



T.C.

TOKAT GAZİOSMANPAŞA ÜNİVERSİTESİ

LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

BİLGİSAYAR MÜHENDİSLİĞİ DOKTORA PROGRAMI

**KONUŞMALARIN DUYGUSAL SINIFLANDIRILMASINDA
ÖZNİTELİK SEÇİMİ İÇİN METASEZGİSEL TABANLI HİBRİT BİR
YAKLAŞIM**

DOKTORA TEZİ

Mustafa ARPACIOĞLU

Danışman: Prof. Dr. Turgut ÖZSEVEN

TOKAT- 2025

ETİK SÖZLEŞME

Tokat Gaziosmanpaşa Üniversitesi Lisansüstü Eğitim Enstitüsü tez yazım kılavuzuna göre, Prof. Dr. Turgut ÖZSEVEN danışmanlığında hazırlamış olduğum “Konuşmaların Duygusal Sınıflandırılmasında Öznitelik Seçimi İçin Metasezgisel Tabanlı Hibrit Bir Yaklaşım” adlı Doktora tezinin bilimsel etik değerlere ve kurallara uygun, özgün bir çalışma olduğunu, aksinin tespit edilmesi halinde her türlü yasal yaptırımını kabul edeceğimi beyan ederim.

.../.../...

Mustafa ARPACIOĞLU

JÜRİ KABUL VE ONAY

Mustafa ARPACIOĞLU tarafından hazırlanan “**Konuşmaların Duygusal Sınıflandırılmasında Öznitelik Seçimi İçin Metasezgisel Tabanlı Hibrit Bir Yaklaşım**” adlı tez çalışmasının savunma sınavı 15/05/2025 tarihinde yapılmış olup aşağıda verilen Jüri tarafından Oy Birliği ile Tokat Gaziosmanpaşa Üniversitesi Lisansüstü Eğitim Enstitüsü (Bilgisayar Mühendisliği Anabilim Dalı)’nda Doktora Tezi olarak kabul edilmiştir.

Jüri Üyeleri (Unvanı, Adı Soyadı)

İmzası

Üye (Başkan):

Üye:

Üye:

Üye:

Üye:

ONAY

...../...../.....

Lisansüstü Eğitim Enstitüsü Müdürü

TEŞEKKÜR

Doktora eğitimim boyunca desteklerini esirgemeyen ve tez çalışmamın başından sonuna kadar yardımcı olan sayın hocam Prof. Dr. Turgut ÖZSEVEN'e çok teşekkür ederim. Aynı zamanda tez izleme süreci boyunca yardımcı olan hocalarım Doç. Dr. Bülent TURAN ve Dr. Öğrt. Üyesi Ebübekir YAŞAR'a teşekkür ederim.

Tez yazımı boyunca verdiği katkılardan dolayı öğretmen arkadaşım Dr. Erkan ERDEMİR'e teşekkür ederim.

Akademik çalışmalarımda beni destekleyen kıymetli eşim Gülşah ARPACIOĞLU'na, canım kızlarım Meleğim'e, Meyram'a, kardeşim Merve'ye bugünlere gelmemde emeği olan Annem ve Babam başta olmak üzere aileme sevgilerimi sunarım.

Mustafa ARPACIOĞLU

Tokat-2025

ÖZET

KONUŞMALARIN DUYGUSAL SINIFLANDIRILMASINDA ÖZNİTELİK SEÇİMİ İÇİN METASEZGİSEL TABANLI HİBRİT BİR YAKLAŞIM

Arpacıoğlu, Mustafa

Doktora, Bilgisayar Mühendisliği Anabilim Dalı

Tez Danışmanı: Prof. Dr. Turgut ÖZSEVEN

Mayıs 2025, xiv + 102 Sayfa

İnsanlık tarihi boyunca kişilerin birbirleri ile iletişim kurdukları araç konuşma olmuştur. İnsanlar konuşarak iletişim kurdukları gibi aynı zamanda karşısındaki kişilere duygularını da ifade edebilmektedir. Konuşma soluduğumuz havanın insan vücudundaki birtakım organlardan geçerek ses telleri vasıtasıyla çıkardığı sinyallerden oluşmaktadır. Çıkan bu sinyallerden aldığımız tını ile karşımızdaki kişinin duygu durumu hakkında tahminde bulunabiliriz. İnsan-Bilgisayar etkileşiminin yoğun olarak kullanıldığı günümüzde sesten duygu tanıma çalışmalarına da sıklıkla rastlanılmaktadır.

Günümüz teknolojisinin gelişmesinde canlılardan ilham alınan örnekleri sıklıkla görmekteyiz. Özellikle kullanılan araç ve gereçlerde, taşıtlarda hem tasarımsal olarak hem de çalışma prensibi açısından doğada bulunan canlılar taklit edilerek sistemler geliştirilmektedir. Yapay zekâ alanında ise canlıları taklit etme çalışması metasezgisel algoritmalar olarak karşımıza çıkmaktadır. Bu algoritmalar canlıların besin arama ve bulma davranışlarından esinlenerek geliştirilen algoritmalarlardır. Çalışmamızda literatürde kullanılan gri kurt optimizasyon ve salp sürü algoritmalarından esinlenerek hibrit bir metasezgisel yöntem önerilmiştir. Önerilen hibrit yöntem konuşmaların duygusal sınıflandırılması için kullanılmıştır. Bu amaç doğrultusunda literatürde sıklıkla kullanılan EmoDB, SAVEE, eNTERFACE ve EMOVA veri setleri kullanılarak önerilen yöntemin performansı analiz edilmiştir. Öncelikle bu veri setinde bulunan ses dosyaları veri ön işleme aşamasından geçmiş ve sonra OpenSmile yazılım ile öznitelik çıkarma işlemi gerçekleştirilmiştir. Elde edilen öznitelikler üzerinden gri kurt optimizasyon, salp sürü algoritmaları ve önerdiğimiz yöntem ile öznitelik seçim işlemi yapılmıştır. Daha sonra elde edilen öznitelikler SVM ve KNN sınıflandırıcılar kullanılarak duygu sınıflandırması yapılmıştır. Elde edilen sonuçlarda SVM sınıflandırıcısının KNN sınıflandırıcıya kıyasla daha iyi sonuçlar verdiği gözlemlenmiştir. KNN sınıflandırıcı ve önerdiğimiz yöntem ile en yüksek doğruluk oranı EmoDB veri setinde %91,92 olarak 586 öznitelik ile elde edilmiştir. Aynı veriseti üzerinde SVM sınıflandırıcı ve önerdiğimiz yöntem

137 öznitelik sayısı ile %98,14 doğruluk oranı sağlamıştır. Sonuç olarak önerilen hibrit yöntem gri kurt optimizasyon ve salp sürü algoritmalarından daha yüksek başarı sağlamıştır.

Anahtar Kelimeler: Hibrit Öznitelik Seçimi, Duygusal Sınıflandırma, Konuşma İşleme, Optimizasyon



ABSTRACT

A METAHEURISTIC-BASED HYBRID APPROACH FOR FEATURE SELECTION IN EMOTIONAL CLASSIFICATION FROM SPEECH

Arpacioğlu, Mustafa

PhD, Department of Computer Engineering

Advisor: Prof.Dr. Turgut ÖZSEVEN

May 2025, xiv + 102 Pages

Throughout human history, people have been communicating with each other through speech. People communicate by speaking and can also express their feelings to the person they are talking to. Speech consists of signals that the air we breathe passes through certain organs in the human body and emits through the vocal cords. We can guess the emotional state of the person we are talking to by the tone we receive from these signals. Today, when human-computer interaction is used intensively, studies on emotion recognition from voice are also frequently encountered.

In the development of today's technology, we often see examples inspired by living things. Especially in the tools and equipment used, systems are developed by imitating living things found in nature both in terms of design and operating principle. In the field of artificial intelligence, the study of imitating living things appears as metaheuristic algorithms. These algorithms are algorithms developed by being inspired by the food search and finding behaviors of living things. In our study, a hybrid metaheuristic algorithm (HGWSSO) design was carried out inspired by the GWO and SS algorithms used in the literature. The HGWSSO algorithm was used for emotional classification of speech in our study. For this purpose, EmoDB, SAVEE, eNTERFACE and EMOVA data sets, which are frequently used in the literature, were used. First, the audio files in this data set went through the data preprocessing stage and then the feature extraction process was performed with OpenSmile software. With the obtained features, feature selection process was performed with both GWO and SS algorithms based on our algorithm and HGWSSO algorithm. Then, with the obtained features, the accuracy of HGWSSO algorithm was tested using SVM and KNN classifiers. In the obtained results, it was observed that SVM classifier gave better results compared to KNN classifier. The highest accuracy rate with KNN classifier was obtained with HGWSSO algorithm with 586 features as

91.92% in EmoDB data set. In the results obtained with the SVM classifier, the HGWSSO algorithm achieved better results than other datasets with 137 features and 98.14% accuracy rate in the EmoDB dataset. As a result, it was seen that the HGWSSO algorithm we developed gave better results especially with the SVM classifier compared to the GWO and SS algorithms we took as basis.

Keywords: Grey Wolf Algorithm, Salp Swarm Algorithm, Metaheuristic Algorithm, Speech Emotion Recognition



ÇİZELGE LİSTESİ

Çizelge 3.1. Kullanılan veri setlerindeki duyguların sayısal dağılımı	16
Çizelge 3.2. Kullanılan özniteliklerin sayısal dağılımı	20
Çizelge 3.3. GWO algoritması kaba kod (Mirjalili vd., 2014).....	27
Çizelge 3.4. SSA algoritması kaba kod (Mirjalili vd., 2017)	29
Çizelge 3.5. Önerilen HGWSSO algoritma kaba kod	40
Çizelge 4.1. EmoDB veri setinde KNN sınıflandırıcı ile elde edilen metrik değerleri.....	45
Çizelge 4.2. EmoDB veri setinde SVM sınıflandırıcı ile elde edilen metrik değerleri.....	50
Çizelge 4.3. EMOVA veri setinde KNN sınıflandırıcı ile elde edilen metrik değerleri	56
Çizelge 4.4. EMOVA veri setinde SVM sınıflandırıcı ile elde edilen metrik değerleri	62
Çizelge 4.5. eINTERFACE veri setinde KNN sınıflandırıcı ile elde edilen metrik değerleri ...	68
Çizelge 4.6. eINTERFACE veri setinde SVM sınıflandırıcı ile elde edilen metrik değerleri ...	73
Çizelge 4.7. SAVEE veri setinde KNN sınıflandırıcı ile elde edilen metrik değerleri	79
Çizelge 4.8. SAVEE veri setinde SVM sınıflandırıcı ile elde edilen metrik değerleri	85
Çizelge 4.9. Literatürde yapılan çalışmaların karşılaştırılması.....	89
Çizelge 5.1. KNN sınıflandırıcı ile doğruluk oranları ve öznitelik sayılarının karşılaştırılması.....	91
Çizelge 5.2. SVM sınıflandırıcı ile doğruluk oranları ve öznitelik sayılarının karşılaştırılması.....	92

ŞEKİLLER LİSTESİ

Şekil 1.1. Sesi oluşumunda rol alan organlar	2
Şekil 3.1 Gri Kurtların sosyal hiyerarşisi	22
Şekil 3.2. 2D ve 3D konum vektörleri ve olası bir sonraki konumları.....	24
Şekil 3.3. GWO algoritmasında pozisyon güncellemesi	25
Şekil 3.4. Bir gri kurtun avına saldırma ve avını arama durumu	26
Şekil 3.5. Bireysel ve sürü salp görünümü	28
Şekil 3.6. İki boyutlu veri noktaları için ayırıcı bir hiper düzlem	31
Şekil 3.7. Sert ve yumuşak marj sınıflandırma	32
Şekil 3.8. C hiperparametresinin sınıflandırmaya etkisi	32
Şekil 3.9. K-en yakın komşu algoritması öklidyen mesafesi	33
Şekil 3.10. Önerilen sistem mimarisi	34
Şekil 3.11. Önerilen HGWSSO algoritma akış şeması	37
Şekil 4.1. EmoDB veri setinde KNN sınıflandırıcı ile elde edilen karışıklık matris değerleri	42
Şekil 4.2. EmoDB veri setinde KNN sınıflandırıcı ile elde edilen yakınsama eğrisi	44
Şekil 4.3. EmoDB veri setinde KNN sınıflandırıcısında öznitelik sayısı ve doğruluk oranı karşılaştırma.....	47
Şekil 4.4. EmoDB veri setinde SVM sınıflandırıcı ile elde edilen karışıklık matris değerleri	48
Şekil 4.5. EmoDB veri setinde SVM sınıflandırıcı ile elde edilen yakınsama eğrisi	49
Şekil 4.6. EmoDB veri setinde SVM sınıflandırıcısında öznitelik sayısı ve doğruluk oranı karşılaştırma.....	52
Şekil 4.7. EMOVA veri setinde KNN sınıflandırıcı ile elde edilen karışıklık matris değerleri	53
Şekil 4.8. EMOVA veri setinde KNN sınıflandırıcı ile elde edilen yakınsama eğrisi.....	55
Şekil 4.9. EMOVA veri setinde KNN sınıflandırıcısında öznitelik sayısı ve doğruluk oranı karşılaştırma.....	58
Şekil 4.10. EMOVA veri setinde SVM sınıflandırıcı ile elde edilen karışıklık matris değerleri.....	59
Şekil 4.11. EMOVA veri setinde SVM sınıflandırıcı ile elde edilen yakınsama eğrisi.....	61
Şekil 4.12. EMOVA veri setinde SVM sınıflandırıcısında öznitelik sayısı ve doğruluk oranı karşılaştırma	63
Şekil 4.13. eINTERFACE veri setinde KNN sınıflandırıcı ile elde edilen karışıklık matris değerleri.....	65
Şekil 4.14. eINTERFACE veri setinde KNN sınıflandırıcı ile elde edilen yakınsama eğrisi....	67
Şekil 4.15. eINTERFACE veri setinde KNN sınıflandırıcısında öznitelik sayısı ve doğruluk oranı karşılaştırma	69
Şekil 4.16. eINTERFACE veri setinde SVM sınıflandırıcı ile elde edilen karışıklık matris değerleri.....	70
Şekil 4.17. eINTERFACE veri setinde SVM sınıflandırıcı ile elde edilen yakınsama eğrisi....	72
Şekil 4.18. eINTERFACE veri setinde SVM sınıflandırıcısında öznitelik sayısı ve doğruluk oranı karşılaştırma	75
Şekil 4.19. SAVEE veri setinde KNN sınıflandırıcı ile elde edilen karışıklık matris değerleri	76

Şekil 4.20. SAVEE veri setinde KNN sınıflandırıcı ile elde edilen yakınsama eğrisi	78
Şekil 4.21. SAVEE veri setinde KNN sınıflandırıcısında öz nitelik sayısı ve doğruluk oranı karşılaştırma	81
Şekil 4.22. SAVEE veri setinde SVM sınıflandırıcı ile elde edilen karışıklık matris değerleri	82
Şekil 4.23. SAVEE veri setinde SVM sınıflandırıcı ile elde edilen yakınsama eğrisi	84
Şekil 4.24. SAVEE veri setinde SVM sınıflandırıcısında öz nitelik sayısı ve doğruluk oranı karşılaştırma.....	86



KISALTMALAR

ALO: Karınca Aslan Optimizasyon Algoritması
BAT: Yarasa Algoritması
CNN: Konvolüsyonel Sinir Ağı
CSA: Guguk Arama (Cuckoo Search) Algoritması
EmoDB : Berlin Duygusal Konuşma Veri Seti
EMOVA: Duygusal konuşma örnekleri içeren veri seti
eNTERFACE: Ses ve görüntü gibi çok modlu duygu tanıma veri seti
FA: Ateşböceği Algoritması
FF: Meyve Sinekleri Optimizasyon Algoritması
FS: Öznitelik Seçimi
GA: Genetik Algoritma
GMM: Gauss Karışım Modeli
GOA: Çekirge Optimizasyon Algoritması
GWO: Gri Kurt Optimizasyon Algoritması
HGWSSO: Hibrit Gri Kurt Salp Sürü Optimi
HMM: Gizli Markov modeli
KNN: K-en Yakın Komşular
LPC: Doğrusal Tahmin Katsayıları
LPCC: Doğrusal Tahmin Cepstrum Katsayıları
MFCC: Mel-Frekans Cepstrum Katsayıları
MLC: Maksimum Olasılık Bayes sınıflandırıcısı
MVO: Çoklu Evren Optimizatörü
NN: Sinir Ağları
PSO: Parçacık Sürü Optimizasyon Algoritması
RAVDESS: Ryerson Sesli ve Görüntülü Duygusal Konuşma ve Şarkı Veri Seti
SAVEE: Surrey Sesli ve Görüntülü Duygusal İfade Veri Seti
SER: Konuşma Duygu Tanıma
SSA: Salp Sürü Algoritması
SVM: Destek Vektör Makineleri
WOA: Balina Optimizasyon Algoritması

İÇİNDEKİLER

ETİK SÖZLEŞME	ii
JÜRİ KABUL VE ONAY	iii
TEŞEKKÜR	iv
ÖZET.	v
ABSTRACT	vii
ÇİZELGE LİSTESİ.....	ix
ŞEKİLLER LİSTESİ.....	x
KISALTMALAR.....	xii
1. GİRİŞ.....	1
2. LİTERATÜR ÖZETLERİ	5
3. MATERYAL VE YÖNTEM.....	16
3.1. Veri Setleri.....	16
3.1.1. EmoDB veri seti	16
3.1.2. SAVEE veri seti	16
3.1.3. EMOVA veri seti	17
3.1.4. eNTERFACE veri seti.....	17
3.2. Sesin Öz nitelikleri.....	17
3.2.1. Prozodik Öz nitelikler	18
3.2.2. Spektral Öz nitelikler	18
3.3. Öz nitelik Çıkartılması	19
3.4. Metasezgisel Algoritmalar	20
3.5. Gri Kurt Algoritması	22
3.6. Salp Sürü Algoritması	27
3.7. Sınıflandırıcılar	30
3.7.1. Destek vektör makineleri (SVM)	30
3.7.2. K-en yakın komşu (KNN).....	33
3.8. Sistem Mimarisi	33
3.9. Önerilen Algoritma (HGWSSO Algoritması).....	35
3.9.1. Parametrelerin Tanımlanması ve Başlangıç Pozisyonu:	37
3.9.2. Lider Salp Güncellemesi:	38
3.9.3. Uzaklık Hesaplamaları (HGWSSO):	38
3.9.4. Yeni Pozisyon Güncellemeleri:.....	39
3.9.5. Keşif ve Sömürü Dengesi:	39


3.9.6. Fitness Değerlendirmesi ve Lider Güncellemesi:	40
3.9.7. Sınır Kontrolü ve Binarizasyon:.....	40
3.9.8. Sonuçların Elde Edilmesi:.....	40
4. BULGULAR VE TARTIŞMA	42
4.1. EmoDB Veri Setine Ait Sonuçlar	42
4.1.1. KNN sınıflandırıcı sonuçları	42
4.1.2. SVM sınıflandırıcı sonuçları	48
4.2. EMOVA Veri Setine Ait Sonuçlar	52
4.2.1. KNN sınıflandırıcı sonuçları	53
4.2.2. SVM sınıflandırıcı sonuçları	59
4.3. eINTERFACE Veri Setine Ait Sonuçlar	64
4.3.1. KNN sınıflandırıcı sonuçları	65
4.3.2. SVM sınıflandırıcı sonuçları	70
4.4. SAVEE Veri Setine Ait Sonuçlar	76
4.4.1. KNN sınıflandırıcı sonuçları	76
4.4.2. SVM sınıflandırıcı sonuçları	82
4.5. Tartışma.....	87
5. SONUÇ VE ÖNERİLER.....	91
5.1. Sonuçlar	91
5.1.1. KNN Sınıflandırıcı Performansı.....	92
5.1.2. SVM Sınıflandırıcı Performansı.....	93
5.2. Öneriler	93
6. KAYNAKLAR.....	95
ÖZGEÇMİŞ	102

1. GİRİŞ

Ses, gaz, sıvı veya katı ortamlarda oluşan mekanik bir titreşimdir ve algılanabilmesi için bir iletim ortamına, enerjiye ve algılayıcı bir sisteme (kulak gibi) ihtiyaç duyar. Bu titreşim, moleküllerin birbirine çarpmasıyla yayılır; bu nedenle ses havasız bir ortamda iletilemez. Sesin yayılma hızı ve kalitesi, ortamın sıcaklığı, yoğunluğu ve nem oranı gibi fiziksel koşullardan doğrudan etkilenir. Örneğin, bir akort çatalının parmaklar arasında zayıf ses üretmesi, titreşimin etkili şekilde yayılmamasından kaynaklanırken, ahşap veya metal yüzeylere temas ettirildiğinde rezonans artar ve daha net bir ses elde edilir (Ergenç & Güner, t.y.).

Sesin fiziksel özellikleri genellikle üç temel öznitelik ile tanımlanır: yoğunluk, frekans ve tını. Sesin yoğunluğu, enerjisi ve dalga biçimiyle ilişkilidir ve desibel (dB) cinsinden ölçülür. İnsan kulağı yaklaşık olarak 0-140 dB aralığındaki sesleri algılayabilir. Frekans ise ses kaynağının saniyedeki titreşim sayısını ifade eder ve insanların en iyi duyabildiği frekans aralığı genellikle 1000–3000 Hz arasında yer alır (Demircan, 2020).

Anatomik olarak bakıldığında ses, akciğerlerden başlayan ve ağız ile burun boşluğuna kadar uzanan solunum ve ses üretim yapılarının koordineli çalışmasıyla ortaya çıkar. Gırtlak (larenks) düzeyinde yer alan ses telleri, akciğerlerden gelen basınçlı havanın etkisiyle titreşerek sesi oluşturur. Bu süreçte fonasyon, rezonans ve artikülasyon olmak üzere üç temel aşama söz konusudur: fonasyon, sesin temel oluşumunu sağlarken; rezonans, sesi uzatır ve güçlendirir; artikülasyon ise dil, dudak ve damak gibi yapılar aracılığıyla sesi konuşmaya dönüştürür (Eray, 2008). Gerçeker ve ark. (2000)'nın da vurguladığı üzere, konuşma yalnızca mekanik bir süreç değil, aynı zamanda sinir sistemi, kaslar ve duyuşal girdilerin etkileşiminden doğan çok boyutlu nöromüsküler bir işlemdir. Beyindeki Wernicke ve Broca alanları başta olmak üzere birçok merkez bu sürece katılır ve düşüncelerin konuşma aracılığıyla dışa vurulmasına olanak tanır (Gerçeker vd., 2000). Şekil 1.1.'de sesin oluşumunda rol oynayan organlar gösterilmektedir.



Şekil 1.1. Sesin oluşumunda rol alan organlar(Anonim, 2024)

Bu fizyolojik ve bilişsel altyapı, özellikle SER (Konuşmadan Duygu Tanıma) için önemli bir temel oluşturur. İnsanlar duygularını ifade ederken yalnızca sözlü içerikleri değil, aynı zamanda ses tonu, ritim ve vurgu gibi özellikleri de kullanır. Bu nedenle konuşma sinyalleri, bireyin yaş, cinsiyet, köken ve duygusal durumuna ilişkin ipuçları içerir. SER sistemleri, bu sinyalleri analiz ederek konuşmacının duygusal durumunu otomatik olarak belirlemeye çalışır. Bu tür sistemler, çağrı merkezlerinde müşteri duygularını tespit etmekten, psikiyatrik durumların değerlendirilmesine ve nörolojik hastalıkların (örneğin Parkinson, Alzheimer) erken teşhisine kadar geniş bir uygulama yelpazesinde kullanılmaktadır (Aina vd., 2024; Bojanić vd., 2020; Albadr vd., 2022).

Bu alandaki gelişmeler, çeşitli konuşma veri setlerinin oluşturulmasını da beraberinde getirmiştir. Berlin (BDES), Danimarka (DES), İspanyol (SES) ve Mandarin (MASC) duygusal konuşma veri setleri bu anlamda öncü örneklerdir (Burkhardt vd., 2005; Ververidis vd., 2004; Sánchez-Gutiérrez vd., 2014; Tsang-Long Pao vd., 2006). Bu veri setleri, perde frekansı, formant yapısı, enerji, MFCC gibi çeşitli özniteliklerin çıkarılması ve analiz edilmesi için kullanılmaktadır. Bu öznitelikler, Sinir Ağları (NN), Gauss Karışım Modeli (GMM), Gizli Markov modeli (HMM), Maksimum Olasılık Bayes sınıflandırıcısı (MLC), Çekirdek Regresyonu ve K-en Yakın Komşular (KNN) ve Destek vektör makineleri (SVM) gibi makine öğrenimi yöntemleriyle sınıflandırılmakta ve yüksek doğrulukta sonuçlar elde edilmeye çalışılmaktadır (P. Shen vd., 2011).

Ancak yüksek boyutlu veri setleriyle çalışmak, bazı zorlukları da beraberinde getirmiştir. Özellikle çok sayıda öznitelik, sistemin işlem süresini artırmakta, bellek kullanımını zorlamakta ve bazı durumlarda model doğruluğunu olumsuz etkileyebilmektedir. Bu sorunları aşmak amacıyla öznitelik seçimi, büyük veri kümelerinin sadeleştirilmesi ve daha verimli modellerin oluşturulması açısından kritik bir ön işleme aşaması olarak öne çıkmaktadır. Son yıllarda bu amaçla evrimsel algoritmalar kullanılarak, gereksiz öznitelikler elenmekte ve model performansı artırılmaktadır. Ancak bu algoritmaların, özellikle sarmallayıcı temelli yaklaşımlarda yüksek hesaplama maliyetine sahip olduğu da bilinmektedir (C. Shen & Zhang, 2022).

Öznitelik seçimi temelde iki hedefi barındırır: mümkün olduğunca az sayıda ama etkili öznitelik seçmek ve sınıflandırma doğruluğunu maksimize etmek. Buna rağmen bazı yöntemler bu süreci yalnızca doğruluk odaklı tek amaçlı optimizasyon problemi olarak ele almakta ve verimliliği sınırlandırmaktadır (Al-Tashi vd., 2020). Oysa çok amaçlı optimizasyon stratejileri, hem model sadeliği hem de başarı oranı açısından daha dengeli sonuçlar sunmaktadır (Abdel-Basset vd., 2020).

Veri madenciliği ve makine öğrenimi uygulamalarının giderek yaygınlaştığı günümüzde, büyük veri kümelerinin artan hacmi; hesaplama süresi, bellek kullanımı ve doğruluk performansı açısından yeni zorluklar doğurmaktadır. Gürültülü ve alakasız öznitelikler, sınıflandırma doğruluğunu düşürmekte, işlem sürelerini uzatmakta ve sistem performansını etkilemektedir. Bu noktada öznitelik seçimi, sadece verimliliği değil, aynı zamanda uzman sistemlerin güvenilirliğini de artırmak adına kritik rol üstlenmektedir (Tubishat vd., 2020). Bununla birlikte, birden fazla öznitelik çıkarma tekniğinin bir arada kullanıldığı hibrit sistemlerde, öznitelik boyutunun aşırı artması, sistem tepkisinin yavaşlaması ve kaynak tüketiminin yükselmesi gibi ek problemler de doğurabilmektedir (Panigrahi & Palo, 2021).

İnsanlar iletişim kurmak ve duyguları iletmek için yüz ifadeleri, jestler, konuşmalar ve beden dilini kullanır. İnsanlar, güçlü bir duygu tanıma sistemi kullanılarak analiz edilebilen konuşma sinyalleri aracılığıyla konuşmacıların duygularını anlayabilir. Bu sistem, dil bilgisi, yaş, köken, cinsiyet ve duygusal durumlar dahil olmak üzere konuşmacının duygusal durumunu otomatik olarak belirler. Bunun insan-bilgisayar etkileşimi için önemli etkileri vardır. SER Sistemleri, çağrı merkezlerinde arayanların duygularını algılama, ruhsal bozuklukları teşhis etme ve Parkinson ve Alzheimer hastalıklarını tespit etme gibi duyguları analiz etmek ve tespit etmek

için gerçek zamanlı uygulamalarda(Aina vd., 2024; Bojanić vd., 2020) kullanılmıştır. SER sistemleri ayrıca eğitim, öğrenme, yalan tespiti, oyunlar ve eğlence uygulamalarında da kullanılır (Albadr vd., 2022).

Son araştırmalar, konuşma bilgilerini kullanarak insan duygusunu tanımaya odaklanmıştır. Tayvan'daki Tsinghua Üniversitesi'nden BDES (Berlin Duygusal Konuşma Veri Seti)(Burkhardt vd., 2005), DES (Danimarka Duygusal Konuşması)(Ververidis vd., 2004), SES (İspanyol Duygusal Konuşması)(Sánchez-Gutiérrez vd., 2014) ve MASC (Mandarin Duygusal Konuşması)(Tsang-Long Pao vd., 2006) dahil olmak üzere çok sayıda konuşma veri seti oluşturulmuştur. Araştırmacılar, enerji, perde frekansı(Ververidis vd., 2004), formant frekansı(Zhongzhe Xiao vd., 2005), Doğrusal Tahmin Katsayıları (LPC), Doğrusal Tahmin

Bu tezin konusu konuşmaların duygusal sınıflandırılmasında öznitelik seçimi için metasezgisel tabanlı yeni hibrit bir yaklaşım geliştirmektir. Literatürde konuşmaların duygusal sınıflandırılmasına yönelik meta sezgisel algoritmaların kullanıldığı çalışmaların çok fazla olmaması ana motivasyon kaynağımız olmuştur. Bu tezin amacı GWO algoritması ile SSA algoritması kullanılarak yeni bir hibrit algoritma geliştirerek konuşmaların duygusal sınıflandırmasında öznitelik seçimi yaparak sınıflandırma doğruluğunu artırmaktır. Yapılan çalışma sayesinde literatüre hem yeni bir hibrit algoritma kazandırılmış olacak hem de konuşmaların duygusal sınıflandırılması için farklı bir yaklaşım sergilenecektir.

Bu çalışmada literatürde sıkça kullanılan EmoDB, EMOVA, eINTERFACE ve SAVEE veri setlerinden yararlanılmış, sınıflandırıcı olarak SVM ve KNN kullanılmıştır.

Birinci bölümde, genel bilgiler verildikten sonra tezin konusu ve tezin amacına değinilmiştir. İkinci bölümde, literatürde tezin konusu ve amacı ile ilgili benzer çalışmalar hakkında bilgilendirme yapılmıştır. Üçüncü bölümde; Sesin öznitelikleri, GWO Algoritması, SSA Algoritması, Hibrit Algoritma ve Sınıflandırıcılar hakkında bilgi verilmiştir. Dördüncü bölümde; Her bir veri seti için KNN ve SVM sınıflandırıcılar ile elde edilen karışıklık matrisi tabloları, yakınsama eğrileri, öznitelik sayıları ve doğruluk oranları yer almaktadır. Beşinci bölümde, dördüncü bölümün değerlendirmesi ve yazarın sonraki çalışmalara ilişkin önerileri yer almaktadır.

2. LİTERATÜR ÖZETLERİ

İkili Gri Kurt Optimizasyonu (bGWO) ile ilgili çalışmalar incelendiğinde, Emary vd. (2016), El-Kenawy vd. (2020), Al-Tashi vd. (2020) ve Shen ve Zhang (2022) tarafından yapılan araştırmalarda, UCI Makine Öğrenmesi veri setleri üzerinde öznitelik seçimi gerçekleştirilmiştir. Bu çalışmaların ortak bulgusu, bGWO'nun geleneksel Parçacık Sürü Optimizasyonu (PSO) ve Genetik Algoritma (GA) gibi yöntemlerden daha iyi performans gösterdiği olmuştur. Özellikle Al-Tashi vd. (2020) tarafından yapılan deneylerde, 15 UCI veri setinde %84,2 doğruluk oranı elde edilmiş ve en iyi sonuç Destek Vektör Makineleri (SVM) ile alınmıştır. El-Kenawy vd. (2020) ise, Stokastik Fraktal Arama (SFA) ile hibrit hale getirdiği MbGWO-SFA algoritmasıyla %81.3 doğruluk ve %38.5 seçilen öznitelik oranı sağlamıştır. Emary vd. (2016), bGWO'nun 18 UCI veri setinde %79.7 doğruluk sağladığını ve özellikle Naive Bayes sınıflandırıcısı ile daha başarılı sonuçlar elde ettiğini belirtmiştir.

