönüyle güncel bir veri setidir.

Veri setinde 40 adet parkinson hastası ve 40 adet sağlıklı kişi bulunmaktadır. Her kişiden sürekli / a / seslendirilmesiyle elde edilmiş üç farklı ses kaydı bulunmaktadır. Böylece 120 adet parkinson hastası ses kaydı ve 120 adet sağlıklı ses kaydı olmak üzere toplam 240 adet ses kaydı bulunmaktadır. Veri seti dengeli bir veri setidir. Veriler Extremadura Üniversitesi Biyoetik Komitesi tarafından onaylanmıştır. Sınıflandırma etiketleri 0 ve 1 şeklinde yapılmıştır. 0 etiketi sağlıklı bireyi, 1 etiketi ise hasta bireyi temsil etmektedir (Naranjo ve ark., 2016). Ses kaydından elde edilen öznitelikler şu şekildedir:

Çizelge 5. 3: Parkinson 1 veri setinin öznitelikleri (Naranjo ve ark., 2017; Narin, 2020)


Öznitelik	Ölçümler
Adım yerel bozulma ölçümleri	Göreceli titreşim, mutlak titreşim, göreceli ortalama bozulma (RAP) ve adım bozulma oranı (PPQ).
Genlik bozulma ölçümleri	Yerel ışıltı, dB cinsinden ışıltı, 3 noktalı genlik bozulma katsayısı (APQ3), 5 noktalı genlik bozulma katsayısı (APQ5), 11 noktalı genlik bozulma katsayısı (APQ11)
Harmonik-gürültü oranı ölçümleri	Harmonik gürültü oranı ölçümleri frekans bantları: 0-500 Hz (HNR05), 0-1500 Hz (HNR15), 0-2500 Hz (HNR25), 0-3500 Hz (HNR35) ve 0-3800 Hz (HNR38).
Spektral ölçüm tabanlı Mel frekans spektral katsayıları	MFCC0, MFCC1, ..., MFCC12.
Mel frekans spektral katsayılarının türevi	Delta0, Delta1, ..., Delta12.
Nüks periyodu yoğunluğu entropisi	
Eğimi yok edilmiş dalgalanma analizi	
Adım periyot entropisi	
Gırtlak-gürültü uyartım oranı	

5.3.1 YA-DVM modeli ile sınıflandırma


Xin-She, YA yönteminde bulunan ses şiddetinin başlangıç değeri $A_0 = 0.5$, sinyal yayma oranı başlangıç değeri $r_0 = 0.5$ ve $\alpha = \gamma = 0.99$ olduğunda YA'nın global yakınsamayı elde edebileceğini belirtmiştir (Yang, 2014). Bu yüzden $A_0 = 0.5$, $r_0 = 0.5$ ve $\alpha = \gamma = 0.99$ seçilmiştir. f_{min} ve f_{max} parametreleri için literatürde sıklıkla kullanılan $f_{min} = 0$ ve $f_{max} = 2$ değerleri seçilmiştir (Tharwat ve ark., 2017; Kamal, 2018). YA'da bulunan yarasa sayısı parametresi algoritmanın başarısını etkileyebilir. Bu parametre için kesin olarak önerilebilecek bir değer yoktur. Yapılan bir çalışmada farklı veri setleri için farklı yarasa sayısı değerleri kullanılmış, en iyi sınıflandırma sonucunun elde edildiği yarasa

sayısı değeri veri setine göre farklılık göstermiştir (Kamal,2018). Bu yüzden bu tez çalışmasında da yarasa sayısı parametresi 5 ile 50 arasında 5'er 5'er arttırılarak testler yapılmış ve yarasa sayısının sınıflandırma doğruluğuna etkisi belirlenmiştir. Sonuçlar 100 iterasyon sonucunda elde edilmiştir.


Parkinson 1 veri seti için RBF, lineer ve polinom çekirdek fonksiyonlarında yarasa sayısı parametresinin sınıflandırma doğruluğuna etkisi Şekil 5.2, 5.3 ve 5.4'de gösterilmiştir.



Şekil 5.2: Parkinson 1 veri seti için YA'da yarasa sayısının sınıflandırma doğruluğuna etkisi (RBF)



Şekil 5.3: Parkinson 1 veri seti için YA'da yarasa sayısının sınıflandırma doğruluğuna etkisi (Lineer fonksiyon)



Şekil 5.4: Parkinson 1 veri seti için YA'da yarasa sayısının sınıflandırma doğruluğuna etkisi (Polinom fonksiyon)

Şekil 5.2, 5.3 ve 5.4'de görüldüğü gibi yarasa sayısı DVM'nin sınıflandırma doğruluğu oranını etkilemektedir. RBF çekirdek fonksiyonu ile yapılan deneyde en iyi sınıflandırma sonucu yarasa sayısı 10 olduğunda elde edilirken lineer ve polinom fonksiyonda ise

sırasıyla 35 ve 40 olduğunda elde edilmiştir. Yarasa sayısı ile sınıflandırma doğruluğu arasında doğru veya ters orantılı bir ilişki yoktur.

YA-DVM modeli ile Parkinson 1 veri setinde yapılan sınıflandırma sonuçları 5 farklı performans değerlendirme ölçütü ile Çizelge 5.4’de gösterilmiştir.

Çizelge 5. 4: Parkinson 1 veri setinin YA-DVM ile sınıflandırma sonuçları


Çekirdek Fonksiyonu	Doğruluk	Duyarlılık	Seçicilik	Kesinlik	F1 Skor
RBF	86.25	95.833	100	86.055	84.88
Lineer	86.667	86.667	85.833	86.381	85.517
Polinom	86.25	87.5	86.667	87.468	84.91

Çizelge 5.4’de görüldüğü gibi üç çekirdek fonksiyonunda doğruluk, kesinlik ve F1 skor değerleri benzer çıkmasına rağmen duyarlılık ve seçicilik değerlerinde RBF çekirdek fonksiyonu ciddi oranda diğer iki fonksiyona göre daha iyi sonuç vermiştir. Duyarlılık, gerçekte hasta olan kişilerin ne kadarının hasta olarak tahmin edildiğini belirleyen ölçüttür. Parkinson 1 veri setinde bulunan hasta sayısını bulmak için YA-DVM modelinde RBF çekirdek fonksiyonu ile yapılan sınıflandırma tercih edilebilir. Seçicilik değeri ise gerçekte hasta olmayan kişilerin ne kadarının hasta değil olarak tahmin edildiğini belirleyen ölçüttür. YA-DVM modelinde RBF çekirdek fonksiyonu ile yapılan sınıflandırmada %100 başarı oranıyla Parkinson 1 veri setindeki hasta olmayan örneklerin tamamı doğru bir şekilde sınıflandırılmıştır. Parkinson 1 veri setindeki hasta olmayan sayısını bulmak için YA-DVM modelinde RBF çekirdek fonksiyonu ile yapılan sınıflandırma tercih edilebilir.


5.3.2 İKPSO-DVM ile yapılan sınıflandırma

PSO’da bulunan c_1 ve c_2 değerleri için literatürde sıklıkla kullanılan 2 değeri seçilmiştir. w_{min} değeri 0.2, w_{max} değeri 1.2 olarak belirlenmiştir (Liu ve ark., 2005). Popülasyon büyüklüğü parametresi YA’da bulunan yarasa sayısı parametresinde olduğu gibi


algoritmanın başarısını etkileyebilir. Bu parametre için de kesin olarak önerilebilecek bir değer yoktur. Probleme göre bu değerin başarısı farklılık göstermektedir. Bu yüzden YA’da olduğu gibi bu algortmada da popülasyon büyüklüğü 5 ile 50 arasında 5’er 5’er arttırılarak analiz edilmiştir. Bu analiz yine RBF, lineer ve polinom çekirdek fonksiyonları için ayrı ayrı yapılmıştır. Parkinson 1 veri seti için popülasyon büyüklüğü parametresinin sınıflandırma doğruluğuna etkisi Şekil 5.5, 5.6 ve 5.7’de gösterilmiştir. Sonuçlar 100 iterasyon sonucunda edilmiştir.



Şekil 5.5: Parkinson 1 veri seti için İKPSO’da popülasyon büyüklüğünün sınıflandırma doğruluğuna etkisi (RBF)



Şekil 5.6: Parkinson 1 veri seti için İKPSO'da popülasyon büyüklüğünün sınıflandırma doğruluğuna etkisi (Lineer fonksiyon)



Şekil 5.7: Parkinson 1 veri seti için İKPSO'da popülasyon büyüklüğünün sınıflandırma doğruluğuna etkisi (Polinom fonksiyon)

İKPSO-DVM modeli ile Parkinson 1 veri setinde yapılan sınıflandırma sonuçları 5 farklı performans değerlendirme ölçütü ile Çizelge 5.5'de gösterilmiştir.


