



## A new approach for gender detection from voice data: Feature selection with optimization methods

Feyza Altunbey Özbay<sup>1\*</sup>, Erdal Özbay<sup>2</sup>

<sup>1</sup>Department of Software Engineering, Faculty Engineering, Firat University, 23119, Elazig, Türkiye

<sup>2</sup>Department of Computer Engineering, Faculty Engineering, Firat University, 23119, Elazig, Türkiye

### Highlights:

- Feature selection for gender detection with metaheuristic optimization algorithms
- Use of Naive Bayes and Decision Tree algorithms for gender detection
- Comparison of the accuracy, fitness function, and selected feature number of PSO, KKO, SSA, and BOA

### Keywords:

- Gender detection
- Feature selection
- Optimization
- Classification

### Article Info:

Research Article

Received: 17.05.2021

Accepted: 20.05.2022

### DOI:

10.17341/gazimmfd.938294

### Correspondence:

Author: Feyza Altunbey Özbay  
e-mail:  
faltunbey@firat.edu.tr  
phone: +90 424 607 5575

### Graphical/Tabular Abstract

Gender detection, which is an important problem in speech analysis, has been used in many different areas, especially in recent years. Our study proposed a feature selection method based on metaheuristic optimization algorithms to detect gender from voice data. In this study, PSO, ACO, SSA, and WOA algorithms have been modeled for the first time to make feature selections from voice data. The flow diagram of the proposed method for gender detection on voice data by applying Naive Bayes and Decision Tree algorithms is shown in Figure A.

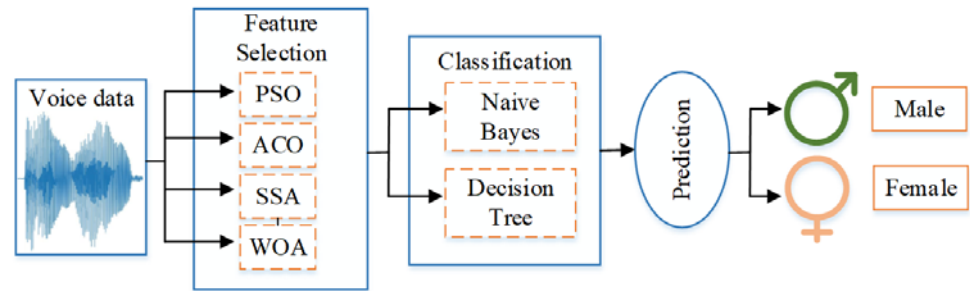


Figure A. General flow diagram of the proposed model

### Purpose:

In the proposed method, nature-inspired optimization algorithms are used to find the feature set that will best represent the sound data. It is aimed to increase the success rate in terms of accuracy, precision, recall, and the area under the ROC area in the gender detection problem by using new data sets that feature selection with optimization algorithms.

### Theory and Methods:

In this study, metaheuristic algorithms, inspired by nature, are used for feature selection to solve the gender determination problem from voice data. In this study, PSO, ACO, SSA, and WOA have modeled for the first time as a feature selection method in gender detection problems from voice data. Accuracy value, fitness function value, and the number of selected features have been used as performance evaluation criteria to evaluate the performance of algorithms. Gender detection has been implemented by applying Naive Bayes and Decision Tree algorithms to new data sets and original data set obtained after feature selection. Feature selection has been made with metaheuristic algorithms and the performances of Naive Bayes and Decision Tree algorithms on the original data sets have been compared according to four different criteria.

### Results:

Metaheuristic algorithms, which provide effective solutions for complex real-world problems, have yielded successful results for feature selection in gender determination problems from voice data. In this study, it was observed that the results obtained by Naive Bayes and Decision Tree algorithms in data sets obtained after feature selection with metaheuristic algorithms have better than the original data sets without feature selection.

### Conclusion:

This study, which performs the feature selection for gender detection problems from voice data for the first time using metaheuristic optimization algorithms, can be accepted as a basic study for the researchers. Since the obtained numerical results are very promising, the experiments can be extended and the proposed method can be applied to different sound data sets.