Salp Sürüsü Algoritması (SSA) ile ilgili çalışmalarda, Faris vd. (2018), Ibrahim vd. (2019), Neggaz vd. (2020), Tubishat vd. (2020), Aljarah vd., (2020), ve Shekhawat vd. (2021) tarafından yapılan araştırmalarda UCI Makine Öğrenmesi veri setlerinde farklı SSA versiyonları test edilmiştir. Faris vd. (2018), SSA'nın ikili versiyonunu kullanarak 22 UCI veri setinde %90 doğruluk oranına ulaştıklarını ve en iyi sonucu SVM ile elde ettiklerini belirtmiştir. Ibrahim vd. (2019), SSA ile PSO'yu birleştirerek 15 UCI veri setinde doğruluk oranını %87.5'e çıkarmış, en iyi sonucu Yapay Sinir Ağları (ANN) ile elde etmiştir. Neggaz vd. (2020), SSA'yı Sinüs-Kosinüs Algoritması (SCA) ile hibrit hale getirerek 20 UCI veri setinde doğruluk oranını %85.9'a kadar yükseltmiş ve Rastgele Orman (RF) sınıflandırıcısında en yüksek başarıyı sağlamıştır. Tubishat vd. (2020), geliştirdikleri SSA algoritması ile Genetik Algoritma, Parçacık Sürü Optimizasyonu, Çekirge Optimizasyon Algoritması ve Karınca Aslanı Optimize Edici gibi iyi bilinen dört optimizasyon algoritmasıyla karşılaştırmışlardır. Aljarah vd., (2020), bilinen Salp Sürü Algoritmasına iki yeni iyileştirme yaparak Dinamik Salp Sürü Algoritması geliştirmişlerdir. Önerilen DSSA, KNN sınıflandırıcısı ile UCI deposunda bulunan 20 veri setinde test edilmiştir. Elde edilen sonuçlara göre DSSA, sınıflandırma doğruluğu, uygunluk fonksiyonu değerleri, seçilen öznitelik sayısı ve yakınsama hızı açısından 23 veri seti üzerinde orijinal SSA ve diğer iyi bilinen optimizasyon algoritmalarından daha iyi performans gösterdiğini belirtmişlerdir.

Hibrit Gri Kurt Optimizasyonu (HGWO) kullanılan çalışmalarda, Arora vd. (2019), Abdel-Basset vd. (2020), Li ve Chen (2021), Al-Wajih vd. (2021) ve Shen ve Zhang (2022) tarafından yapılan araştırmalarda, GWO'nun diğer optimizasyon algoritmalarıyla birleştirilerek daha güçlü sonuçlar verdiği gösterilmiştir. Abdel-Basset vd. (2020), iki aşamalı mutasyonla güçlendirilmiş HGWO algoritmasını 35 UCI veri seti üzerinde test etmiş ve %92.1 doğruluk oranı elde etmiştir. Arora vd. (2019), GWO ile Karga Arama Algoritmasını (CSA) birleştirerek SVM sınıflandırıcı ile GA ve PSO'dan %5-8 daha yüksek doğruluk elde etmişlerdir. Shen ve Zhang (2022) tarafından yapılan çalışmada, hibrit GWO'nun tıbbi veri setlerinde test edilerek Derin Sinir Ağları (DNN) ile %86.9 doğruluk oranı sağladığı belirtilmiştir.

Liu vd. (2018), öznitelik seçimini optimize etmek ve sınıflandırma doğruluğunu artırmak amacıyla Korelasyon Analizi ve Fisher kriteri ile öznitelik seçimi yapılmasını ve ardından Aşırı Öğrenme Makinesi (Extreme Learning Machine - ELM) tabanlı bir karar ağacı (Decision Tree) kullanılmasını önermektedir. Önerilen yöntemde, ilk olarak öznitelik çıkarımı süreci gerçekleştirilmiştir. Çin Bilimler Akademisi Otomasyon Enstitüsü (CASIA) konuşma veri seti kullanılmış ve mel frekans kepsral katsayıları (MFCC), spektral öznitelikler, temel frekans (F0) ve enerji öznitelikleri gibi çeşitli akustik öznitelikler çıkarılmıştır. Seçilen öznitelikler, ELM tabanlı bir karar ağacına beslenerek duygu sınıflandırması gerçekleştirilmiştir. ELM, tek gizli katmanlı ileri beslemeli bir sinir ağı olup, eğitim sürecinde ağırlıkları rastgele belirleyip doğrudan bir çözüm matrisi oluşturarak öğrenme sürecini hızlandırmaktadır. Deneysel sonuçlar, önerilen Korelasyon Analizi + Fisher + ELM modelinin ortalama %89.6 doğruluk oranına ulaştığını göstermektedir (Liu vd., 2018).

Tu ve ark., (2019), farklı optimizasyon problemlerinin çözümü için GWO algoritmasının tek arama yönteminin sınırlarını farklı bir yöntemle çözmek için MEGWO(Multi-strategy ensemble grey wolf optimizer) algoritması geliştirmişlerdir. Önerilen yöntem çözümleri güncellemek için, geliştirilmiş küresel en iyi liderlik stratejisi, uyarlanabilir işbirlikçi avlanma stratejisi ve dağınık yiyecek arama stratejisi olmak üzere üç ana temel bileşenden oluşmaktadır. Önerilen algoritmanın deneysel performansı IEEE CEC2014 test seti ve 18 test fonksiyonu üzerinde gerçekleştirilmiştir. Ayrıca MEGWO'nun gerçek dünya problemlerini çözme becerileri araştırmak için öznitelik seçimi kullanılmıştır. Elde edilen sonuçlar, orijinal GWO üzerinde yapılan değişikliklerin yakınsama hızını, arama verimliliğini ve hesaplama hassasiyetini arttırdığını göstermiştir. (Tu vd., 2019).

Özseven (2019), konuşma duygu tanıma (Speech Emotion Recognition - SER) alanında daha yüksek doğruluk elde etmek ve iş yükünü azaltmak amacıyla yeni bir öznitelik seçimi yöntemi önermiştir. Önerilen yöntem, duygusal durumların akustik özniteliklerdeki değişimlerine dayalı olarak geliştirilmiştir. Çalışma kapsamında, dört farklı veri kümesi (EmoDB, eNTERFACE'05, EMOVO, SAVEE) ve üç sınıflandırıcı (SVM, MLP, KNN) kullanılarak yöntemin performansı değerlendirilmiştir. Önerilen yöntemin etkinliği, PCA, SFS ve FCBF gibi yaygın kullanılan yöntemlerle karşılaştırılmıştır. Deneysel sonuçlar, önerilen yöntemin başarıyla sınıflandırma doğruluğunu artırdığını ve iş yükünü azalttığını göstermiştir. Örneğin, EmoDB veri setinde sınıflandırma doğruluğu %84.62'den %85.71'e yükselmiştir. Ayrıca, başlangıçta 1582 öznitelik içeren veri seti, önerilen yöntemle %75 ile %98.6 arasında bir oranda azaltılarak iş yükü önemli ölçüde hafifletilmiştir. Önerilen yöntem, sınıflandırma başarısını artırırken iş yükünü artırmadan öznitelik boyutunu küçülmüş ve toplam işlem süresini etkili bir şekilde optimize etmiştir (Özseven, 2019).

Dey vd., (2020), araştırmalarında, SER için daha uygun maliyetli hesaplama modeli sağlamak amacıyla, Oran tabanlı Denge Optimizasyonu (GREO) algoritması adında, Altın Oran Optimizasyonu (GRO) ve Denge Optimizasyonu (EO) algoritmalarının hibrit modelini kullanan bir meta-sezgisel öznitelik seçimi yöntemi önermişlerdir. Modelin en uygun şekilde seçilmiş öznitelikleri, Doğrusal Tahminli Kodlama (LPC) ve Doğrusal Tahmin Cepstral Katsayıları (LPCC) tabanlı öznitelikleri kullanan XGBoost sınıflandırıcısına beslenmiştir. Geliştirilen model ile, iki standart veri kümesi olan SAVEE ve EmoDB üzerinde sırasıyla %97.31 ve %98.46 tanıma doğruluğuna ulaşılmıştır. (Dey vd., 2020).

Daneshfar ve Kabudian (2020), çalışmalarında SER için ayrıştırıcı boyut indirgeme (discriminative dimension reduction) tekniklerini kullanarak model performansını artırmayı amaçlamaktadırlar. Özellikle, Modifiye Edilmiş Kuantum Davranışlı Parçacık Sürü Optimizasyonu (Modified Quantum-Behaved Particle Swarm Optimization - pQPSO) algoritmasını kullanarak boyut indirgeme ve Gaussian Karışım Modeli (GMM) sınıflandırıcı parametrelerinin aynı anda optimize edilmesi önerilmektedir. Çalışmalarını, EmoDB, SAVEE ve IEMOCAP veri setleri üzerinde gerçekleştirilmiştir. Deneysel sonuçlarda EmoDB için %82.82, SAVEE için %60.79 ve IEMOCAP için %74.80 doğruluk oranları elde edilmiştir (Daneshfar & Kabudian, 2020).

Kanwal & Asghar, (2021), arařtırmalarında kümeleme tabanlı genetik algoritma kullanan bir öznitelik optimizasyon algoritması önermişlerdir. Uyguladıkları metotta yeni neslin rastgele seçilmesi yerine, bir sonraki neslin parçası olmak amacıyla aykırı değerlerin tespit edilmesi için uygunluk değerlendirme düzeyinde kümeleme işlemi uygulamışlardır. Çalışmalarını EmoDB, RAVDESS ve SAVEE veri setlerinde standart Genetik Algoritma ile karşılaştırarak test etmişlerdir. Konuşmacıdan bağımsız deneyleri MATLAB üzerinde SVM sınıflandırıcı ile yapmış ve EmoDB'de %77.5, RAVDESS'te %76.2 ve SAVEE'de %69.8 doğruluk oranı elde etmişlerdir. (Kanwal & Asghar, 2021).

Rajeshwar (2021) tarafından gerçekleştirilen çalışmada, SER sistemlerinde doğruluğu artırmak amacıyla Hibrit PSO ve Kütleçekimsel Arama Algoritması (Gravitational Search Algorithm - GSA) ile optimize edilmiş Derin İnanç Ağı (Deep Belief Network - DBN) modelini önermektedir. Çalışmanın temel amacı, SER sistemlerinde yalnızca duygu tanıma değil, aynı zamanda cinsiyet tanıma da yaparak modelin genelleme yeteneğini artırmaktır. Önerilen model, EmoDB ve genişletilmiş bir İngilizce veri seti üzerinde test edilmiştir. Öznitelik çıkarımı aşamasında, Pitch, MFCC ve Negatif Matris Çarpanlaması (Non-Negative Matrix Factorization - NMF) öznitelikleri kullanılmıştır. Öznitelik boyutunu düşürmek amacıyla Ana Bileşen Analizi (Principal Component Analysis-PCA) uygulanmıştır. Seçilen öznitelikler, DBN sınıflandırıcısına giriş olarak verilmiş ve DBN'in ağırlıkları PSO-GSA algoritması ile optimize edilmiştir. Deneysel sonuçlar, önerilen PSO-GSA tabanlı DBN modelinin, geleneksel optimizasyon yöntemlerine kıyasla daha yüksek doğruluk oranları sunduğunu göstermektedir. EmoDB veri setinde %96.7 doğruluk oranı elde edilmiştir, bu da Genetik Algoritma (GA), Standart PSO, Ateş Böceği Algoritması (Firefly - FF) ve Balina Optimizasyonu Algoritması (WOA) ile karşılaştırıldığında %13 ila %20 arasında daha iyi bir performans sağladığını ortaya koyduğunu belirtmişlerdir (J Rajeshwar, 2021).

Yıldırım vd. (2021) yaptıkları çalışmada, SER sistemlerinde öznitelik seçimini optimize etmek için iki farklı meta-sezgisel algoritma olan NSGA-II (Non-dominated Sorting Genetic Algorithm-II) ve Cuckoo Search (CS) yöntemlerini karşılaştırmalı olarak ele almışlardır. Geleneksel meta-sezgisel optimizasyon algoritmalarında başlangıç popülasyonu rastgele oluşturulurken, bu çalışmada ReliefF yöntemi kullanılarak başlangıç popülasyonunun daha optimize edilmesi sağlanmıştır. Çalışmada, EmoDB ve Interactive Emotional Dyadic Motion Capture (IEMOCAP) veri setleri kullanılmıştır. Öznitelik seçim süreci, NSGA-II ve CS algoritmalarıyla gerçekleştirilmiş ve ardından SVM, KNN ve Bagged Decision Trees

sınıflandırıcıları ile model doğruluk oranları hesaplanmıştır. Deneyler, konuşmacıya bağımlı (speaker-dependent) ve konuşmacıya bağımsız (speaker-independent) senaryolarda gerçekleştirilmiştir. Deneysel sonuçlar, önerilen M-Cuckoo Search (Modifiye Edilmiş Cuckoo Search) yönteminin, hem EMO-DB hem de IEMOCAP veri setlerinde en iyi sınıflandırma sonuçlarını sağladığını göstermektedir. Konuşmacıya bağımlı senaryoda EmoDB veri setinde %87.66, IEMOCAP veri setinde %69.30 doğruluk oranı elde edilirken, konuşmacıya bağımsız senaryoda EmoDB veri setinde %76.82, IEMOCAP veri setinde %59.52 doğruluk oranına ulaşılmıştır (Yildirim vd., 2021).

Huang vd., (2021) çalışmalarında, üç katman içeren çok katmanlı bir hibrit bulanık destek vektör makinesi (MLHF-SVM) modeli önermişlerdir. Bu katmanlar öznitelik çıkarma katmanı, ön sınıflandırma katmanı ve sınıflandırma katmanından oluşmaktadır. Model, insan ve çok katmanlı SVM sınıflandırıcılarına dayanan bulanık c-ortalamlarını (FCM) ve optimizasyon için geliştirilmiş bir doğal üstel atalet ağırlıklı parçacık sürüsü optimizasyonu (IEPSO) algoritmasını kullanır. Öznitelik çıkarma katmanı, doğruluğu artırmak için kişiselleştirilmemiş ve kişiselleştirilmiş öznitelikleri birleştirir. Modelin etkinliği, üç popüler veri kümesindeki tüm duyguların simüle edilmesiyle doğrulanmıştır. Sonuçlar, modelin, EmoDB veri kümesinde maksimum %97.67 değerle sınıflandırmanın başarı oranını etkili bir şekilde artırabildiğini göstermiştir (Huang vd., 2021).

Al Dujaili vd. (2021), tarafından yapılan çalışmada, SER için SVM ve KNN algoritmalarını birleştirerek daha yüksek doğruluk oranları elde etmeyi amaçlamaktadır. Öznitelik çıkarımı aşamasında, iki farklı öznitelik grubu incelenmiştir. İlk grup, temel frekans (F0), enerji (E) ve sıfır geçiş oranı (Zero-Crossing Rate - ZCR) (FEZ) bileşenlerinden oluşmaktadır. İkinci grup ise Fourier parametreleri (FP) modeline dayalıdır. FEZ öznitelikleri, konuşmanın tonlama ve ritmik yapısını temsil ederken, FP analizi sinyalin frekans bileşenlerine ayrılmasını sağlamaktadır. Sınıflandırma aşamasında, SVM ve KNN algoritmaları birlikte kullanılmış ve sınıflandırma kararlarının iyileştirilmesi için çoğunluk oylama kuralı (Majority Voting Rule - MVR) uygulanmıştır. Bu yöntem ile her sınıflandırıcının verdiği kararları birleştirerek en doğru sınıflandırmayı yapmayı hedeflemişlerdir. Deneyler sonucunda, SVM ile EmoDB veri seti üzerinde FEZ öznitelikleri kullanıldığında %85.1 doğruluk oranı elde edilmiştir. Öte yandan, KNN ile FP+FEZ özniteliklerinin birleşimi kullanıldığında %87.85 doğruluk oranına ulaşılmıştır. İngilizce veri setinde en yüksek doğruluk oranı, SVM ile %85.2 ve KNN ile %90.83 olarak hesaplanmıştır (Al Dujaili vd., 2021).

Bagadi ve Sivappagari, (2022), çalışmalarında konuşma ile duygu tanımda doğruluğu artırmak ve hesaplama maliyetlerini düşürmek için CSEO adını verdikleri equilibrium optimization ve cuckoo search algoritmalarının hibrit modelini geliştirmişlerdir. Çalışmalarının performansını EmoDB ve RAVDESS veri setlerinde test etmişler ve sırasıyla %94.35 ve %96.78 yüksek düzeyde duygu tanıma oranlarına ulaştıklarını belirtmişlerdir (Bagadi & Sivappagari, 2022).

Abdelhamid vd., (2022), konuşma ile duygu tanıma için çalışmalarında LSTM katmanından oluşan CNN ağı geliştirmişlerdir. Çalışmalarında konuşma ile duygu tanıma için mevcut yaklaşımların derin öğrenme modeli oluştururken eğitim için büyük bir veri kümesinin olmamasından ve bu olumsuzluğu veri artırma algoritması ile aşabileceklerini belirtmişlerdir. Ayrıca hiperparametrelerinde optimize edildiği bir derin öğrenme modeli geliştirmişlerdir. Bu derin ağın performansını artırmak için, öğrenme hızı ve etiket yumuşatma düzenleme faktörü, stokastik fraktal arama (SFS) kılavuzlu balina optimizasyon algoritması (WOA) kullanılarak optimize etmişlerdir. Önerilen yaklaşımın etkinliğini kanıtlamak için, yürütülen deneylere IEMOCAP, EmoDB, RAVDESS ve SAVEE olmak üzere dört konuşma duygu veri seti dahil edilmişlerdir. Dört veri kümesine dayanarak elde edilen tanıma doğrulukları sırasıyla %98.13, %99.76, %99.47 ve %99.50'dir. (Abdelhamid vd., 2022).

Marik vd. (2023) yaptıkları çalışmada, derin öğrenme tabanlı bir hibrit öznitelik seçme (Hybrid Deep Feature Selection - HDFS) çerçevesi geliştirmişlerdir. Çalışmanın temel amacı, otomatik özellik mühendisliği ve derin öğrenmeyi birleştirerek yüksek doğruluk ve hesaplama verimliliği sağlayan bir SER modeli oluşturmaktır. Bunun için, öznitelik çıkarımı aşamasında Wide-ResNet-50-2 modeli kullanılarak mel-spektrogramlardan öznitelikler çıkarılmış ve ardından öznitelik seçimi için bulanık entropi tabanlı sıralama yöntemi ile Balina Optimizasyon Algoritması (Whale Optimization Algorithm - WOA) birlikte kullanılmıştır. Önerilen model, RAVDESS, Urdu ve EmoDB veri setleri üzerinde test edilmiştir. İlk olarak, konuşma sinyalleri mel-spektrogram dönüşümüne tabi tutulmuş ve ardından Wide-ResNet-50-2 derin sinir ağı modeli kullanılarak yüksek seviyeli öznitelikler çıkarılmıştır. Deneysel sonuçlarda önerilen HDFS modelinde beş katlı çapraz doğrulama yöntemi kullanılarak, RAVDESS veri setinde %89.72, Urdu veri setinde %96.25, EmoDB veri setinde %93.64 doğruluk oranı elde etmişlerdir (Marik vd., 2022).

Manohar & Logashanmugam, (2022), geleneksel akustik yöntemlerin dezavantajlarını ortadan kaldırmak için farklı bir hibrit model önermişlerdir. Kullandıkları veri setlerinde MFCC,

melscale spektrogramı, ton gücü ve spektral akı kullanılarak öznitelik çıkarma işlemini gerçekleştirmişlerdir. Elde edilen özniteliklerin boyutunu azaltmak için Uyarlanabilir Arama (DH-AS) algoritması ile Geyik Avı algoritması kullanmışlardır. Sınıflandırma işlemi için ise, “Derin Sinir Ağı (DNN) ve Tekrarlayan Sinir Ağı (RNN)” ile Hibrit Derin Öğrenme (HDL) yöntemini benimsemişlerdir. Önerilen DH-AS-HDL performansının PSO-HDL, GWO-HDL, WOA-HDL ve DHOA-HDL'ye göre sırasıyla %3.15, %5.37, %4.25 ve %4.81 daha iyi doğruluk sağladığını belirtmişlerdir (Manohar & Logashanmugam, 2022).

Akinpelu ve Viriri (2022) tarafından gerçekleştirilen çalışmada, konuşma duygu sınıflandırmasını geliştirmek amacıyla Derin Transfer Öğrenme ve Öznitelik Seçimi yöntemlerini birleştiren bir yaklaşım önermektedir. Çalışmanın amacı, transfer öğrenme tabanlı öznitelik çıkarımı ve Neighborhood Component Analysis (NCA) yöntemiyle öznitelik seçim sürecini optimize ederek sınıflandırma doğruluğunu artırmaktır. Model, VGGNet temel alınarak önceden eğitilmiş bir ağ kullanılarak geliştirilmiş ve konuşma sinyallerinden çıkarılan Mel-Spektrogram görüntüleri model girdisi olarak kullanılmıştır. Çalışmada, deneyler EmoDB, Toronto English Speech Set (TESS) ve TESS-EMO-DB birleşimi veri setleri üzerinde gerçekleştirilmiştir. Öznitelik çıkarma aşamasında Derin Evrişimli Sinir Ağı (DCNN) kullanılmış, ardından NCA yöntemi ile en iyi ayrıştırıcı öznitelikler belirlenerek gereksiz öznitelikler elenmiştir. Bu süreç, modelin işlem maliyetini azaltırken doğruluk oranını artırmayı sağlamıştır. Özellikle TESS veri setinde %97.2, EmoDB veri setinde %94.3 ve TESS- EmoDB birleşiminde %95.7 doğruluk oranları elde edilmiştir (Akinpelu & Viriri, 2022).

Albadr vd. (2022), SER içi yaptıkları çalışmada, sınıflandırma sürecini iyileştirmek için Optimizasyonlu Genetik Algoritma-Aşırı Öğrenme Makinesi (OGA-ELM) yaklaşımını önermektedir. Çoğu SER çalışması, yalnızca öznitelik çıkarımı aşamasına odaklanırken, bu çalışma sınıflandırma sürecine özel bir vurgu yaparak sistemin genel doğruluğunu artırmayı amaçlamaktadır. Ayrıca, çoğu SER sistemi yalnızca Konuşmacı Bağımsız (SI - Subject Independent) senaryosuna göre değerlendirilirken, bu çalışma Konuşmacı Bağımlı (SD - Subject Dependent), Cinsiyet Bağımlı Kadın (GD-Female) ve Cinsiyet Bağımlı Erkek (GD-Male) olmak üzere dört farklı senaryoya göre değerlendirme yapmaktadır. OGA-ELM modeli, Genetik Algoritma (GA) ile optimize edilmiş Aşırı Öğrenme Makinesi (Extreme Learning Machine - ELM) kullanarak sınıflandırma sürecini iyileştirmiştir. Genetik Algoritma, ELM'in rastgele ağırlıklarını optimize etmek için kullanılmıştır ve bu sayede modelin doğruluk oranları önemli ölçüde artırılmıştır. Çalışmada, dört farklı değerlendirme senaryosunda elde edilen en

yüksek doğruluk oranları şu şekildedir: Konuşmacı Bağımsız (SI) senaryosunda %93.26, Konuşmacı Bağımlı (SD) senaryosunda %100.00, Cinsiyet Bağımlı Erkek (GD-Male) senaryosunda %96.14 ve Cinsiyet Bağımlı Kadın (GD-Female) senaryosunda %97.10. Bu sonuçlar, önerilen OGA-ELM yaklaşımının geleneksel yöntemlere kıyasla daha yüksek doğruluk sunduğunu ve genetik algoritma ile optimize edilmiş ELM'in sınıflandırma performansını önemli ölçüde artırdığını göstermektedir (Albadr vd., 2022).

Sun vd. (2022), SER için GA ve Karar Ağacı (Decision Tree - DT) tabanlı bir yöntem geliştirmişlerdir. Önerilen yöntem, EmoDB ve Chinese Emotion Speech Database (CASIA) veri setleri üzerinde test edilmiştir. Öznitelik çıkarımı aşamasında, MFCC, sıfır geçiş oranı (Zero Crossing Rate - ZCR), perde frekansı (pitch frequency) ve kısa süreli enerji (short-term energy) gibi geleneksel akustik öznitelikler kullanılmıştır. Bunun yanı sıra, DNN tabanlı bir model kullanılarak, yüksek seviyeli derin öznitelikler çıkarılmıştır. Fisher kriteri kullanılarak en iyi öznitelikler seçilmiş ve ardından GA kullanılarak akustik ve derin özniteliklerin en iyi şekilde birleştirilmesi için optimal ağırlık değerleri belirlenmiştir. GA, her özelliğin sınıflandırmaya katkısını optimize eden ağırlıkları öğrenerek, en iyi öznitelik kümesini oluşturmuştur. Son olarak, GA ile optimize edilen öznitelikler, Karar Ağacı Destek Vektör Makineleri (DT-SVM) yapısına giriş olarak verilmiş ve duygu sınıflandırması gerçekleştirilmiştir. Deneysel sonuçlar, önerilen GA-DT modeli ile elde edilen duygu tanıma başarımının, geleneksel yöntemlere kıyasla daha yüksek olduğunu göstermektedir. EmoDB veri setinde %85.89, CASIA veri setinde ise %85.3 doğruluk oranı elde edilmiştir (Sun vd., 2022).

Falahzadeh vd., (2023) çalışmalarında, Derin Evrişimli Sinir Ağı (Deep Convolutional Neural Network - DCNN) ve GWO algoritmasını birleştirerek model doğruluğunu artırmayı amaçlamaktadırlar. Çalışma, konuşma sinyallerini 3B faz uzayında yeniden yapılandırarak ve bunları Chaogram adı verilen yeni bir görsel temsile dönüştürüp, VGG ağını kullanarak duygu sınıflandırmasını geliştirmeyi hedeflemektedirler. Elde edilen görüntüler Chaogram olarak adlandırılmış ve VGG tabanlı derin öğrenme modeline giriş olarak kullanılmıştır. Modelin eğitim sürecinde, önceden eğitilmiş VGG DCNN modeli kullanılmış ve transfer öğrenme uygulanmıştır. Modelin hiperparametrelerini optimize etmek için ise GWO algoritması kullanılmıştır. EmoDB veri setinde %82.41, eNTERFACE05 veri setinde %79.83 doğruluk oranı elde edilmiştir (Falahzadeh vd., 2023)

Darekar vd., (2023) yaptıkları çalışmada, hibrit bir öznitelik vektörü oluşturmak için Butterworth filtresi, sinyallerin bölünmesi, Evrişimli Sinir Ağı (CNN), Spektrogram öznitelik çıkarımı ve Gelişmiş-ReliefF (E-ReliefF) kullanan yeni bir otomatik konuşma duygusu yeniden düzenleme modeli önermektedirler. Sınıflandırıcılar topluluğu (EC), Tekrarlayan Sinir Ağı (RNN), Derin Sinir Ağı (DBN) ve Yapay Sinir Ağı (ANN) içerir. EC, hibrit öznitelik vektörü kullanılarak eğitilir ve giriş konuşmasındaki duyguları temsil etmek için optimize edilmiş bir RNN'ye beslenir. Aritmetik Keşifle güncellenen Yabani Canavar Modeli (AEUWB), Aritmetik Optimizasyon Algoritmasını (AOA) ve Wildebeest sürü optimizasyonunu (WHO) birleştiren hibrit bir optimizasyon model olarak tasarlamışlardır. Modelin doğruluğu diğer geleneksel modellerle karşılaştırıldığında %12.3 ila %17.5 daha yüksek başarı oranı elde ettiğini bildirmişlerdir (Darekar vd., 2023) .

Shahin vd., (2023) konuşma ile duygu tanıma işlemi için GWO-KNN adını verdikleri yeni bir metod geliştirmişlerdir. Duygusal sınıflandırma işlemlerini RAVDESS, Arap Emirliği aksanlı konuşma veriseti ve SAVEE veri setlerinde gerçekleştirmişlerdir. Önerdikleri yönetimin BAT, CS, WSH ve AOA gibi algoritmalarla göre daha iyi bir performans gösterdiğini belirtmişlerdir. Arabic Emirati-accented veri setinde %88.95, RAVDESS veri setinde %80.48, SAVEE veri setinde %83.54 başarı oranları elde etmişlerdir (Shahin vd., 2023).

Ramesh vd., (2023) geleneksel naif Bayes'in sınırlamalarının üstesinden gelebilmek için GWO algoritmasını da kullanarak hibrit bir algoritma geliştirmişlerdir. Çalışmalarında SAVEE ve TESS veri setlerini ayrı ayrı kullanmak yerine, bu veri setlerini birleştirerek ortak bir veri seti elde etmişlerdir. Geliştirdikleri hibrit algoritma ile mevcut yöntemlerle karşılaştırıldığında %15.76 daha yüksek doğruluk, %20.69 artırılmış özgüllük elde etmişlerdir. (Ramesh vd., 2023).

Ozseven ve Arpacioğlu, (2024) çalışmalarında konuşma sinyallerinden duygu tanıma sistemlerinde metasezgisel öznitelik seçimi yöntemlerinin performanslarını karşılaştırmışlardır. Araştırmada dört veri seti (EmoDB , EMOVA, eNTERFACE'05, SAVEE) üzerinde sekiz metaheuristik algoritma (PSO, MVO, GWO, MFO, WO, FA, BAT, CS) ve üç sınıflandırıcı (SVM, KNN, ANN) kullanılmıştır. Sonuçlar, öznitelik sayısının azaltılmasıyla sınıflandırma doğruluğunun genellikle arttığını göstermektedir. En yüksek doğruluk SVM sınıflandırıcısı ile elde edilmiştir. EmoDB'de %88.1, EMOVA'da %73.8, eNTERFACE'05'te %73.3, ve SAVEE'de %75.7 doğruluk oranlarına ulaşılmıştır (Ozseven & Arpacioğlu, 2024).

Tyagi ve Szénási (2024) gerçekleştirdikleri çalışmada SER sistemlerinde derin öğrenme modelleri ile GWO algoritmasını birleştirerek doğruluk oranlarını artırmayı hedeflemektedir. Çalışmanın temel amacı, konuşma sinyallerinden çıkarılan öznitelikleri optimize etmek ve derin sinir ağı modellerini en uygun parametrelerle eğiterek duygu sınıflandırma performansını iyileştirmektir. Bu bağlamda, CNN ve Uzun-Kısa Süreli Bellek (LSTM) modelleri kullanılarak duygu sınıflandırma gerçekleştirilmiş ve bu modellerin parametreleri GWO algoritması ile optimize edilmiştir. Çalışmada, RAVDESS, SAVEE, TESS ve EmoDB veri setleri kullanılmıştır. Öznitelik çıkarımı aşamasında MFCC ve logMel öznitelikleri kullanılmıştır. Öznitelik seçimi için GWO algoritması uygulanmış ve en iyi özellik alt kümesi belirlenmiştir. Bu işlem, geleneksel doğrusal ve çekirdek tabanlı SVM ile de test edilerek karşılaştırmalar yapılmıştır. Deneysel süreçte, CNN ve LSTM modelleri SVM ile karşılaştırılmış ve optimizasyon sürecinin sınıflandırma performansına etkisi değerlendirilmiştir. Deney sonuçları, GWO optimizasyonunun doğruluk oranlarını önemli ölçüde artırdığını göstermektedir. Deneysel sonuçlarda; EmoDB veri setinde GWO-SVM doğruluğu %85, GWO-CNN doğruluğu %78, SAVEE veri setinde GWO-SVM doğruluğu %75, GWO-CNN doğruluğu %65.47 elde etmişlerdir (Tyagi & Szénási, 2024).

Yue vd., (2024) çalışmalarında hibrit bir filtre-wrapper algoritmasıyla çok amaçlı bir dengeleme optimizasyonu stratejisi uygulamışlardır. İlk aşamada, bilgi kazancı ve Fisher Skoru gibi filtre yöntemleri kullanılarak özniteliklerin sıralanması gerçekleştirilmiştir. Daha sonra, sıralanan bu öznitelikler çok amaçlı bir sıralama yöntemiyle değerlendirilmiş ve önem derecelerine göre seçim yapılmıştır. Çalışmanın sonuçları, dört farklı veri seti (eNTERFACE05, RAVDESS, SAVEE ve TESS) üzerinde test edilerek değerlendirilmiştir. Random Forest ve KNN sınıflandırıcılarının kullanıldığı deneylerde, önerilen algoritma tüm veri setlerinde yüksek doğruluk oranları elde etmiştir. KNN ile doğruluk oranları eNTERFACE05 için %75, RAVDESS için %80, SAVEE için %79 ve TESS için %99 olarak kaydedilmiştir. Random Forest ile yapılan deneylerde ise bu oranlar sırasıyla %76, %81, %82 ve %99 olmuştur. Özellikle TESS veri setinde elde edilen %99 doğruluk oranı, algoritmanın etkili bir çözüm sunduğunu göstermektedir. Sonuçlar, önerilen yöntemin hem doğruluk hem de verimlilik açısından diğer karşılaştırma algoritmalarından üstün olduğunu ortaya koymaktadır (Yue, Hu, Chu, vd., 2024).