Çizelge 5. 5: Parkinson 1 veri setinin İKPSO-DVM ile sınıflandırma sonuçları

Çekirdek Fonksiyonu	Doğruluk	Duyarlılık	Seçicilik	Kesinlik	F1 Skor
RBF	88.75	87.5	100	88.484	85.61
Lineer	86.25	85.833	85.833	86.542	85.828
Polinom	86.667	86.667	89.167	87.947	85.96


Çizelge 5.5’de görüldüğü gibi RBF çekirdek fonksiyonunda doğruluk değeri az bir farkla diğer iki çekirdek fonksiyonuna göre daha yüksektir. Duyarlılık, kesinlik ve F1 skor değerleri üç çekirdek fonksiyonunda da birbirine oldukça yakındır. Seçicilik değeri RBF’de %100’e ulaşmıştır. Yani İKPSO-DVM modelinde RBF çekirdek fonksiyonu ile yapılan sınıflandırmada Parkinson 1 veri setindeki hasta olmayan örneklerin tamamı doğru bir şekilde sınıflandırılmıştır. RBF ile diğer iki çekirdek fonksiyonu arasında seçicilik kriterinde ciddi bir performans farkı bulunmaktadır.

5.3.3 İGA-DVM ile yapılan sınıflandırma


P_{cmax} değeri 0.9, P_{cmin} değeri 0.4, P_{mmin} değeri 0.01 ve P_{mmax} değeri 0.08 seçilmiştir (Wu,2019). GA’da bulunan seçim işlemi için rulet çemberi tekniği, çaprazlama işlemi için tekdüze çaprazlama işlemi kullanılmıştır. Popülasyon büyüklüğü 10 ile 50 arasında 10’ar 10’ar arttırılarak analiz edilmiştir. GA’da iki ebeveynden iki çocuk üretilmektedir. Bu yüzden popülasyon büyüklüğü değeri için çift sayılar seçilmiş, tek sayılarla hesaplama yapılmamıştır. RBF, lineer ve polinom çekirdek fonksiyonları için ayrı ayrı analiz yapılmıştır. Parkinson 1 veri seti için popülasyon büyüklüğü parametresinin sınıflandırma doğruluğuna etkisi Şekil 5.8, 5.9 ve 5.10’da gösterilmiştir. Sonuçlar 100 iterasyon sonucunda elde edilmiştir.



Şekil 5.8: Parkinson 1 veri seti için İGA'da popülasyon büyüklüğünün sınıflandırma doğruluğuna etkisi (RBF)



Şekil 5.9: Parkinson 1 veri seti için İGA'da popülasyon büyüklüğünün sınıflandırma doğruluğuna etkisi (Lineer fonksiyon)



Şekil 5.10: Parkinson 1 veri seti için İGA’da popülasyon büyüklüğünün sınıflandırma doğruluğuna etkisi (Polinom fonksiyon)

İGA-DVM modeli ile Parkinson 1 veri setinde yapılan sınıflandırma sonuçları 5 farklı performans değerlendirme ölçütü ile Çizelge 5.6’da gösterilmiştir.


Çizelge 5. 6: Parkinson 1 veri setinin İGA-DVM ile sınıflandırma sonuçları

Çekirdek Fonksiyonu	Doğruluk	Duyarlılık	Seçicilik	Kesinlik	F1 Skor
RBF	88.333	97.5	88.333	86.846	86.395
Lineer	85.417	88.333	84.167	84.14	81.658
Polinom	85.833	84.167	84.167	86.467	85.458


Çizelge 5.6’da görüldüğü gibi en iyi doğruluk değeri RBF çekirdek fonksiyonunda bulunmaktadır. Duyarlılık değeri RBF çekirdek fonksiyonunda oldukça başarılı bir sonuca ulaşmıştır ve diğer iki çekirdek fonksiyonu ile arada ciddi bir başarı farkı bulunmaktadır. İGA-DVM modelinde RBF kullanılarak yapılan sınıflandırmada Parkinson 1 veri setindeki hastaların %97.5’i doğru bir şekilde sınıflandırılmıştır.

5.3.4 AAA-DVM ile yapılan sınıflandırma


AAA’da Armoni Belleği Boyutu (HMS), Armoni Belleğini Dikkate Alma Oranı (HMCR) ve Ton Ayarlama Oranı (PAR) olmak üzere üç farklı parametre bulunmaktadır. Bu parametrelerin sınıflandırma doğruluğuna olan etkilerinin analizi yapılmıştır. HMS değeri 5 ile 50 arasında 5’er 5’er arttırılarak, HMCR ve PAR değerleri 0 ile 1 arasında değer aldıkları için 0.1 ile 0.9 arasında 0.1’er 0.1’er arttırılarak analiz edilmiştir. HMS değeri analiz edilirken HMCR ve PAR değerleri 0.5 alınmıştır. HMCR değeri analiz edilirken HMS değeri 20 ve PAR değeri 0.5 alınmıştır. PAR değeri analiz edilirken de HMS değeri 20 ve HMCR değeri 0.5 alınmıştır. Sonuçlar 1000 iterasyon sonucunda elde edilmiştir. Parkinson 1 veri seti için HMS parametresinin sınıflandırma doğruluğuna etkisi Şekil 5.11, 5.12 ve 5.13’de gösterilmiştir.



Şekil 5.11: Parkinson 1 veri seti için AAA’da HMS’nin sınıflandırma doğruluğuna etkisi (RBF)




Şekil 5.12: Parkinson 1 veri seti için AAA'da HMS'nin sınıflandırma doğruluğuna etkisi (Lineer fonksiyon)




Şekil 5.13: Parkinson 1 veri seti için AAA'da HMS'nin sınıflandırma doğruluğuna etkisi (Polinom fonksiyon)


Parkinson 1 veri seti için HMCR parametresinin sınıflandırma doğruluğuna etkisi Şekil 5.14, 5.15 ve 5.16'da gösterilmiştir.



Şekil 5.14: Parkinson 1 veri seti için AAA'da HMCR'nin sınıflandırma doğruluğuna etkisi (RBF)



Şekil 5.15: Parkinson 1 veri seti için AAA'da HMCR'nin sınıflandırma doğruluğuna etkisi (Lineer fonksiyon)



Şekil 5.16: Parkinson 1 veri seti için AAA’da HMCR’nin sınıflandırma doğruluğuna etkisi (Polinom fonksiyon)


Parkinson 1 veri seti için PAR parametresinin sınıflandırma doğruluğuna etkisi Şekil 5.17, 5.18 ve 5.19’da gösterilmiştir.



Şekil 5.17: Parkinson 1 veri seti için AAA’da PAR’ın sınıflandırma doğruluğuna etkisi (RBF)



Şekil 5.18: Parkinson 1 veri seti için AAA'da PAR'ın sınıflandırma doğruluğuna etkisi (Lineer fonksiyon)



Şekil 5.19: Parkinson 1 veri seti için AAA'da PAR'ın sınıflandırma doğruluğuna etkisi (Polinom fonksiyon)

En iyi sınıflandırma doğruluğu değeri RBF fonksiyonda $HMS = 20$, $HMCR = 0.5$ ve $PAR = 0.5$ iken elde edilmiştir. AAA-DVM modeli ile Parkinson 1 veri setinde yapılan

sınıflandırma sonuçları 5 farklı performans değerlendirme ölçütü ile Çizelge 5.7’de gösterilmiştir.

Çizelge 5. 7: Parkinson 1 veri setinin AAA-DVM ile sınıflandırma sonuçları

Çekirdek Fonksiyonu	Doğruluk	Duyarlılık	Seçicilik	Kesinlik	F1 Skor
RBF	88.333	95	87.5	88.277	87.2
Lineer	83.333	84.167	85	83.083	81.351
Polinom	85.833	85	88.333	87.545	85.68

Çizelge 5.7’de görüldüğü gibi doğruluk, seçicilik, kesinlik ve F1 skor değerlerinde benzer sonuçlar olmasına rağmen duyarlılık ölçütünde en başarılı performansı ciddi bir oranda farkla RBF göstermiştir. AAA-DVM modelinde RBF fonksiyon ile yapılan sınıflandırmada Parkinson 1 veri setinde bulunan hastaların %95’i doğru bir şekilde sınıflandırılmıştır.

5.3.5 Sınıflandırma modellerinin karşılaştırılması

Bu tez çalışmasında önerilen YA-DVM, İKPSO-DVM, İGA-DVM ve AAA-DVM modellerinin Parkinson 1 veri setindeki sınıflandırma sonuçları Çizelge 5.8’de karşılaştırılmıştır.