## Ses verilerinden cinsiyet tespiti için yeni bir yaklaşım: Optimizasyon yöntemleri ile özellik seçimi

Feyza Altunbey Özbay<sup>1\*</sup>, Erdal Özbay<sup>2</sup>

<sup>1</sup>Firat Üniversitesi, Mühendislik Fakültesi, Yazılım Mühendisliği Bölümü, 23119, Elazığ, Türkiye

<sup>2</sup>Firat Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 23119, Elazığ, Türkiye

### ÖNEÇIKANLAR

- Metasezgisel optimizasyon algoritmaları ile cinsiyet tespiti için özellik seçimi
- Cinsiyet tespiti için Naive Bayes ve Karar Ağacı algoritmalarının kullanımı
- PSO, KKO, SSA ve BOA'nın doğruluk, uygunluk fonksiyonu ve seçilen özellik sayısı değerlerinin karşılaştırılması

### Makale Bilgileri

Araştırma Makalesi

Geliş: 17.05.2021

Kabul: 20.05.2022

### DOI:

10.17341/gazimmfd.938294

### Anahtar Kelimeler:

Cinsiyet tespiti,  
özellik seçimi,  
optimizasyon,  
sınıflandırma

### ÖZ

Son yıllarda, birçok farklı uygulama alanına sahip cinsiyet tespiti, konuşma analizinin önemli bir problemidir. Cinsiyet tespiti için perde, medyan, frekans gibi ses verilerinin farklı özelliklerinden yararlanılmaktadır. Bu çalışmada, ses verilerinden cinsiyet tespiti için metasezgisel optimizasyon algoritmalarını temel alan bir özellik seçimi yöntemi önerilmiştir. Önerilen yöntemde, ses verilerini en uygun biçimde temsil edecek özellik kümesi optimizasyon algoritmaları ile seçilmiş ve elde edilen özellikler kullanılarak yapay zekâ algoritmaları ile cinsiyet tespiti yapılmıştır. Ses verilerinden özellik seçimi yapmak için karmaşık problemleri çözmek konusunda yeteneklere sahip doğadan esinlenmiş metasezgisel optimizasyon algoritmaları kullanılmıştır. Parçacık Sürüsü Optimizasyonu (PSO), Karınca Koloni Optimizasyonu (KKO), Salp Sürüsü Algoritması (SSA) ve Balina Optimizasyonu Algoritması (BOA) ses verilerinden özellik seçimi için ilk kez modellenmiştir. Metasezgisel optimizasyon algoritmalarının etkinliğini ölçmek için genel erişime açık veri kümesi kullanılmıştır. PSO, KKO, SSA ve BOA'nın özellik seçimi için performansları uygunluk fonksiyonu değeri, doğruluk değeri ve seçilen özellik sayısı olmak üzere üç farklı ölçüt bakımından karşılaştırılmıştır. Metasezgisel optimizasyon algoritmaları ile özellik seçimi yapıldıktan sonra elde edilen yeni veri kümeleri ve orijinal veri kümesine Naive Bayes ve Karar Ağacı algoritmaları uygulanmıştır. Yapılan analizler sonucunda, metasezgisel optimizasyon algoritmalarını özellik seçimi için kullanan bu yöntem sayesinde Naive Bayes ve Karar Ağacı algoritmaları ile elde edilen sonuçlarda başarı oranının arttığı gözlemlenmiştir.

## A new approach for gender detection from voice data: Feature selection with optimization methods

### HIGHLIGHTS

- Feature selection for gender detection with metaheuristic optimization algorithms
- Use of Naive Bayes and Decision Tree algorithms for gender detection
- Comparison of the accuracy, fitness function, and selected feature number values of PSO, KKO, SSA, and BOA

### Article Info

Research Article

Received: 17.05.2021

Accepted: 20.05.2022

### DOI:

10.17341/gazimmfd.938294

### Keywords:

Gender detection,  
feature selection,  
optimization,  
classification

### ABSTRACT

In recent years, gender detection has been an important problem in speech analysis, with many different applications. Different features of sound data such as pitch, median, and frequency are used for gender detection. In this study, a feature selection method based on metaheuristic optimization algorithms is proposed for gender detection from voice data. In the proposed method, the feature set representing the voice data in the most appropriate way is selected with optimization algorithms, and gender detection has been implemented with artificial intelligence algorithms using the obtained features. Nature-inspired metaheuristic optimization algorithms, which are capable of solving complex problems, are used to select features from voice data. Particle Swarm Optimization (PSO), Ant Colony Optimization (ACO), Salp Swarm Algorithm (SSA), and Whale Optimization Algorithm (WOA) have been modeled for the first time for feature selection from voice data. A publicly accessible data set has been used to measure the efficiency of metaheuristic optimization algorithms. The performances of PSO, ACO, SSA, and WOA for feature selection have been compared in terms of three different criteria: fitness function value, accuracy value, and the number of selected features. After feature selection with metaheuristic optimization algorithms, Naive Bayes and Decision Tree algorithms have been applied to the new data sets obtained and the original data set. As a result of the analysis, it was observed that this method which uses metaheuristic optimization algorithms for feature selection increased the success rate in the results obtained with Naive Bayes and Decision Tree algorithms.