Yue, Hu, & Zhu, (2024) yaptıkları çalışmada, cinsiyetin konuşma tabanlı duygu tanıma sistemleri üzerindeki etkisini ve cinsiyete özgü özniteliklerin duygu tanıma doğruluğunu nasıl

artırdığını araştırmışlardır. Yöntem, Fisher Puanı öznitelik değerlendirmesi, genetik algoritma seçimi ve cinsiyete dayalı duygu tahmin süreçlerini içermektedir. Model, tonlama, perde ve yoğunluk gibi akustik özniteliklere göre duyguları analiz eden dört İngilizce veri kümesi üzerinde test edilmiştir. Sınıflandırma aşamasında destek vektör makineleri (SVM) kullanıldı ve mevcut algoritmalarla kıyasla üstün sonuçlar elde edilmiştir. Model, CREMA-D, EmergencyCalls, IEMOCAP-S1 ve RAVDESS veri kümelerinde sırasıyla %65.6, %75.0, %58.5 ve %67.5 doğruluk oranları elde edilmiştir. (Yue, Hu, & Zhu, 2024).

Agrawal & Jain, (2025) çalışmalarında Random Forest algoritmasının hiperparametrelerini optimize eden ve spectral ile akustik öznitelikleri birleştiren hibrit bir yöntem önermişlerdir. Geliştirilen Hibrit Bat Optimizasyon (HBA) algoritması ile sistemin dayanıklılığını artırarak hem doğruluk hem de verimlilik açısından önemli iyileştirmeler hedeflenmiştir. Önerilen yöntemde spectral ve prosodik özniteliklerin harmanlanmasıyla oluşturulan hibrit bir öznitelik kümesi kullanmıştır. Bu öznitelikler arasında MFCC, kromatik öznitelikler, spektrum enerjisi, perde (pitch), yoğunluk (intensity) gibi veriler bulunmaktadır. Öznitelik seçimi ve optimizasyon aşamalarında, hibrit Bat algoritması ile hiperparametre ayarı yapılmıştır. Eğitim aşamasında kullanılan veri setleri arasında RAVDESS, SAVEE ve ANAKE bulunmaktadır. Sonuçlar incelendiğinde RAVDESS veri setinde hibrit özniteliklerle %93.8, SAVEE veri setinde %85.4, ANAKE veri setinde ise %89.8 olarak doğruluk oranı elde edilmiştir (Agrawal & Jain, 2025).

Yapılan literatür araştırmasında araştırmacılar metasezgisel algoritmalar kullanılarak farklı problemlerin çözümü için yöntemler geliştirilmiştir. Fakat metasezgisel algoritmalar ile SER alanında yapılan çalışmaların kısır kaldığı özellikle GWO ve SS algoritmaları ile SER alanında fazla çalışma olmadığı görülmüştür. Geliştireceğimiz hibrit algoritma sayesinde hem literatüre yeni bir algoritma kazandırılmış olacak hem de SER alanında meta sezgisel algoritmalar ile alakalı farklı bir çalışma gerçekleştirilmiş olacaktır.

3. MATERYAL VE YÖNTEM

3.1. Veri Setleri

Çalışma kapsamında önerilen hibrit metasezgisel yöntemin deneysel sonuçlarını elde edebilmek için literatürde sıklıkla kullanılan 4 farklı veri seti kullanılmıştır.

Çizelge 3.1.'de çalışmamızda kullanılan veri setlerindeki duyguların sayısal dağılımı gösterilmektedir.

Çizelge 3.1. Kullanılan veri setlerindeki duyguların sayısal dağılımı

Data Set	AG	DG	FR	HP	SD	BD	SR	NR	Total
EmoDB	127	46	69	71	62	81	-	79	535
eNTERFACE'05	176	190	196	198	182	-	205	-	1147
EMOVA	72	68	69	72	72	-	72	72	497
SAVEE	60	60	60	60	60	-	60	120	480

AG: anger, DG: disgust, FR: anxiety/fear, HP: happiness, SD: sadness, BD: boredom, SR: surprise, NR: neutral

3.1.1. EmoDB veri seti

EmoDB f. Burkhardt tarafından almanca olarak kaydedilmiş 10 profesyonelden (erkek ve kadın) oluşan bir veri setidir. Öfke, sıkıntı, korku, mutlu, nefret, normal ve üzüntü olmak üzere yedi duygu sınıfıyla etiketlenmiştir. Veri kümesi oluşturmak için on farklı cümle seçilmiştir. Bu 10 cümleden 5'i kısa (yaklaşık 1,5 saniye uzunluğunda) ve 5'i uzun (yaklaşık 4 saniye uzunluğunda) cümledir. Her duygu sınıfı, yetersiz örneklenmesi sorununu önlemek için neredeyse eşit sayıda duygusal ifadeye sahiptir. Bu veri setinde toplam 535 cümleden oluşan ses dosyası vardır (Burkhardt vd., 2005).

3.1.2. SAVEE veri seti

SAVEE, İngiltere'deki Surrey Üniversitesi tarafından geliştirilmiş olup, duygusal konuşma ve yüz ifadelerinden oluşan çok modlu bir veri setidir. Veri setinde dört erkek konuşmacıya ait, yedi temel duyguyu (öfke, iğrenme, korku, mutluluk, üzüntü, şaşkınlık ve nötr) içeren toplam 480 adet ses ve video kaydı bulunmaktadır. Her konuşmacı, her duygu için önceden belirlenmiş

çeşitli cümleleri seslendirmiştir. Kayıtlar yüksek kaliteli WAV formatında ses dosyaları ve senkronize video görüntüleri olarak sunulmaktadır.

3.1.3. EMOVA veri seti

İtalyanca için geliştirilen EMOVA veri seti Sapienza Roma Üniversitesi tarafından geliştirilmiş olup, altı farklı konuşmacının (üç erkek, üç kadın) yedi temel duyguyu (öfke, iğrenme, korku, neşe, üzüntü, sürpriz ve nötr) ifade ettiği 588 adet ses kaydından oluşmaktadır. Her konuşmacı, her duygu için 14 farklı cümleyi seslendirmiştir. Ses kayıtları WAV formatında, 48 kHz örnekleme hızı ve 16 bit çözünürlük ile yüksek kalitede sağlanmıştır. (Costantini vd., 2014).

3.1.4. eNTERFACE veri seti

Bu veri seti, farklı etnik kökenlerden 42 katılımcının altı temel duyguyu (mutluluk, üzüntü, öfke, korku, iğrenme ve şaşkınlık) ifade ettiği toplam 1260 video ve ses kaydından oluşmaktadır. Her katılımcı, her duygu için beş farklı cümleyi sesli ve görsel olarak ifade etmiştir. Kayıtlar, senaryo bazlı olarak gerçekleştirilmiş ve katılımcılardan duyguları oynayarak ifade etmeleri istenmiştir.(Martin vd., 2006).

3.2. Sesin Öznitelikleri

Konuşma işleme, dijital sinyal işleme yöntemleriyle ses ve konuşmanın analiz edilmesi, sınıflandırılması ve anlamlandırılmasını kapsayan bir alandır. Bu süreçte, sınıflandırma ve analiz işlemleri için kullanılacak anlamlı verilerin elde edilmesi aşaması olan öznitelik çıkarımı, kritik bir role sahiptir. Öznitelikler genellikle zamansal ve frekans tabanlı olmak üzere iki ana grupta toplanır ve akustik öznitelikler, dilbilimsel bilgiler, bağlamsal bilgiler ve hibrit öznitelikler gibi alt kategorilere ayrılır. Örneğin, temel frekans (F0), formantlar, jitter ve shimmer gibi parametreler akustik özniteliklere, konuşmacının durumu veya çevresel koşullara bağlı bilgiler ise bağlamsal özniteliklere örnek olarak verilebilir (Özseven & Düğenci, 2018).

Sesin öznitelikleri, konuşma sinyallerinden anlamlı bilgiler çıkarılması için kullanılan kritik parametrelerdir. Özellikle konuşma duygu tanıma sistemlerinde, sesin temel özniteliklerinin doğru seçimi ve çıkarımı, model performansını doğrudan etkiler (Oflazoglu, 2011).

Ses, insanların iletişim kurarken kullandığı en önemli araçlardan biridir ve yalnızca dilsel içerik değil, aynı zamanda duygu, yaş, cinsiyet ve fizyolojik durum gibi bilgiler de içerir. Bu nedenle, sesin içindeki bilgilerin doğru şekilde çıkarılması, sesin sınıflandırılması için önemli avantajlar sağlar. Özellikle konuşma duygu tanıma gibi uygulamalarda, ses sinyalinin analiz edilmesi için belirli özniteliklerin çıkarılması gerekmektedir. Bu öznitelikler, sinyalin çeşitli yönlerini yansıtarak sınıflandırma süreçlerinde önemli rol oynar.

Ses öznitelikleri, temel olarak iki ana kategoriye ayrılır: prozodik öznitelikler ve spektral öznitelikler. Bu öznitelikler, ses sinyalinin hem zaman hem de frekans alanında analiz edilmesini sağlar.

3.2.1. Prozodik Öznitelikler

Prozodik öznitelikler, sesin yüksekliği (pitch), enerjisi, süresi ve ritmi gibi zaman alanı özniteliklerini kapsar. Bu öznitelikler, konuşma sırasında duygu değişimlerini anlamak için oldukça önemlidir (Sönmez, 2021).

Pitch (F0): Temel frekans olarak bilinen pitch, ses tellerinin titreşimi sonucu oluşan frekans bileşenidir. Farklı duygular, pitch değişiklikleriyle ifade edilebilir; örneğin, öfke genellikle yüksek pitch ile ilişkilendirilirken, üzüntü düşük pitch ile ilişkilendirilebilir.

Enerji: Sesin gücü ya da şiddeti olarak bilinen enerji, ses sinyalinin zaman içindeki yoğunluğunu gösterir. Duyguların ifadesinde enerji değişimleri önemli bir rol oynar. Örneğin, öfkeli bir konuşma yüksek enerjiye sahipken, üzgün bir konuşma daha düşük enerji içerir .

Süre: Ses sinyalinin süresi ve bu süre içerisindeki duraklamalar, bir konuşmacının duygusal durumunu gösterebilir. Heyecanlı ya da kızgın konuşmalarda süre daha kısa, sakin konuşmalarda ise daha uzun olabilir.

3.2.2. Spektral Öznitelikler

Spektral öznitelikler, ses sinyalinin frekans bileşenleri ile ilgili bilgileri içerir. Bu öznitelikler, sinyalin farklı frekanslardaki enerji dağılımını analiz ederek daha derin bilgiler sağlar.

Mel-Frekans Kepstral Katsayıları (MFCC): MFCC'ler, konuşma sinyallerinin frekans içeriğini insan işitme sistemine benzer bir şekilde analiz eden özniteliklerdir. MFCC, duygu tanıma

sistemlerinde en yaygın kullanılan spektral özniteliktir. Farklı duygusal durumlar, farklı MFCC kalıpları üretebilir (Erdem, 2014).

Spektral Akı (Spectral Flux): Bu öznitelik, ses sinyalindeki ardışık spektrumlar arasındaki değişiklikleri ölçer. Duygular arasındaki geçişler sırasında spektral akı değişiklik gösterebilir (Akkurt, 2019).

Spektral Centroid: Sesin parlaklığı veya keskinliği hakkında bilgi verir. Yüksek spektral centroid değerleri, genellikle daha keskin, parlak seslerle ilişkilidir; bu durum, örneğin kızgınlık gibi duygularla ilişkilendirilebilir (Akkurt, 2019).

Jitter ve Shimmer: Jitter, temel frekanstaki düzensizlikleri (zaman varyasyonu), shimmer ise sesin genliğindeki değişiklikleri (genlik varyasyonu) ifade eder. Bu iki öznitelik, sesin stabilitesini ölçer ve farklı duygusal durumların değerlendirilmesinde kullanılır (Demir, 2021).

3.3. Öznitelik Çıkartılması

Çalışmamızda deneysel çalışmalarımızı test edeceğimiz veri setlerindeki ses dosyalarından öznitelikleri elde etmek için açık kaynak kodlu OpenSMILE yazılımı kullanılmıştır. OpenSMILE, özellikle konuşma tanıma, duygu analizi, konuşmacı tanıma ve ses sınıflandırması olmak üzere ses sinyallerinin analizine yardımcı olan güçlü bir yazılımdır. Mel-Frekans Cepstral Katsayıları (MFCC), Perde (F0), Jitter ve Parıltı gibi yüzlerce özelliği çıkarabilir ve bu öznitelikleri zaman dilimleri boyunca istatistiksel olarak özetleyebilir. Çoklu platform desteği, modüler yapısı ve kapsamlı dokümantasyonu ile OpenSMILE, araştırmacılar ve geliştiriciler için kritik bir araç haline gelmiştir (Atalay, 2018).

OpenSMILE'in uygulama alanları arasında konuşma tanıma, duygu analizi, konuşmacı tanıma ve ses sınıflandırması yer alır. Modüler yapısı kullanıcıların özelleştirilmiş öznitelik setleri oluşturmaya ve Windows, macOS ve Linux gibi çeşitli platformlarda sorunsuz bir şekilde çalışmasına olanak tanır. Sonuç olarak, OpenSMILE çok çeşitli akustik ve paralinguistik öznitelikleri çıkararak ses ve konuşma analizi süreçlerini büyük ölçüde iyileştiren çok yönlü ve güçlü bir yazılım paketidir. Özellikle konuşma tanıma, duygu analizi ve konuşmacı tanıma gibi alanlardaki esnekliği ve doğruluğu, onu bu alanlardaki araştırma ve uygulamalarda vazgeçilmez kılar (Akkurt, 2019).

Çizelge 3.2.'de OpenSmile yazılımı kullanılarak elde edilen öznitelik sayılarının dağılımı gösterilmiştir.

Çizelge 3.2. Kullanılan özniteliklerin sayısal dağılımı

Öznitelikler	Öznitelik Sayısı
Loudness	42
MFCC	630
Logarithmic power of mel band	336
Line spectral pair frequency	336
Envelope of smoothed fundamental frequency contour	42
Voicing probability of the final fundamental frequency candidate	40
Smooth fundamental frequency contour	40
Local jitter & Differential jitter	76
Partial shimmer	38

3.4. Metasezgisel Algoritmalar

Metasezgisel Optimizasyon, geleneksel optimizasyon tekniklerinin yetersiz kaldığı, çok boyutlu ve karmaşık problemlerin çözümü için geliştirilmiş, sezgisel ve üst düzey yöntemlerden oluşan bir optimizasyon yaklaşımıdır. Bu yöntemler, klasik sezgisel (heuristic) yaklaşımların ötesine geçerek, daha kapsamlı ve esnek çözüm arayışlarına olanak tanır. Özellikle büyük çözüm uzaylarına sahip veya çözüm sürecinde yerel minimuma sıkışma riski bulunan problemlerde, metasezgisel optimizasyon teknikleri daha etkin çözümler sunar(Onwubolu & Babu, 2004).

Metasezgisel algoritmalar genellikle çeşitlendirme ve yoğunlaşma adı verilen iki temel bileşenden oluşur. Çeşitlendirme (exploration), arama alanının genişletilmesi ve daha fazla alternatif çözüm üretilmesi anlamına gelir. Bu süreç, yeni ve farklı çözüm alanlarının keşfedilmesine olanak tanıyarak, arama sürecini daha kapsamlı hale getirir. Yoğunlaşma (exploitation) ise belirli bir çözüm bölgesine odaklanarak, bu alanda en iyi sonucun bulunmasını hedefler. Bu iki bileşenin uyumlu bir şekilde kullanılması, metasezgisel optimizasyonun başarıya ulaşmasında kritik rol oynar; çünkü çeşitlendirme olmadan arama

süreci kısır döngüye girebilir, yoğunlaşma olmadan ise çözümler yüzeysel kalabilir(Gandomi vd., 2015).

Metasezgisel yöntemlerin birçoğu doğadaki canlıların davranışlarından esinlenerek geliştirilmiştir. Örneğin, karınca kolonisi algoritması, karıncaların yiyecek arama sürecindeki iş birliğini ve feromon izlerini takip etme davranışlarını taklit eder. Karıncalar, yiyecek bulmak için rastgele dolaşır, buldukları yiyeceğe geri dönerken feromon izi bırakır ve bu iz yoğunlaştıkça diğer karıncalar da bu yolu takip eder. Bu davranış, karmaşık problemlerin çözümünde güçlü bir örnek sunar, çünkü arama sürecini yönlendiren kolektif bir bilgi paylaşımı vardır (Slowik, 2020).

Bir diğer yaygın metasezgisel yöntem olan sürü zekası algoritmaları ise kuş sürüleri veya balık sürüleri gibi toplulukların uyum içinde hareket etme yeteneğinden esinlenir. Bu algoritmalar, bireysel unsurların hareketleri ile kolektif bir zekaya ulaşmayı amaçlar. Örneğin, PSO her parçacığın bir çözüm uzayında hareket ederek en iyi çözümü bulmaya çalıştığı bir yöntemdir. Parçacıklar, hem kendi en iyi konumlarına hem de sürünün en iyi konumuna göre hareket eder. Bu süreç, sürekli bilgi güncellemesi ve topluluk içindeki iş birliği ile ideal çözüme ulaşmayı kolaylaştırır (Xue vd., 2013).


Metasezgisel optimizasyon yöntemleri, çok çeşitli alanlarda uygulanabilir. Mühendislik problemlerinden biyolojik modellemeye, finansal karar süreçlerinden lojistik optimizasyona kadar birçok alanda, karmaşık problemlerin çözümünde etkili araçlar sunarlar (Abualigah vd., 2022; Soler-Dominguez vd., 2018). Özellikle küresel optimuma ulaşmanın zor olduğu, çok sayıda yerel optimum içeren problemlerde, metasezgisel algoritmalar klasik yöntemlere göre daha başarılı sonuçlar verebilir. Bu yöntemler hem dinamik hem de değişken çevresel koşullarda çözüm arayışını sürdürebildikleri için esnek ve güçlü çözümler sunar.

Metasezgisel yöntemler, yalnızca teknik problemler için değil, aynı zamanda karar verme süreçlerinde ve kaynakların verimli kullanımı gerektiren alanlarda da yaygın olarak kullanılmaktadır. Örneğin, üretim süreçlerinde kaynak tahsisi, rota planlama, personel çizelgeleme gibi operasyonel sorunlarda hızlı ve etkili çözümler sağlamaktadırlar (Baykasoglu, 2002).

3.5. Gri Kurt Algoritması

Gri Kurt Optimize Edici (GWO), gri kurtların davranışlarını taklit eden yeni bir sürü zekası algoritmasıdır. Yetenekleri arasında hızlı yakınsama, basitlik ve kolay gerçekleştirilme sayılabilir. Üstün performansı kanıtlanmıştır ve küme analizi, mühendislik problemi, sinir ağı eğitimi vb. gibi sürekli uygulamaları optimize etmek için yaygın olarak kullanılmaktadır. (Hu vd., 2020).

Canidae familyasının bir parçası olan gri kurtlar, besin zincirinin en üstünde yer alan en üst düzey yırtıcılarıdır. Katı bir sosyal baskın hiyerarşiye sahip, 5-12 bireyden oluşan sürüler halinde yaşamayı tercih ederler. Liderler, avlanma, uyuma ve uyanma zamanları hakkında kararlar alan erkek ve dişi alfa kurtlardır. Bu kararlar sürüye dikte edilir, ancak bazı demokratik davranışlar da gözlemlenmiştir. Alfa kurt, emirlerine tüm sürünün uyması gerektiği için baskın kurt olarak da adlandırılır. Alfa kurtların yalnızca sürü içinde çiftleşmesine izin verilir. Alfa, sürünün en güçlü üyesi olmak zorunda değildir, ancak sürüyü yönetmede en iyisidir ve bu da bir sürünün organizasyonunun ve disiplininin gücünden daha önemli olduğunu gösterir (Mirjalili vd., 2014). Şekil 3.1.'de gri kurtların sosyal hiyerarşisi gösterilmektedir.



Şekil 3.1. Gri Kurtların sosyal hiyerarşisi(Mirjalili vd., 2014)

Gri kurtlar üç seviyeye ayrılır: beta, omega ve ast. Betalar, alfaya karar verme ve sürü faaliyetlerinde yardımcı olan ast kurtlardır. Erkek veya dişi olabilirler ve biri ölürse veya çok yaşlanırsa alfa olmak için en iyi adaydırlar. Sürü için danışman ve disiplin görevlisi olarak hizmet ederler, alfanın emirlerini güçlendirir ve geri bildirim sağlarlar. Omega kurtlar en düşük rütbelidir, günah keçisi rolünü oynar ve tüm baskın kurtlara boyun eğler. Önemsiz görünebilirler, ancak kaybolurlarsa iç çatışmalara ve sorunlara neden olabilirler. Bir kurt alfa,

beta veya omega değilse, ast (veya delta) olarak adlandırılırlar. Delta kurtları alfalara ve betalara boyun eğmeli ancak omega'ya hâkim olmalıdır. Diğer ast kurtlar arasında İzçiler, nöbetçiler, yaşlılar, avcılar ve bakıcılar bulunur. İzçiler bölge sınırlarını izler ve tehlike durumunda sürüyü uyarır. Nöbetçiler sürünün güvenliğini sağlar, yaşlılar alfa veya beta olan deneyimli kurtlardır, avcılar avlanmaya yardım eder ve yiyecek sağlar ve bakıcılar sürüdeki zayıf, hasta ve yaralı kurtlarla ilgilenir (Mirjalili vd., 2014).

GWO algoritması, en uygun çözümü alfa (α), ardından beta (β) ve delta (δ) ve kalan aday çözümleri omega (ω) olarak kabul ederek kurtların sosyal hiyerarşisini matematiksel olarak modeller. Algoritma, bu üç kurtu takip eden ω kurt ile α , β ve δ 'ye göre avlanmayı yönlendirir.

Gri kurtlar avlanma sırasında avlarını çevrelerler ve önerilen denklemler kullanılarak davranışlarının matematiksel olarak modellenmesi esastır (Mirjalili vd., 2014).

$$\vec{D} = |\vec{C} \cdot \vec{X}_p(t) - \vec{X}(t)| \quad (3.1)$$

$$\vec{X}(t+1) = \vec{X}_p(t) - \vec{A} \cdot \vec{D} \quad (3.2)$$


Burada t geçerli yinelemeyi, $\vec{A}$ ve $\vec{C}$ katsayı vektörlerini, $\vec{X}_p$ avın konum vektörünü ve $\vec{X}$ gri kurdun konum vektörünü gösterir. $\vec{A}$ ve $\vec{C}$ vektörleri aşağıdaki gibi hesaplanır:

$$\vec{A} = 2\vec{a} \cdot \vec{r}_1 - \vec{a} \quad (3.3)$$

$$\vec{C} = 2 \cdot \vec{r}_2 \quad (3.4)$$

$\vec{a}$ 'nın bileşenleri yinelemeler boyunca 2'den 0'a doğrusal olarak azalır ve r_1, r_2 $[0, 1]$ 'deki rastgele vektörlerdir.

Denklemler (3.1) ve (3.2)'nin iki boyutlu bir konum vektörü ve olası komşular üzerindeki etkilerini göstermektedir. Bir gri kurt, avının konumuna (X, Y) göre konumunu güncelleyebilir. En iyi ajan, $\vec{A}$ ve $\vec{C}$ vektörlerinin değerlerini ayarlayarak elde edilebilir. Bir gri kurdun 3B uzaydaki olası güncellenmiş konumları Şekil 3(b)'de gösterilmiştir. Rastgele vektörler r_1 ve r_2 , kurtların Şekil 3.2'de gösterilen noktalar arasındaki herhangi bir konuma ulaşmasını sağlayarak, konumlarını herhangi bir rastgele konumda güncellemelerine olanak tanır.



Şekil 3.2. 2D ve 3D konum vektörleri ve olası bir sonraki konumları (Mirjalili vd., 2014)


Gri kurtlar av yerlerini tanıyabilir ve onları çevreleyebilir, genellikle alfa kurt tarafından yönlendirilmektedirler. Beta ve delta ara sıra avlanmaya katılabilir. Gri kurt avlanma davranışını matematiksel olarak simüle etmek için, alfa, beta ve deltanın potansiyel av yerleri hakkında daha iyi bilgiye sahip olduğu varsayılmaktadır. Öncelikle ilk üç en iyi çözüm kaydedilir ve diğer arama ajanlarının konumlarını en iyi arama ajanlarının konumlarına göre güncellemesi gerçekleştirilir. Bu amaçla 3.5, 3.6 ve 3.7’de belirtilen formüller önerilmiştir(Mirjalili vd., 2014).

$$\vec{D}_\alpha = |\vec{C}_1 \cdot \vec{X}_\alpha - \vec{X}|, \vec{D}_\beta = |\vec{C}_2 \cdot \vec{X}_\beta - \vec{X}|, \vec{D}_\delta = |\vec{C}_3 \cdot \vec{X}_\delta - \vec{X}| \quad (3.5)$$

$$\vec{X}_1 = \vec{X}_\alpha - \vec{A}_1 \cdot (\vec{D}_\alpha), \vec{X}_2 = \vec{X}_\beta - \vec{A}_2 \cdot (\vec{D}_\beta), \vec{X}_3 = \vec{X}_\delta - \vec{A}_3 \cdot (\vec{D}_\delta) \quad (3.6)$$


$$\vec{X}(t+1) = \frac{\vec{X}_1 + \vec{X}_2 + \vec{X}_3}{3} \quad (3.7)$$

Şekil 3.3.’de, bir arama aracısının alfa, beta ve deltaya dayalı olarak 2 boyutlu bir arama alanındaki konumunu nasıl güncellediğini gösterilmektedir. Son konum, bu konumlarla tanımlanan bir daire içinde rastgeledir ve alfa, beta ve deltanın avın konumunu tahmin ettiğini, diğer kurtların ise avın etrafındaki konumlarını güncellediğini gösterir.



Şekil 3.3. GWO algoritmasında pozisyon güncellemesi (Mirjalili vd., 2014)

Gri kurtlar, $\vec{a}$ değerini azaltan bir matematiksel model kullanarak av hareket etmeyi bıraktığında ona saldırır. $\vec{A}$ 'nın dalgalanma aralığı da iterasyon boyunca 2'den 0'a doğru azalır ve bu da arama ajanlarının alfa, beta ve delta konumlarına göre konumlarını güncellemelerine olanak tanır. $\vec{A} \in [-1, 1]$ konumunda olduğunda, arama ajanının bir sonraki konumu mevcut konumu ile avın konumu arasında olabilir. Şekil 3.4(a)'da görüldüğü gibi eğer $|A| < 1$ ise, kurtlar avına doğru saldırır. GWO algoritması, arama ajanlarının konumlarını bu operatörlere göre güncellemelerine olanak tanır, ancak yerel çözümlerde durgunluğa eğilimlidir. Şekil 3.4(b)'de görüldüğü gibi Eğer $|A| > 1$ ise, önerilen çevreleme mekanizması biraz keşif gösterir, ancak keşfi vurgulamak için daha fazla operatöre ihtiyaç vardır.



Şekil 3. 4. Bir gri kurtun avına saldırma ve avını arama durumu (Mirjalili vd., 2014)

Gri kurtlar, av bulmak için ayrılarak ve avına saldırmak için birleşerek alfa, beta ve delta konumlarına göre arama yaparlar. GWO algoritması, keşfi ve genel aramayı vurgulayarak ayrışmayı modellemek için rastgele bir değişken $\vec{A}$ kullanır. $\vec{C}$ vektörü, av için ağırlıklar sağlamak, avın mesafe üzerindeki etkisini vurgulamak veya önemsizleştirmek için $[0, 2]$ içinde rastgele değerler içerir. Bu bileşen doğrusal olarak azaltılmaz, ancak ilk ve son yinelemeler sırasında keşfi vurgulamak için her zaman rastgele değerler sağlamak için kasıtlı olarak gereklidir(Mirjalili vd., 2014).

C vektörü ayrıca doğada avın yaklaşmasına yönelik engellerin etkisi olarak da düşünülebilir. Av için rastgele bir ağırlık verir, kurtların ulaşmasını zorlaştırır veya daha uzağa götürür. Arama süreci, GWO algoritmasında rastgele bir gri kurt popülasyonu (aday çözümler) oluşturmakla başlar. Yinelemeler boyunca, alfa, beta ve delta kurtları avın olası konumunu tahmin eder ve her aday çözüm avdan olan mesafesini günceller. Parametre a , keşif ve sömürüyü vurgulamak için 2'den 0'a düşürülür(Mirjalili vd., 2014).

Kurtlar avına saldırma esnasında avın konumu ile mevcut konumunu $|A| < 1$ olması için ayarlarlar. Alfa, beta, delta avı saldırı esnasında birleşme av arama esnasında ise birbirlerinden uzaklaşma eğilimindedirler. $\vec{A}$ vektörü rastgele değerler alabilir ve kurtların avdan uzaklaşmasını sağlayabilir(Mirjalili vd., 2014).

Çizelge 3.3' de sunulan GWO algoritması, yinelemeler boyunca elde edilen en iyi çözümleri kaydetmek için sosyal bir hiyerarşi kullanan teorik bir optimizasyon yöntemidir. Çevreleme

mekanizması, çözümlerin etrafında hiper küre olarak daha yüksek boyutlara genişletilebilen daire şeklinde bir alan oluşturur. Rastgele parametreler A ve C, aday çözümlerin farklı yarıçaplara sahip hiper kürelere sahip olmasına yardımcı olur. Avlanma yöntemi, aday çözümlerin olası av konumunu bulmasına yardımcı olur. Algoritmanın keşfi ve sömürüsü, a ve A'nın uyarlanabilir değerleri tarafından garanti altına alınır ve keşif ile sömürü arasında yumuşak bir geçiş sağlar. A azaldıkça, yinelemelerin yarısı keşfe ayrılırken diğer yarısı sömürüye ayrılır. Çizelge 3.3.'de GWO algoritmasının kaba kodu gösterilmektedir.


Çizelge 3.3. GWO algoritması kaba kod (Mirjalili vd., 2014)

No	Adımlar
1.	Gri kurt popülasyonu X_i ($i = 1, 2, \dots, n$) ayarla
2.	a, A ve C' yi ayarla
3.	Her arama ajanının uygunluk (fitness) değerini hesapla
4.	X_α = en iyi arama ajanı
5.	X_β = ikinci en iyi arama ajanı
6.	X_δ = üçüncü en iyi arama ajanı
7.	$t = 0$
8.	while ($t < \text{Maksimum iterasyon sayısı}$) do
9.	for her arama ajanı do
10.	Mevcut arama ajanının konumunu Denklem (3.7) ile güncelle
11.	end for
12.	a, A ve C değerlerini güncelle
13.	Tüm arama ajanlarının uygunluk değerini hesapla
14.	X_α , X_β ve X_δ değerlerini güncelle
15.	$t = t + 1$
16.	end while
17.	return X_α

3.6. Salp Sürü Algoritması

Salpidae familyasının bir üyesi olan salplar, şeffaf fiçı biçimli bir gövdeye ve denizanasına benzer dokulara sahiptir. İtici güç olarak suyu kullanarak denizanasına benzer şekilde hareket ederler. Salplar üzerindeki biyolojik araştırmalar, zorlu yaşam ortamları ve laboratuvar koşulları nedeniyle erken aşamalıdır. Salpların ilginç davranışlarından biri, derin okyanuslarda bir

salp zinciri olarak ortaya çıkan sürü davranışıdır. Bu davranışın temel nedeni henüz net değildir, ancak bazı araştırmacılar bunun hızlı koordineli değişimler ve yiyecek arama yoluyla daha iyi hareket etmek için olduğuna inanmaktadır (Mirjalili vd., 2017). Şekil 3.5'te hem bireysel hemde sürü halindeki salplerin görünümüne yer verilmiştir.



Şekil 3.5. Bireysel ve sürü salp görünümü (Mirjalili vd., 2017)

Salp zinciri, popülasyonu iki gruba bölerek matematiksel olarak modellenir: lider ve takipçiler. Lider ön salp iken, geri kalanlar takipçi olarak kabul edilir. Lider sürüyü yönlendirir ve takipçiler birbirlerini takip eder. Tüm salpların konumu, x 'in iki boyutlu bir matris olduğu n boyutlu bir arama alanında tanımlanır. Sürünün hedefinin arama alanında F olarak adlandırılan bir yiyecek kaynağı olduğu varsayılır (Mirjalili vd., 2017).