Çizelge 5. 8: Önerilen modellerin Parkinson 1 veri setindeki sınıflandırma sonuçları

Çekirdek Fonksiyonu	Değerlendirme Ölçütü	YA-DVM	İKPSO-DVM	İGA-DVM	AAA-DVM
RBF	Doğruluk	86.25	88.75	88.333	88.333
	Duyarlılık	95.833	87.5	97.5	95
	Kesinlik	86.055	88.484	86.846	88.277
	Seçicilik	100	100	88.333	87.5
	F1 Skor	84.88	85.61	86.395	87.2
Lineer	Doğruluk	86.667	86.25	85.417	83.333
	Duyarlılık	86.667	85.833	88.333	84.167
	Kesinlik	86.381	86.542	84.14	83.083
	Seçicilik	85.833	85.833	84.167	85
	F1 Skor	85.517	85.828	81.658	81.351
Polinom	Doğruluk	86.25	86.667	85.833	85.833
	Duyarlılık	87.5	86.667	84.167	85
	Kesinlik	87.468	87.947	86.467	87.545
	Seçicilik	86.667	89.167	84.167	88.333
	F1 Skor	84.91	85.96	85.458	85.68

Çizelge 5.8’de görüldüğü gibi doğruluk, kesinlik ve F1 skor değerlendirme ölçütlerinde 4 farklı sınıflandırma modeli de benzer sonuçlar vermiştir. Duyarlılık değerlendirme kriterinde diğer modellere göre en başarısız performans İKPSO-DVM modeline aittir. YA-DVM, İGA-DVM ve AAA-DVM modelinde RBF ile yapılan sınıflandırmada duyarlılık değerleri sırasıyla %95.833, %97.5 ve %95’dir ve en başarılı performansa sahiptirler. Ayrıca duyarlılık ölçütünde çekirdek fonksiyonları içinde en başarılı performansı RBF göstermiştir. Seçicilik değerlendirme ölçütünde ise en başarılı performans %100 değerle YA-DVM ve İKPSO-DVM modellerinde RBF ile yapılan

sınıflandırmaya aittir. Sınıflandırma modelinde hangi ölçüt kullanıcının elde etmek istediği sonuç ise ona göre bir performans değerlendirmesi yapılabilir. Örneğin kullanıcı veri setindeki hastaların doğru bir şekilde sınıflandırılmasını istiyorsa duyarlılık ölçütüne göre değerlendirme yapmalıdır. Parkinson 1 veri seti için duyarlılık ölçütünde YA-DVM, İGA-DVM ve AAA-DVM modelleri tercih edilebilir. Eğer kullanıcı veri setindeki hasta olmayan örneklerin doğru bir şekilde sınıflandırılmasını istiyorsa seçicilik ölçütüne göre değerlendirme yapmalıdır. Parkinson 1 veri seti için seçicilik ölçütünde YA-DVM ve İKPSO-DVM modelleri tercih edilebilir. Eğer genel bir performans değerlendirmesi yapılmak isteniyorsa sınıflandırma doğruluğu dikkate alınmalıdır. Fakat veri seti dengesiz ise F1 skor ölçütü de dikkate alınmalıdır.

Çizelge 5.9’da bu tez çalışmasında önerilen 4 modelin Parkinson 1 veri setindeki sınıflandırması sonucunda bulunan maksimum sınıflandırma değerleri sonuçları ile literatürde Parkinson 1 veri setinde yapılan sınıflandırma sonucunda elde edilen sınıflandırma doğruluğu değerleri karşılaştırılmıştır.

Çizelge 5. 9: Önerilen modellerin literatürdeki diğer çalışmalarla sınıflandırma doğruluğu karşılaştırması

Önerilen model	Sınıflandırma Doğruluğu Oranı
YA-DVM	86.667
İKPSO-DVM	88.75
İGA-DVM	88.333
AAA-DVM	88.333
Naranjo ve ark. (2016)	85.0
Naranjo ve ark. (2016)	86.2
Narin (2020)	87.5

Çizelge 5.9’da görüldüğü gibi bu tez çalışmasında önerilen İKPSO-DVM modeli en başarılı sınıflandırma doğruluğu değeri sonucunu vermiştir.

5.4 Parkinson 2 Veri Seti Deneyleri


Bu veri seti Oxford Üniversitesinden Max Little tarafından oluşturulmuştur (Little ve ark., 2007). 23 hasta, 8 sağlıklı olmak üzere toplam 31 kişinin ses kayıtlarından oluşmaktadır (Little ve ark., 2009). Toplam 195 veri ve 22 öznelik bulunmaktadır. Ses kayıtları alınan insanların tedavi süreleri 0 ila 28 yıl arasındadır ve yaşları 46 ile 85 arasındadır. Ses kayıtlarının öznelikleri Çizelge 5.10'da gösterilmiştir (Tezcan,2018).

Çizelge 5. 10: Parkinson 2 veri setinin öznelikleri (Tezcan, 2018)


Öznitelik	Tanım
MDVP: Fo (Hz)	Ortalama vokal temel frekansı
MDVP: Fhi (Hz)	Maksimum vokal temel frekansı
MDVP: Flo (Hz)	Minimum vokal temel frekansı
MDVP: Jitter (%),MDVP: Jitter (Abs), MDVP: RAP, MDVP: PPQ, Jitter: DDP	Temel frekanstaki değişimlerin birkaç ölçümü
MDVP: Shimmer, MDVP: Shimmer (dB), Shimmer: APQ3, Shimmer: APQ5, MDVP: APQ, Shimmer: DDA	Genlikteki değişimlerin birkaç ölçümü
NHR, HNR	Sesteki gürültünün ton bileşenlerine oranının iki ölçümü
RPDE, D2	İki doğrusal olmayan dinamik karmaşıklık ölçümü
DFA	Sinyal fraktal ölçekleme üssü
spread1, spread2, PPE	Temel frekans değişiminin üç doğrusal olmayan ölçümü

5.4.1. YA-DVM ile yapılan sınıflandırma


A_0 , r_0 , α ve γ parametreleri için Parkinson 1 veri setine uygulanan YA-DVM modelindeki parametre değerlerinin aynısı seçilmiştir. Yarasa sayısı için ise yine 5 ile 50 arasında 5'er 5'er artırılarak parametre analizi yapılmıştır. Parkinson 2 veri seti için yarasa sayısı parametresinin sınıflandırma doğruluğuna etkisi Şekil 5.20, 5.21 ve 5.22'de gösterilmiştir. Sonuçlar 100 iterasyon sonucunda elde edilmiştir.



Şekil 5.20: Parkinson 2 veri seti için YA'da yarasa sayısının sınıflandırma doğruluğuna etkisi (RBF)



Şekil 5.21: Parkinson 2 veri seti için YA'da yarasa sayısının sınıflandırma doğruluğuna etkisi (Lineer fonksiyon)



Şekil 5.22: Parkinson 2 veri seti için YA'da yarasa sayısının sınıflandırma doğruluğuna etkisi (Polinom fonksiyon)

Şekil 5.20'de görüldüğü gibi RBF çekirdek fonksiyonu kullanılarak yapılan sınıflandırmada yarasa sayısı 15 iken sınıflandırma doğruluğu değeri %88.794, yarasa sayısı 30 iken sınıflandırma doğruluğu değeri %95.422'dir. Bu sonuç göstermektedir ki yarasa sayısı sınıflandırma performansını ciddi şekilde etkileyebilmektedir. Ayrıca Şekil

5.21’de görüldüğü gibi lineer fonksiyon ile yapılan sınıflandırmada sınıflandırma doğruluğu değeri %79.493 ile %81.031 arasında değişkenlik göstermektedir. Fakat RBF ve polinom çekirdek fonksiyonlarda Şekil 5.20 ve Şekil 5.22’de görüldüğü gibi sınıflandırma doğruluğu değerleri %90’nın üzerine çıkmıştır. Bu veri setinde YA-DVM ile yapılan sınıflandırmada lineer fonksiyonun sınıflandırma doğruluğu sonuçları diğer iki fonksiyona göre oldukça düşüktür.

YA-DVM modeli ile Parkinson 2 veri setinde yapılan sınıflandırma sonuçları 5 farklı performans değerlendirme ölçütü ile Çizelge 5.11’de gösterilmiştir.

Çizelge 5. 11: Parkinson 2 veri setinin YA-DVM ile sınıflandırma sonuçları


Çekirdek Fonksiyonu	Doğruluk	Duyarlılık	Seçicilik	Kesinlik	F1 Skor
RBF	95.422	88	97.954	93.333	87.567
Lineer	81.031	87.778	79.678	57.824	67.596
Polinom	93.859	89.333	94.598	90.21	84.629

Çizelge 5.11’de görüldüğü gibi doğruluk değerlerinde RBF ve polinom oldukça başarılı bir performans göstermişlerdir. Parkinson 2 veri setinde 23 hasta, 8 sağlıklı kişinin kayıtları bulunmaktadır ve bu nedenle bu veri seti dengesiz bir veri setidir. Dengesiz veri setlerinde sadece sınıflandırma doğruluğu değerine göre sınıflandırıcının performansının iyi olduğuna karar vermek yanıltıcı olabilir. Bu yüzden dengesiz veri setlerinin daha net bir şekilde performansının belirlenebilmesi için kesinlik ve duyarlılık değerlerinin harmonik ortalaması olan F1 skor değerlerinin incelenmesi gerekir. F1 skor değerleri incelendiğinde RBF ve polinom fonksiyonlarda bulunan sınıflandırma doğruluğu değerler ulaşamamaları da iyi bir performans göstermişlerdir. Fakat lineer fonksiyon da %81.031 doğruluk değerine ulaşılmasına rağmen F1 skor ölçütünde %67.596’ya ulaşılabilmiştir. Bu da dengesiz veri setinde sadece doğruluk değerine göre değerlendirme yapılmasının yanlış olduğunu ispatlamaktadır. Lineer fonksiyon diğer fonksiyonlara göre doğruluk, seçicilik, kesinlik ve F1 skor değerlerinde daha başarısız kalmıştır. Özellikle


seicilik, kesinlik ve F1 skor deęerlerinde lineer fonksiyon olduka bařarisızdır. Kesinlik deęerinin dūřuk ıkması, doęru olarak sınıflandırılan hasta sayısının dūřuk olduęunu gōstermektedir. Seicilik deęerinin dūřuk ıkması ise doęru olarak sınıflandırılan hasta olmayan sayısının dūřuk olduęunu gōstermektedir.