Denklem 3.8'e göre, j 'inci boyuttaki liderin konumunu, j 'inci boyutun üst ve alt sınırlarına bağlı olarak ilk salp (lider), F_j (j 'inci boyuttaki gıda kaynağının konumu), ub_j , lb_j ve c_1 , c_2 ve c_3 'ün konumunu rastgele sayılar olarak hesaplayarak günceller.

$$x_j^1 = \begin{cases} F_j + c_1 \left((ub_j - lb_j)c_2 + lb_j \right) & c_3 \geq 0 \\ F_j - c_1 \left((ub_j - lb_j)c_2 + lb_j \right) & c_3 < 0 \end{cases} \quad (3.8)$$

Denklem 3.8, liderin pozisyonunu yalnızca yiyecek kaynağına göre güncellediğini, SSA'da keşif ve sömürü arasında denge sağladığı için c_1 katsayısının kritik olduğunu göstermektedir; denklem 3.9 da l mevcut yinelemeyi, L ise maksimum yineleme sayısını temsil etmektedir.

$$c_1 = 2e^{-\left(\frac{4}{L}\right)^2} \quad (3.9)$$

Newton'un hareket yasası, bir sistemdeki takipçilerin konumunu güncellemek için kullanılır; denklem 3.10'da i 2'den büyük, x_j^i takipçinin j 'inci boyuttaki konumunu temsil eder, t zamandır ve $a = v$ son v_0 .

$$x_j^i = \frac{1}{2}at^2 + v_0t \quad (3.10)$$

Optimizasyon süreci yinelemeleri içerir ve yinelemeler arasındaki tutarsızlık 1'e eşittir. Denklem, $i \geq 2$ olan ve i 'inci takipçi salp'ın konumunu temsil eden x_j^i şeklinde ifade edilebilir.

$$x_j^i = \frac{1}{2}(x_j^i + x_j^{i-1}) \quad (3.11)$$

(3.8) ve (3.11) denklemleri ile salp zincirleri simüle edilmektedir.

Çizelge 3.4. SSA algoritması kaba kod (Mirjalili vd., 2017)

No	Adımlar
1.	Salp popülasyonunu x_i ($i = 1, 2, \dots, n$) üst ve alt sınırları (ub, lb) dikkate alarak oluştur
2.	while (bitiş koşulu sağlanmadıysa) do
3.	Her salp (arama ajanı) için uygunluk (fitness) değerini hesapla
4.	$F =$ en iyi arama ajanı (salp)
5.	c_1 değerini Denklem (3.9) ile güncelle
6.	for her salp (x_i) do
7.	if ($i == 1$) then
	Öncü salpın konumunu Denklem (3.8) ile güncelle
8.	else
	Takipçi salpın konumunu Denklem (3.11) ile güncelle
9.	end if
10.	end for
11.	Salpleri değişkenlerin üst ve alt sınırlarına göre düzelt
12.	end while
13.	return F

SSA algoritmasının kaba kodu Çizelge 3.4’de gösterilmektedir. Bu algoritma, küresel optimuma ulaşmayı hedefleyerek, farklı noktalarda rastgele yerleştirilen bir grup salp ile başlar. İlk olarak, her bir salpın uygunluk değeri hesaplanır ve en iyi sonucu veren salp belirlenir. Bu en iyi konuma sahip salp, diğer salpların takip edeceği bir hedef olarak kabul edilir ve F değişkenine atanır. Bu süreçte, c1 katsayısı Denklem (3.9) kullanılarak güncellenir. Algoritmanın her bir boyutu için, önde bulunan lider salp, Denklem (3.8) ile konumunu güncellerken, diğer takipçi salplar ise Denklem (3.11) kullanılarak yeni konumlarını belirler. Eğer bir salp belirlenen arama sınırlarını aşarsa, tekrar sınırlar içine geri döndürülür. Başlangıç aşaması dışında, bu adımlar algoritma belirlenen bitiş koşuluna ulaşana kadar tekrarlanarak devam eder.


3.7. Sınıflandırıcılar

Makine öğrenimi, verilerden desenler çıkaran ve bunları yeni verilere uygulayan bir alandır. Sınıflandırma ise bir veri kümesine dayalı olarak bir örneğin kategorisini belirleyen yaygın bir araç olarak kullanılmaktadır. Sınıflandırıcılar, çeşitli varsayımlara ve matematiksel ilkelere dayalı olarak geliştirilen algoritmalar olarak veri bilimine hizmet etmektedir. SER çalışmalarında Doğdu vd.,(2022) ve Pao vd.,(2005) KNN algoritması ile sınıflandırma yapmışlardır, Huang vd.,(2021), Bandela & Kumar (2019) ve Al Dujaili vd., (2021) yaptıkları çalışmalarda SVM modelini kullanmışlardır. Çalışmamızın performansının değerlendirilmesi için literatürde sıklıkla kullanılan Destek Vektör Makineleri ve K-en yakın komşu algoritmaları kullanılmıştır(Al Dujaili vd., 2021; Bandela & Kumar, 2019; Doğdu vd., 2022; Huang vd., 2021; Pao vd., 2005).

3.7.1. Destek vektör makineleri (SVM)

Destek Vektör Makinesi (SVM), 1992’de Boser, Guyon ve Vapnik tarafından tanıtılan, sınıflandırma ve regresyon için kullanılan bir gözetimli öğrenme yöntemidir. SVM’ler, verilere aşırı uyumu önlerken tahmin doğruluğunu en üst düzeye çıkarmak için makine öğrenimi teorisini kullanan genelleştirilmiş doğrusal sınıflandırıcılardır. Yüksek boyutlu bir öznelik alanında doğrusal fonksiyonları kullanan ve istatistiksel öğrenme teorisinden türetilen bir öğrenme önyargısına sahip bir optimizasyon teorisi öğrenme algoritması kullanılarak eğitilen sistemlerdir (Jakkula, 2006).

SVM, veri noktalarını sınıflandırmak için Şekil 3.6.'daki gibi bir hiper düzlem veya birden fazla hiper düzlem bulur. Temel amacı, iki sınıf arasındaki marjini (sınıfları ayıran çizgi veya düzlemin en yakın veri noktalarına olan mesafesi) maksimize etmektir.



Şekil 3.6. İki boyutlu veri noktaları için ayırıcı bir hiper düzlem (AKÇA, 2020)


Veri sınıflandırmasında, iki sınıfın (örneğin, siyahlar ve beyazlar) ayrılması, modelin doğruluğunu artırmak için kritik bir adımdır. Bu tür bir sınıflandırmada, temel amaç, gelecekteki verilerin hangi sınıfa ait olduğunu belirlemektir. Sınıflandırma sürecinde, iki sınıf arasında bir sınır çizgisi oluşturulur; bu çizgi, sınıfları ayıran karar sınırını temsil eder.

SVM, iki veya daha fazla etiketli sınıfa sahip veri kümelerinde ayırıcı sınıflandırma için kullanılır. Karar sınırı, sınıflar arasına bir hiper düzlem çizilerek belirlenir ve destek noktaları veya değerler karar sınırına en yakın olur. Bu noktalar, en iyi yerden geçen çizginin oluşturulmasını destekler. Bu noktaların konumu değişirse, en iyi durum ve karar sınırları da değişecektir. Boşluğu optimize etmek ve sınıflar arasına bir hiper düzlem yerleştirmek, yeni değerlerin doğru sınıf kategorisine düşme şansını artırabilir.

$$\hat{y} = \begin{cases} 0 & \text{if } w^T \cdot x + b < 0 \\ 1 & \text{if } w^T \cdot x + b \geq 0 \end{cases} \quad (3.12)$$


Denklem 3.12'ye göre; ağırlık vektörü (w), giriş vektörü (x) ve bias (b), beyaz ve siyah noktalar arasındaki mesafeyi belirlemek için kullanılır. 0'dan küçük yeni bir değer beyaz noktalara daha yakın olacakken, 0'dan büyük veya ona eşit bir değer siyah noktalara daha yakın olacaktır.

Marj her zaman doğrusal olarak ayrılmayabilir ve Şekil 3.7'de görüldüğü gibi örnekler Yumuşak Marj bölgesine girebilir. Sert Marj, aykırı değerlere ve doğrusal ayırmaya duyarlı veriler için uygundur, bu nedenle belirli durumlarda tercih edilebilir (AKÇA, 2020).



Şekil 3.7. Sert ve yumuşak marj sınıflandırma (AKÇA, 2020)

İkisi arasındaki dengeyi SVM içerisindeki C hiperparametresi ile kontrol edebiliriz. Şekil 3.8'de gösterildiği gibi C ne kadar büyükse Marj o kadar dardır.




Şekil 3.8. C hiperparametresinin sınıflandırmaya etkisi (AKÇA, 2020)

Modelin aşırı öğrendiği durumlarda c parametresinin azaltılması gerekmektedir.

3.7.2. K-en yakın komşu (KNN)

KNN algoritması, benzer özelliklere veya değerlere sahip bir nesne kümesinden komşuları bulmak için Öklid mesafesini kullanan tembel bir öğrenme yöntemidir. Algoritma bir eğitim veri kümesi kullanır ve algoritmayı uygulamadan önce parametreleri normalleştirilmiş bir ölçeğe ölçekler. A ve B noktaları arasındaki Öklid mesafesi, denklem 3.13'de açıklandığı gibi bunları birbirine bağlayan doğru parçasının uzunluğudur (Pandey & Jain, 2017).



Şekil 3.9. K-en yakın komşu algoritması öklidyen mesafesi

Sekil 3.9'daki görselde, öklidyen mesafesinin nasıl hesaplandığını göstermektedir. A (2,3) ve B (7,6) noktaları arasındaki doğrusal mesafe (düz çizgi) Öklidyen mesafesi olarak tanımlanır. Bu mesafe, iki nokta arasındaki doğrudan doğrusal uzaklığı temsil etmektedir. KNN algoritmasında, bu mesafe kullanılarak yeni bir veri noktasının en yakın komşuları belirlenir.


$$d(A,B) = \sqrt{(x_1 - x_2)^2 + (y_2 - y_1)^2} \quad (3.13)$$

KNN, basit ve güçlü bir algoritmadır. Doğru K ve mesafe ölçümünün seçilmesi ile çeşitli sınıflandırma ve regresyon problemlerinde etkili olmaktadır.

3.8. Sistem Mimarisi

Duygu tanıma sisteminin ilk adımı, ses sinyalinin alınmasıdır. Kullanıcı tarafından konuşulan veya kaydedilen ses dalgaları, sistem tarafından dijital formata dönüştürülerek analiz edilmeye

hazır hale getirilir. Bu aşamada, kaydedilen sesin kalitesi ve gürültü seviyesinin düşük olması, modelin başarısını doğrudan etkilemektedir. Şekil 3.10.'da sesin sisteme girişinden çıktı olarak duygunun elde edilmesine kadar gerçekleşen sürecin genel mimarisi gösterilmektedir.



Şekil 3.10. Önerilen sistem mimarisi

Ses sinyallerinin doğru bir şekilde analiz edilebilmesi için çeşitli ön işleme teknikleri uygulanır. Ön işleme adımları aşağıdaki gibi sıralanabilir:

Çerçeveleme: Ses sinyali belirli zaman aralıklarına (örneğin, 20-30 ms) bölünerek analiz edilir. Böylece, zaman içerisindeki değişimler daha iyi yakalanabilir (Akkurt, 2019).

Pencereme: Çerçeveleme sonrasında her çerçevenin başı ve sonu arasındaki geçişleri yumuşatmak amacıyla pencereleme işlemi uygulanır. Genellikle Hamming veya Hanning penceresi tercih edilir. Bu adımlar, ses sinyalinin spektral özniteliklerini koruyarak daha doğru öznitelik çıkarımına olanak tanır (Akkurt, 2019).

Öznitelik çıkartımı aşamasında, ses sinyalinden duygu durumunu belirlemede etkili olabilecek önemli akustik öznitelikler belirlenir. Bu sistemde kullanılan temel öznitelikler şunlardır:

Pitch: Sesin temel frekansını belirleyerek kişinin duygu durumunu ifade etmede önemli bir faktördür (Sönmez, 2021).

Loudness (Ses Şiddeti): Konuşma sırasında ses seviyesindeki değişimler, duygusal durumun tespitinde kritik bir rol oynar (Akkurt, 2019).

Jitter ve Shimmer: Sesin kararlılığını ve titreşim seviyelerini belirleyerek stres veya heyecan gibi durumları analiz eder (Demir, 2021) .

MFCC (Mel Frekans Kepstral Katsayıları): Sesin spektral özniteliklerini çıkararak konuşmacının duygularını tespit etmek için en yaygın kullanılan özniteliklerden biridir (Erdem, 2014).

LSP (Line Spectral Pairs): Ses dalgalarının spektral özniteliklerini analiz ederek duygu tanımada önemli katkılar sağlar (Akkurt, 2019).

Öznitelik çıkartımı sonrasında elde edilen geniş veri kümesi, boyut azaltma ve en iyi öznitelik kombinasyonunu belirlemek için önerilen algoritmamız olan HGWSSO algoritması ile GWO ve SS algoritmaları kullanılmıştır. Öznitelik seçiminden sonra çalışmamız, duygu tanıma süreci sınıflandırma aşamasında KNN ve SVM algoritmaları ile sınıflandırma işlemi gerçekleştirilmiştir. Sınıflandırma sonucunda ise ses dosyasından duygu durumları tahmin edilebilmektedir.

3.9. Önerilen Algoritma (HGWSSO Algoritması)

Bu çalışmada, Gri Kurt Optimizasyonu (GWO) algoritmasının lider konumunu güncellemek için Salp Sürüsü Algoritması (SSA)'ndan esinlenen bir yaklaşım kullanılmıştır. Bu yaklaşım, lider kurtun (en iyi çözüm) pozisyonunu güncellerken, rastgelelik ve geniş arama alanı keşfi özniteliklerini birleştirerek daha etkili bir şekilde çözüm uzayını araştırmayı hedeflemektedir. Bu işlem sırasında, belirli olasılıklarla kurtların mevcut lider pozisyonlarına doğru yaklaşması veya ondan uzaklaşması sağlanmaktadır.


Bu yapı, GWO algoritmasında lider kurtun konumunu güncellerken Salp Sürüsü Algoritması'nda olduğu gibi bir rastgelelik bileşeni ekleyerek araştırma (exploration) ve yararlanma (exploitation) arasında bir denge kurar. Kod şu adımlarla çalışır:

1. Rastgele Parametrelerin Üretimi: C1, C2 ve C3, her iterasyonda rastgele üretilen değerlerdir. Bu parametreler, kurtların liderden ne kadar uzakta veya yakında olacağını ve

hangi yöne doğru hareket edeceklerini belirler. Özellikle $C3$ değeri, kurtun lider pozisyonuna yaklaşp yaklaşmayacağını belirlemek için bir karar mekanizması sağlar.

2. Hareket Yönünün Belirlenmesi: Eğer $C3 \geq 0.5$ ise, kurt liderin pozisyonuna bir adım daha yaklaşır (lider pozisyonuna pozitif yönde bir adım atılır). Aksi takdirde, kurt lider pozisyonundan uzaklaşır (negatif yönde bir hareket gerçekleştirilir). Bu adımda, kurtların lider etrafında dengeli bir şekilde dağılması sağlanır ve bu durum algoritmanın geniş bir çözüm uzayını keşfetmesine olanak tanır.
3. Dinamik Güncelleme: Her güncelleme, $C1$ ve $C2$ parametrelerine bağlı olarak dinamik bir şekilde gerçekleştirilir. Bu parametreler kurtların konumlarının belirlenmesinde bir ölçeklendirme faktörü görevi görerek, kurtların hem keşif hem de yararlanma süreçlerini dengeli bir şekilde yürütmelerine olanak tanır.

Bu mekanizma, GWO algoritmasının arama kapasitesini artırır ve yerel çözümlerden kaçınarak daha geniş bir çözüm uzayını keşfetmesini sağlar. Ayrıca, Salp Sürüsü Algoritması'ndan alınan bu yaklaşım, GWO'nun klasik yapısına rastgeleliğe dayalı bir bileşen eklenerek performans artışı hedeflenmiştir. Şekil 3.11.'de önerilen HGWSSO algoritmasının akış şeması gösterilmektedir.



Şekil 3.11. Önerilen HGWSSO algoritma akış şeması

HGWSSO algoritması, GWO ve SSA'nın birbirini tamamlayan özelliklerini bir araya getirerek çalışmaktadır. Aşağıda algoritmanın temel çalışma prensibi açıklanmıştır

3.9.1. Parametrelerin Tanımlanması ve Başlangıç Pozisyonu:

Algoritmanın ilk aşamasında, çözüm uzayındaki bireylerin (kurtlar ve salpler) başlangıç pozisyonları rastgele olarak belirlenir. Bu pozisyonlar, her bir boyut için belirlenen alt sınır (lb) ve üst sınır (ub) değerleri arasında olacak şekilde üretilir. Pozisyonlar denklem 3.14'e göre hesaplanır:

$$X[i, d] = lb_d + (ub_d - lb_d) \cdot \text{rand}() \quad (3.14)$$

Bu formülde: $X[i,d]$, i-inci bireyin d-inci boyuttaki pozisyonunu ifade eder, lb_d ve ub_d d-inci boyutun alt ve üst sınırlarını belirtir, $rand()$, 0 ile 1 arasında rastgele bir sayı üretir. Bu işlem, algoritmanın başlangıçta çözüm uzayını homojen bir şekilde kapsamalarını sağlar. Grey Wolf Optimizer (GWO) algoritmasının liderleri olan alfa (X_α), beta (X_β) ve delta (X_δ), fitness değerine göre en iyi üç bireyi temsil eder. Buna ek olarak, Salp Sürüşü Algoritması'ndan (SSA) alınan lider salp davranışı, liderlerin çözüm uzayında daha geniş çaplı keşif yapmalarına imkan tanır. Bu, algoritmanın çeşitliliğini artırarak yerel minimumlara takılma olasılığını azaltır.

3.9.2. Lider Salp Güncellemesi:

Lider salp pozisyonu, SSA'nın lider güncelleme mekanizması ile rastgele olarak güncellenir. Eğer C_3 parametresi 0.5'ten büyükse lider salp denklem 3.15'e göre, çözüm uzayının pozitif tarafına hareket eder:

$$X[i, d] = X_f[0, d] + C_1 \cdot ((ub_d - lb_d) \cdot C_2 + lb_d) \quad (3.15)$$

Eğer C_3 parametresi 0.5'ten küçük ise lider salp denklem 3.16'ya göre, çözüm uzayının negatif tarafına hareket eder:

$$X[i, d] = X_f[0, d] - C_1 \cdot ((ub_d - lb_d) \cdot C_2 + lb_d) \quad (3.16)$$

$X_f[0,d]$: En iyi liderin d. boyuttaki pozisyonu, C_1 , C_2 ve C_3 0,1 arasında rastgele oluşturulan katsayılardan oluşmaktadır. lb_d, ub_d , Alt ve üst sınırları temsil etmektedir. Bu mekanizma, lider salp'ın pozisyonunu dinamik olarak değiştirerek, algoritmanın çözüm uzayını daha geniş bir alanda keşfetmesini sağlar.

3.9.3. Uzaklık Hesaplamaları (HGWSSO):

HGWSSO'nın liderlik mekanizması, bireylerin liderlere ($X_\alpha, X_\beta, X_\delta$) olan uzaklıklarının hesaplanmasına dayanır. Uzaklıklar, bireyin mevcut pozisyonu ve liderlerin pozisyonu arasındaki mutlak fark kullanılarak denklem 3.17, 3.18, 3.19'a göre hesaplanır:

$$D_\alpha = |C_1 \cdot X_\alpha - X[i, d]| \quad (3.17)$$

$$D_\beta = |C_2 \cdot X_\beta - X[i, d]| \quad (3.18)$$

$$D_\delta = |C_3 \cdot X_\delta - X[i, d]| \quad (3.19)$$

Burada: D_α , D_β , D_δ bireylerin sırasıyla alfa, beta ve delta liderlerine olan uzaklıklarını ifade eder. C_1 , C_2 , C_3 uzaklık hesaplamalarını çeşitlendirmek için kullanılan rastgele katsayılarıdır.

Bu uzaklık hesaplamaları, bireylerin liderlere doğru hareketini kontrol eder ve HGWSSO algoritmasının hızlı yakınsamayı gerçekleştirmesine olanak tanır.

3.9.4. Yeni Pozisyon Güncellemeleri:

Bireylerin yeni pozisyonları, liderlere olan uzaklıkları ve bu uzaklıklara dayalı olarak hesaplanan parametrelerle güncellenir. Yeni pozisyonlar 3.20, 3.21, 3.22 ve 3.23'e göre hesaplanır:

$$X_1 = X_\alpha - A_1 \cdot D_\alpha \quad (3.20)$$

$$X_2 = X_\beta - A_2 \cdot D_\beta \quad (3.21)$$

$$X_3 = X_\delta - A_3 \cdot D_\delta \quad (3.22)$$

$$X[i, d] = \frac{X_1 + X_2 + X_3}{3} \quad (3.23)$$

Burada:

X_1 , X_2 , X_3 , bireyin liderlere dayalı hareketine göre yeni pozisyonları temsil etmektedir. A_1 , A_2 , A_3 , keşif ve sömürü süreçlerini kontrol eden doğrusal katsayılarıdır ($A=2a \cdot \text{rand}() - a$). D_α , D_β ve D_δ ise liderlere olan uzaklıklardır. Bu güncelleme, bireylerin liderlere doğru dengeli bir şekilde yakınsamalarını sağlar.

3.9.5. Keşif ve Sömürü Dengesi:

GWO'nun lineer kontrol parametresi (α) denklem 3.24'e göre, keşif ve sömürü süreçlerini dengelemek için iterasyonlar boyunca kademeli olarak azaltılır:

$$\alpha = 2 - t \cdot \left(\frac{2}{\text{max_iter}} \right) \quad (3.24)$$

Burada; t : Mevcut iterasyon, max_iter : Maksimum iterasyon sayısıdır. max_iter 'a yaklaşıldıkça α 'nın değeri azalır, böylece algoritma keşiften sömürüye geçiş yapmaktadır.

3.9.6. Fitness Değerlendirmesi ve Lider Güncellemesi:

Her iterasyonda, bireylerin performansı bir fitness fonksiyonu ile değerlendirilir. En iyi üç birey, liderler (X_α , X_β , X_δ) olarak seçilir ve bu liderler bir sonraki iterasyonda sürüyü yönlendirmek için kullanılır.

3.9.7. Sınır Kontrolü ve Binarizasyon:

Yeni pozisyonlar, alt ve üst sınırları aşmayacak şekilde kontrol edilir ve normalize edilir. Eğer algoritma, öznitelik seçimi gibi ikili (binary) bir problem üzerinde çalışıyorsa, bireylerin pozisyonları bir eşik değeri (thres) kullanılarak denklem 3.25'teki gibi ikili forma dönüştürülür:

$$X_{\text{binary}}[i, d] = \begin{cases} 1, & \text{eğer } X[i, d] > \text{thres} \\ 0, & \text{aksi takdirde} \end{cases} \quad (3.25)$$

3.9.8. Sonuçların Elde Edilmesi:

İterasyonlar tamamlandığında, algoritma en iyi çözümü ve bu çözümün fitness değerini döndürür. Önerilen HGWSSO algoritması GWO'nun liderlik mekanizmasını SSA'nın lider salp davranışıyla birleştirerek optimizasyon problemlerinde etkili ve hızlı çözümler sunar. HGWSSO algoritması güçlü keşif yeteneği, geniş çözüm uzaylarını tarayarak daha kaliteli çözümler bulmasını sağlar. Aynı zamanda, sömürü süreçleriyle çözüm hassasiyeti artırılır ve algoritmanın yakınsama hızı optimize edilir. Bu özellikler, hibrit algoritmayı karmaşık optimizasyon problemleri için güçlü bir araç haline getirir. Çizelge 3.5.'de önerilen HGWSSO algoritmasının kaba kodu gösterilmektedir.

Çizelge 3.5. Önerilen HGWSSO algoritma kaba kod

No	Adımlar
1.	Hibrit popülasyonu X_i ($i = 1, 2, \dots, n$) ayarla
2.	a , A ve C' yi ayarla
3.	Her arama ajanının uygunluk (fitness) değerini hesapla
4.	X_α = en iyi arama ajanı
5.	X_β = ikinci en iyi arama ajanı
6.	X_δ = üçüncü en iyi arama ajanı

```
7.    t = 0
8.    while (t < Maksimum iterasyon sayısı) do
9.        for her arama ajanı do
10.            eğer(c3>=0.5) ise
11.                Mevcut arama ajanının konumunu Denklem (3.15) ile güncelle
12.            eğer(c3<0.5) ise
13.                Mevcut arama ajanının konumunu Denklem (3.16) ile güncelle
14.                Mevcut arama ajanının konumunu Denklem (3.7) ile güncelle
15.        end for
16.        a, A ve C değerlerini güncelle
17.        Tüm arama ajanlarının uygunluk değerini hesapla
18.         $X\alpha$ ,  $X\beta$  ve  $X\delta$  değerlerini güncelle
19.        t = t + 1
20.    end while
21.    return  $X\alpha$ 
```

4. BULGULAR VE TARTIŞMA


Geliştirilen algoritmamız farklı veri üzerinde 30 arama ajanı ile 1000 iterasyon olacak şekilde KNN ve SVM sınıflandırıcılar ile çalıştırılmıştır. Çalışmamız EmoDB, SAVEE, eINTERFACE ve EMOVA veri setleri üzerinde test edilmiştir. Bu veri setleri üzerinde her iki sınıflandırıcı için elde edilen karışıklık matris değerleri, yakınsama eğrisi, doğruluk oranı ve öznelite sayısı gibi sonuçlar analiz edilmiştir.

4.1. EmoDB Veri Setine Ait Sonuçlar

EmoDB veri seti kullanılarak farklı optimizasyon algoritmalarıyla iyileştirilmiş SVM ve KNN tabanlı sınıflandırıcıların performansları karşılaştırılmıştır. Kullanılan algoritmalar arasında GWO , SSA ve hibrit algoritma yer almaktadır. Elde edilen karmaşıklık matrislerine göre, algoritmaların farklı duygu sınıflarında gösterdiği performans detaylı bir şekilde incelenmiştir.

4.1.1. KNN sınıflandırıcı sonuçları

Şekil 4.1.'de, GWO, SSA ve HGWSSO algoritmalarına ait KNN sınıflandırıcı ile elde edilen karışıklık matrisleri gösterilmiştir. Her bir matris, algoritmaların sınıflandırma performansını gerçek etiketler ile tahmin edilen etiketler arasındaki ilişkiyi kullanarak analiz etmektedir.



Şekil 4.1. EmoDB veri setinde KNN sınıflandırıcı ile elde edilen karışıklık matris değerleri (0=Happiness 1=Neutral 2=Anger 3=Sadness 4=Anxiety/Fear 5=Boredom 6=Disgust)

GWO algoritmasının karışıklık matris sonuçlarına göre, model özellikle Anger (2) ve Neutral (1) sınıflarında başarılı tahminler yapmıştır. Anger (2) sınıfında 36 doğru tahmin varken, Neutral (1) sınıfında 23 doğru tahmin elde edilmiştir. Sadness (3) ve Boredom (5) sınıfları da 18 ve 23 doğru tahmin ile nispeten iyi sınıflandırılmıştır. Ancak, Happiness (0) sınıfı 7 kez Neutral (1) sınıfı ile karışmış, bu da modelin bu iki sınıfı birbirinden ayırt etmekte zorlandığını göstermektedir. Sadness, Anxiety/Fear, Boredom ve Disgust (6) sınıflarında ise 1'er örneğin diğer sınıflara kaydığı görülmektedir.


SSA algoritmasının performansı incelendiğinde, en az karmaşıklığı Sadness (3) sınıfında yaptığı görülmektedir. Anger (2) için 34 doğru tahmin yapılırken, Neutral (1) için 21 doğru tahmin yapılmıştır. Bununla birlikte, Sadness (3) ve Anxiety/Fear (4) sınıflarında hatalar mevcuttur. Anxiety/Fear (4) sınıfında 5 yanlış tahmin yapılmış ve bunların çoğu Disgust (6) sınıfına karışmıştır. Bu da modelin bu iki sınıfı birbirinden ayırt etmekte zorlandığını göstermektedir. Disgust (6) sınıfında ise yalnızca 10 doğru tahmin yapılmış ve yanlış sınıflandırma oranı diğer algoritmalarla göre daha yüksektir.

HGWSSO algoritması, genel olarak en iyi performansı göstermiştir. Anger (2) sınıfında 37 doğru tahminle en yüksek doğruluğa ulaşılmıştır. Ayrıca, Neutral (1) sınıfında 23, Sadness (3) sınıfında 19 ve Boredom (5) sınıfında 22 doğru tahmin yapılmıştır. Happiness (0) sınıfında ise 17 doğru tahminle diğer algoritmalarla daha iyi bir sonuç elde edilmiştir. Disgust (6) sınıfında 12 doğru tahmin yapılmış olup, yanlış sınıflandırma oranı SSA algoritmasına göre daha düşük olmuştur. Genel olarak, HGWSSO algoritması tüm sınıflarda dengeli bir performans sergilemiştir.

Happiness (0) sınıfı için en yüksek doğruluk HGWSSO algoritmasında elde edilmiştir (17 doğru tahmin). GWO algoritması 14 doğru tahmin yaparken, SSA algoritması ise 15 doğru tahmin ile orta seviyede kalmıştır. Neutral (1) sınıfında, GWO ve HGWSSO algoritmaları 23 doğru tahmin yaparak en iyi sonucu elde etmiştir, SSA algoritması ise 21 doğru tahmin ile biraz daha düşük performans göstermiştir. Anger (2) sınıfında HGWSSO en iyi sonucu veren algoritma olmuştur (37 doğru tahmin). GWO algoritması 36, SSA algoritması ise 34 doğru tahmin yapmıştır. Sadness (3) sınıfı için ise HGWSSO (19 doğru tahmin) en iyi sonucu elde etmiş, GWO (18 doğru tahmin) ikinci sırada yer almış ve SSA (17 doğru tahmin) en düşük performansı göstermiştir.

Anxiety/Fear (4) sınıfında, GWO ve HGWSSO algoritmaları 20 ve 18 doğru tahminle benzer performans göstermiştir, ancak SSA algoritması 16 doğru tahmin yaparak bu sınıfta en düşük başarıyı göstermiştir. Boredom (5) sınıfında, HGWSSO algoritması 22 doğru tahmin yaparak en başarılı algoritma olurken, GWO algoritması 23 ve SSA algoritması 20 doğru tahmin yaparak benzer performans göstermiştir. Disgust (6) sınıfında ise GWO algoritması 13, HGWSSO algoritması 12 ve SSA algoritması 10 doğru tahmin yaparak sıralanmıştır.

Elde edilen sonuçlar değerlendirildiğinde, HGWSSO algoritması genel olarak en iyi performansı göstermiştir. Anger, Neutral, Sadness ve Boredom sınıflarında diğer algoritmalara göre daha yüksek doğruluk elde edilmiştir. GWO algoritması ise bazı sınıflarda iyi performans gösterse de Happiness ve Disgust sınıflarında hatalar yapmıştır. SSA algoritması ise Anxiety/Fear ve Disgust sınıflarında en fazla hata yapan model olmuştur.



Şekil 4.2. EmoDB veri setinde KNN sınıflandırıcı ile elde edilen yakınsama eğrisi

Şekil 4.2.'de görülen yakınsama eğrisi, Gri Kurt Optimizasyonu (GWO), Salp Sürüsü Algoritması (SSA) ve Hibrit algoritmanın EmoDB veri seti üzerinde KNN sınıflandırıcısı kullanılarak elde edilen sonuçlar karşılaştırılmaktadır. Yatay eksen iterasyon sayısını, dikey eksen ise her iterasyon sırasında algoritmaların uygunluk fonksiyonu değerini göstermektedir.

GWO algoritması, hızlı bir başlangıç yakınsama eğilimi sergilemektedir. İlk birkaç iterasyon içinde uygunluk fonksiyonunda önemli bir düşüş yaşanmış ve yaklaşık 150. iterasyondan sonra daha yavaş bir yakınsamaya girmiştir. GWO'nun hızlı bir şekilde çözüme yaklaşma kabiliyeti, yerel çözümlere hızlı bir şekilde ulaşma eğiliminde olduğunu göstermektedir. Ancak, yaklaşık 750. iterasyondan itibaren uygunluk fonksiyonundaki iyileşme neredeyse tamamen durmuştur, bu da algoritmanın potansiyel olarak daha iyi bir global minimum bulma yeteneğinin sınırlı olabileceğini işaret etmektedir.

SSA, grafikte daha sabit bir eğri profili sergilemektedir. İlk iterasyonlarda hızlı bir yakınsama gözlemlenmemiştir ve uzun bir süre boyunca uygunluk değeri neredeyse sabit kalmıştır. SSA, diğer iki algoritmaya kıyasla çok daha az dalgalanma göstermekte ve uygunluk fonksiyonunu iyileştirme hızı oldukça düşüktür. Bu sonuç, SSA'nın geniş bir arama alanını daha uzun süre taradığı, ancak yerel çözümlere hızlı bir şekilde yaklaşımda yetersiz kaldığını ortaya koymaktadır.

HGWSSO algoritma, başlangıçta GWO'ya yakın yakınsama değerleri elde etse de 100. İterasyondan itibaren yavaşlama eğilimine geçmiş 900. İterasyondan itibaren hızlı bir yakınsama eğilimi yaparak GWO'yu geride bırakmıştır. HGWSSO algoritması, ilerleyen iterasyonlarda daha düşük uygunluk değerlerine ulaşarak genel performansta en iyi sonuçları elde etmiştir. Bu durum, HGWSSO algoritmasının, keşif ve yararlanma süreçlerini dengeli bir şekilde yürüttüğünü ve global çözüme ulaşma potansiyelinin yüksek olduğunu göstermektedir.

Çizelge 4.1.'de, GWO, SSA ve HGWSSO algoritmalarının sınıflandırma performansını özetleyen çeşitli metrikleri göstermektedir. Bu metrikler, öznelite sayısı, doğruluk, kesinlik, duyarlılık ve F1 skor'u içermektedir.

Çizelge 4.1. EmoDB veri setinde KNN sınıflandırıcı ile elde edilen metrik değerleri

	Öznelite Sayısı	Doğruluk	Kesinlik	Duyarlılık	F1 Skor
GWO	198	91.30	91.64	91.30	91.15
SSA	765	82.61	83.03	82.61	82.68
HGWSSO	586	91.93	92.56	91.93	91.88

Çizelge 4.1.'de, her bir yöntemin sahip olduğu öznitelik boyutu, doğruluk, kesinlik, duyarlılık ve F1 skoru değerleri verilmiştir. Öznitelik boyutları incelendiğinde, SSA'nın 765 ile en yüksek öznitelik sayısına sahip olduğu görülmektedir. Buna karşın, GWO 198 öznitelik kullanarak en düşük boyutta bir öznitelik kümesi elde etmişken, HİBRİT yöntemi 586 öznitelik ile bu iki yöntem arasında bir noktada yer almaktadır. Bu durum, algoritmaların veri boyutunu nasıl ele aldığını ve hangi seviyede öznitelik seçimi gerçekleştirdiğini göstermektedir.


Doğruluk değerleri açısından bakıldığında, SSA %82,60 doğruluk ile en düşük performansı sergilemektedir. Bu, daha yüksek sayıda öznitelik kullanılmasına rağmen, SSA'nın diğer yöntemler kadar etkili bir performans gösteremediğini ifade etmektedir. GWO, %91,30 doğruluk ile dikkat çeken bir performans ortaya koymaktadır. Bu, daha az öznitelik kullanarak yüksek doğruluk elde etmesiyle, algoritmanın etkili bir seçim yapabildiğini göstermektedir. HİBRİT yöntemi ise, %91,92 doğruluk değeriyle en iyi sonucu elde etmiştir. Bu da, farklı algoritmaların birleşiminin daha etkili bir genelleme yeteneği sağladığını ortaya koymaktadır. Kesinlik değerleri açısından bakıldığında, SSA %83,02 ile en düşük değeri alırken, GWO %91,64 ve HİBRİT %92,55 kesinlik oranıyla oldukça yüksek değerlere sahiptir. Kesinlik, yanlış pozitiflerin azaltılması açısından önemli bir metrik olduğundan, HGWSSO algoritması burada en başarılı sonuçları elde etmiştir.

Duyarlılık açısından da benzer bir tablo söz konusudur. SSA %82,60 duyarlılık ile düşük bir değer elde ederken, GWO %91,30 ve HGWSSO %91,92 duyarlılık değeri ile öne çıkmaktadır. Bu durum, HGWSSO algoritmasının hem yanlış pozitifleri hem de yanlış negatifleri en aza indirme konusunda dengeli bir performans sergilediğini göstermektedir. F1 skoru, kesinlik ve duyarlılığı birleştirerek daha genel bir değerlendirme sağlar ve burada da SSA %82,61 ile en düşük değeri alırken, GWO %91,15 ve HGWSSO %91,87 ile yine öne çıkan değerlerdedir. Özellikle HGWSSO yöntemi, tüm metriklerde en yüksek değerlere ulaşarak, kesinlik ve duyarlılık arasında iyi bir denge sağladığını ve genel performans açısından üstün olduğunu göstermektedir.

Bu verilerden yola çıkarak, GWO ve HGWSSO yöntemlerinin SSA'ya kıyasla çok daha verimli oldukları sonucuna varılabilir. Özellikle HGWSSO yöntemi, doğruluk, kesinlik, duyarlılık ve F1 skoru açısından en iyi sonuçları elde ederek üstün bir performans sergilemiştir. SSA'nın yüksek öznitelik boyutuna rağmen daha düşük metrik değerleri sunması, bu algoritmanın öznitelik seçimi açısından verimsiz olduğunu ortaya koymaktadır. GWO ise, daha az öznitelik

kullanarak başarılı bir performans sergileyerek, verimlilik ve etkinlik açısından öne çıkmaktadır. Sonuç olarak, HGWSSO yöntemi, algoritmaların iyi yönlerini birleştirerek daha dengeli ve etkili bir çözüm sunmaktadır. Bu bağlamda, HGWSSO yöntemi genel performans açısından daha tercih edilebilir ve uygulanabilir bir seçenek olarak değerlendirilebilir.

Şekil 4.3’de EmoDB veri setinde KNN sınıflandırıcı ile elde edilen öznitelik sayıları ve doğruluk oranları gösterilmiştir.




Şekil 4.3. EmoDB veri setinde KNN sınıflandırıcısında öznitelik sayısı ve doğruluk oranı karşılaştırma

SSA algoritması en fazla öznitelik boyutuna (765) sahip olmasına rağmen, doğruluk oranı %82,6 olarak elde edilmiştir. Bu, özniteliklerin fazlalığının her zaman daha iyi performansa neden olmadığını göstermektedir. GWO ise en az sayıda öznitelik (198) kullanmasına rağmen, doğruluk oranı %91,3, yani SSA'dan çok daha yüksektir. Bu, GWO'nun daha etkili bir öznitelik seçimi yaptığını ve gereksiz öznitelikleri eleyerek daha iyi bir doğruluk sağladığını göstermiştir. HGWSSO algoritması 586 öznitelik boyutuyla GWO'ya göre yüksek SSA'ya göre düşük öznitelik sayısı elde edilmiştir. Bununla birlikte, doğruluk oranı %91,9, yani en yüksek doğruluğa sahip olmuştur. Bu da hibrit yaklaşımın öznitelik boyutuyla doğruluk arasında denge sağlayarak en iyi performansı elde ettiğini göstermektedir.

4.1.2. SVM sınıflandırıcı sonuçları

Şekil 4.4.'de, GWO, SSA ve HGWSSO algoritmalarına ait SVM sınıflandırıcı ile elde edilen karışıklık matrisleri gösterilmiştir.




Şekil 4.4. EmoDB veri setinde SVM sınıflandırıcı ile elde edilen karışıklık matris değerleri (0=Happiness 1=Neutral 2=Anger 3=Sadness 4= Anxiety/Fear 5=Boredom 6=Disgust)

GWO algoritması, özellikle Neutral(1), Anger (2), Sadness(3) sınıflarında en yüksek doğruluğu (%100'e yakın bir oranla) sağlamış ve Anxiety/Fear sınıfı hariç diğer tüm sınıflarda SSA'dan daha iyi sonuçlar vermiştir. Ayrıca, Neutral (Nötr) ve Sadness (Üzüntü) sınıflarında da tatmin edici bir performans sergilemiştir. Bununla birlikte, Happiness, Anxiety/Fear ve Boredom sınıflarında doğru sınıflama oranı HGWSSO'dan daha düşük kalmıştır. Genel olarak, GWO algoritması Happiness ve Anger sınıfları hariç diğer sınıflarda güçlü sonuçlar üretmiş,

SSA algoritması Anxiety/Fear, Boredom ve Disgust sınıflarında GWO ile benzer bir doğruluk oranına ulaşmasına rağmen Happiness (Mutluluk) sınıfında belirgin bir şekilde daha düşük performans göstermiştir. Yanlış sınıflamaların büyük bir kısmının Anger sınıfına kayması, Happiness sınıfının özelliklerinin diğer sınıflarla karışabilir yapıda olduğunu işaret etmektedir. Benzer şekilde, Disgust sınıfında düşük doğru sınıflama oranı SSA'nın da bu sınıfta yetersiz kaldığını göstermektedir. SSA, belirli sınıflar için makul bir doğruluk sağlamış olsa da Happiness ve Anger sınıflarındaki performans düşüklüğü algoritmanın geliştirilmesi gerektiğini ortaya koymaktadır.

Önerilen HGWSSO algoritması, sınıflar arası dengesizliği azaltarak genel doğruluk oranını artırmayı başarmıştır. Anger sınıfında 38 doğru sınıflama ile bu sınıfta en iyi sonucu sağlamış, ayrıca Happiness, Neutral, ve Disgust sınıflarında 1'er örnek başka sınıflarla karışmasına rağmen diğer sınıflarda ise %100 doğruluk oranı elde etmiştir. HGWSSO algoritması, özellikle Boredom (Can Sıkıntısı) sınıfında en yüksek doğru sınıflama oranına (24) ulaşarak, bu sınıfta diğer algoritmalarından daha iyi bir performans sunmuştur. HGWSSO algoritmasının başarısı, farklı optimizasyon yaklaşımlarının güçlü yönlerini bir araya getirerek daha tutarlı ve istikrarlı bir performans sağlamasından kaynaklanmaktadır.

Genel olarak, GWO ve SSA algoritmaları belirli sınıflarda iyi sonuçlar üretse de sınıflar arası performans farklılıkları dikkat çekmektedir. HGWSSO algoritması ise tüm sınıflar arasında daha dengeli bir dağılım sergilemiş ve yüksek doğruluk oranı ile üstünlük sağlamıştır. HGWSSO algoritmasının başarısı ise bu alanda daha karmaşık optimizasyon yöntemlerinin uygulanabilirliğini ve etkinliğini göstermektedir.



Şekil 4.5. EmoDB veri setinde SVM sınıflandırıcı ile elde edilen yakınsama eğrisi

Şekil 4.5’de görüldüğü gibi GWO algoritmasının yakınsama eğrisi, başlangıçta hızlı bir düşüş göstermekte ve iterasyon ilerledikçe daha yavaş bir azalma eğilimine girmektedir. İlk 200 iterasyonda yakınsama değeri önemli ölçüde düşmüş ve yaklaşık 0,05 değerine ulaşmıştır. Daha sonraki iterasyonlarda GWO’nun iyileştirme kapasitesinin azaldığı ve eğrinin daha sabit bir

hale geldiği görülmektedir. Bu, GWO algoritmasının hızlı bir başlangıç yaptığı ancak optimum çözüme ulaşma konusunda son aşamalarda yavaşladığını göstermektedir.

SSA algoritmasının yakınsama eğrisi, başlangıçta diğer algoritmalarla kıyasla daha yavaş bir düşüş eğilimi sergilemektedir. Yaklaşık 300 iterasyondan sonra eğri, neredeyse sabit bir hale gelmiş ve yakınsama değeri 0,08 civarında sabitlenmiştir. Bu durum, SSA algoritmasının hedef çözümüne ulaşma sürecinde daha düşük bir iyileştirme hızıyla ilerlediğini göstermektedir. SSA'nın iterasyon sayısı arttıkça performansının stabilize olması, algoritmanın optimuma ulaşma yeteneğinin sınırlı olduğunu düşündürmektedir.

HGWSSO algoritması, yakınsama eğrisinde en hızlı ve en etkili düşüşü sergileyen yöntem olarak öne çıkmaktadır. İlk 150 iterasyonda, GWO'dan daha hızlı bir şekilde yakınsama değeri 0,04'ün altına düşmüştür. Eğri, sonraki iterasyonlarda daha yavaş bir iyileşme göstermiş olsa da, diğer algoritmalarla kıyasla daha düşük bir yakınsama değeri ile sonlanmıştır. HGWSSO algoritmasının bu performansı, farklı algoritmaların güçlü yönlerini birleştirerek daha hızlı ve kesin sonuçlar üretebildiğini kanıtlamaktadır.

Yakınsama eğrisine dayanarak, HGWSSO algoritması en hızlı ve etkili optimizasyonu sağlayarak diğer algoritmaların önüne geçmiştir. GWO algoritması hızlı bir başlangıç yapmış, ancak optimum çözüme ulaşma konusunda daha sınırlı bir performans sergilemiştir. SSA algoritması ise daha yavaş bir başlangıç yapmış ve düşük bir iyileşme hızıyla diğer algoritmaların gerisinde kalmıştır. Bu analiz, HGWSSO algoritmasının SVM sınıflandırıcısı için optimizasyon sürecinde hem hız hem de doğruluk açısından üstün olduğunu göstermektedir.

Çizelge 4.2. EmoDB veri setinde SVM sınıflandırıcı ile elde edilen metrik değerleri

	Öznitelik Sayısı	Doğruluk	Kesinlik	Duyarlılık	F1 Skor
GWO	124	96.89	97.01	96.89	96.88
SSA	760	91.30	91.62	91.30	91.29
HGWSSO	137	98.14	98.22	98.14	98.13

Çizelge 4.2.'deki veriler, EmoDB veri setinde SVM sınıflandırıcı ile üç farklı optimizasyon algoritmasının (SSA, GWO ve HGWSSO) performans ölçümlerini karşılaştırmaktadır.

Değerlendirme ölçütleri arasında öznitelik sayısı, doğruluk, kesinlik, duyarlılık ve F1 skor bulunmaktadır. Bu metrikler, her algoritmanın sınıflandırma yeteneğini ayrıntılı bir şekilde ortaya koymaktadır.

SSA algoritması ile diğer iki algoritmaya kıyasla en yüksek öznitelik boyutu (760) elde edilmiştir. Ancak, doğruluk (%91,30), kesinlik (%91,62), duyarlılık (%91,30) ve F1 skoru (%91,29) açısından daha düşük bir performans sergilemiştir. Öznitelik boyutunun yüksek olması, SSA algoritmasının gereksiz veya tekrarlayan öznitelikleri işleme dahil ettiğini ve bu durumun performansı sınırladığını göstermektedir. SSA'nın daha düşük doğruluk ve diğer metrik değerleri, bu algoritmanın EmoDB veri setindeki duygu sınıflandırma görevlerinde daha az etkili olduğunu işaret etmektedir.


GWO algoritması, özniteliklerin boyutunu oldukça düşük bir seviyeye (124) indirerek daha az bir öznitelik kümesi ile çalışmıştır. Bu durum, algoritmanın sınıflandırma için en uygun öznitelikleri seçmekte etkili olduğunu göstermektedir. Doğruluk oranı %96,89 ile yüksek bir seviyeye ulaşmış, kesinlik (%97,01), duyarlılık (%96,89) ve F1 skoru (%96,88) ile istikrarlı bir performans sergilemiştir. GWO algoritmasının düşük öznitelik boyutuna rağmen yüksek doğruluk sağlaması, bu yöntemle yapılan öznitelik seçiminin başarılı olduğunu göstermektedir.

HGWSSO algoritması, diğer iki algoritmaya kıyasla en iyi performansı sergileyen yöntem olmuştur. Öznitelik boyutu 137 ile GWO'ya yakın bir seviyede tutulmuş, ancak doğruluk oranı %98,14 ile tüm algoritmalar arasında en yüksek seviyeye ulaşmıştır. Kesinlik (%98,22), duyarlılık (%98,14) ve F1 skoru (%98,13) metriklerinde de üstün sonuçlar elde edilmiştir. HGWSSO algoritmasının başarısı, farklı optimizasyon yöntemlerinin güçlü yönlerini birleştirerek öznitelik seçiminde daha etkili ve duygu sınıflandırmasında daha doğru sonuçlar üretmesinden kaynaklanmaktadır. Bu durum, hibrit yaklaşımın sadece doğruluk açısından değil, genel performans metriklerinde de üstünlük sağladığını ortaya koymaktadır.

Çizelge 4.2.'deki sonuçlar, öznitelik seçiminin sınıflandırma başarısındaki kritik rolünü açıkça göstermektedir. SSA algoritması, en yüksek öznitelik boyutuyla çalışmış ve nispeten düşük bir doğruluk sağlamıştır. Bu durum, daha fazla özelliğin her zaman daha iyi bir sınıflandırma performansı anlamına gelmediğini ortaya koymaktadır. GWO ve HGWSSO algoritmaları, daha az öznitelik kullanarak daha yüksek doğruluk ve diğer metriklerde üstün sonuçlar elde etmiştir. Özellikle HGWSSO algoritması, tüm metriklerde en iyi sonuçları sağlamış ve sınıflar arası

ayırım gücünün yüksek olduğunu kanıtlamıştır. Bu analiz, HGWSSO algoritmasının EmoDB veri setinde duygu sınıflandırma görevleri için en etkili yöntem olduğunu göstermektedir.

Şekil 4.6’da EmoDB veri setinde SVM sınıflandırıcı ile elde edilen öznelik sayıları ve doğruluk oranları gösterilmiştir.



Şekil 4.6. EmoDB veri setinde SVM sınıflandırıcısında öznelik sayısı ve doğruluk oranı karşılaştırma

Şekil 4.6.’da görüldüğü üzere daha fazla özelliğin her zaman daha yüksek doğruluk sağlamadığını açıkça göstermektedir. SSA algoritmasının geniş bir öznelik boyutuyla çalışmasına rağmen düşük doğruluk oranı elde etmesi, öznelik seçiminin etkisizliğini vurgulamaktadır. GWO ve HGWSSO algoritmaları, öznelik boyutunu ciddi ölçüde düşürerek hem işlem yükünü azaltmış hem de doğruluk oranını artırmıştır. Özellikle HGWSSO algoritma, düşük öznelik boyutunda en yüksek doğruluk oranına ulaşarak optimizasyon başarısını ortaya koymaktadır. Bu sonuçlar, HGWSSO algoritmasının hem sınıflandırma doğruluğunu artırma hem de daha az öznelik kullanarak işlem maliyetini azaltma potansiyeline sahip olduğunu göstermektedir.


4.2. EMOVA Veri Setine Ait Sonuçlar

EMOVA veri seti kullanılarak KNN ve SVM sınıflandırıcıları ile elde edilen sınıflandırma sonuçları, GWO, SSA ve HGWSSO algoritmaları kullanılarak optimize edilmiştir. Karmaşıklık

matrislerine dayalı olarak, algoritmaların her bir duygu sınıfındaki başarısı değerlendirilmiştir. Bu duygu sınıfları arasında Disgust (0), Joy (1), Neutral (2), Anxiety/Fear (3), Anger (4), Surprise (5) ve Sadness (6) bulunmaktadır. Sınıflandırma sonuçları, duygu kategorileri arasındaki ayrımın algoritmalara göre nasıl değiştiği bu bölümde anlatılmıştır.

4.2.1. KNN sınıflandırıcı sonuçları

Şekil 4.7.'de EMOVA veri setinde Knn sınıflandırıcı ile elde edilen karışıklık matris değerleri gösterilmektedir.



Şekil 4.7. EMOVA veri setinde KNN sınıflandırıcı ile elde edilen karışıklık matris değerleri (0=Disgust, 1=Joy, 2=Neutral 3=Anxiety/Fear, 4=Anger, 5=Suprise, 6=Sadness)


GWO algoritmasıyla optimize edilen KNN sınıflandırıcısı, bazı sınıflarda yüksek doğruluk oranlarına ulaşırken diğerlerinde sınırlı bir performans sergilemiştir. Joy (1) ve Neutral (2) sınıflarında sırasıyla 20 ve 21 doğru sınıflama yapılmıştır. Anxiety/Fear (3) sınıfında 17 doğru sınıflama yapılmış ve az sayıda örnek diğer sınıflara karışmıştır. Sadness (6) sınıfında ise 12 doğru sınıflama yapılmış, bu da HGWSSO algoritmasına kıyasla bu sınıfta düşük bir doğruluk oranı sunduğunu göstermektedir. Özellikle Suprise (5) ve Sadness (6) sınıflarında yanlış sınıflama oranlarının yüksek olması dikkat çekmektedir.

SSA algoritması, özellikle Anxiety/Fear (3) ve Joy (1) sınıflarında daha yüksek doğruluk oranlarına ulaşmıştır. Bu sınıflarda sırasıyla 19 ve 18 doğru sınıflama yapılmıştır. Bu sınıflardaki karmaşıklık değerlerinin diğer sınıflara oranla daha az öldüğü görülmektedir. Neutral (2) sınıfında ise 14 doğru sınıflama yapılmış ve bu sınıfın öznelikleri kısmen iyi

ayrıştırılmıştır. Bununla birlikte, Disgust (0) sınıfında yanlış sınıflamalar önemli ölçüde artmış ve örneklerin diğer sınıflara kaydığı görülmüştür. Sadness (6) sınıfında 8 doğru sınıflama yapılmış, bu da diğer yöntemlere kıyasla düşük bir başarı göstermektedir. SSA algoritması, Anxiety/Fear (3) sınıfında GWO'dan daha başarılı olsa da Disgust ve Sadness sınıflarındaki düşük performansıyla sınıflar arası ayırırda yeterli sonuçlar sağlayamamıştır.

HGWSSO algoritması, diğer iki optimizasyon yöntemine kıyasla daha dengeli bir performans sergilemiştir. Özellikle Neutral (2), Anxiety/Fear (3) ve Anger (4) sınıflarında sırasıyla 17, 21 ve 20 doğru sınıflama yaparak dikkat çekmiştir. Bununla birlikte, Disgust (0) sınıfında 18 doğru sınıflama yapılmış, ancak bu sınıfta diğer sınıflarla karışıklık oranı tamamen azalmamıştır. Sadness (6) sınıfında 17 doğru sınıflama yapılarak SSA ve GWO algoritmalarına kıyasla daha iyi bir performans sergilenmiştir. HGWSSO algoritması, tüm sınıflar arasında en dengeli performansı sağlayarak sınıflar arası tutarlılığı artırmıştır. Ancak Surprise (5) sınıfında GWO algoritmasına kıyasla belirgin bir üstünlük sağlamamıştır.

Bu bölümde elde edilen sonuçlar, duygu sınıflandırmasında farklı algoritmaların belirli sınıflar için farklı düzeylerde performans gösterdiğini ortaya koymaktadır. GWO algoritması, Joy ve Neutral sınıflarında iyi bir doğruluk oranı sağlasa da Anxiety/Fear ve Sadness sınıflarındaki düşük doğruluk oranları nedeniyle sınıf dengesini yeterince sağlayamamıştır. SSA algoritması, özellikle Anxiety/Fear ve Joy sınıflarında iyi bir performans sergilemiş olsa da Disgust ve Sadness sınıflarındaki doğruluk oranlarını artırmakta zorluk çekmiştir. HGWSSO algoritması ise genel doğruluk oranlarını artırarak daha dengeli bir performans sergilemiş, ancak bazı sınıflarda (örneğin, Surprise) GWO algoritmasına benzer bir doğruluk oranına sahip olmuştur.



Şekil 4.8. EMOVA veri setinde KNN sınıflandırıcı ile elde edilen yakınsama eğrisi

Şekil 4.8.'de, EMOVA veri setinde KNN sınıflandırıcısı için kullanılan GWO, SSA ve HGWSSO algoritmalarının yakınsama süreçlerini karşılaştırmaktadır. Yatay eksen iterasyon sayısını, dikey eksen ise her algoritmanın yakınsama değerini temsil etmektedir. Bu grafik, algoritmaların hedef çözüme ulaşmadaki hızını ve son yakınsama değerini göstermektedir.

GWO algoritması, başlangıç iterasyonlarından itibaren hızlı bir iyileşme sürecine girmiştir. İlk 200 iterasyon boyunca yakınsama değerinde belirgin bir azalma gözlemlenmiştir. Bu hızlı başlangıç, algoritmanın optimize edilmiş öznitelik seçiminde etkili bir başlangıç performansı sunduğunu göstermektedir. Yaklaşık 600. iterasyondan itibaren yakınsama eğrisi daha yatay bir seyir izleyerek stabil hale gelmiştir. Nihai yakınsama değeri düşük seviyede sabitlenmiş ve HGWSSO algoritmasına oldukça yakın bir performans sergilemiştir. Bu durum, GWO algoritmasının KNN sınıflandırıcı ile uyumlu olduğunu ve optimize edilmiş öznitelik seçimi sağlayarak etkili bir sınıflandırma gerçekleştirdiğini göstermektedir.

SSA algoritması, başlangıç iterasyonlarında hızlı bir iyileşme göstermiş ancak yaklaşık 300. iterasyondan sonra yakınsama eğrisi büyük ölçüde sabitlenmiştir. Bu sabitleme, SSA'nın hedef çözüme ulaşma konusunda sınırlı bir başarı gösterdiğini ortaya koymaktadır. Nihai yakınsama değeri, GWO ve HGWSSO algoritmalarına kıyasla daha yüksek seviyede kalmıştır. Yüksek yakınsama değeri, SSA'nın gereksiz veya tekrarlayan öznitelikleri ayıklamakta etkisiz kaldığını

ve optimizasyon sürecinde yetersiz olduğunu göstermektedir. Bu durum, SSA'nın KNN sınıflandırıcı ile EMOVA veri setinde sınırlı bir performans sergilediğini işaret etmektedir.

HGWSSO algoritma, başlangıçtan itibaren hızlı ve istikrarlı bir yakınsama süreci sergilemiştir. İlk 200 iterasyonda hızlı bir iyileşme sağlanmış ve 600. iterasyona kadar yakınsama eğrisi belirgin şekilde azalmıştır. 600. iterasyondan itibaren düşük bir yakınsama değeri ile stabilize olmuştur. Nihai yakınsama değeri açısından en düşük seviyeye ulaşarak, HGWSSO algoritması optimizasyon sürecinde en başarılı algoritma olarak öne çıkmıştır. HGWSSO algoritmasının bu başarısı, farklı optimizasyon tekniklerinin güçlü yönlerini birleştirme yeteneği ile ilişkilendirilebilir. Özellikle HGWSSO algoritmasının sağladığı düşük yakınsama değeri, seçilen özniteliklerin daha az hata ile sınıflandırma yapılmasını sağladığını ortaya koymaktadır.

HGWSSO algoritma, düşük yakınsama değeri ve hızlı iyileşme süreci ile EMOVA veri setinde KNN sınıflandırıcı için en etkili algoritma olarak öne çıkmıştır. Bu sonuçlar, HGWSSO algoritmasının sınıflandırma görevlerinde diğer yöntemlere kıyasla üstün performans sunduğunu ve optimize öznitelik seçimi konusunda daha başarılı olduğunu göstermektedir. GWO, alternatif bir çözüm olarak dikkat çekerken, SSA sınırlı performansı ile diğer algoritmaların gerisinde kalmıştır.

Çizelge 4.3. EMOVA veri setinde KNN sınıflandırıcı ile elde edilen metrik değerleri

	Öznitelik Sayısı	Doğruluk	Kesinlik	Duyarlılık	F1 Skor
GWO	152	82.55	83.05	82.55	82.26
SSA	771	65.10	65.95	65.10	64.67
HGWSSO	211	87.25	87.05	85.91	85.85


Çizelge 4.3'te, EMOVA veri setinde KNN sınıflandırıcısının GWO, SSA ve HGWSSO algoritmaları ile optimize edilerek elde edilen performans ölçümlerini göstermektedir. Öznitelik sayısı, doğruluk, kesinlik, duyarlılık ve F1 skor metrikleri ile her algoritmanın sınıflandırma performansı ayrıntılı olarak karşılaştırılmıştır.

GWO algoritması, yalnızca 152 öznitelik kullanarak düşük veri boyutunda etkili bir işlem gerçekleştirmiştir. Bu durum, algoritmanın gereksiz öznitelikleri başarıyla filtrelediğini ve optimize ettiğini göstermektedir. Doğruluk oranı %82,55 kesinlik %83,05 ve duyarlılık %82,55 ile makul seviyede dengeli bir performans sergilemiştir. F1 skoru ise %82,26 olup, kesinlik ve duyarlılık arasındaki uyumu yansıtmaktadır. Öznitelik boyutunun düşük tutulması, GWO algoritmasının işlem maliyetini azaltırken doğruluğunu korumasını sağlamıştır.

SSA algoritması, 771 öznitelik boyutu ile en büyük veri boyutuna sahip olmasına rağmen, sınıflandırma başarısı açısından yetersiz kalmıştır. Doğruluk oranı %65,10, kesinlik %65,95 ve duyarlılık %65,10 ile düşük seviyelerde kalmıştır. Bu, algoritmanın gereksiz öznitelikleri elemeye yetersiz olduğunu göstermektedir. F1 skoru %64,67 ile en düşük seviyede olup, bu durum sınıflandırmadaki başarısız performansı açıkça ortaya koymaktadır. SSA algoritması, yüksek öznitelik boyutuna rağmen düşük metrik değerleri ile sınıflandırma için uygun bir seçenek olmadığını göstermiştir.

HGWSSO algoritması, 211 öznitelik boyutu ile optimize edilmiş bir veri boyutu kullanmıştır. Doğruluk oranı %87,25, kesinlik %87,05 ve duyarlılık %85,91 ile en yüksek seviyeye ulaşarak üstün bir performans sergilemiştir. F1 skoru %85,85 ile, tüm metriklerde diğer algoritmalarından daha yüksek bir başarı göstermiştir. Bu sonuçlar, HGWSSO algoritmasının farklı optimizasyon yöntemlerinin güçlü yönlerini birleştirerek en iyi performansı sunduğunu kanıtlamaktadır. Düşük öznitelik boyutu ile yüksek doğruluk oranı sağlayarak hem işlem maliyetinde hem de sınıflandırma başarısında optimal bir denge sağlamıştır.

HGWSSO algoritması, SAVEE veri seti ile KNN sınıflandırıcı kullanıldığında en iyi sonuçları vermiştir. Özellikle doğruluk, kesinlik, duyarlılık ve F1 skoru açısından üstün bir performans sergileyerek, sınıflandırma görevinde en uygun algoritma olarak öne çıkmıştır. GWO algoritması, düşük öznitelik boyutuyla etkili bir alternatif olurken, SSA algoritması en yüksek öznitelik boyutuna rağmen en düşük doğruluk ve F1 skoru ile sınıflandırma görevinde başarısız olmuştur. Bu durum, HGWSSO algoritmasının genel performans açısından daha tercih edilebilir olduğunu ortaya koymaktadır. Şekil 4.9.'da KNN sınıflandırıcısı ile elde edilen doğruluk oranı ve öznitelik sayılarının grafiği gösterilmektedir.



Şekil 4.9. EMOVA veri setinde KNN sınıflandırıcısında öznitelik sayısı ve doğruluk oranı karşılaştırma

SSA algoritması, 771 öznitelik ile en yüksek öznitelik boyutuna sahiptir. Ancak bu geniş öznitelik kümesi, sınıflandırma doğruluğunu artırmakta etkisiz kalmıştır. SSA'nın doğruluk oranı yalnızca %65 olarak ölçülmüştür. Bu durum, algoritmanın gereksiz veya tekrarlayan öznitelikleri filtrelemekte yetersiz olduğunu ve KNN sınıflandırıcı ile uyumlu çalışmadığını göstermektedir. Yüksek öznitelik boyutuna rağmen düşük doğruluk oranı, SSA'nın öznitelik seçimi ve optimizasyon görevlerinde başarısız kaldığını ortaya koymaktadır.


GWO algoritması, 152 öznitelik ile düşük bir öznitelik boyutunda çalışmıştır. Bu durum, GWO'nun gereksiz öznitelikleri etkili bir şekilde filtrelediğini ve veri boyutunu önemli ölçüde azalttığını göstermektedir. Doğruluk oranı %82,55 ile oldukça başarılı bir sonuç vermiştir. GWO, düşük işlem maliyeti ile yüksek doğruluk sağlayarak etkili bir öznitelik seçimi yapabirmiştir. Bu sonuç, GWO'nun KNN sınıflandırıcı ile optimize bir performans sunduğunu kanıtlamaktadır.

HGWSSO algoritma, 211 öznitelik ile çalışmış ve %87,25 doğruluk oranı ile en yüksek başarıyı elde etmiştir. HGWSSO algoritmasının doğruluk oranı, diğer algoritmalarla kıyasla en yüksek seviyede olup, düşük veri boyutunu koruyarak sınıflandırma performansını optimize ettiğini göstermektedir. Farklı optimizasyon yöntemlerinin güçlü yönlerini birleştiren HGWSSO algoritması, KNN sınıflandırıcı ile etkili bir uyum sergilemiştir.

HGWSSO algoritma, düşük öznitelik boyutunu koruyarak en yüksek doğruluk oranını sağlamış ve en başarılı algoritma olarak öne çıkmıştır. Öznitelik seçimi ve sınıflandırma performansı açısından HGWSSO algoritma, diğer yöntemlere kıyasla üstün bir çözüm sunmuştur. GWO algoritması ise düşük öznitelik boyutu ve %87,25 doğruluk oranı ile makul bir alternatif olarak değerlendirilmiştir. Özellikle işlem maliyetini azaltma ve doğruluk oranını artırma kabiliyetiyle dikkat çekmektedir. SSA algoritması ise, yüksek öznitelik boyutuna rağmen düşük doğruluk oranı ile sınıflandırma görevlerinde zayıf bir performans sergilemiştir.