5.4.2 İKPSO ile yapılan sınıflandırma


c_1 , c_2 , w_{min} ve w_{max} parametreleri iin Parkinson 1 veri setine uygulanan İKPSO-DVM modelindeki parametre deęerlerinin aynısı seilmiřtir. Poplasyon byklę iin ise yine 5 ile 50 arasında 5'er 5'er arttırılarak parametre analizi yapılmıřtır. Parkinson 2 veri seti iin poplasyon byklę parametresinin sınıflandırma doęruluęuna etkisi řekil 5.23, 5.24 ve 5.25'de gōsterilmiřtir. Sonular 100 iterasyon sonucunda elde edilmiřtir.



řekil 5.23: Parkinson 2 veri seti iin İKPSO'da poplasyon byklęnn sınıflandırma doęruluęuna etkisi (RBF)



Şekil 5.24: Parkinson 2 veri seti için İKPSO’da popülasyon büyüklüğünün sınıflandırma doğruluğuna etkisi (Lineer fonksiyon)



Şekil 5.25: Parkinson 2 veri seti için İKPSO’da popülasyon büyüklüğünün sınıflandırma doğruluğuna etkisi (Polinom fonksiyon)

İKPSO-DVM modeli ile Parkinson 2 veri setinde yapılan sınıflandırma sonuçları 5 farklı performans değerlendirme ölçütü ile Çizelge 5.12’de gösterilmiştir.


Çizelge 5. 12: Parkinson 2 veri setinin İKPSO-DVM ile sınıflandırma sonuçları

Çekirdek Fonksiyonu	Doğruluk	Duyarlılık	Seçicilik	Kesinlik	F1 Skor
RBF	95.385	92	98	93.556	89.58
Lineer	81.042	90	80.23	60.421	67.964
Polinom	86.103	86.004	85.347	85.079	84.941


Çizelge 5.12’de görüldüğü gibi doğruluk, seçicilik, kesinlik ve F1 skor değerlerinde en başarısız performans lineer fonksiyon ile yapılan sınıflandırmadır. Lineer fonksiyon özellikle kesinlik ve F1 skor ölçütlerinde oldukça başarısızdır. Fakat lineer fonksiyon duyarlılık değerinde iyi bir performans göstermiştir. Yani İKPSO-DVM modeli ile lineer fonksiyon kullanılarak yapılan sınıflandırmada Parkinson 2 veri setindeki hastaların %90’ı doğru bir şekilde sınıflandırılmıştır. Bu da şunu göstermektedir ki bir performans ölçütünde başarısız sonuç elde edilse bile diğer performans ölçütünde başarılı sonuçlar elde edilebilmektedir. RBF fonksiyon 5 farklı performans değerlendirme ölçütünde de en başarılı performansa sahiptir.

5.4.3 İGA-DVM ile yapılan sınıflandırma


P_{cmax} , P_{cmin} , P_{mmax} ve P_{mmin} parametreleri için Parkinson 1 veri setine uygulanan İGA-DVM modelindeki parametre değerlerinin aynısı seçilmiştir. Popülasyon büyüklüğü için ise yine 10 ile 50 arasında 10’ar 10’ar artırılarak parametre analizi yapılmıştır. Parkinson 2 veri seti için popülasyon büyüklüğü parametresinin sınıflandırma doğruluğuna etkisi Şekil 5.26, 5.27 ve 5.28’de gösterilmiştir. Sonuçlar 100 iterasyon sonucunda elde edilmiştir.



Şekil 5.26: Parkinson 2 veri seti için İGA'da popülasyon büyüklüğünün sınıflandırma doğruluğuna etkisi (RBF)



Şekil 5.27: Parkinson 2 veri seti için İGA'da popülasyon büyüklüğünün doğruluğa etkisi (Lineer fonksiyon)



Şekil 5.28: Parkinson 2 veri seti için İGA'da popülasyon büyüklüğünün doğruluğa etkisi (Polinom fonksiyon)

İGA-DVM modeli ile Parkinson 2 veri setinde yapılan sınıflandırma sonuçları 5 farklı performans değerlendirme ölçütü ile Çizelge 5.13’de gösterilmiştir.


Çizelge 5. 13: Parkinson 2 veri setinin İGA-DVM ile sınıflandırma sonuçları

Çekirdek Fonksiyonu	Doğruluk	Duyarlılık	Seçicilik	Kesinlik	F1 Skor
RBF	94.41	92	100	87.045	87.919
Lineer	80.449	88	81.011	60.835	67.856
Polinom	93.791	91.556	95.931	88.671	83.268


Çizelge 5.13’de görüldüğü gibi 5 farklı performans değerlendirme ölçütünde de lineer fonksiyon diğer iki fonksiyona göre daha başarısızdır. Seçicilik ölçütünde en başarılı performansı %100 ile RBF göstermiştir. Yani Parkinson 2 veri setindeki hasta olmayan örneklerin tamamı İGA-DVM modelinde RBF fonksiyon ile doğru bir şekilde sınıflandırılmıştır.

5.4.4 AAA-DVM ile yapılan sınıflandırma


Parkinson 1 veri seti için AAA-DVM modeli ile yapılan sınıflandırmada olduğu gibi Parkinson 2 veri seti için AAA-DVM modeli ile yapılan sınıflandırmada da HMS, HMCR ve PAR değerleri için parametre analizi yapılmıştır. HMS değeri 5 ile 50 arasında 5’er 5’er arttırılarak, HMCR ve PAR değerleri de 0.1 ile 0.9 arasında 0.1’er 0.1’er arttırılarak analiz yapılmıştır. HMS değeri analiz edilirken HMCR ve PAR değerleri 0.5 alınmıştır. HMCR değeri analiz edilirken HMS değeri 20 ve PAR değeri 0.5 alınmıştır. PAR değeri analiz edilirken de HMS değeri 20 ve HMCR değeri 0.5 alınmıştır. Sonuçlar 1000 iterasyon sonucunda elde edilmiştir. Parkinson 2 veri seti için HMS parametresinin sınıflandırma doğruluğuna etkisi Şekil 5.29, 5.30 ve 5.31’de gösterilmiştir.



Şekil 5.29: Parkinson 2 veri seti için AAA'da HMS'nin sınıflandırma doğruluğuna etkisi (RBF)




Şekil 5.30: Parkinson 2 veri seti için AAA'da HMS'nin sınıflandırma doğruluğuna etkisi (Lineer fonksiyon)




Şekil 5.31: Parkinson 2 veri seti için AAA’da HMS’nin sınıflandırma doğruluğuna etkisi (Polinom fonksiyon)


Parkinson 2 veri seti için HMCR parametresinin sınıflandırma doğruluğuna etkisi Şekil 5.32, 5.33 ve 5.34’de gösterilmiştir.



Şekil 5.32: Parkinson 2 veri seti için AAA’da HMCR’nin sınıflandırma doğruluğuna etkisi (RBF)




Şekil 5.33: Parkinson 2 veri seti için AAA’da HMCR’nin sınıflandırma doğruluğuna etkisi (Lineer fonksiyon)




Şekil 5.34: Parkinson 2 veri seti için AAA’da HMCR’nin sınıflandırma doğruluğuna etkisi (Polinom fonksiyon)

Parkinson 2 veri seti için PAR parametresinin sınıflandırma doğruluğuna etkisi Şekil 5.35, 5.36 ve 5.37’de gösterilmiştir.



Şekil 5.35: Parkinson 2 veri seti için AAA'da PAR'ın sınıflandırma doğruluğuna etkisi (RBF)



Şekil 5.36: Parkinson 2 veri seti için AAA'da PAR'ın sınıflandırma doğruluğuna etkisi (Lineer fonksiyon)



Şekil 5.37: Parkinson 2 veri seti için AAA'da PAR'ın sınıflandırma doğruluğuna etkisi (Polinom fonksiyon)

En iyi sınıflandırma doğruluğu değeri RBF fonksiyonda HMS = 20, HMCR = 0.5 ve PAR = 0.3 iken elde edilmiştir. AAA-DVM modeli ile Parkinson 2 veri setinde yapılan sınıflandırma sonuçları 5 farklı performans değerlendirme ölçütü ile Çizelge 5.14'de gösterilmiştir.

Çizelge 5. 14: Parkinson 2 veri setinin AAA-DVM ile sınıflandırma sonuçları

Çekirdek Fonksiyonu	Doğruluk	Duyarlılık	Seçicilik	Kesinlik	F1 Skor
RBF	95.41	91.778	97.31	92.143	88.785
Lineer	80.966	87.778	79.563	57.505	67.991
Polinom	88.333	86.667	87.917	87.083	86.667

Çizelge 5.14'de görüldüğü gibi doğruluk ölçütünde en başarılı performans RBF fonksiyona aittir. Fakat daha önce de değinildiği gibi Parkinson 2 veri seti dengesiz olduğu için sadece doğruluk değerine göre performans hakkında karar verilemez. Dengesiz veri setlerinde daha net performans ayrımı yapabilmeye yarayan F1 skor

ölçütüne bakılır. F1 skor ölçütüne bakıldığında RBF'nin yine başarılı bir performans gösterdiği gözlemlenmektedir. Tüm değerlendirme ölçütlerinde en başarılı performans RBF'ye aittir. Polinom fonksiyonda genel olarak başarılı bir performans göstermiştir. Duyarlılık ölçütü hariç diğer ölçütlerde lineer fonksiyon başarısız bir performansa sahiptir.