4.2.2. SVM sınıflandırıcı sonuçları

Şekil 4.10.' da EMOVA veri setinde SVM sınıflandırıcı kullanılarak elde edilen karışıklık matris değerleri gösterilmektedir.



Şekil 4.10. EMOVA veri setinde SVM sınıflandırıcı ile elde edilen karışıklık matris değerleri (0=Disgust, 1=Joy, 2=Neutral 3=Anxiety/Fear, 4=Anger, 5=Surprise, 6=Sadness)


GWO algoritmasıyla optimize edilen SVM sınıflandırıcısı, bazı sınıflarda yüksek doğruluk oranlarına ulaşırken diğerlerinde sınırlı bir performans sergilemiştir. Joy (1) ve Anxiety/Fear (3) sınıflarında sırasıyla 20 ve 22 doğru sınıflama yapılmıştır. Bu durum, bu sınıflardaki özniteliklerin algoritma tarafından daha iyi ayrıştırılabildiğini göstermektedir. Neutral (2) sınıfında 19 doğru sınıflama yapılmış, ancak bazı örnekler farklı sınıflara kaymıştır. Sadness (6) sınıfında 17 doğru sınıflama yapılmış, bu da makul bir performans sergilendiğini göstermektedir. Sadness (6) ve Surprise (5) sınıflarında ise yanlış sınıflama oranlarının görece yüksek olması dikkat çekmektedir.

SSA algoritması, özellikle Disgust (0) ve Surprise (5) sınıflarında daha yüksek doğruluk oranlarına ulaşmıştır. Bu sınıflarda sırasıyla 21 ve 19 doğru sınıflama yapılmıştır. Joy (1) sınıfında ise 12 doğru sınıflama yapılmış ve diğer algoritmalarla kıyasla tahminde zorlandığı görülmektedir. Bununla birlikte, Disgust (0) sınıfında 21 doğru sınıflama yapılmış, bu da diğer algoritmalarla göre bu sınıfta daha iyi bir performans sergilediğini göstermektedir. Sadness (6) sınıfında 13 doğru sınıflama yapılmış, bu da SSA'nın bu sınıfta daha düşük bir performans gösterdiğini ortaya koymaktadır. SSA algoritması, bazı sınıflarda GWO'dan daha başarılı olsa da Joy ve Sadness sınıflarında düşük performansı ile sınıflar arası tutarlılığı tam olarak sağlayamamıştır.

HGWSSO algoritması, diğer iki optimizasyon yöntemine kıyasla daha dengeli bir performans sergilemiştir. Özellikle Neutral (2), Anxiety/Fear (3) ve Joy (1) sınıflarında sırasıyla 21, 22 ve 22 doğru sınıflama yaparak dikkat çekmiştir. Bununla birlikte, Disgust (0) sınıfında 17 doğru sınıflama yapılmış, ancak bu sınıfta diğer sınıflarla karışıklık oranı tamamen azalmamıştır. Sadness (6) sınıfında ise 17 doğru sınıflama yapılarak SSA algoritmasına göre daha iyi bir performans sergilenmiştir. HGWSSO algoritması, genel olarak en dengeli performansı sağlayarak sınıflar arası tutarlılığı artırmıştır. Ancak Surprise (5) sınıfında 16 doğru sınıflama yapılmış, bu da bu sınıfta diğer algoritmalarla göre bir miktar geride kaldığı görülmektedir.

Bu bölümde elde edilen sonuçlar, duygu sınıflandırmasında farklı algoritmaların belirli sınıflar için farklı düzeylerde performans gösterdiğini ortaya koymaktadır. GWO algoritması, Joy ve Anxiety/Fear sınıflarında iyi bir doğruluk oranı sağlasa da Disgust ve Surprise sınıflarındaki düşük doğruluk oranları nedeniyle sınıf dengesini yeterince sağlayamamıştır. SSA algoritması, özellikle Disgust ve Anxiety/Fear sınıflarında iyi bir performans sergilemiş olsa da Joy ve Sadness sınıflarındaki doğruluk oranlarını artırmakta zorluk çekmiştir. HGWSSO algoritması ise genel doğruluk oranlarını artırarak daha dengeli bir performans sergilemiş, ancak bazı sınıflarda (örneğin, Disgust ve Sadness) diğer algoritmalarla benzer doğruluk oranına sahip olmuştur.

Şekil 4.11.'de EMOVA veri setinde SVM sınıflandırıcı ile elde edilen yakınsama eğrisi gösterilmektedir.



Şekil 4.11. EMOVA veri setinde SVM sınıflandırıcı ile elde edilen yakınsama eğrisi

GWO algoritması, başlangıç iterasyonlarında hızlı bir yakınsama eğilimi göstermiştir. İlk 200 iterasyonda belirgin bir azalma görülmüş, bu durum algoritmanın optimize edilmiş öznelilik seçiminde etkili olduğunu göstermektedir. Yaklaşık 600. iterasyondan itibaren eğri daha yatay bir seyir izlemiş ve sabit bir noktaya ulaşmıştır. Nihai yakınsama değeri düşük bir seviyede sabitlenmiştir. Bu sonuçlar, GWO'nun SVM sınıflandırıcı ile uyumlu çalıştığını ve iyi bir optimizasyon performansı sergilediğini göstermektedir.

SSA algoritması, başlangıçta kısmi bir iyileşme göstermiş ancak yaklaşık 300. iterasyondan sonra yakınsama eğrisi sabitlenmiştir. Nihai yakınsama değeri GWO ve Hibrit algoritmalarına kıyasla çok daha yüksek bir seviyede kalmıştır. Yüksek nihai yakınsama değeri, SSA'nın özellik seçimi konusunda gereksiz veya tekrarlayan öznelilikleri filtrelemekte etkisiz olduğunu göstermektedir. Bu durum, SSA'nın EMOVA veri seti üzerinde sınırlı bir başarı sağladığını ve SVM sınıflandırıcı ile uyumsuz olduğunu ifade etmektedir.

HGWSSO algoritması, başlangıçtan itibaren hızlı bir iyileşme süreci sergilemiştir. İlk 300 iterasyonda hızlı bir düşüş gerçekleşmiş ve ardından 600. iterasyona kadar daha düzenli bir azalma gözlemlenmiştir. Nihai yakınsama değeri açısından en düşük seviyeye ulaşarak diğer algoritmaları geride bırakmıştır. Bu durum, HGWSSO algoritmasının optimizasyon sürecinde

GWO algoritmasına çok yakın bir başarı elde ettiği görülmektedir. Aynı zamanda seçilen özniteliklerin sınıflandırma doğruluğunu artırmada etkili olduğunu göstermektedir.

HGWSSO algoritması, EMOVA veri setinde SVM sınıflandırıcı ile en iyi performansı sağlayarak düşük nihai yakınsama değeri ve etkili bir optimizasyon süreci ile öne çıkmıştır. GWO, iyi bir alternatif olarak dikkat çekerken, SSA sınırlı performansı ile diğer algoritmaların gerisinde kalmıştır. Bu sonuçlar, GWO algoritması ile birlikte HGWSSO algoritmasının öznitelik seçimi ve sınıflandırma görevlerinde üstün bir çözüm sunduğunu kanıtlamaktadır. Çizelge 4.4'de EMOVA veri setinde SVM sınıflandırıcı ile elde edilen metrik değerleri gösterilmektedir.

Çizelge 4.4. EMOVA veri setinde SVM sınıflandırıcı ile elde edilen metrik değerleri

	Öznitelik Sayısı	Doğruluk	Kesinlik	Duyarlılık	F1 Skor
GWO	192	90.60	90.84	90.60	90.62
SSA	750	76.51	76.29	76.51	76.10
HGWSSO	147	89.93	90.57	89.93	89.87

GWO algoritması, 192 öznitelik boyutu ile orta büyüklükte bir veri boyutunda çalışmış ve bu öznitelik kümesiyle en yüksek doğruluk oranını (%90,60) sağlamıştır. Kesinlik (%90,84) ve duyarlılık (%90,60) gibi diğer metriklerde de yüksek performans göstermiştir. F1 skoru (%90,62), GWO'nun dengeli bir sınıflandırma performansı sergilediğini göstermektedir. GWO algoritmasının nispeten düşük öznitelik boyutuyla yüksek doğruluk ve diğer metriklerde güçlü bir performans elde etmesi, etkili bir optimizasyon sağladığını ortaya koymaktadır.


SSA algoritması, 750 öznitelik boyutu ile en yüksek öznitelik boyutuna sahip model olmuştur. Ancak, doğruluk oranı (%76,51), kesinlik (%76,29), duyarlılık (%76,51) ve F1 skoru (%76,10) açısından diğer algoritmalarla açık bir şekilde daha düşük performans göstermiştir. Özellikle yüksek öznitelik boyutuna rağmen düşük doğruluk oranı, SSA'nın öznitelik seçimi konusunda etkisiz olduğunu ve gereksiz verilerin sınıflandırma sürecini olumsuz etkilediğini düşündürmektedir. Bu sonuç, SSA'nın EMOVA veri setinde SVM sınıflandırıcı için daha az uygun bir algoritma olduğunu göstermektedir.

HİBRİT algoritması, 147 öznitelik boyutu ile en küçük öznitelik kümesiyle çalışmış, ancak %89,93 doğruluk oranı ile GWO'ya yakın bir performans sergilemiştir. Kesinlik (%90,57),

duyarlılık (%89,93) ve F1 skoru (%89,87) açısından güçlü bir sonuç elde edilmiştir. Öznitelik boyutu açısından en düşük değeri kullanmasına rağmen oldukça yüksek doğruluk oranına ulaşması, HİBRİT algoritmasının optimize edilmiş bir öznitelik seçimi sağladığını göstermektedir.

Çizelge 4.4'deki sonuçlara göre, GWO algoritması, EMOVA veri setinde SVM sınıflandırıcı için en etkili optimizasyonu sağlamıştır. Özellikle düşük öznitelik boyutuna rağmen yüksek doğruluk, kesinlik ve F1 skoru ile diğer yöntemlere açık bir üstünlük göstermiştir. SSA algoritması, en yüksek öznitelik boyutuyla çalışmasına rağmen düşük doğruluk ve diğer metrik değerleri ile sınıflandırma performansı açısından zayıf bir sonuç ortaya koymuştur. HİBRİT algoritması ise en düşük öznitelik boyutuyla neredeyse GWO kadar yüksek doğruluk sağlamış, bu da öznitelik seçiminde en verimli algoritmalarından biri olduğunu göstermektedir. GWO ve HİBRİT algoritmaları, doğruluk ve işlem gücü arasında güçlü bir denge sağlarken, SSA algoritmasının gereksiz öznitelik seçimi nedeniyle düşük performans sergilediği gözlemlenmiştir.

Şekil 4.12.'de, EMOVA veri seti üzerinde SVM sınıflandırıcı kullanılarak SSA, GWO ve HGWSSO algoritmalarının öznitelik boyutu (Öznitelik Sayısı) ve doğruluk oranı (Doğruluk) metriklerini karşılaştırmaktadır.



Şekil 4.12. EMOVA veri setinde SVM sınıflandırıcısında öznitelik sayısı ve doğruluk oranı karşılaştırma

SSA algoritması, 750 öznitelik seçimi yapmış, ancak bu geniş öznitelik boyutu sınıflandırma başarısına yansımamış ve SSA, yalnızca %76,51 doğruluk oranı ile en düşük performansı sergilemiştir. Yüksek öznitelik boyutuna rağmen düşük doğruluk oranı, SSA'nın gereksiz veya tekrarlayan öznitelikleri ayıklamada etkisiz olduğunu ve SVM sınıflandırıcı ile optimize bir performans sağlayamadığını göstermektedir. Bu durum, SSA algoritmasının öznitelik seçimi açısından yetersiz kaldığını ve sınıflandırma görevleri için verimli bir seçenek olmadığını işaret etmektedir.

GWO algoritması, 192 öznitelik seçerek öznitelik boyutunu önemli ölçüde azaltmıştır. Düşük öznitelik boyutuna rağmen, %90,60 doğruluk oranı ile oldukça yüksek bir performans sergilemiştir. Bu sonuç, GWO algoritmasının gereksiz öznitelikleri başarıyla filtrelediğini ve SVM sınıflandırıcı ile uyumlu bir yapı sunduğunu ortaya koymaktadır. Özellikle düşük veri boyutuyla yüksek doğruluk sağlaması, GWO'nun işlem maliyeti açısından da avantajlı bir seçenek olduğunu göstermektedir.

HİBRİT algoritması, 147 öznitelik seçimi yaparak en düşük öznitelik boyutuyla çalışmış, ancak %89,93 doğruluk oranına ulaşarak etkileyici bir performans sergilemiştir. HİBRİT algoritması, GWO'ya benzer bir doğruluk oranına ulaşırken daha az öznitelik kullanmasıyla dikkat çekmektedir. Bu durum, HİBRİT algoritmasının optimize edilmiş öznitelik seçimi yaparak sınıflandırma doğruluğunu yüksek seviyede koruyabildiğini göstermektedir.

Sonuç olarak, GWO algoritması EMOVA veri setinde SVM sınıflandırıcı ile en yüksek doğruluk oranını sağlayarak en başarılı yöntem olmuştur. HİBRİT algoritması, en düşük öznitelik boyutuyla neredeyse GWO kadar başarılı bir doğruluk oranına ulaşarak etkili bir alternatif sunmuştur. SSA'nın yüksek öznitelik boyutuna rağmen düşük doğruluk göstermesi ise, bu algoritmanın öznitelik seçimi açısından sınırlı bir performans sunduğunu ortaya koymaktadır. GWO ve HİBRİT algoritmaları, doğruluk ve işlem maliyeti arasında güçlü bir denge sağlarken, SSA algoritmasının gereksiz öznitelikler nedeniyle sınıflandırma sürecini olumsuz etkilediği gözlemlenmiştir.


4.3. eNTERFACE Veri Setine Ait Sonuçlar

Bu bölümde, eNTERFACE veri seti kullanılarak farklı optimizasyon algoritmaları (GWO, SSA, HGWSSO) ile optimize edilen KNN ve SVM sınıflandırıcısının performansı

karşılaştırılmıştır. Duygu sınıfları Anger (0), Disgust (1), Fear (2), Happiness (3), Sadness (4) ve Surprise (5) olmak üzere altı kategoriye ayrılmıştır. Karmaşıklık matrislerine dayalı olarak, her algoritmanın bu sınıflardaki sınıflandırma başarısı ayrıntılı bir şekilde değerlendirilmiştir.

4.3.1. KNN sınıflandırıcı sonuçları

Şekil 4.13’de eNTERFACE veri setinde KNN sınıflandırıcı ile elde edilen karışıklık matris değerleri gösterilmektedir.



Şekil 4.13. eNTERFACE veri setinde KNN sınıflandırıcı ile elde edilen confusion matrixkarışıklık (0=Anger, 1=Disgust, 2=Fear, 3= Happiness, 4= Sadness, 5= Suprise)

Şekil 4.13'te gösterilen karışıklık matrisleri incelendiğinde, GWO yöntemi genel olarak yüksek doğruluk oranları sunmaktadır. Özellikle Anger (0) ve Disgust (1) sınıflarında başarılı sonuçlar elde edilmiştir. Bununla birlikte, Happiness (3) sınıfı sıklıkla Sadness (4) olarak hatalı tahmin edilmiştir. Sadness (4) sınıfı ise çoğunlukla Happiness (3) olarak yanlış sınıflandırılmıştır. Surprise (5) sınıfı ise diğer sınıflara kıyasla daha düşük doğruluk oranına sahiptir, özellikle Fear (2) ve Happiness (3) sınıflarına kaymalar gözlemlenmiştir.

SSA yöntemi, genel doğruluk açısından GWO yöntemine kıyasla daha düşük bir başarı göstermektedir. Özellikle Happiness (3) ve Sadness (4) sınıflarında belirgin hata oranları gözlemlenmiştir. Happiness (3) çoğunlukla Disgust (1) ve Fear (2) olarak yanlış sınıflandırılmıştır. Sadness (4) sınıfı, bazı durumlarda Anger (0) ve Disgust (1) olarak yanlış tahmin edilmiştir. Ayrıca, Anger (0) ve Disgust (1) sınıflarında da başarı düşüşü yaşandığı görülmektedir. Bunun yanı sıra, Fear (2) ve Surprise (5) sınıflarında hatalı tahminlerin arttığı gözlemlenmiştir; Fear (2) sınıfı genellikle Sadness (4) olarak tahmin edilirken, Surprise (5) sınıfı


çoğunlukla Anger (0) ve Disgust (1) olarak sınıflandırılmıştır. Bu sonuçlar, SSA yönteminin sınıflandırma doğruluğunu artırma konusunda diğer yöntemlere kıyasla daha az etkili olduğunu göstermektedir.

HGWSSO yöntemi, sınıflandırma başarımı açısından en yüksek doğruluk oranlarına ulaşan yöntem olarak öne çıkmaktadır. Özellikle Anger (0), Fear (2) ve Surprise (5) sınıflarında diğer yöntemlere göre çok daha başarılı bir performans sergilemiştir. Fear (2) ve Sadness (4) sınıflarında bazı hatalı sınıflandırmalar bulunmasına rağmen, SSA'ya kıyasla belirgin bir iyileşme gözlemlenmiştir. Surprise (5) sınıfında hatalar Sadness (4) ve Ager (0) sınıfına kayma eğilimindedir, ancak bu yanlış tahmin oranı diğer yöntemlere kıyasla düşüktür. Genel olarak değerlendirildiğinde, HGWSSO yöntemi, sınıflandırma doğruluğunu artırmada en etkili yöntem olarak öne çıkmaktadır.

Bu üç optimizasyon yöntemi karşılaştırıldığında, HGWSSO yöntemi en iyi performansı sergileyerek diğer yöntemlerden daha başarılı bir sonuç vermektedir. SSA yöntemi, diğer yöntemlere kıyasla daha düşük doğruluk oranları ile dikkat çekmektedir. GWO yöntemi, bazı sınıflarda yüksek doğruluk sağlasa da HGWSSO yöntemi, genel sınıflandırma başarısı açısından daha üstün bir performans göstermektedir. Sonuç olarak, HGWSSO yöntemi ile güçlendirilmiş KNN sınıflandırıcısının, duygu tanıma sistemlerinde daha güvenilir ve başarılı sonuçlar üretebileceği görülmektedir. Bu nedenle, gelecekte yapılacak çalışmalarda HGWSSO yönteminin daha geniş veri kümeleri üzerinde test edilmesi ve diğer makine öğrenme modelleriyle karşılaştırılması önerilmektedir.

Bununla birlikte, Surprise ve Happiness gibi bazı sınıflar, tüm algoritmalar için düşük doğruluk oranlarına sahiptir. Bu durum, bu sınıflar arasındaki özniteliklerin yeterince ayrıştırılamadığını veya sınıf dengesi açısından ek iyileştirmelere ihtiyaç duyulduğunu göstermektedir. HGWSSO algoritmasının başarısı, birden fazla optimizasyon yöntemini birleştirmenin sınıflar arası genel performansı artırdığını göstermektedir ve gelecekteki çalışmalar için önemli bir temel sunmaktadır.

Şekil 4.14.'de eNTERFACE veri setinde KNN sınıflandırıcı ile elde edilen yakınsama eğrisi değerleri gösterilmektedir.



Şekil 4.14. eNTERFACE veri setinde KNN sınıflandırıcı ile elde edilen yakınsama eğrisi

GWO algoritması, iterasyon başına yakınsama değerinde tutarlı bir düşüş sergileyerek, başlangıçtan itibaren sürekli bir iyileşme göstermiştir. Yakınsama eğrisi, yaklaşık 600. iterasyona kadar hızlı bir azalma eğiliminde olup sonrasında daha yavaş bir düşüşle nihai yakınsama değerine ulaşmıştır. GWO'nun eğrisi, düşük ve stabil bir yakınsama seviyesine ulaşarak etkili bir optimizasyon kapasitesine işaret etmektedir. Bu durum, algoritmanın eNTERFACE veri seti üzerinde KNN sınıflandırıcısında uygun bir çözüm arayışında başarılı olduğunu göstermektedir.

SSA algoritması, başlangıç iterasyonlarında hızlı bir iyileşme göstermesine rağmen, yaklaşık 300. iterasyondan sonra yakınsama süreci yavaşlamış ve büyük ölçüde sabit bir seviyede kalmıştır. SSA'nın eğrisi, GWO ve HGWSSO algoritmalarına kıyasla daha yüksek bir yakınsama değeri ile sonlanmaktadır. Bu durum, SSA'nın optimizasyon sürecinde yetersiz kaldığını ve hedef çözüme diğer algoritmalarla göre daha az etkili bir şekilde yaklaştığını göstermektedir.

HGWSSO algoritması, başlangıçtan itibaren hızlı ve tutarlı bir yakınsama eğrisi sergileyerek hem GWO hem de SSA'ya kıyasla daha düşük bir yakınsama değerine ulaşmıştır. İlk 400 iterasyonda hızlı bir azalma gösteren eğri, 600. iterasyondan itibaren daha yavaş bir iyileşme eğilimi sergileyerek stabil hale gelmiştir. HGWSSO algoritmasının eğrisi, en düşük yakınsama değeri ile sonuçlanarak, optimizasyon sürecinde en etkili algoritma olduğunu ortaya koymaktadır.

Sonuç olarak, HGWSSO algoritması, hem yakınsama süreci hem de nihai performans açısından en etkili yöntem olarak öne çıkmaktadır. GWO, makul bir alternatif olarak değerlendirilirken, SSA'nın bu veri seti ve sınıflandırıcı kombinasyonu için düşük verimlilik sunduğu görülmektedir.

Çizelge 4.5. eINTERFACE veri setinde KNN sınıflandırıcı ile elde edilen metrik değerleri

	Öznitelik Sayısı	Doğruluk	Kesinlik	Duyarlılık	F1 Skor
GWO	199	69.19	71.64	69.19	67.92
SSA	788	53.78	57.53	53.78	51.99
HGWSSO	193	75.00	77.80	75.00	74.19

Çizelge 4.5.'de, eINTERFACE veri seti üzerinde KNN sınıflandırıcısı kullanılarak GWO, SSA ve HGWSSO algoritmaları ile optimize edilmiş sonuçları göstermektedir. Öznitelik sayısı, doğruluk, kesinlik, duyarlılık ve F1 skor metrikleri, algoritmaların performanslarını karşılaştırmak için değerlendirilmiştir.

GWO algoritması, 199 öznitelik boyutu ile orta düzeyde bir veri boyutuyla çalışmış ve %69,19 doğruluk oranına ulaşmıştır. Kesinlik (%71,64), duyarlılık (%69,19) ve F1 skoru (%67,92) ile makul bir performans sergilemiştir. Ancak, doğruluk oranının sınırlı olması, GWO'nun KNN sınıflandırıcı ile bu veri setinde en etkili algoritma olmadığını göstermektedir. Özellikle HGWSSO algoritmasına kıyasla daha düşük bir performans sergilemiştir. GWO, öznitelik boyutunu düşük tutabilmiş ancak bu avantajını doğruluk oranına tam olarak yansıtamamıştır.


SSA algoritması, 788 öznitelik boyutu ile en büyük veri boyutuyla çalışmıştır. Ancak, doğruluk oranı yalnızca %53,78 ile oldukça düşük bir seviyede kalmıştır. Kesinlik (%57,53), duyarlılık (%53,78) ve F1 skoru (%51,99) da diğer algoritmalara kıyasla zayıf bir performansı işaret etmektedir. Yüksek öznitelik boyutuna rağmen düşük doğruluk oranı, SSA algoritmasının öznitelik seçiminde yetersiz olduğunu ve gereksiz veya tekrarlayan özniteliklerin sınıflandırmayı olumsuz etkilediğini göstermektedir. Bu sonuç, SSA'nın eINTERFACE veri seti için uygun bir optimizasyon yöntemi olmadığını açıkça ortaya koymaktadır.

HGWSSO algoritma, 193 öznitelik boyutu ile GWO'ya benzer bir veri boyutuyla çalışmış ancak doğruluk oranında (%75,00) en iyi sonucu elde etmiştir. Kesinlik (%77,80), duyarlılık (%75,00)

ve F1 skoru (%74,19) gibi diğer metriklerde de güçlü bir performans sergilemiştir. HGWSSO algoritmasının, öznelik boyutunu GWO ve SSA'ya kıyasla daha çok azaltması KNN sınıflandırıcısında etkili bir sonuç sağlamıştır. Bu durum, HGWSSO algoritmasının öznelik seçiminde daha başarılı olduğunu ve sınıflandırma görevindeki performansını optimize ettiğini göstermektedir.

Çizelge 4.5.'deki sonuçlara göre, HGWSSO algoritması, eNTERFACE veri seti üzerinde KNN sınıflandırıcısı ile en yüksek doğruluğu sağlayarak en etkili algoritma olarak öne çıkmaktadır. Öznelik boyutunun düşük tutulması ve doğruluk oranının yüksekliği, HGWSSO algoritmasının hem verimli hem de güçlü bir optimizasyon yöntemi olduğunu göstermektedir. GWO algoritması, makul bir performans sergilemiş ancak doğruluk oranı açısından HGWSSO algoritmasının gerisinde kalmıştır. SSA algoritması ise hem doğruluk hem de diğer metriklerde en düşük performansı sergileyerek bu veri seti ve sınıflandırıcı kombinasyonu için uygun olmadığını göstermiştir.

Şekil 4.15'de eNTERFACE veri setinde KNN sınıflandırıcı kullanılarak elde edilen öznelik sayıları ve doğruluk oranlarını karşılaştıran grafik gösterilmektedir.



Şekil 4.15. eNTERFACE veri setinde KNN sınıflandırıcısında öznelik sayısı ve doğruluk oranı karşılaştırma

SSA algoritması, en yüksek öznitelik boyutuna (788 öznitelik) sahiptir. Ancak, bu büyük veri boyutuna rağmen doğruluk oranı %53,78 seviyesinde kalmıştır. Yüksek öznitelik boyutuna rağmen düşük doğruluk, SSA'nın optimize edilmiş öznitelik seçimi konusunda yetersiz kaldığını ve gereksiz ya da tekrarlayan öznitelikleri ayıklayamadığını göstermektedir.


GWO algoritması, 199 öznitelik boyutu kullanarak çok daha küçük bir veri kümesi ile çalışmıştır. Buna rağmen doğruluk oranı %69,19 seviyesine ulaşmıştır. Bu, GWO'nun daha az öznitelik kullanarak sınıflandırma doğruluğunu artırma konusunda etkili bir performans sergilediğini göstermektedir. Düşük öznitelik boyutu ile yüksek doğruluk arasında kurduğu bu denge, GWO'nun avantajını ortaya koymaktadır.

HGWSSO algoritması, GWO'ya benzer bir şekilde düşük öznitelik boyutu ile çalışmış ve doğruluk oranı yaklaşık %75 ile en yüksek seviyeye ulaşmıştır. Bu, HGWSSO algoritmasının optimize edilmiş öznitelik seçiminde etkili olduğunu ve KNN sınıflandırıcı ile en iyi sonuçları sağladığını göstermektedir. Özellikle düşük öznitelik boyutu ve yüksek doğruluk kombinasyonu, HGWSSO algoritmasının güçlü bir çözüm sunduğunu ortaya koymaktadır.

Şekil 4.15'teki grafiğe göre HGWSSO algoritmasının KNN sınıflandırıcı ile sınıflandırma görevlerinde en etkili ve dengeli bir çözüm sunduğunu, GWO'nun ise makul bir alternatif olarak değerlendirilebileceğini göstermektedir. SSA, optimize öznitelik seçimi açısından diğer algoritmalarla kıyasla yetersiz bir performans sergilemiştir.

4.3.2. SVM sınıflandırıcı sonuçları

Şekil 4.16.'da eNTERFACE veri setinde SVM sınıflandırıcı ile elde edilen confusion matrix değerleri gösterilmektedir.



Şekil 4.16. eNTERFACE veri setinde SVM sınıflandırıcı ile elde edilen karışıklık matris değerleri (0=Anger, 1=Disgust, 2=Fear, 3= Happiness, 4= Sadness, 5= Suprise)


GWO algoritması, özellikle belirgin duyguların sınıflandırılmasında etkili sonuçlar vermiştir. Anger (0) sınıfında 50 doğru sınıflama ile yüksek bir başarı göstermiş ve bu sınıfta yanlış sınıflamaları oldukça düşük bir seviyede tutmuştur. Benzer şekilde, Disgust (1) sınıfında 47 doğru sınıflama oranı yakalamış ve sınıf karışıklığını büyük ölçüde azaltmıştır. Bununla birlikte, Fear (2) ve Happiness (3) sınıflarında sırasıyla 44 ve 46 doğru sınıflama ile makul bir performans sergilemiştir. Ancak Surprise (5) sınıfında yalnızca 36 doğru sınıflama yapılmış ve bu sınıf, diğer sınıflarla sıklıkla karıştırılmıştır. GWO'nun özellikle Sadness (4) sınıfında 53 doğru sınıflama ile güçlü bir sonuç sağlaması, bu algoritmanın bazı duygular için daha yüksek bir ayırtma kabiliyetine sahip olduğunu göstermektedir.

SSA algoritması, genel olarak dengeli bir performans sergilemekle birlikte bazı sınıflarda daha fazla karışıklık ortaya çıkarmıştır. Anger (0) ve Disgust (1) sınıflarında sırasıyla 48 ve 52 doğru sınıflama yapılmış ve bu sınıflarda diğer duygularla olan karışıklıklar minimal düzeyde tutulmuştur. Disgust sınıfında diğer algoritmalara üstünlük sağlayarak %100 başarı oranı elde etmiştir. Fear (2) sınıfında 46 doğru sınıflama ile diğer algoritmalara yakın bir performans sergilemiştir. Özellikle Happiness (3) sınıfında yalnızca 37 doğru sınıflama yapılmış ve bu sınıf diğer tüm sınıflarla sıklıkla karıştığı görülmektedir. Sadness (4) sınıfında 40 doğru sınıflama yapılırken, Surprise (5) sınıfında doğruluk oranı 32'ye düşmüştür. Surprise (5) sınıfının daha çok Disgust (1) ile karıştığı görülmektedir. Bu durum, SSA algoritmasının daha az belirgin özniteliklere sahip duygular arasında ayırım yapmakta zorluk çektiğini göstermektedir.

HGWSSO algoritması, sınıflar arasında en dengeli ve yüksek doğruluk oranına sahip sonuçları sunmuştur. Anger (0) sınıfında 51 doğru sınıflama yapılmış ve bu sınıfta en yüksek doğruluk elde edilmiştir. Benzer şekilde, Disgust (1) sınıfında 49 doğru sınıflama yapılmış ve diğer sınıflarla karışıklık önemli ölçüde azaltılmıştır. Fear (2) sınıfında 45 doğru sınıflama yapılmış ve bu sonuç GWO ile kıyaslandığında oldukça benzer bir başarıyı yansıtmaktadır. Happiness (3) ve Sadness (4) sınıflarında sırasıyla 45 ve 46 doğru sınıflama ile, GWO algoritmasının gerisinde kaldığı görülmüştür. Surprise (5) sınıfında ise 38 doğru sınıflama yapılmış ve bu sınıfta karışıklık oranı diğer algoritmalara kıyasla daha düşük seviyede kalmıştır. HGWSSO algoritmasının, özellikle Surprise ve Sadness gibi diğer algoritmalarda düşük performans gösteren sınıflarda başarı oranını artırdığı gözlemlenmiştir.

Elde edilen sonuçlar, SVM sınıflandırıcısının GWO, SSA ve HGWSSO algoritmalarla optimize edildiğinde duygu kategorileri arasındaki sınıflandırma performansının nasıl farklılaştığını açıkça ortaya koymaktadır. GWO algoritması, özellikle Sadness ve Anger sınıflarında yüksek doğruluk oranlarına ulaşmış, ancak Surprise sınıfında nispeten düşük doğruluk oranları sergilemiştir. SSA algoritması ise, Disgust sınıfında güçlü bir performans gösterirken, Happiness ve Surprise gibi sınıflarda sınıflandırma karışıklıklarının arttığı gözlemlenmiştir. HGWSSO algoritması, tüm sınıflar arasında dengeli bir başarı sergileyerek, özellikle düşük performans gösteren sınıflarda doğruluk oranlarını artırmıştır.

Şekil 4.17’de, eINTERFACE veri setinde SVM sınıflandırıcı ile GWO, SSA ve HGWSSO algoritmalarının yakınsama süreçlerini göstermektedir. Yatay eksen iterasyon sayısını, dikey eksen ise algoritmaların yakınsama değerlerini ifade etmektedir. Grafik, algoritmaların optimizasyon sürecinde hedef çözüme nasıl yaklaştığını ve verimliliklerini değerlendirmek için incelenmiştir.