5.4.5 Sınıflandırma modellerinin karşılaştırılması

Bu tez çalışmasında önerilen YA-DVM, İKPSO-DVM, İGA-DVM ve AAA-DVM modellerinin Parkinson 2 veri setindeki sınıflandırma sonuçları Çizelge 5.15'de karşılaştırılmıştır.

Çizelge 5. 15: Önerilen modellerin Parkinson 2 veri setindeki sınıflandırma sonuçları

Çekirdek Fonksiyonu	Değerlendirme Ölçütü	YA-DVM	İKPSO-DVM	İGA-DVM	AAA-DVM
RBF	Doğruluk	95.422	95.385	94.41	95.41
	Duyarlılık	88	92	92	91.778
	Kesinlik	93.333	93.556	87.045	92.143
	Seçicilik	97.954	98	100	97.31
	F1 Skor	87.567	89.58	87.919	88.785
Lineer	Doğruluk	81.031	81.042	80.449	80.966
	Duyarlılık	87.778	90	88	87.778
	Kesinlik	57.824	60.421	60.835	57.505
	Seçicilik	79.678	80.23	81.011	79.563
	F1 Skor	67.596	67.964	67.856	67.991
Polinom	Doğruluk	93.859	86.103	93.791	88.333
	Duyarlılık	89.333	86.004	91.556	86.667
	Kesinlik	90.21	85.079	88.671	87.083
	Seçicilik	94.598	85.347	95.931	87.917
	F1 Skor	84.629	84.941	83.268	86.667

Çizelge 5.15’de görüldüğü gibi seçicilik ölçütünde en başarılı performans %100 ile İGA-DVM modelinde RBF ile yapılan sınıflandırmaya aittir. İGA-DVM modeli RBF ile yapılan sınıflandırmada Parkinson 2 veri setindeki hasta olmayan örneklerin tamamı doğru bir şekilde sınıflandırılmıştır. Doğruluk ölçütünde en başarılı performans RBF’ye aittir. YA-DVM, İKPSO-DVM, İGA-DVM ve AAA-DVM modellerinde RBF ile yapılan sınıflandırmanın sonucunda doğruluk değerleri birbirine oldukça yakın çıkmıştır.

Çizelge 5.16’da bu tez çalışmasında önerilen 4 modelin Parkinson 2 veri setindeki sınıflandırması sonucunda bulunan maksimum sınıflandırma değerleri sonuçları ile literatürde Parkinson 2 veri setinde yapılan sınıflandırma sonucunda elde edilen sınıflandırma doğruluğu değerleri karşılaştırılmıştır.

Çizelge 5. 16: Önerilen modellerin literatürdeki diğer çalışmalarla doğruluk karşılaştırması

Önerilen model	Sınıflandırma doğruluğu değeri
YA-DVM	95.422
İKPSO-DVM	95.385
İGA-DVM	94.41
AAA-DVM	95.41
KAA-DVM (Tezcan, 2018)	94.87
SSA-DVM (Tezcan, 2018)	95.38
Çekirge Optimizasyon Alg. (Aljarah ve ark., 2018)	94.95
Mevve Sineği Algoritması (Shen ve ark., 2016)	96.90
CS-PSO-DVM (Kaya, 2019)	97.4359
DE-DVM (Jun ve ark., 2013)	85.00

Çizelge 5.16’da görüldüğü gibi bu tez çalışmasında önerilen 4 model ile elde edilen sınıflandırma doğruluğu değerleri literatürde aynı veri seti üzerinde yapılan sınıflandırma sonucunda elde edilen sınıflandırma doğruluğu değerlerinin bazılarında daha iyi, bazıları ile de rekabet edebilecek seviyededir.



6. SONUÇ ve ÖNERİLER

Parkinson, yaşa bağlı olarak artan bir nörolojik hastalıktır. Bu hastalığın belirtileri depresyon, eklem hastalıkları ve yaşlanma ile ilişkilendirilerek başlangıçta yanlış tanı konulabilmektedir. Bu hastalığı tamamen ortadan kaldıracak bir tedavi yöntemi bulunmamakla birlikte hastalığın ilk evrelerindeki belirtileri azaltmak için ilaç tedavisi uygulanmaktadır. Bu yüzden hastalığın erken teşhisi oldukça önemlidir. Bu tez çalışmasında parkinson hastalığının erken teşhisine yardımcı olması için makine öğrenmesi algoritmalarından biri olan DVM kullanılarak parkinson hastalığı tahmini yapılmıştır.

DVM’de parametrelerin optimizasyonu sınıflandırmanın başarısını etkilemektedir. Bu konuda literatürde birçok çalışma bulunmaktadır. Bu çalışmada dört farklı meta sezgisel algoritma ile DVM parametre optimizasyonu yapılmıştır. Bu algoritmalar kullanılarak önerilmiş olan sınıflandırma modellerine YA-DVM, İKPSO-DVM, İGA-DVM ve AAA-DVM isimleri verilmiştir. Bu modellerle UCI veri tabanından alınan iki farklı parkinson hastalığı veri seti üzerinde DVM’nin üç farklı çekirdek fonksiyonu kullanılarak sınıflandırma yapılmış ve parkinson hastalığı tahmini yapılmıştır.

Elde edilen sonuçlara göre her iki veri setinde yapılan sınıflandırmada RBF çekirdek fonksiyonu en başarılı performansa sahiptir. Kullanılan meta sezgisel algoritmaların başarısı performans değerlendirme ölçütüne göre farklılık göstermektedir. Sadece sınıflandırma doğruluğuna göre bir değerlendirme yapılacak olursa Parkinson 1 veri setinde yapılan sınıflandırmada en başarılı sonuç İKPSO-DVM modeline, Parkinson 2 veri setinde yapılan sınıflandırmada en başarılı sonuç YA-DVM modeline aittir. Önerilen 4 farklı model literatürde aynı veri seti ile yapılan diğer sınıflandırma sonuçları ile karşılaştırılmış ve Parkinson 1 veri setinde en iyi sınıflandırma doğruluğu değeri sonucu bu tez çalışmasında önerilen İKPSO-DVM ile elde edilmiştir. Parkinson 2 veri setinde ise önerilen 4 yöntemin literatürdeki diğer çalışmaların bazılarında daha iyi sonuç verdiği, bazıları ile de rekabet edebilecek seviyede olduğu gözlemlenmiştir.

Gelecek alıřmalarda arařtırmacılar farklı meta sezgisel algoritmaların avantajlı yönlerini kullanarak birden fazla meta sezgisel algoritmanın birleřtirildięi hibrit yöntemler ile optimizasyon yaparak farklı DVM sınıflandırma modelleri önerebilirler.



KAYNAKLAR

- Akyol, S. ve Alataş, B., 2012. Güncel sürü zekâsı optimizasyon algoritmaları. Nevşehir Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 1(1), 36-50.
- Akyol, S. ve Alatas, B., 2016. Plant intelligence based metaheuristic optimization algorithm. Artificial Intelligence Review, 47(4), 417-462.
- Alhakbani, H. A. ve al-Rifaie, M. M., 2017. Optimising SVM to classify imbalanced data using Dispersive Flies Optimisation, 2017 Federated Conference on Computer Science and Information Systems (FedCSIS), Prague, Czech Republic.
- Alia, O. M. ve Mandava, R., 2011. The variants of the harmony search algorithm: An overview. Artificial Intelligence Review, 36(1), 49-68.
- Aljarah, I., Al-Zoubi, A. M., Hassonah, M. A., Mirjalili, S. ve Saadeh, H., 2018. Simultaneous feature selection and support vector machine optimization using the grasshopper optimization algorithm. Cognitive Computation, 10(2), 478-495.
- Ao, H., Cheng J., Yang, Y. ve Truong T. K., 2015. The support vector machine parameter optimization method based on artificial chemical reaction optimization algorithm and its application to roller bearing fault diagnosis. Journal of Vibration and Control. 21(12), 2434-2445.
- Arıcı, S. S., 2021. Karınca Kolonisi Optimizasyonu ve Genetik Algoritma Tabanlı Tramp Gemi Rotalama ve Çizelgeleme. (Y. Lisans Tezi), İstanbul Teknik Üniversitesi. Lisansüstü Eğitim Enstitüsü, İstanbul.
- Askarzadeh, A., 2016. A novel metaheuristic method for solving constrained engineering optimization problems: Crow search algorithm. Computers & Structures, 169, 1-12.
- Ayhan, E., 2021. Kan Tedarik Zinciri Dağıtım Ağı Modellemesi ve Hibrit Genetik Algoritma ile Çözümü. (Doktora Tezi), Yıldız Teknik Üniversitesi. Endüstri Mühendisliği Anabilim Dalı, İstanbul.
- Ayvaz, M. T., 2007a. Simultaneous determination of aquifer parameters and zone structures with fuzzy means clustering and meta-heuristic harmony search algorithm. Advances in Water Resources. 30(11), 2326-2338.
- Ayvaz, M. T., Karahan, H. ve Gürarlan, G., 2007b. Su dağıtım şebekelerinin armoni araştırması optimizasyon tekniği ile optimum tasarımı. 5. Kentsel Altyapı Ulusal Sempozyumu, Antakya-Hatay.
- Bolat, B., Erol, K. O. ve İmrak, C. E., 2005. Genetic algorithms in engineering applications and the function of operators sigma. Journal of Engineering and Natural Sciences.
- Bryson, J. T., Jin, X. ve Agrawal, S. K., 2016. Optimal design of cable-driven manipulators using particle swarm optimization. Journal of Mechanisms and Robotics, 8(4), p. 8.
- Can, H., Juelong, L. ve Jianchun, X., 2018. A new model for structural damage assessment using adaptive mutation particle swarm optimization and support vector machine. 2018 Chinese Control And Decision Conference (CCDC), Shenyang, China.
- Cervantes, J., Garcia-Lamont, F., Rodriguez, L., López, A., Castilla, J. R. ve Trueba, A., 2017. PSO-based method for SVM classification on skewed data sets. Neurocomputing, 228(C), 187-197.