Şekil 4.17. eINTERFACE veri setinde SVM sınıflandırıcı ile elde edilen yakınsama eğrisi

GWO algoritması, başlangıç iterasyonlarından itibaren istikrarlı bir şekilde yakınsama değeri düşüşü sergilemiştir. Yaklaşık 400. iterasyondan sonra iyileşme hızı yavaşlamış ve eğri, 700. iterasyondan itibaren oldukça düşük bir yakınsama değeriyle stabilize olmuştur. Nihai yakınsama değeri açısından HGWSSO algoritmasına yakın bir performans sergilemiştir ve SSA'ya kıyasla daha etkili bir optimizasyon sağlamıştır.

SSA algoritması, başlangıç iterasyonlarında hızlı bir düşüş göstermiş ancak 300. iterasyondan itibaren eğri büyük ölçüde sabit kalmıştır. Yakınsama değeri, GWO ve HGWSSO algoritmalarından daha yüksek bir seviyede stabilize olmuştur. Bu durum, SSA'nın optimizasyon sürecinde sınırlı bir başarı sağladığını ve hedef çözüme ulaşma konusunda diğer algoritmalara kıyasla daha yetersiz olduğunu göstermektedir.

HGWSSO algoritma, başlangıçtan itibaren hızlı bir iyileşme göstermiş ve ilk 400 iterasyonda yakınsama değerini etkili bir şekilde azaltmıştır. Eğri, 700. iterasyondan sonra oldukça düşük bir yakınsama değeriyle sabitlenmiştir. Nihai yakınsama değeri, en düşük seviyeye ulaşarak HGWSSO algoritmasının en etkili optimizasyonu gerçekleştirdiğini göstermiştir. Bu durum, HGWSSO algoritmasının eNTERFACE veri setinde SVM sınıflandırıcı ile en iyi sonuçları verdiğini kanıtlamaktadır.

Şekil 4.17'deki grafik GWO algoritmasının SVM sınıflandırıcı ile optimizasyon sürecinde etkili yöntem olduğunu ve HGWSSO'nun makul bir alternatif sunduğunu göstermektedir. SSA ise daha az etkili bir algoritma olarak öne çıkmaktadır. HGWSSO ve GWO algoritmalarının hızlı iyileşme ve düşük yakınsama değeri, onu eNTERFACE veri setindeki SVM sınıflandırma görevleri için en uygun seçenek yapmaktadır.

Çizelge 4.6.'da eNTERFACE veri setinde SVM sınıflandırıcı ile elde edilen metrik değerleri gösterilmektedir.

Çizelge 4.6. eNTERFACE veri setinde SVM sınıflandırıcı ile elde edilen metrik değerleri

	Öznitelik Sayısı	Doğruluk	Kesinlik	Duyarlılık	F1 Skor
GWO	234	80.23	80.74	80.23	80.08
SSA	773	74.13	74.55	74.13	73.45
HGWSSO	248	79.65	80.11	79.65	79.49


GWO algoritması, 234 öznitelik boyutu ile çalışmış ve %80,23 doğruluk oranı elde etmiştir. Kesinlik (%80,74), duyarlılık (%80,23) ve F1 skoru (%80,08) ile diğer algoritmalar arasında en yüksek doğruluğu sağlayarak dikkat çekmiştir. Özellikle, öznitelik boyutunu sınırlı tutarak yüksek doğruluk sağlaması, GWO'nun etkili bir optimizasyon algoritması olduğunu göstermektedir. Bu sonuç, GWO'nun SVM sınıflandırıcısı ile iyi bir uyum sağladığını ve öznitelik seçimi sürecinde etkili olduğunu göstermektedir.

SSA algoritması, 773 öznitelik boyutu ile en büyük veri boyutunda çalışmış ancak doğruluk oranı yalnızca %74,13 ile sınırlı kalmıştır. Kesinlik (%74,55), duyarlılık (%74,13) ve F1 skoru (%73,45) diğer algoritmalarla kıyasla düşük performansı işaret etmektedir. Yüksek öznitelik boyutuna rağmen düşük doğruluk ve diğer metriklerdeki başarısızlık, SSA'nın gereksiz ve tekrarlayan öznitelikleri etkili bir şekilde ayıklayamadığını ve sınıflandırma performansını olumsuz etkilediğini göstermektedir. Bu sonuç, SSA'nın bu veri seti için en uygun algoritma olmadığını açıkça ortaya koymaktadır.

HGWSSO algoritma, 248 öznitelik boyutu ile çalışarak GWO'ya benzer bir öznitelik boyutuyla işlem yapmıştır. Doğruluk oranı %79,65 ile GWO'ya yakın bir sonuç elde etmiştir. Kesinlik (%80,11), duyarlılık (%79,65) ve F1 skoru (%79,49) gibi metriklerde de istikrarlı bir performans sergilemiştir. HGWSSO algoritma, öznitelik boyutunu düşük seviyede tutarak makul bir doğruluk sağlamış ve GWO'ya alternatif bir yöntem olarak dikkat çekmiştir. Bu sonuç, HGWSSO algoritmasının dengeli bir öznitelik seçimi sağladığını ve sınıflandırma performansını optimize ettiğini göstermektedir.

Sonuçlar, GWO algoritmasının eNTERFACE veri setinde SVM sınıflandırıcı ile en yüksek doğruluğu sağlayarak en etkili algoritma olduğunu göstermektedir. GWO'nun öznitelik boyutunu düşük tutarak sınıflandırma performansını optimize ettiği gözlemlenmiştir. HGWSSO algoritması, GWO'ya oldukça yakın bir doğruluk ve diğer metriklerde dengeli bir performans sergilemiştir. Özellikle HGWSSO algoritmasının daha az öznitelik boyutu kullanarak neredeyse GWO kadar iyi sonuçlar elde etmesi, bu yöntemin işlem maliyetini düşürmede avantaj sağlayabileceğini göstermektedir. SSA algoritması ise yüksek öznitelik boyutuna rağmen düşük doğruluk oranı ile diğer algoritmaların oldukça gerisinde kalmıştır.

Şekil 4.18.'de SVM sınıflandırıcı ile SSA, GWO ve HGWSSO algoritmalarının öznitelik boyutu ve doğruluk oranı performanslarını karşılaştırmaktadır.



Şekil 4.18. eNTERFACE veri setinde SVM sınıflandırıcısında öznitelik sayısı ve doğruluk oranı karşılaştırma

SSA algoritması, en yüksek öznitelik boyutuna (yaklaşık 800) sahiptir. Ancak bu büyük veri boyutuna rağmen doğruluk oranı yalnızca yaklaşık %74 seviyesindedir. Öznitelik boyutunun yüksek olmasına rağmen düşük doğruluk, SSA'nın gereksiz veya tekrarlayan öznitelikleri filtreleyemediğini göstermektedir. Bu durum, SSA'nın öznitelik seçimi sürecindeki verimsizliğini ve SVM sınıflandırıcı için etkisizliğini işaret etmektedir.

GWO algoritması 234 öznitelik boyutu ile çok daha küçük bir veri kümesiyle çalışmıştır. Buna rağmen doğruluk oranı %80 seviyesine ulaşmıştır. Özellikle düşük öznitelik boyutu ve yüksek doğruluk kombinasyonu, GWO'nun etkili bir öznitelik seçimi sağladığını göstermektedir. GWO, SVM sınıflandırıcı ile optimize bir çözüm sunmuş ve işlem maliyeti ile doğruluk oranı arasında iyi bir denge kurmuştur.

HGWSSO algoritma, 248 öznitelik boyutuna yakın bir veri kümesi kullanmış ve doğruluk oranında %79 seviyesine ulaşarak GWO'ya çok yakın bir performans sergilemiştir. HGWSSO algoritması, öznitelik boyutunu düşük seviyede tutarken yüksek doğruluk oranı sağlamış ve

optimize edilmiş bir performans sunmuştur. HGWSSO algoritmasının GWO'ya çok yakın performansı, farklı optimizasyon tekniklerinin birleşiminin avantajını ortaya koymaktadır.


Şekil 4.18'deki grafik, GWO ve HGWSSO algoritmalarının SVM sınıflandırıcı ile en iyi sonuçları sağladığını, SSA'nın ise düşük doğruluk oranı ve yüksek öznelilik boyutu nedeniyle diğer algoritmalarla göre yetersiz kaldığını göstermektedir. HGWSSO algoritmasının, farklı yöntemlerin güçlü yönlerini birleştirerek sınıflandırma başarısını artırdığı ve dengeli bir sonuç sunduğu açıkça görülmektedir.

4.4. SAVEE Veri Setine Ait Sonuçlar

Çalışmanın bu kısmında, SAVEE veri seti kullanılarak KNN ve SVM sınıflandırıcısının GWO, SSA ve HGWSSO optimizasyon algoritmaları ile elde edilen performansı karşılaştırılmıştır. Duygu sınıfları arasında Anger (0), Disgust (1), Fear (2), Happiness (3), Neutral (4) ve Sadness (5) bulunmaktadır. Karmaşıklık matrislerinden elde edilen sonuçlar, her algoritmanın bu duygu kategorilerindeki performansını detaylı bir şekilde yansıtmaktadır.

4.4.1. KNN sınıflandırıcı sonuçları

Şekil 4.19.'da SAVEE veri setinde KNN sınıflandırıcı ile elde edilen karışıklık matris değerleri gösterilmektedir.



Şekil 4.19. SAVEE veri setinde KNN sınıflandırıcı ile elde edilen karışıklık matris değerleri (0=Anger, 1=Disgust, 2= Fear, 3=Happiness, 4=Neutral)


GWO algoritması ile optimize edilen sınıflandırıcı, belirli sınıflarda yüksek doğruluk oranları ile öne çıkmıştır. Disgust (1) sınıfında 71 doğru sınıflama ile diğer algoritmalarından daha güçlü bir performans sergilemiş olmasına rağmen Neutral (4) sınıfı ile karışıklık göstermiştir. Anger (0) sınıfında ise 15 doğru sınıflama yapılmış, ancak bu sınıf diğer sınıflarla biraz karışmıştır. Fear (2) sınıfında 16 doğru sınıflama sağlanmış, ancak bu sınıfta bazı örnekler Disgust (1) sınıfına kaymıştır. Happiness (3) ve Neutral (4) sınıflarında doğru sınıflama oranları nispeten düşüktür ve bu sınıflar diğer sınıflarla karışıklığa sebep olmuştur. GWO algoritması, özellikle belirgin özniteliklere sahip sınıflarda yüksek bir doğruluk oranı sağlasa da bazı sınıflarda hata oranını düşürmek için daha fazla geliştirme gerektirebilir.

SSA algoritmasının performansında, diğer algoritmalarla göre tüm sınıflarda düşük kaldığı görülmektedir. Disgust (1) sınıfında 66 doğru sınıflama yapılmış olmasına rağmen bazı sonuçların Anger ve Fear sınıflarına kaydığı görülmektedir. Bununla birlikte, Anger (0) ve Fear (2) sınıflarında doğruluk oranları sırasıyla 14 ve 10 olarak gerçekleşmiştir. Fear (2) sınıfının genellikle Anger (0) sınıfı ile Anger (0) sınıfının ise Disgust (1) sınıfı ile karışıklık gösterdiği görülmüştür. Bu algoritmadaki en büyük karışıklık Happiness (3) ve Neutral (4) sınıflarında olmuştur. Bu sınıftaki örneklerin büyük çoğunluğunun Disgust (1) sınıfı ile karışıklık olduğu görülmektedir.

HGWSSO algoritma, sınıflar arasında genel olarak en dengeli ve yüksek doğruluk oranlarını sağlamıştır. Disgust (1) sınıfında 71 doğru sınıflama ile bu sınıfta GWO algoritması ile benzer şekilde en iyi performansı sergilemiştir. Anger (0) ve Fear (2) sınıflarında sırasıyla 15 ve 16 doğru sınıflama yapılmış ve bu sınıflarda diğer algoritmalarla kıyasla daha az karışıklık yaşanmıştır. Happiness (3) sınıfında ise 9 doğru sınıflama ile nispeten düşük bir doğruluk elde edilmiştir. Bunun yanı sıra, Neutral (4) sınıfında doğruluk oranı 15'e yükselmiş ve bu sınıfta önceki algoritmalarla kıyasla daha başarılı bir performans sağlanmıştır. HGWSSO algoritmasının, sınıflar arasındaki dengeli sonuçları ve karışıklığı azaltmadaki başarısı dikkat çekmektedir.

SAVEE veri setinin KNN ile sınıflandırma sonuçları incelendiğinde tüm algoritmalarda genel olarak Happiness ve Neutral sınıflarının Disgust sınıfı ile karışıklık gösterdiği görülmektedir. Bu sonuçlara bakıldığında bu sınıflardaki öznitelik değerlerinin birbirinden ayrışacak nitelikte olmadığı düşünülmektedir.

Şekil 4.20’de SAVEE veri setinde KNN sınıflandırıcı kullanılarak GWO, SSA ve HGWSSO algoritmalarının yakınsama süreçlerini göstermektedir. Yatay eksen iterasyon sayısını, dikey eksen ise algoritmaların yakınsama değerlerini ifade etmektedir. Grafik, algoritmaların optimizasyon süreçlerindeki farklılıkları ve etkilerini değerlendirmek için incelenmiştir.



Şekil 4.20. SAVEE veri setinde KNN sınıflandırıcı ile elde edilen yakınsama eğrisi

GWO algoritması, başlangıçtan itibaren istikrarlı bir yakınsama eğrisi sergilemiştir. İlk 200 iterasyonda hızlı bir yakınsama gösteren GWO, daha sonra kademeli bir azalma eğilimi ile düşük bir yakınsama değerine ulaşmıştır. Yaklaşık 700. iterasyondan sonra eğri, düşük bir değerle stabil hale gelmiştir. GWO'nun eğrisi, düşük nihai yakınsama değeri ile HGWSSO algoritmasına yakın bir performans göstermekte ve optimizasyon sürecinde etkili olduğunu kanıtlamaktadır.

SSA algoritması, başlangıç iterasyonlarında hızlı bir iyileşme göstermiş ancak 200. iterasyondan itibaren eğri büyük ölçüde sabit kalmıştır. Nihai yakınsama değeri diğer iki algoritmaya kıyasla oldukça yüksektir. Bu durum, SSA'nın optimizasyon sürecinde sınırlı bir başarı sağladığını ve hedef çözüme ulaşmada etkisiz kaldığını göstermektedir. SSA'nın yakınsama eğrisi, gereksiz öznitelikleri filtrelemede yetersiz kaldığını ve düşük bir optimizasyon kapasitesine sahip olduğunu işaret etmektedir.

HGWSSO algoritma, başlangıç iterasyonlarından itibaren hızlı ve etkili bir yakınsama eğrisi göstermiştir. İlk 300 iterasyonda hızlı bir düşüş sergileyen eğri, 700. iterasyondan itibaren düşük bir değerle stabilize olmuştur. HGWSSO algoritma, nihai yakınsama değerinde en düşük seviyeye ulaşarak optimizasyon sürecinde en etkili algoritma olduğunu göstermiştir. Bu durum, HGWSSO algoritmasının öznelik seçiminde başarılı olduğunu ve KNN sınıflandırıcı ile etkili bir çözüm sunduğunu göstermektedir.

Şekil 4.20'deki grafik, HGWSSO algoritmasının KNN sınıflandırıcı ile öznelik seçimi ve optimizasyon sürecinde en iyi performansı sağladığını göstermektedir. GWO, makul bir alternatif olarak değerlendirilirken, SSA, performans açısından geride kalmaktadır. HGWSSO algoritmasının hızlı ve etkili yakınsama süreci, onu SAVEE veri setindeki KNN sınıflandırma görevlerinde tercih edilen bir yöntem yapmaktadır.

Çizelge 4.7. SAVEE veri setinde KNN sınıflandırıcı ile elde edilen metrik değerleri

	Öznelik Sayısı	Doğruluk	Kesinlik	Duyarlılık	F1 Skor
GWO	113	85.42	86.70	85.42	84.52
SSA	779	70.14	76.35	70.14	67.41
HGWSSO	158	87.50	88.73	87.50	86.72

Çizelge 4.7'de, SAVEE veri seti üzerinde KNN sınıflandırıcısı kullanılarak GWO, SSA ve HGWSSO algoritmaları ile optimize edilmiş sınıflandırma sonuçları gösterilmektedir. Öznelik sayısı, doğruluk, kesinlik, duyarlılık ve F1 Skoru, algoritmaların performanslarını değerlendirmek için kullanılan metriklerdir.

GWO algoritması, 113 öznelik boyutu ile en düşük veri boyutunda çalışarak %85,42 doğruluk oranı elde etmiştir. Kesinlik (%86,70), duyarlılık (%85,42) ve F1 skoru (%84,52) ile güçlü ve dengeli bir performans sergilemiştir. Öznelik boyutunun düşük tutulmasına rağmen bu yüksek doğruluk oranı, GWO'nun öznelik seçiminde oldukça etkili olduğunu göstermektedir. GWO, düşük veri boyutuyla işlem maliyetini azaltırken sınıflandırma performansında da iyi bir sonuç sunmuştur.


SSA algoritması, 779 öznelik boyutu ile en yüksek veri boyutuna sahiptir. Ancak doğruluk oranı (%70,14), kesinlik (%76,35), duyarlılık (%70,14) ve F1 skoru (%67,41) ile düşük bir performans sergilemiştir. Yüksek öznelik boyutuna rağmen düşük doğruluk oranı, SSA'nın

öznitelik seçimi sırasında gereksiz veya tekrarlayan öznitelikleri filtreleyemediğini göstermektedir. Bu durum, SSA'nın SAVEE veri setinde KNN sınıflandırıcısı için uygun olmadığını ve diğer algoritmalara göre daha zayıf bir performans sergilediğini işaret etmektedir.

HGWSSO algoritması, 158 öznitelik boyutu ile GWO'ya yakın bir veri boyutuyla çalışmış, ancak doğruluk oranında (%87,50) en yüksek sonucu elde etmiştir. Kesinlik (%88,73), duyarlılık (%87,50) ve F1 skoru (%86,72) metriklerinde de GWO'yu geride bırakmıştır. HGWSSO algoritma, düşük veri boyutunu koruyarak en yüksek sınıflandırma doğruluğunu ve metrik dengesini sağlamış, bu da bu yöntemin optimize edilmiş öznitelik seçimi ve sınıflandırma başarısında etkili olduğunu göstermektedir.

Çizelge 4.7'deki sonuçlara göre, HGWSSO algoritma, SAVEE veri setinde KNN sınıflandırıcısı ile en iyi performansı sergilemiştir. Hem düşük öznitelik boyutu hem de yüksek doğruluk ve diğer metriklerdeki üstün başarısı, HGWSSO algoritmasının güçlü bir optimizasyon aracı olduğunu ortaya koymaktadır. GWO algoritması, düşük öznitelik boyutuyla etkili bir performans sunmuş, ancak HGWSSO algoritmasına kıyasla biraz daha düşük bir doğruluk oranı elde etmiştir. SSA algoritması ise yüksek öznitelik boyutuna rağmen doğruluk ve diğer metriklerde düşük bir performans sergilemiş ve SAVEE veri seti için en zayıf algoritma olarak dikkat çekmiştir.

Şekil 4.21.'de, SAVEE veri setinde KNN sınıflandırıcı kullanılarak SSA, GWO ve HGWSSO algoritmalarının öznitelik boyutu (Öznitelik Sayısı) ve doğruluk oranı (Doğruluk) performanslarını karşılaştırmaktadır.



Şekil 4.21. SAVEE veri setinde KNN sınıflandırıcısında öznitelik sayısı ve doğruluk oranı karşılaştırma

SSA algoritması, en yüksek öznitelik boyutuna (779) sahiptir. Ancak, bu geniş veri boyutuna rağmen doğruluk oranı yaklaşık %70 seviyesinde kalmıştır. Öznitelik boyutunun yüksek olması, SSA'nın birçok gereksiz veya tekrarlayan özelliği seçtiğini göstermektedir. Bu durum, SSA'nın öznitelik seçimindeki yetersizliğini ve KNN sınıflandırıcı ile düşük verimliliğini işaret etmektedir.


GWO algoritması, 113 öznitelik boyutu ile çalışmış ve doğruluk oranında yaklaşık %85 seviyesine ulaşmıştır. GWO'nun düşük öznitelik boyutuna rağmen yüksek doğruluk oranı, etkili bir öznitelik seçimi sağladığını ve KNN sınıflandırıcı ile başarılı bir uyum yakaladığını göstermektedir. İşlem maliyetini düşük tutarken doğruluk oranını artırması, GWO'nun avantajlarını ortaya koymaktadır.

HGWSSO algoritma, GWO'ya benzer şekilde düşük bir öznitelik boyutu (158) ile çalışmış, ancak doğruluk oranında %87 ile en yüksek başarıyı elde etmiştir. HGWSSO algoritma, düşük veri boyutunu koruyarak sınıflandırma performansını optimize etmiş ve KNN sınıflandırıcı ile etkili bir sonuç sağlamıştır. Farklı optimizasyon tekniklerinin güçlü yönlerini birleştirerek daha üstün bir genel performans sunduğunu göstermektedir.

HGWSSO algoritması, KNN sınıflandırıcı ile SAVEE veri setinde sınıflandırma görevlerinde en iyi sonucu sağlamıştır. GWO algoritması, düşük öznitelik boyutuyla güçlü bir alternatif olarak değerlendirilebilirken, SSA algoritması öznitelik seçimindeki yetersizliği nedeniyle zayıf bir performans sergilemiştir. HGWSSO algoritmasının hızlı ve etkili öznitelik seçimi, yüksek doğruluk oranını düşük veri boyutuyla birleştirerek öne çıkmaktadır.

4.4.2. SVM sınıflandırıcı sonuçları

Şekil 4.22.'de SAVEE veri setinde SVM sınıflandırıcı ile elde edilen karışıklık matris değerleri gösterilmektedir.



Şekil 4.22. SAVEE veri setinde SVM sınıflandırıcı ile elde edilen karışıklık matris değerleri (0=Anger, 1=Disgust, 2= Fear, 3=Happiness, 4=Neutral)

GWO algoritması, Disgust (1) sınıfında oldukça yüksek doğruluk oranı sağlamış, bu sınıf için 72 doğru sınıflama yapılmıştır. Ayrıca Anger (0) sınıfı da başarılı bir şekilde ayrıştırılmış, 18 doğru sınıflama yapılmıştır. Ancak Fear (2) sınıfı, yalnızca 16 doğru sınıflama ile düşük doğruluk oranına sahip olmuş ve Happiness (3) sınıfı ile karışıklık yaşanmıştır. Neutral (4) sınıfında ise sadece 13 doğru sınıflama yapılmış ve bu sınıf oldukça düşük performans göstermiştir. GWO algoritması, belirgin duygular arasında iyi bir ayrım sağlasa da özellikle Neutral (4) sınıfında daha fazla iyileştirme gerektirmektedir.


SSA algoritması da Disgust (1) sınıfında güçlü bir performans sergileyerek 67 doğru sınıflama sağlamıştır. Anger (0) sınıfında da 15 doğru sınıflama yapılmış, ancak bu sınıfta diğer sınıflarla bazı karışıklıklar gözlemlenmiştir. Fear (2) ve Happiness (3) sınıflarında sırasıyla 16 ve 13 doğru sınıflama yapılmış ve bu sınıflarda düşük doğruluk oranları kaydedilmiştir. Neutral (4)

sınıftaki doğruluk oranı, 10 doğru sınıflama ile en düşük seviyeye ulaşmıştır. SSA algoritması, Disgust (1) ve Fear (2) sınıflarında makul sonuçlar üretse de Neutral (4) ve Happiness (3) gibi sınıflarda performans düşüklüğü sergilemiştir.

HGWSSO algoritma, genel olarak en tutarlı sonuçları elde etmiştir. Disgust (1) sınıfında 71 doğru sınıflama ile en yüksek doğruluk oranını yakalamış ve bu sınıfın doğru ayrıştırılmasında başarılı olmuştur. Anger (0) sınıfında da 17 doğru sınıflama yapılmış ve bu sınıf ile karışıklık en aza indirilmiştir. Fear (2) sınıfında ise 15 doğru sınıflama elde edilmiştir ve bu sınıf da Anger (0) ve Disgust (1) ile karışmış olsa da nispeten yüksek bir doğruluk sergilenmiştir. Neutral (4) ve Sadness (5) sınıflarında ise sırasıyla 17 ve 13 doğru sınıflama yapılmış, bu da HGWSSO algoritmasının bu sınıflarda daha dengeli bir sonuç sağladığını göstermektedir. Genel olarak, HGWSSO algoritma, sınıflar arasında daha tutarlı ve dengeli bir doğruluk oranı sunarak diğer algoritmalarla kıyasla daha iyi bir performans göstermektedir.

Sonuçlar, SAVEE veri setindeki duygu sınıflandırması için kullanılan SVM sınıflandırıcısının farklı optimizasyon algoritmaları ile nasıl farklı performanslar sergilediğini göstermektedir. GWO algoritması, Disgust (1) ve Anger (0) sınıflarında başarılı olurken, Fear (2) ve Neutral (4) gibi sınıflarda iyileştirilmiş performansa ihtiyaç duymaktadır. SSA algoritması daha dengeli bir performans sergilemiş olsa da özellikle Neutral (4) ve Happiness (3) sınıflarında daha düşük doğruluk oranları gözlemlenmiştir. HGWSSO algoritma, tüm sınıflarda yüksek doğruluk oranları sağlayarak en iyi genel performansı sergilemiş ve sınıflar arası karışıklığı azaltmıştır.

Şekil 4.23.'de, SAVEE veri setinde SVM sınıflandırıcı kullanılarak GWO, SSA ve HGWSSO algoritmalarının yakınsama süreçlerini göstermektedir. Yatay eksen iterasyon sayısını, dikey eksen ise algoritmaların yakınsama değerlerini ifade etmektedir. Grafik, algoritmaların optimizasyon süreçlerindeki performanslarını karşılaştırmak için analiz edilmiştir.



Şekil 4.23. SAVEE veri setinde SVM sınıflandırıcı ile elde edilen yakınsama eğrisi

GWO algoritması, başlangıç iterasyonlarından itibaren hızlı bir iyileşme göstermiştir. İlk 200 iterasyonda belirgin bir yakınsama sağlayan GWO, yaklaşık 600. iterasyondan itibaren daha yavaş bir azalma ile düşük bir yakınsama değeri seviyesine ulaşmıştır. Eğrinin düşük bir değerde stabilize olması, GWO'nun SAVEE veri setinde SVM sınıflandırıcı ile etkili bir öznetelik seçimi gerçekleştirdiğini göstermektedir. HGWSSO algoritma ile benzer performans sergilemiş, ancak HGWSSO algoritmasının biraz gerisinde kalmıştır.

SSA algoritması, başlangıç iterasyonlarında hızlı bir düşüş göstermiş ancak 200. iterasyondan sonra eğri sabit bir seviyeye gelerek yüksek bir yakınsama değeri ile stabilize olmuştur. SSA'nın eğrisinin GWO ve HGWSSO algoritmasına kıyasla daha yüksek bir seviyede kalması, algoritmanın optimizasyon sürecinde yetersiz olduğunu ve hedef çözüme etkili bir şekilde yaklaşmadığını göstermektedir.

HGWSSO algoritması, başlangıç iterasyonlarında hızlı bir yakınsama sağlamış ve GWO'ya benzer bir iyileşme göstermiştir. İlk 300 iterasyondan itibaren eğri daha yavaş bir şekilde düşmüş ve nihai yakınsama değeri açısından en düşük seviyeye ulaşmıştır. HGWSSO algoritmasının eğrisi, optimize edilmiş bir öznetelik seçimi ve güçlü bir performans gösterdiğini açıkça ortaya koymaktadır. Bu durum, HGWSSO algoritmasının SAVEE veri setinde SVM sınıflandırıcı ile en etkili sonuçları sağladığını göstermektedir.

Şekil 4.23'teki grafik, HGWSSO algoritmasının SAVEE veri setinde SVM sınıflandırıcı ile optimizasyon sürecinde en etkili yöntem olduğunu göstermektedir. GWO algoritması ise makul bir alternatif olarak değerlendirilmiştir. SSA ise diğer algoritmalarla kıyasla sınırlı bir performans sergilemiş ve yakınsama sürecinde etkisiz bir algoritma olarak dikkat çekmiştir. HGWSSO algoritmasının hızlı ve düşük yakınsama değeri, bu veri seti ve sınıflandırıcı kombinasyonu için en uygun çözüm olduğunu ortaya koymaktadır.

Çizelge 4.8.'de SAVEE veri setinde SVM sınıflandırıcı kullanılarak elde edilen metrik değerleri gösterilmektedir.

Çizelge 4.8. SAVEE veri setinde SVM sınıflandırıcı ile elde edilen metrik değerleri

	Öznitelik Sayısı	Doğruluk	Kesinlik	Duyarlılık	F1 Skoru
GWO	156	91.67	92.36	91.67	91.29
SSA	765	84.03	83.81	84.03	83.52
HGWSSO	144	92.36	92.49	92.36	92.22

GWO algoritması, 156 öznitelik boyutu ile çalışmış ve %91,67 doğruluk oranı elde etmiştir. Kesinlik (%92,36), duyarlılık (%91,67) ve F1 skoru (%91,29) ile güçlü ve dengeli bir performans sergilemiştir. Öznitelik boyutunun düşük tutulmasıyla birlikte bu yüksek doğruluk oranı, GWO algoritmasının etkili bir şekilde optimize edilmiş öznitelik seçim yeteneğini göstermektedir. Ancak HGWSSO algoritma, doğruluk ve diğer metriklerde GWO'yu az bir farkla geride bırakmıştır.


SSA algoritması, 765 öznitelik boyutu ile en büyük veri boyutuna sahiptir, ancak doğruluk oranı yalnızca %84,03 ile sınırlı kalmıştır. Kesinlik (%83,81), duyarlılık (%84,03) ve F1 skoru (%83,52) değerleri de diğer algoritmalarla göre daha düşük performans sergilemiştir. Yüksek öznitelik boyutuna rağmen bu düşük doğruluk oranı, SSA algoritmasının gereksiz veya tekrarlayan öznitelikleri ayıklamada yetersiz kaldığını ve sınıflandırma görevinde sınırlı bir başarı sağladığını göstermektedir.

HGWSSO algoritma, 144 öznitelik boyutu ile GWO'ya kıyasla daha küçük bir öznitelik kümesiyle çalışmış, ancak doğruluk oranında %92,36 ile en iyi sonucu elde etmiştir. Kesinlik (%92,49), duyarlılık (%92,36) ve F1 skoru (%92,22) gibi metriklerde de üstün performans sergilemiştir. HGWSSO algoritmasının bu başarısı, optimize edilmiş öznitelik seçimi ve

sınıflandırma görevlerinde güçlü bir performans sağladığını göstermektedir. HGWSSO algoritma, düşük öznitelik boyutuyla yüksek doğruluk oranını birleştirerek etkili bir çözüm sunmuştur.

Sonuçlar, HGWSSO algoritmasının SAVEE veri setinde SVM sınıflandırıcısı için en iyi performansı sergilediğini açıkça göstermektedir. Özellikle düşük öznitelik boyutuyla en yüksek doğruluğu ve diğer metriklerde üstün başarıyı sağlaması, HGWSSO algoritmasının etkinliğini ortaya koymaktadır. GWO algoritması, HGWSSO algoritmasının hemen ardından yer almış ve makul bir performans göstermiştir. Özellikle düşük öznitelik boyutuyla dikkat çekse de, doğruluk ve diğer metriklerde HGWSSO algoritmasının biraz gerisinde kalmıştır. SSA algoritması, yüksek özellik boyutuna rağmen düşük doğruluk oranıyla en zayıf performansı sergilemiş ve diğer algoritmalarla kıyasla belirgin bir şekilde geri kalmıştır.

Şekil 4.24.'de, SAVEE veri setinde SVM sınıflandırıcısı ile SSA, GWO ve HGWSSO algoritmalarının öznitelik boyutu (Öznitelik Sayısı) ve doğruluk oranı (Doğruluk) arasındaki performans karşılaştırmasını göstermektedir.



Şekil 4.24. SAVEE veri setinde SVM sınıflandırıcısında öznitelik sayısı ve doğruluk oranı karşılaştırma

SSA algoritması, en yüksek öznitelik boyutuna (yaklaşık 800) sahiptir. Ancak bu büyük öznitelik boyutuna rağmen doğruluk oranı yaklaşık %84 seviyesinde kalmıştır. Yüksek öznitelik boyutu, SSA'nın birçok gereksiz veya tekrarlayan özelliği seçtiğini ve sınıflandırma

doğruluğunu artırmada etkisiz kaldığını göstermektedir. Bu durum, SSA'nın SAVEE veri setinde SVM sınıflandırıcı ile zayıf bir performans sergilediğini ortaya koymaktadır.