- Ceylan, O. ve Taşkın, G., 2016a. SVM parameter selection based on harmony search with an application to hyperspectral image classification. 2016 24th Signal Processing and Communication Application Conference (SIU), Zonguldak.
- Ceylan, O. ve Taşkın, G., 2016b. A comparison of differential evolution and harmony search methods for SVM model selection in hyperspectral image classification. 2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS), Beijing, China.
- Chen, C., Hoang, T. T. ve Cho M., 2019. Parameter optimisation of support vector machine using mutant particle swarm optimisation for diagnosis of metal-oxide surge arrester conditions. *Journal of Experimental & Theoretical Artificial Intelligence*, 31(1), 163-175.
- Chen, C., Song, L., Bo, C. ve Shuo, W., 2021. A support vector machine with particle swarm optimization grey wolf optimizer for network intrusion detection. 2021 International Conference on Big Data Analysis and Computer Science (BDACS), Kunming, China.
- Chen, J., Liu, H., Wu, W. ve Xie, D., 2011. Estimation of monthly solar radiation from measured temperatures using support vector machines – A case study. *Renewable Energy*, 36(1), 413-420.
- Chen, T. Y. ve Chen, C. J., 1998. Improvements of simple genetic algorithm in structural design. *International Journal for Numerical Methods in Engineering*, 40(7), 1323-1334.
- Cheng, R., Gen, M. ve Tsujimura, Y. 1999. A tutorial survey of job-shop scheduling problems using genetic algorithms: Part II. Hybrid genetic search strategies. *Computers & Industrial Engineering* 37(1-2), 51-55.
- Cheng, Y., Fu, Y. ve Gong, G., 2010. A hybrid support vector regression based on chaotic particle swarm optimization algorithm in forecasting financial returns. 2010 2nd International Conference on Information Engineering and Computer Science, Wuhan, China.
- Cho, M. Y. ve Hoang, T. T., 2017. Feature selection and parameters optimization of svm using particle swarm optimization for fault classification in power distribution systems. *Computational Intelligence and Neuroscience*, 2017(3), 1-9.
- Civicioglu, P., 2013. Backtracking search optimization algorithm for numerical optimization problems. *Applied Mathematics and Computation*, 219(15), 8121-8144.
- Cortes, C. ve Vapnik, V., 1995. Support-vector networks. *Machine Learning*, 20(3), 273-297.
- Çakar., K., 2009. Genetik Algoritmalar Yardımıyla Acil Servis İstasyonu Yerleşiminin Optimizasyonu. (Doktora Tezi), Atatürk Üniversitesi. Sosyal Bilimler Enstitüsü, Erzurum.
- Çolak, S., 2010. Genetik algoritmalar yardımı ile gezgin satıcı probleminin çözümü üzerine bir uygulama. *Çukurova Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 19(3), 423-438.
- Dawid, H., 1999. *Adaptive Learning by Genetic Algorithms: Analytical Results and Applications to Economic Models*. Springer Verlag, 166 s, Berlin, Heidelberg.
- Demir, M., 2015. *Sezgisel Yöntemlerde Altın Oran*. (Doktora Tezi), İnönü Üniversitesi. Fen Bilimleri Enstitüsü, Malatya.

- Dorigo, M. ve Blum, C., 2005. Ant colony optimization theory: A survey. *Theoretical Computer Science*, 344(2-3), 243-278.
- Duman, A., 2010. Multiple Criteria Sorting Methods Based on Support Vector Machines. (Master Thesis), The Graduate School of Natural and Applied Sciences of Middle East Technical University, İstanbul.
- Dursun, P., 2009. Zaman Pencereli Araç Rotalama Problemi'nin Genetik Algoritma İle Modellenmesi. (Yüksek Lisans Tezi), İstanbul Teknik Üniversitesi. Endüstri Mühendisliği Anabilim Dalı, İstanbul.
- Elmas, Ç. ve Yiğit, T., 2007. Genetic algorithm based on-line tuning of a PI controller for a switched reluctance motor drive. *Electric Power Components and Systems*, 35(6), 675-691.
- Elmas, Ç. 2016. Yapay Zeka Uygulamaları: yapay sinir ağı, bulanık mantık, sinirsel bulanık mantık, genetik algoritma. Seçkin Yayıncılık, 479 s., Ankara.
- Fenton, M. B., 2004. Bat Natural History and Echolocation. *Bat Echolocation Research: tools, techniques and analysis*, Ed: R. M. Brigham, E. K. V. Kalko, G. Janes, S. Parsons ve H. J. G. A. Limpens. Bat Conversation International, Austin, Texas, 2-6.
- Fesanghary, M., Damangir, E. Ve Soleimani, I., 2009. Design optimization of shell and tube heat exchangers using global sensitivity analysis and harmony search algorithm. *Applied Thermal Engineering*, 29(5-6), 1016-1031.
- Fink, A. ve Voß, S., 1999. Generic metaheuristics application to industrial engineering problems. *Computers and Industrial Engineering*, 37(1-2), 281-284.
- Gao, X., Yu, P., Mao, W. ve Peng, D., 2012. Classification of hyperspectral image based on SVM optimized by a new particle swarm optimization. 2012 2nd International Conference on Remote Sensing, Environment and Transportation Engineering, Nanjing, China.
- Geem, Z. W., Kim, J. H. ve Loganathan, G. V., 2001. A new heuristic optimization algorithm: harmony search. *Simulation*, 76(2), 60-68.
- Guo, X. C., Yang, J. H., Wu, C. G., Wang, C. Y. ve Liang, Y. C., 2008. A novel LS-SVMs hyper-parameter selection based on particle swarm optimization. *Neurocomputing*, 71(16-18), 3211-3215.
- Güneş T., 2020. Parkinson hastalığı nedir? Belirtileri nelerdir?. Medical Park Hastanesi. <https://www.medicalpark.com.tr/parkinson-hastaligi/hg-1976>; (30.09.2021).
- Güngör, S., 2015. Armoni Arama Algoritması'nın Takım Kurma Problemlerinin Çözümünde Kullanımı: Kayserispor Futbol Takımı Uygulaması. (Yüksek Lisans Tezi), Erciyes Üniversitesi. Sosyal Bilimler Enstitüsü, Kayseri.
- Han, H. ve Houjun, W., 2011. Study on power transformer protection based on chaos particle swarm optimization. *IEEE 2011 10th International Conference on Electronic Measurement & Instruments*, Chengdu, China.
- He, Z. Ding, S., Li, B., Yin, M., Zhang, X., 2017. An improved particle swarm optimization of support vector machine parameters for hyperspectral image classification. 2017 12th IEEE Conference on Industrial Electronics and Applications (ICIEA), Siem Reap, Cambodia.
- Holland, J. H., 1992. *Adaptation in Natural and Artificial Systems: An Introductory Analysis with Applications to Biology, Control, and Artificial Intelligence*. MIT Press, 211 p, Cambridge, USA.

- Hong-qi, L., Li, L., Kim, T. H. ve Shao-long, X., 2008. An improved PSO-based of harmony search for complicated optimization problems. *International Journal of Hybrid Information Technology*, 1(1), 57-64.
- Hric, M., Chmulík, M. ve Jarina, R., 2011. Model parameters selection for SVM classification using particle swarm optimization. *Proceedings of 21st International Conference Radioelektronika*, Brno, Czech Republic.
- Huang, C. L. ve Wang, C. J., 2006. A GA-based feature selection and parameters optimization for support vector machines. *Expert Systems with Applications*, 31(2), 231-240.
- Huang, J., Zhang, G. ve Shen, Y., 2019. DGA domain name detection based on SVM under grey wolf optimization algorithm. *2019 IEEE 10th International Conference on Software Engineering and Service Science*, Beijing, China.
- Huang, Y., Wu, D., Zhang, Z. ve Chen, H., 2017. EMD-based pulsed TIG welding process porosity defect detection and defect diagnosis using GA-SVM. *Journal of Materials Processing Technology*, 239, 92-102.
- İplikçi, S., 2009. Controlling the Experimental Three-Tank System via Support Vector Machine. *Adaptive and Natural Computing Algorithms*, Ville, K., Pekka, T. ve B. Beliczynski. Springer, Berlin, Heidelberg, 391-400.
- Jafrasteh, B. ve Fathianpour, N., 2017. A hybrid simultaneous perturbation artificial bee colony and back-propagation algorithm for training a local linear radial basis neural network on ore grade estimation. *Neurocomputing*, 235(C), 217-227.
- Jin, Z., Chaorong, W., Chengguang, H. ve Feng, W. 2014. Parameter optimization algorithm of SVM for fault classification in traction converter. *The 26th Chinese Control and Decision Conference (2014 CCDC)*, Changsha, China.
- Jun, L., Lixin, D. ve Ying, X., 2013. Differential evolution based parameters selection for support vector machine. *2013 Ninth International Conference on Computational Intelligence and Security*, Emeishan, China.
- Juste, F. S., Sassi, F. C., Costa, J. B. ve de Andrade, C. R. F., 2018. Frequency of speech disruption in Parkinson's Disease and developmental stuttering: A comparison among speech tasks. *PLoS One*, 13(6).
- Kahraman, A. M. ve Özdağlar, D., 2004. Su dağıtım sistemlerinin genetik algoritma ile optimizasyonu. *Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi*, 6(3), 1-18.
- Kalınlı, A. ve Aksu, Ö., 2013. Baskın gen seçimi operatörüne dayalı genetik algoritma modeli. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 26(4), 869-875.
- Kamal, L. L. K., 2018. Yarasa Algoritması Kullanarak Yapay Sinir Ağlarının Eğitilmesi. (Yüksek Lisans Tezi), Selçuk Üniversitesi. Bilgisayar Mühendisliği Anabilim Dalı, Konya.
- Kamel, S. R., YaghoubZadeh, R. ve Kheirabadi, M., 2019. Improving the preformance of support-vector machine by selecting the best features by gray wolf algorithm to increase the accuracy of diagnosis of breast cancer. *Journal of Big Data*, 6(1).
- Karaboğa, D., 2011. Yapay Zeka Optimizasyon Algoritmaları. Nobel Akademik Yayıncılık, 246 s, Ankara.
- Kavzoğlu, T. ve Çölkesen, İ., 2010. Destek vektör makineleri ile uydu görüntülerinin sınıflandırılmasında kernel fonksiyonlarının etkilerinin incelenmesi. *Harita Dergisi*, 76(144), 73-82.

- Kaya, D., 2019, Optimization of SVM parameters with hybrid CS-PSO algorithms for Parkinson's Disease in LabVIEW environment. Parkinson's Disease, 2019(18), 1-9.
- Kaya, K., 2016. Destek Vektör Makineleri Yardımıyla Tüketici Kredilerinin Sınıflandırılması. (Yüksek Lisans Tezi), İstanbul Teknik Üniversitesi. Fen Bilimleri Enstitüsü, İstanbul.
- Kennedy, J. ve Eberhart, R., 1995. Particle swarm optimization. International Conference on Neural Networks, Perth, WA, Australia.
- Kırda, K., 2013. Evsel İlaç Atıklarının Toplanması Projesindeki Tersine Lojistik Sürecinin Modellenmesi İçin Genetik Algoritmaların Kullanılması. (Doktora Tezi), Dokuz Eylül Üniversitesi. İşletme Anabilim Dalı, İzmir.
- Kumar, V. ve Panneerselvam, R., 2017. A study of crossover operators for genetic algorithms to solve VRP and its variants and new sinusoidal motion crossover operator. International Journal of Computational Intelligence Research, 13(7), 1717-1733.
- Ladjal, M., Ouali, M. A. ve Lass, M. D., 2020. Optimization of SVM parameters with hybrid PCA-PSO methods for water quality monitoring. 2020 International Conference on Electrical Engineering (ICEE), İstanbul, Turkey.
- Li, J. ve Ding, S., 2012. Spectral feature selection with particle swarm optimization for hyperspectral classification. 2012 International Conference on Industrial Control and Electronics Engineering, Xi'an, China.
- Li, M., Yan, X., Cao, Y., Peng, Q. ve Zhang, H., 2013. A method for the oil chromatographic on-line data reconciliation based on GSO and SVM. IEEE 2013 Tencon – Spring, Sydney, NSW, Australia.
- Li, X. Z. ve Kong, J. M., 2014. Application of GA-SVM method with parameter optimization for landslide development prediction. Natural Hazards and Earth System Sciences, 14(3), 525-533.
- Liang, Y. ve Wang, L., 2020. Applying genetic algorithm and ant colony optimization algorithm into marine investigation path planning model. Soft Computing, 24(11), 8199-8210.
- Lin, S. W., Ying, K. C., Chen, S. C. ve Lee, Z. J., 2008. Particle swarm optimization for parameter determination and feature selection of support vector machines. Expert Systems with Applications, 35(4), 1817-1824.
- Little, M. A., McSharry, P. E., Roberts, S. J., Costello, D. A. ve Moroz, I. M., 2007. Exploiting nonlinear recurrence and fractal scaling properties for voice disorder detection. BioMedical Engineering OnLine, 6(1), 23 p.
- Little, M. A., McSharry, P. E., Hunter, E. J., Spielman, J., Ramig, L. O., 2009. Suitability of dysphonia measurements for telemonitoring of Parkinson's Disease. IEEE Transactions on Biomedical Engineering, 56(4), 1015-1022.
- Liu, B., Wang, L., Jin, Y. H., Tang, F. ve Huang, D. X., 2005. Improved particle swarm optimization combined with chaos. Chaos, Solitons & Fractals, 25(5), 1261-1271.
- Liu, C., 2014. Multi-robot task allocation for inspection problems with cooperative tasks using hybrid genetic algorithms. Kassel University Press, 148 p, Germany.
- Liu, Q., Huang, G., Mao, C., Shang, Y. ve Wang, F., 2016. Recognition of dissolved gas in transformer oil by ant colony optimization support vector machine. 2016 IEEE

- International Conference on High Voltage Engineering and Application (ICHVE), Chengdu, China.
- Marras, C., Beck, J.C., Bower, J. H., Roberts, E., Ritz, B., Ross, G.W., Abbott, D., Savica R., Eeden, S. K. V. D., Willis, A.W. ve Tanner, C., 2018. Prevalence of Parkinson's disease across North America. *npj Parkinson's Disease*, 4(1).
- May, R. M., 1976. Simple mathematical models with very complicated dynamics. *Nature*, 261, 459-467.
- Metlek, S. ve Kayaalp, K., 2020. Makine Öğrenmesinde, Teoriden Örnek Matlab Uygulamalarına Kadar Destek Vektör Makineleri. *İksad Yayınevi*, 100 s., Ankara.
- Mountrakis, M., Im, J. ve Ogole, C., 2011. Support vector machines in remote sensing: a review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 66(3), 247-259.
- Naranjo, L., Pérez, C. J., Campos-Roca, Y. ve Martín, J., 2016. Addressing voice recording replications for Parkinson's disease detection. *Expert Systems with Applications*, 46, 286-292.
- Naranjo L., Pérez, C. J., Martín, J. ve Campos-Roca, Y., 2017. A two-stage variable selection and classification approach for Parkinson's disease detection by using voice recording replications. *Computer Methods and Programs in Biomedicine*, 142, 147-156.
- Narin, A., 2020. Parkinson hastalarının tespitinde karınca koloni algoritması ile seçilen öz niteliklerin performansa etkisi. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 8(4), 2443-2454.
- Okur, E. ve Atlas, M., 2020. Araç rotalama probleminin genetik algoritma ile çözümü. *Anadolu Üniversitesi Sosyal Bilimler Dergisi*, 20(3), 227-254.
- Omran, M. G. H. ve Mahdavi, M., 2008. Global-best harmony search. *Applied Mathematics and Computation*, 198(2), 643-656.
- Onan, A., 2013. Metasezgisel yöntemler ve uygulama alanları. *Çukurova Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 17(2), 113-128.
- Osuna, E., Freund, R. ve Girosi, F., 1997. *Support Vector Machines: Training and Applications*. Massachusetts Institute of Technology, 201 Vassar Street, W59-200 Cambridge, MA, United States.
- Özalp, M. ve Alp, S., 2020. Uygun dağıtım rotası belirlenmesi probleminde hibrit sezgisel bir yöntem önerisi: bir kargo firması örneği. *Akıllı Ulaşım Sistemleri ve Uygulamaları Dergisi*, 3(1), 59-70.
- Özbeyaz, A., Gürsoy, M. İ. ve Çoban, R., 2011. Regularization and kernel parameters optimization based on PSO algorithm in EEG signals classification with SVM. 2011 IEEE 19th Signal Processing and Communications Applications Conference (SIU), Antalya.
- Özseven, T., Ertürkler, M., Nurmhammed, M., Gül, M. ve Harputluoğlu, M., 2012. Quantifying the necrotic areas on liver tissues using support vector machine (SVM) algorithm and Gabor filters. 2012 International Symposium on Innovations in Intelligent Systems and Applications. Trabzon.
- Rajalaxmi, R. R. ve Vidyha, E., 2019. A mutated salp swarm algorithm for optimization of support vector machine parameters. 2019 5th International Conference on Advanced Computing & Communication Systems (ICACCS), Coimbatore, India.
- Rastgoufard, S. ve Charalampidis, D., 2016. Parameter selection of multi-class SVM with evolutionary optimization methods for static security evaluation in power