GWO algoritması, yaklaşık 150 öznitelik boyutu ile çalışmış ve doğruluk oranında %91,67 seviyesine ulaşmıştır. Bu, GWO'nun az sayıda öznitelik ile yüksek doğruluk elde edebilme yeteneğini göstermektedir. Düşük öznitelik boyutuyla işlem maliyetini azaltması ve aynı zamanda yüksek bir doğruluk sağlaması, GWO'nun SAVEE veri setinde etkili bir optimizasyon yöntemi olduğunu kanıtlamaktadır.

HGWSSO algoritma, GWO'ya benzer bir şekilde yaklaşık 150 öznitelik boyutu ile çalışmıştır. Ancak doğruluk oranı %92,36 ile en yüksek başarıyı elde etmiştir. HGWSSO algoritmasının, farklı optimizasyon tekniklerinin güçlü yönlerini birleştirerek en iyi performansı sağladığı açıkça görülmektedir. Düşük öznitelik boyutuyla yüksek doğruluk oranı elde etmesi, HGWSSO algoritmasını diğer algoritmalarından üstün kılmaktadır.

HGWSSO algoritma, SAVEE veri setinde SVM sınıflandırıcı ile en iyi performansı sergileyerek, düşük öznitelik boyutu ve yüksek doğruluk oranı ile öne çıkmaktadır. GWO, düşük öznitelik boyutuyla makul bir alternatif sunarken, SSA yüksek öznitelik boyutuna rağmen sınırlı bir doğruluk oranı ile diğer algoritmaların gerisinde kalmıştır. HGWSSO algoritma, dengeli ve etkili bir çözüm olarak en uygun yöntemdir.

4.5. Tartışma

HGWSSO Algoritması hem KNN hem de SVM sınıflandırıcılarında çoğu veri setinde öne çıkmış ve özellikle karmaşık veri setlerinde doğruluğu optimize etmiştir. GWO algoritması, sınıflandırıcıların genel performansında tutarlı bir yapı sunmuş ve EmoDB gibi karmaşık olmayan veri setlerinde yüksek doğruluk oranlarına ulaşmıştır. Ancak, daha karmaşık veri setlerinde Hybrid algoritma kadar etkili olamamıştır. SSA algoritması, genel olarak daha yüksek öznitelik boyutlarında çalışmasına rağmen düşük doğruluk oranları sergilemiştir.

Önerilen HGWSSO algoritması, Grey Wolf Optimizer (GWO) ve Salp Swarm Algorithm (SSA) yöntemlerinin avantajlarını birleştiren hibrit bir yapı sunmaktadır. GWO'nun lider birey (alfa, beta, delta) odaklı güncelleme mekanizması, iyi çözümlere odaklanarak güçlü bir sömürü yeteneği sağlar. Bu sayede, çözüm uzayında daha önce elde edilmiş yüksek kaliteli çözümler

etrafında yoğunlaşarak modelin hızlı ve kararlı bir şekilde yakınsamasını destekler. Diğer yandan, SSA'nın lider-takipçi temelli yapısı ve özellikle lider bireyin hedefe rastgele yönelimi sayesinde arama uzayında geniş çaplı bir keşif gerçekleştirilir. SSA'nın lider davranışı, algoritmanın çözüm çeşitliliğini korumasına ve erken aşamalarda küresel optimumu kaçırmamasına katkı sağlamaktadır. HGWSSO algoritmasında SSA'dan devralınan bu keşif yeteneği, GWO'nun sömürü kabiliyeti ile dengeli bir biçimde birleştirilmiş; ayrıca en iyi birey etrafında yapılan yönlendirme ile keşif davranışı daha da güçlendirilmiştir. Böylece HGWSSO, iterasyon başlarında yüksek keşif kabiliyeti ile arama uzayının geniş bir kısmını değerlendirebilmekte, ilerleyen aşamalarda ise daha iyi bireylere odaklanarak etkili bir sömürü gerçekleştirmektedir. Bu çift yönlü mekanizma, önerilen yöntemin hem genel doğruluk başarımını artırmakta hem de lokal minimumlara sıkışma riskini minimize etmektedir.

Konuşma tabanlı duygu tanıma alanında yapılan çalışmalar, farklı makine öğrenimi ve optimizasyon teknikleri kullanarak çeşitli veri kümeleri üzerinde önemli başarımlar elde etmiştir. Literatürde sıkça başvurulanan veri kümeleri arasında EmoDB, RAVDESS, SAVEE, CASIA, TESS, ANAKE ve Urdu gibi çok dilli ve çok modelli kaynaklar yer almaktadır. Bu çalışmada önerilen HGWSSO+SVM tabanlı yaklaşımın başarımlar düzeyi, önceki yöntemlerle karşılaştırmalı olarak Çizelge 4.9'da incelenmiştir.

Kanwal & Asghar (2021) çalışmasında Clustered Genetic Algorithm ile SVM kombinasyonu EmoDB üzerinde %77.5 doğruluk elde ederken, Rajeswhar (2021) tarafından PSO-GSA ile optimize edilmiş DBN modeli %96.7 gibi yüksek bir başarı sağlamıştır. Benzer şekilde, Al Dujaili vd. (2021) tarafından SVM + KNN with MVR kombinasyonu ile EmoDB üzerinde KNN kullanımıyla %87.85 doğruluk oranına ulaşılmıştır. Bu sonuçlar, optimizasyon temelli hibrit modellerin, klasik sınıflandırıcılara kıyasla daha iyi performans gösterdiğini ortaya koymaktadır.

Son yıllarda derin öğrenme mimarilerinin de literatürde daha fazla yer bulduğu görülmektedir. Marik vd. (2023) tarafından HDFS ve Wide-ResNet-50-2+WOA bileşimiyle EmoDB'de %93.64 doğruluk sağlanmıştır. Benzer şekilde, DCNN (VGG) + GWO yaklaşımı ile Falahzadeh vd. (2023), eNTERFACE05 veri kümesinde %79.83 doğruluk oranına ulaşmıştır. Hybrid Bat Optimization + RF kombinasyonu kullanan Agrawal & Jain (2025) ise EmoDB'de %98.14 doğrulukla öne çıkmaktadır.

Bu bağlamda, bu çalışmada önerilen HGWSSO+SVM yöntemi ile EmoDB’de %98.14, SAVEE veri kümesinde %92.36 ve EMOVA’da %93.89 doğruluk oranlarına ulaşılmıştır. Elde edilen sonuçlar, önerilen yöntemin mevcut literatürdeki birçok çalışmadan daha yüksek performans sergilediğini göstermektedir. HGWSSO algoritmasının hem global hem de yerel arama yeteneklerini dengeli bir şekilde kullanması ve SVM gibi güçlü bir sınıflandırıcıyla entegre edilmesi, başarımın temel nedenleri arasında değerlendirilebilir.

Çizelge 4.9. Literatürde yapılan çalışmaların karşılaştırılması

Yazarlar	Yöntem	Sonuçlar
Kanwal & Asghar (2021)	Clustered Genetic Algorithm+ SVM	EmoDB:%77.5 RAVDESS:%76.2 SAVEE: %69.8
Rajeshwar (2021)	PSO-GSA optimized DBN	EmoDB: %96.7 SVM: %85.1
Al Dujaili vd. (2021)	SVM + KNN with MVR	KNN:%87.85 (EmoDB)
Bagadi & Sivappagari (2022)	CSEO (EO + CS)	EmoDB:%94.35 RAVDESS:%96.78
Marik vd. (2023)	HDFS;Wide-ResNet-50-2+WOA	RAVDESS:%89.72 Urdu:%96.25 EmoDB: %93.64
Sun vd. (2022)	GA + DT-SVM	EmoDB:%85.89 CASIA: %85.3
Falahzadeh vd. (2023)	DCNN (VGG) + GWO	EmoDB:%82.41 eNTERFACE05: %79.83 Arabic:%88.95
Shahin vd. (2023)	GWO-KNN	RAVDESS:%80.48 SAVEE: %83.54
Tyagi & Szénási (2024)	CNN/LSTM + GWO	EmoDB GWO-SVM: %85 GWO-CNN: %78 RAVDESS: %93.8
Agrawal & Jain (2025)	Hybrid Bat Optimization + RF	SAVEE: %85.4 ANAKE: %89.8 EmoDB:98.14
Özseven & Arpacioğlu(2025)	HGWSSO+SVM	SAVEE:92.36 EMOVA:89.93

Çalışmamızda HGWSSO algoritmasının SVM sınıflandırıcısıyla birlikte kullanıldığında genel olarak en yüksek performansı sağladığı tespit edilmiştir. Özellikle SAVEE ve eNTERFACE gibi karmaşık veri setlerinde HGWSSO algoritması SVM ile birleştirildiğinde üstün başarı sergilemiştir. GWO algoritması EmoDB gibi daha basit veri setlerinde etkili olurken, SSA algoritmasının genelde daha düşük performans sunduğu gözlemlenmiştir. Bu bulgular, çalışmanın gelecekteki geliştirme ve uygulama çalışmaları için önemli bir temel oluşturmaktadır.



5. SONUÇ VE ÖNERİLER

5.1. Sonuçlar

Bu çalışmanın temel amacı, GWO ve SSA öz niteliklerini birleştiren bir hibrit algoritma geliştirerek duygu tanıma sistemlerinde etkili bir öz nitelik seçimi ve sınıflandırma performansı sağlamaktır. Amaç, geleneksel algoritmaların karşılaştığı optimizasyon problemlerini çözmek, öz nitelik boyutlarını azaltırken sınıflandırma doğruluğunu artırmaktır. Algoritma, veri setleri üzerinde hem KNN hem de SVM sınıflandırıcılarıyla test edilmiş ve dört farklı veri seti (EmoDB , SAVEE, EMOVA, eINTERFACE) kullanılmıştır.

Çizelge 5.1. ve 5.2.'de GWO, SSA ve HGWSSO algoritmalarının hem KNN hem de SVM sınıflandırıcılarıyla çeşitli veri setlerinde kullanılmasıyla elde edilen öz nitelik sayıları ve doğruluk oranları gösterilmektedir.

Çizelge 5.1. KNN sınıflandırıcı ile doğruluk oranları ve öz nitelik sayılarının karşılaştırılması

Veri Seti	Algoritma	Öz nitelik Sayısı	Doğruluk (%)	Sınıflandırıcı
EmoDB	GWO	198	91.30	KNN
EmoDB	SSA	765	82.61	KNN
EmoDB	HGWSSO	586	91.92	KNN
SAVEE	GWO	113	85.42	KNN
SAVEE	SSA	779	70.14	KNN
SAVEE	HGWSSO	158	87.50	KNN
EMOVA	GWO	152	82.55	KNN
EMOVA	SSA	771	65.10	KNN
EMOVA	HGWSSO	211	87.25	KNN
eINTERFACE	GWO	199	69.19	KNN
eINTERFACE	SSA	788	53.78	KNN
eINTERFACE	HGWSSO	193	75.00	KNN

Çizelge 5.2. SVM sınıflandırıcı ile doğruluk oranları ve öznitelik sayılarının karşılaştırılması

Veri Seti	Algoritma	Öznitelik Sayısı	Doğruluk (%)	Sınıflandırıcı
EmoDB	GWO	124	96,89	SVM
EmoDB	SSA	760	91,30	SVM
EmoDB	HGWSSO	137	98.14	SVM
SAVEE	GWO	156	91.67	SVM
SAVEE	SSA	765	84.03	SVM
SAVEE	HGWSSO	144	92.36	SVM
EMOVA	GWO	192	90.60	SVM
EMOVA	SSA	750	76.51	SVM
EMOVA	HGWSSO	147	89.93	SVM
eINTERFACE	GWO	234	80.23	SVM
eINTERFACE	SSA	773	74.13	SVM
eINTERFACE	HGWSSO	248	79.65	SVM

Veri setleri, öznitelik boyutu, sınıflandırma doğruluğu ve algoritmaların etkinliği üzerine odaklanılmış ve aşağıdaki çıkarımlar yapılmıştır.

5.1.1. KNN Sınıflandırıcı Performansı:

EmoDB veri seti üzerinde yapılan değerlendirmelerde, KNN sınıflandırıcı ile kullanılan HGWSSO algoritmasının %91,92 oranında en yüksek doğruluk değerine ulaştığı görülmüş, buna karşılık GWO algoritması %91,30 doğruluk oranı ile HGWSSO algoritmasına oldukça yakın bir performans sergilemiştir. SAVEE veri setinde ise HGWSSO algoritmasının %87,50 doğruluk oranıyla öne çıktığı gözlemlenmiş, bu sonuç HGWSSO algoritmasının düşük öznitelik boyutlarında dahi etkili ve başarılı bir performans ortaya koyduğunu göstermektedir. eINTERFACE veri seti üzerinde yapılan analizlerde, HGWOSS algoritmasının %75 doğruluk oranı ile en yüksek başarıyı elde ettiği, buna karşın SSA algoritmasının %53,78 doğruluk oranı ile daha düşük bir performans sergilediği belirlenmiştir. EMOVA veri seti açısından değerlendirildiğinde, HGWSSO algoritması %87,25 oranıyla en yüksek doğruluğu sağlayarak en başarılı yöntem olurken, bu algoritmayı %85,91 doğruluk oranı ile GWO algoritması takip etmiştir.

5.1.2. SVM Sınıflandırıcı Performansı:

EmoDB veri seti üzerinde gerçekleştirilen değerlendirmelerde, HGWSSO algoritması %98,14 doğruluk oranı ile en yüksek başarıyı elde etmiş, buna karşılık Gri Kurt Optimizasyonu (GWO) algoritması %96,89 doğruluk oranı ile HGWSSO algoritmasına oldukça yakın bir performans göstermiştir. SAVEE veri setinde HGWSSO algoritması %92,36 doğruluk oranıyla öne çıkmış ve SVM tabanlı yapıların karmaşık veri setlerinde etkili sonuçlar verebildiğini ortaya koymuştur. eNTERFACE veri setinde ise GWO algoritması %80,23 doğruluk oranı ile diğer iki algoritmaya kıyasla daha iyi bir performans sergilemiş, bu sonucu %79,65 doğruluk oranı ile HGWSSO algoritması takip etmiştir.

SVM, genellikle KNN'ye kıyasla daha yüksek doğruluk oranlarına ulaşmış ve daha karmaşık veri setlerinde daha tutarlı performans sergilemiştir. Bu, SVM'nin ayrışım yeteneğinin daha yüksek olmasından kaynaklanmaktadır. KNN, daha düz veri setlerinde (EmoDB ve SAVEE) etkili performans sergilemiş ve hesaplama maliyeti düşük olması nedeniyle avantaj sağlamıştır.

5.2. Öneriler

Önerilen HGWSSO algoritmasının daha geniş kapsamlı bir şekilde test edilmesi ve uygulanması için çeşitli geliştirmeler önerilmektedir. Öncelikle, farklı dil ve aksanlara sahip daha karmaşık veri setlerinde test edilebilir. Ek olarak, gürültülü ve eksik veri setlerinde algoritmanın dayanıklılığı test edilmelidir. Bu testler, algoritmanın gerçek dünya uygulamalarında daha iyi performans ortaya koymasına katkı sağlayabilecektir.

Önerilen algoritmanın kullanım alanları genişletilerek biyomedikal veri analizi, sahtecilik tespiti ve finansal analiz gibi farklı alanlarda test edilmesi sağlanmalıdır. Ayrıca, sesli asistanlar ve insan-bilgisayar etkileşimi (HCI) projelerinde kullanılabilirliği artırılarak pratik uygulamalara entegre edilebilir. Böylelikle, algoritmanın ticari ve akademik alanlarda daha fazla benimsenmesi sağlanacaktır.

Hesaplama verimliliğini artırmak için paralel işlem tekniklerinin kullanılması önerilmektedir. Bu sayede, algoritma daha büyük veri setleri üzerinde daha hızlı ve etkili çalışabilir. Ek olarak, enerji verimliliği odaklı algoritmik optimizasyonlar, büyük veri setleri için önemli bir avantaj sağlayarak sürdürülebilir bilgi işlem çözümleri sunabilir.

Algoritmanın daha geniş bir kitle tarafından benimsenmesi ve kolay kullanılabilmesi için kullanıcı dostu ara yüzler geliştirilmelidir. Grafikselle ve sezgisel ara yüzler, özellikle eğitimsiz kullanıcıların algoritmanın faydalarından yararlanmasını kolaylaştırabilir. Böylece, HGWSSO algoritması akademik çalışmaların yanı sıra pratik uygulamalarda da yaygın olarak kullanılabilir.

Son olarak, bu çalışmanın sonuçları, farklı makine öğrenimi modelleri ve metasezgisel algoritmalar ile karşılaştırılması önerilmektedir. Yapılacak kapsamlı karşılaştırmalar, algoritmanın çeşitli uygulama senaryolarındaki etkinliğini değerlendirmek için kritik bir adım olacaktır. Bu tür doğrulamalar, HGWSSO algoritmasının güvenilirliğini artırarak gelecekteki araştırmalar için sağlam bir temel oluşturacaktır.



6. KAYNAKLAR

- Abdelhamid, A. A., El-Kenawy, E.-S. M., Alotaibi, B., Amer, G. M., Abdelkader, M. Y., Ibrahim, A., & Eid, M. M. (2022). Robust Speech Emotion Recognition Using CNN+LSTM Based on Stochastic Fractal Search Optimization Algorithm. *IEEE Access*, 10, 49265-49284. <https://doi.org/10.1109/ACCESS.2022.3172954>
- Abualigah, L., Elaziz, M. A., Khasawneh, A. M., Alshinwan, M., Ibrahim, R. A., Al-qaness, M. A. A., Mirjalili, S., Sumari, P., & Gandomi, A. H. (2022). Meta-heuristic optimization algorithms for solving real-world mechanical engineering design problems: A comprehensive survey, applications, comparative analysis, and results. *Neural Computing and Applications*, 34(6), 4081-4110. <https://doi.org/10.1007/s00521-021-06747-4>
- Agrawal, A., & Jain, A. (2025). Brhamo: Metaheuristic optimization algorithm for speech emotion recognition using spectral and hybrid features. *Evolutionary Intelligence*, 18(1), 4. <https://doi.org/10.1007/s12065-024-00994-9>
- Aina, J., Akinniyi, O., Rahman, Md. M., Odero-Marrah, V., & Khalifa, F. (2024). A Hybrid Learning-Architecture for Mental Disorder Detection Using Emotion Recognition. *IEEE Access*, 12, 91410-91425. <https://doi.org/10.1109/ACCESS.2024.3421376>
- AKÇA, M. F. (2020). *Nedir Bu Destek Vektör Makineleri?* <https://medium.com/deep-learning-turkiye/nedir-bu-destek-vekt%C3%B6r-makineleri-makine-%C3%B6%C4%9Frenmesi-serisi-2-94e576e4223e>
- Akinpelu, S., & Viriri, S. (2022). Robust Feature Selection-Based Speech Emotion Classification Using Deep Transfer Learning. *Applied Sciences*, 12(16), 8265. <https://doi.org/10.3390/app12168265>
- Akkurt, G. (2019). *DATA MINING FOR EMOTION RECOGNITION IN SPEECH*.
- Al Dujaili, M. J., Ebrahimi-Moghadam, A., & Fatlawi, A. (2021). Speech emotion recognition based on SVM and KNN classifications fusion. *International Journal of Electrical and Computer Engineering (IJECE)*, 11(2), 1259. <https://doi.org/10.11591/ijece.v11i2.pp1259-1264>

- Albadr, M. A. A., Tiun, S., Ayob, M., AL-Dhief, F. T., Omar, K., & Maen, M. K. (2022). Speech emotion recognition using optimized genetic algorithm-extreme learning machine. *Multimedia Tools and Applications*, 81(17), 23963-23989. <https://doi.org/10.1007/s11042-022-12747-w>
- Aljarah, I., Habib, M., Faris, H., Al-Madi, N., Heidari, A. A., Mafarja, M., Elaziz, M. A., & Mirjalili, S. (2020). A dynamic locality multi-objective salp swarm algorithm for feature selection. *Computers & Industrial Engineering*, 147, 106628. <https://doi.org/10.1016/j.cie.2020.106628>
- Anonim. (2024). *Ses Oluşumu*. <https://www.bulbapp.io/p/097ea99d-26a2-4064-a8cc-65007960ec6d/ses-oluumu-sesin-artc-gc>
- Atalay, T. (2018). *COMPARISON OF FEATURE SELECTION AND EXTRACTION METHODS AND ACTIVE LEARNING IN VOICE BASED EMOTION RECOGNITION SYSTEMS*.
- Bagadi, K. R., & Sivappagari, C. M. R. (2022). A robust feature selection method based on meta-heuristic optimization for speech emotion recognition. *Evolutionary Intelligence*. <https://doi.org/10.1007/s12065-022-00772-5>
- Bandela, S. R., & Kumar, T. K. (2019). Speech emotion recognition using semi-NMF feature optimization. *TURKISH JOURNAL OF ELECTRICAL ENGINEERING & COMPUTER SCIENCES*, 27(5), 3741-3757. <https://doi.org/10.3906/elk-1903-121>
- Baykasoglu, A. (2002). Linguistic-based meta-heuristic optimization model for flexible job shop scheduling. *International Journal of Production Research*, 40(17), 4523-4543. <https://doi.org/10.1080/00207540210147043>
- Bojanić, M., DeliĆ, V., & Karpov, A. (2020). Call Redistribution for a Call Center Based on Speech Emotion Recognition. *Applied Sciences*, 10(13), 4653. <https://doi.org/10.3390/app10134653>
- Burkhardt, F., Paeschke, A., Rolfes, M., Sendlmeier, W. F., & Weiss, B. (2005). A database of German emotional speech. *Interspeech 2005*, 1517-1520. <https://doi.org/10.21437/Interspeech.2005-446>
- Costantini, G., Iadarola, I., Paoloni, A., & Todisco, M. (2014). *EMOVO Corpus: An Italian Emotional Speech Database*.
- Daneshfar, F., & Kabudian, S. J. (2020). Speech emotion recognition using discriminative dimension reduction by employing a modified quantum-behaved particle swarm optimization algorithm.

- Multimedia Tools and Applications*, 79(1-2), 1261-1289. <https://doi.org/10.1007/s11042-019-08222-8>
- Darekar, R. V., Chavan, M., Sharanyaa, S., & Ranjan, N. M. (2023). A hybrid meta-heuristic ensemble based classification technique speech emotion recognition. *Advances in Engineering Software*, 180, 103412. <https://doi.org/10.1016/j.advengsoft.2023.103412>
- Demir, A. (2021). *DERİN ÖĞRENME VE SES TABANLI DUYGU TANIMA*.
- Dey, A., Chattopadhyay, S., Singh, P. K., Ahmadian, A., Ferrara, M., & Sarkar, R. (2020). A Hybrid Meta-Heuristic Feature Selection Method Using Golden Ratio and Equilibrium Optimization Algorithms for Speech Emotion Recognition. *IEEE Access*, 8, 200953-200970. <https://doi.org/10.1109/ACCESS.2020.3035531>
- Doğdu, C., Kessler, T., Schneider, D., Shadaydeh, M., & Schweinberger, S. R. (2022). A Comparison of Machine Learning Algorithms and Feature Sets for Automatic Vocal Emotion Recognition in Speech. *Sensors*, 22(19), 7561. <https://doi.org/10.3390/s22197561>
- Erdem, E. S. (2014). SES SİNYALLERİNDE DUYGU TANIMA VE GERİ ERİŞİMİ. *BAŞKENT ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ*.
- Falahzadeh, M. R., Farokhi, F., Harimi, A., & Sabbaghi-Nadooshan, R. (2023). Deep Convolutional Neural Network and Gray Wolf Optimization Algorithm for Speech Emotion Recognition. *Circuits, Systems, and Signal Processing*, 42(1), 449-492. <https://doi.org/10.1007/s00034-022-02130-3>
- Gandomi, A. H., Kashani, A. R., Roke, D. A., & Mousavi, M. (2015). Optimization of retaining wall design using recent swarm intelligence techniques. *Engineering Structures*, 103, 72-84. <https://doi.org/10.1016/j.engstruct.2015.08.034>
- Gerçekker, M., Yorulmaz, İ., & Ural, A. (2000). Ses ve konuşma. *K.B.B. ve Baş Boyun Cerrahisi Dergisi*, 8(1), 71-78.
- Hu, P., Pan, J.-S., & Chu, S.-C. (2020). Improved Binary Grey Wolf Optimizer and Its application for feature selection. *Knowledge-Based Systems*, 195, 105746. <https://doi.org/10.1016/j.knosys.2020.105746>

- J Rajeshwar. (2021). Hybrid Particle Swarm Optimization-Gravitational Search Algorithm based Deep Belief Network: Speech Emotion Recognition. *Journal of Computational Mechanics, Power System and Control*, 4(3), 23-31. <https://doi.org/10.46253/jcmps.v4i3.a4>
- Jakkula, V. (2006). Tutorial on Support Vector Machine (SVM). *School of EECS, Washington State University*, 37(2.5)(3).
- Kanwal, S., & Asghar, S. (2021). Speech Emotion Recognition Using Clustering Based GA-Optimized Feature Set. *IEEE Access*, 9, 125830-125842. <https://doi.org/10.1109/ACCESS.2021.3111659>
- Liu, Z.-T., Wu, M., Cao, W.-H., Mao, J.-W., Xu, J.-P., & Tan, G.-Z. (2018). Speech emotion recognition based on feature selection and extreme learning machine decision tree. *Neurocomputing*, 273, 271-280. <https://doi.org/10.1016/j.neucom.2017.07.050>
- Manohar, K., & Logashanmugam, E. (2022). Hybrid deep learning with optimal feature selection for speech emotion recognition using improved meta-heuristic algorithm. *Knowledge-Based Systems*, 246, 108659. <https://doi.org/10.1016/j.knosys.2022.108659>
- Marik, A., Chattopadhyay, S., & Singh, P. K. (2022). A hybrid deep feature selection framework for emotion recognition from human speeches. *Multimedia Tools and Applications*. <https://doi.org/10.1007/s11042-022-14052-y>
- Martin, O., Kotsia, I., Macq, B., & Pitas, I. (2006). The eNTERFACE’05 Audio-Visual Emotion Database. *22nd International Conference on Data Engineering Workshops (ICDEW'06)*, 8-8. <https://doi.org/10.1109/ICDEW.2006.145>
- Mirjalili, S., Gandomi, A. H., Mirjalili, S. Z., Saremi, S., Faris, H., & Mirjalili, S. M. (2017). Salp Swarm Algorithm: A bio-inspired optimizer for engineering design problems. *Advances in Engineering Software*, 114, 163-191. <https://doi.org/10.1016/j.advengsoft.2017.07.002>
- Mirjalili, S., Mirjalili, S. M., & Lewis, A. (2014). Grey Wolf Optimizer. *Advances in Engineering Software*, 69, 46-61. <https://doi.org/10.1016/j.advengsoft.2013.12.007>
- Oflazoglu, Ç. (2011). TÜRKÇE KONUŞMA SİNYALİNDEN DUYGU TANIMA. *Mustafa Kemal Üniveristesi Fen Bilimleri Enstitüsü*.
- Onwubolu, G. C., & Babu, B. V. (2004). *New Optimization Techniques in Engineering* (C. 141). Springer Berlin Heidelberg. <https://doi.org/10.1007/978-3-540-39930-8>

- Ozseven, T., & Arpaciglu, M. (2024). Comparative Performance Analysis of Metaheuristic Feature Selection Methods for Speech Emotion Recognition. *Measurement Science Review*, 24(2), 72-82. <https://doi.org/10.2478/msr-2024-0010>
- Özseven, T. (2019). A novel feature selection method for speech emotion recognition. *Applied Acoustics*, 146, 320-326. <https://doi.org/10.1016/j.apacoust.2018.11.028>
- Özseven, T., & Düğenci, M. (2018). SPeech ACoustic (SPAC): A novel tool for speech feature extraction and classification. *Applied Acoustics*, 136, 1-8. <https://doi.org/10.1016/j.apacoust.2018.02.009>
- Pandey, A., & Jain, A. (2017). Comparative Analysis of KNN Algorithm using Various Normalization Techniques. *International Journal of Computer Network and Information Security*, 9(11), 36-42. <https://doi.org/10.5815/ijcnis.2017.11.04>
- Pao, T.-L., Chen, Y.-T., Yeh, J.-H., & Chang, Y.-H. (2005). *Emotion Recognition and Evaluation of Mandarin Speech Using Weighted D-KNN Classification*.
- Ramesh, S., Gomathi, S., Sasikala, S., & Saravanan, T. R. (2023). Automatic speech emotion detection using hybrid of gray wolf optimizer and naïve Bayes. *International Journal of Speech Technology*, 26(3), 571-578. <https://doi.org/10.1007/s10772-021-09870-8>
- Sánchez-Gutiérrez, M. E., Albornoz, E. M., Martínez-Licon, F., Rufiner, H. L., & Goddard, J. (2014). Deep Learning for Emotional Speech Recognition. İçinde J. F. Martínez-Trinidad, J. A. Carrasco-Ochoa, J. A. Olvera-Lopez, J. Salas-Rodríguez, & C. Y. Suen (Ed.), *Pattern Recognition* (C. 8495, ss. 311-320). Springer International Publishing. https://doi.org/10.1007/978-3-319-07491-7_32
- Shahin, I., Alomari, O. A., Nassif, A. B., Afyouni, I., Hashem, I. A., & Elnagar, A. (2023). An efficient feature selection method for arabic and english speech emotion recognition using Grey Wolf Optimizer. *Applied Acoustics*, 205, 109279. <https://doi.org/10.1016/j.apacoust.2023.109279>
- Slowik, A. (Ed.). (2020). *Swarm Intelligence Algorithms: Modifications and Applications* (1. bs). CRC Press. <https://doi.org/10.1201/9780429422607>
- Soler-Dominguez, A., Juan, A. A., & Kizys, R. (2018). A Survey on Financial Applications of Metaheuristics. *ACM Computing Surveys*, 50(1), 1-23. <https://doi.org/10.1145/3054133>

- Sönmez, Y. Ü. (2021). *KONUŞMA SESLERİNDEN DUYGULARI TANIMAK İÇİN YEREL İKİLİ VE ÜÇLÜ ÖRÜNTÜLERE DAYALI YENİ BİR MODELİN GELİŞTİRİLMESİ*.
- Sun, L., Li, Q., Fu, S., & Li, P. (2022). Speech emotion recognition based on genetic algorithm–decision tree fusion of deep and acoustic features. *ETRI Journal*, 44(3), 462-475. <https://doi.org/10.4218/etrij.2020-0458>
- Tsang-Long Pao, Yu-Te Chen, Jun-Heng Yeh, & Pei-Jia Li. (2006). Mandarin Emotional Speech Recognition Based on SVM and NN. *18th International Conference on Pattern Recognition (ICPR '06)*, 1096-1100. <https://doi.org/10.1109/ICPR.2006.780>
- Tu, Q., Chen, X., & Liu, X. (2019). Multi-strategy ensemble grey wolf optimizer and its application to feature selection. *Applied Soft Computing*, 76, 16-30. <https://doi.org/10.1016/j.asoc.2018.11.047>
- Tyagi, S., & Szénási, S. (2024). Optimizing Speech Emotion Recognition with Deep Learning and Grey Wolf Optimization: A Multi-Dataset Approach. *Algorithms*, 17(3), 90. <https://doi.org/10.3390/a17030090>
- Ververidis, D., Kotropoulos, C., & Pitas, I. (2004). Automatic emotional speech classification. *2004 IEEE International Conference on Acoustics, Speech, and Signal Processing*, 1, 1-593-596. <https://doi.org/10.1109/ICASSP.2004.1326055>
- Xue, B., Zhang, M., & Browne, W. N. (2013). Particle Swarm Optimization for Feature Selection in Classification: A Multi-Objective Approach. *IEEE Transactions on Cybernetics*, 43(6), 1656-1671. <https://doi.org/10.1109/TSMCB.2012.2227469>
- Yildirim, S., Kaya, Y., & Kılıç, F. (2021). A modified feature selection method based on metaheuristic algorithms for speech emotion recognition. *Applied Acoustics*, 173, 107721. <https://doi.org/10.1016/j.apacoust.2020.107721>
- Yue, L., Hu, P., Chu, S.-C., & Pan, J.-S. (2024). Multi-Objective Equilibrium Optimizer for Feature Selection in High-Dimensional English Speech Emotion Recognition. *Computers, Materials & Continua*, 78(2), 1957-1975. <https://doi.org/10.32604/cmc.2024.046962>
- Yue, L., Hu, P., & Zhu, J. (2024). Gender-Driven English Speech Emotion Recognition with Genetic Algorithm. *Biomimetics*, 9(6), 360. <https://doi.org/10.3390/biomimetics9060360>

Zhongzhe Xiao, Dellandrea, E., Weibei Dou, & Liming Chen. (2005). Features extraction and selection for emotional speech classification. *Proceedings. IEEE Conference on Advanced Video and Signal Based Surveillance, 2005.*, 411-416. <https://doi.org/10.1109/AVSS.2005.1577304>



ÖZGEÇMİŞ