- systems. 2016 IEEE Electrical Power and Energy Conference (EPEC), Ottawa, ON, Canada.
- Saini, A. ve Sharma, R., 2019. A hybrid pain detection technique using SVM parameter optimization and contourlet-gabor transform feature fusion. *International Journal of Innovative Technology and Exploring Engineering (IJITEE)*, 8(12), 2278-3075.
- Satman, M.H., 2016. *Genetik Algoritmalar*. Türkmen Kitabevi, 280 s.
- Schnitzler, H. U. ve Kalko, E. K. V., 2001. Echolocation by insect-eating bats: we define four distinct functional groups of bats and find differences in signal structure that correlate with the typical echolocation tasks faced by each group. *BioScience*, 51(7), 557-569.
- Shen, L., Chen, H., Yu, Z., Kang, W., Zhang, B., Li, H., Yang, B. ve Liu, D., 2016. Evolving support vector machines using fruit fly optimization for medical data classification. *Knowledge-Based Systems*, 96, 61-75.
- Sherin, B.M. ve Supriya, M. H., 2015. GA based selection and parameter optimization for an SVM based underwater target classifier. 2015 International Symposium on Ocean Electronics (SYMPOL), Kochi, India.
- Singh, I. ve Bansal, R., 2020. A hybrid grey wolf-whale optimization algorithm for optimizing SVM in breast cancer diagnosis. 2020 Sixth International Conference on Parallel, Distributed and Grid Computing (PDGC), 286-290.
- Sivanandam, S. N. ve Deepa, S. N., 2008. *Genetic Algorithms. Introduction to Genetic Algorithms*, Springer, Berlin, Heidelberg, 15-37.
- Song, P. He, Y. ve Ma, Qingfeng, 2016. Fault diagnosis for missile autopilot based on GSA-SVM. 2016 IEEE Advanced Information Management, Communicates, Electronic and Automation Control Conference (IMCEC), Xi'an, China.
- Syarif, I., Prugel-Bennett, A. ve Wills, G., 2016. SVM parameter optimization using grid search and genetic algorithm to improve classification performance. *TELKOMNIKA Telecommunication Computing Electronics and Control*, 14(4), 1502-1509.
- Tao, Z., Huiling, L., Wenmen, W. ve Xia, Y., 2019. GA-SVM based feature selection and parameter optimization in hospitalization expense modeling. *Applied Soft Computing*, 75, 323-332.
- Taşkın, Ç. ve Emel, G. G., 2009. *Sayısal Yöntemlerde Genetik Algoritmalar*. Alfa Aktüel Yayınları, 153 s., Bursa.
- Tezcan, B., 2018. *Destek Vektör Makineleri Parametrelerinin Meta Sezgisel Optimizasyon Algoritmaları İle Belirlenmesi*. (Yüksek Lisans Tezi), Selçuk Üniversitesi. Fen Bilimleri Enstitüsü, Konya.
- Thai, V., Cheng, J., Nguyen, V. ve Daothi, P., 2019. Optimizing SVM's parameters based on backtracking search optimization algorithm for gear fault diagnosis. *Journal of Vibroengineering*, 21(1), 66-81.
- Tharwat, A., Hassanien, A. E. ve Elnaghi, B. E., 2017. A BA-based algorithm for parameter optimization of Support Vector Machine. 93, 13-22.
- Tharwat, A. ve Hassanien, A. E., 2019. Quantum-behaved particle swarm optimization for parameter optimization of support vector machine. *Journal of Classification*, 36(1), 576-598.

- Tuba, E., Tuba, M. ve Simian, D., 2016. Adjusted bat algorithm for tuning of support vector machine parameters. 2016 IEEE Congress on Evolutionary Computation (CEC), Vancouver, BC, Canada.
- Tuba, E. ve Stanimirovic, Z., 2017. Elephant herding optimization algorithm for support vector machine parameters tuning. 2017 9th International Conference on Electronics, Computers and Artificial Intelligence (ECAI), Targoviste, Romania.
- Uçak, K., 2012. Destek Vektör Regresyonu İle PID Kontrolör Tasarımı. (Yüksek Lisans Tezi), İstanbul Teknik Üniversitesi. Fen Bilimleri Enstitüsü, İstanbul.
- Vapnik, V., 1999. The Nature of Statistical Learning Theory. Springer.
- Vural, M., 2005. Genetik Algoritma Yöntemi İle Toplu Üretim Planlama (Yüksek Lisans Tezi), İstanbul Teknik Üniversitesi. Fen Bilimleri Enstitüsü, İstanbul.
- Wahab, M. N. A., Nefti-Meziani, S. ve Atyabi, A., 2015. A comprehensive review of swarm optimization algorithms. PLoS ONE, 10(5).
- Wang, J., Shan, G., Zhang, Q. ve Duan, X., 2011. Analog circuit fault diagnosis method based on CPSO-SVM. 2011 International Conference on Quality, Reliability, Risk, Maintenance, and Safety Engineering, Xi'an, China.
- Wang, L., 2005. Support Vector Machines: Theory and Applications. Springer, 431 p., Berlin, Heidelberg.
- Wang, L., Xu, G., Wang, J., Yang, S., Guo, L. ve Yan, W., 2011. GA-SVM based feature selection and parameters optimization for BCI research. 2011 Seventh International Conference on Natural Computation, Shanghai, China.
- Wang, M. ve Chen, H., 2020. Chaotic multi-swarm whale optimizer boosted support vector machine for medical diagnosis. Applied Soft Computing, 88(6).
- Wang, S., 2012. Support vector machines classification for high-dimensional dataset. 2012 Fourth International Conference on Multimedia Information Networking and Security, Nanjing, China.
- Wu, 2019. Research on the influence of crossover probability and mutation probability in GA-SVM model. 2019 IEEE 9th International Conference on Electronics Information and Emergency Communication, Beijing, China.
- Xiangdong, H. ve Shaoqing, W., 2018. Prediction of bottom-hole flow pressure in coalbed gas wells based on GA optimization SVM. 2018 IEEE 3rd Advanced Information Technology, Electronic and Automation Control Conference (IAEAC), Chongqing, China.
- Xiao-Cong, L., 2014. A hybrid SVM-QPSO model based ceramic tube surface defect detection algorithm. 2014 Fifth International Conference on Intelligent Systems Design and Engineering Applications, Hunan, China.
- Xie, Y., Bian, C., Murphey, Y. L. ve Kochhar, D. S., 2017. An SVM parameter learning algorithm scalable on large data size for driver fatigue detection. 2017 IEEE Symposium Series on Computational Intelligence (SSCI), Honolulu, HI, USA.
- Xue, Z., Du, P. ve Su, H., 2013. A novel classification technique for hyperspectral imagery based on Harmonic Analysis, SVM and PSO. 2013 5th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS), Gainesville, FL, USA.
- Yan, S., Xiao-Min, L. ve Xiao-Hui, Q., 2010. Parameter optimization of support vector machine based on combined algorithm of QPSO and SA. 2010 First International Conference on Pervasive Computing, Signal Processing and Applications, Harbin, China.

- Yang, L. ve Xu, Z., 2019. Feature extraction by PCA and diagnosis of breast tumors using SVM with DE-based parameter tuning. *International Journal of Machine Learning and Cybernetics*, 10(3), 591-601.
- Yang, X. S., 2010a. A New Metaheuristic Bat-Inspired Algorithm. *Nature Inspired Cooperative Strategies for Optimization (NICSO-2010)*, Juan, R. G., David, A. P., Carlos, C., Germán, T. ve Natalio K., Berlin, Heidelberg, 65-74.
- Yang, X. S., 2010b. *Engineering Optimization: An Introduction with Metaheuristic Applications*. Wiley-Blackwell, 376 p.
- Yang, X. S., 2012. Bat algorithm for multi-objective optimisation. *International Journal of Bio-Inspired Computation*, 3(5), 267-274.
- Yang, X. S. ve He, X., 2013. Bat algorithm: literature review and applications. *International Journal of Bio-Inspired Computation*, 5(3), 141-149.
- Yang, X. S., 2014. *Nature-Inspired Optimization Algorithms*. Elsevier.
- Yang, Z., Shumin, Y., Shaoxiong, W. ve Dongrong, X., 2019. A new object detection method based on T mutation PSO for SVM parameter optimization. 2019 11th International Conference on Measuring Technology and Mechatronics Automation (ICMTMA), Qiqihar, China.
- Yetkin, M. ve Berber, M., 2014. Implementation of robust estimation in GPS networks using the artificial bee colony algorithm. *Earth Science Informatics*, 7(1), 39-46.
- Yetkin, M., 2016. Metasezgisel algoritmaların Jeodezi’de kullanımı. *Geomatik Dergisi*, 1(1), 8-13.
- Yılmaz, S., 2014. Yarasa Algoritmasının Unimodal, Multimodal ve Kaydırılmış Sayısal Optimizasyon Problemleri (CEC05) Üzerinde Geliştirilmesi (Yüksek Lisans Tezi). Süleyman Demirel Üniversitesi. Fen Bilimleri Enstitüsü. Isparta.
- Yuan, S. F. ve Chu, F., 2007. Fault diagnostics based on particle swarm optimisation and support vector machines. *Mechanical Systems and Signal Processing*, 21(4), 1787-1798.
- Zhang, X., Chen, X. ve He, Z., 2010. An ACO-based algorithm for parameter optimization of support vector machines. 37(9), 6618-6628.

ÖZGEÇMİŞ