## 1. Giriş (Introduction)

Konuşma, günlük yaşantıda insanların birbirleriyle iletişim kurmalarını ve düşüncelerini ifade etmek için kullandıkları en önemli araçlardan biridir. Havanın akciğerlerden boşaltılması ve dil, diş, ses telleri gibi organlardan geçmesi ile konuşma üretilmektedir. Konuşma ile cinsiyet, yaş, duyu, durum gibi birçok veri elde edilebilmektedir. Bu nedenle konuşma işleme, duyu tanıma, ses biyometrisi, yaş ve cinsiyet belirleme gibi farklı araştırmalara konu olmuştur. Konuşma sinyallerini işleyerek bir konuşmacının cinsiyetinin belirlenmesi, son yıllarda oldukça ilgi çeken aktif bir araştırma alanıdır. İnsan kulağının mükemmel mekanizması sayesinde insanlar için sesli cinsiyet tanıma kolay bir görevdir. Benzer şekilde, makineler ile etkili bir sesli cinsiyet tanıma sistemi geliştirilebilmektedir. Bunun dışında kulak, yüz bölgesi, parmak izi ve göz iris deseni gibi bireyler arasındaki ayrıştırılmayı kolaylaştıracak olgu ve öğeler de cinsiyet tespiti için kullanılmaktadır [1].

Cinsiyet tespiti, konuşmacının ses sinyallerinin işlenerek cinsiyet kategorisine karar verilmesi için kullanılan tekniklerdir. Kaydedilmiş bir konuşmadan alınan konuşma sinyalleri, süre, yoğunluk, frekans ve filtreleme gibi akustik nitelikleri elde etmek için kullanılabilir [2]. Duygu tanıma, insan makine etkileşimi, cinsiyete göre telefon çağrılarının sıralanması, otomatik selamlama, cinsiyete göre ses/video kategorizasyonu gibi birçok uygulama alanında cinsiyet tespiti yöntemlerine başvurulmaktadır.

Bilgi miktarındaki artış, veri madenciliği tekniklerinde özellik seçimi gibi ön işlem adımlarını gerekli hale getirmiştir. Bununla birlikte, veri miktarındaki artış, sınıflandırma yöntemlerinin başarı oranını etkilemektedir. Bu nedenle, öğrenme algoritmalarının performansının artırmak için yeni yöntemler gereklidir. Cinsiyet tespiti problemi için önerilen yöntemlerin performansını artırmak için özellik seçimi yöntemleri kullanılabilir. Gereksiz ve ilgisiz özellikler, sınıflandırma için kullanışlı olmadığı gibi öğrenme algoritmalarının başarısını azaltmaktadır. Optimum bir alt kümeyi aramak, özellik seçiminde çok önemli bir konudur. Olası tüm alt kümeler, en iyi alt kümeyi oluşturmak için kapsamlı bir şekilde oluşturulabilir [3]. Bu yaklaşım büyük veri kümeleri için uygulanabilir değildir. Örneğin;  $N$  adet özellik içeren bir veri kümesinde  $2^N$  adet çözüm üretilir ve son derece yüksek bir hesaplama maliyetine neden olur [4]. Diğer bir yaklaşım ise rastgele bir minimum indirgeme yapmaktır. Bu yaklaşım en iyi durumda erken aşamalarda minimum azalmayı bulurken, en kötü durumda ise tam bir arama yapmaktadır. Özellik seçimi algoritmaları ile özellik kümesi içerisinde önemli nitelikler belirlenmektedir [5]. Özellik seçim algoritmalarının, gereksiz özellikleri kaldırma, hesaplama maliyetini düşürmede, bir sınıflandırıcının performansını iyileştirmede ve gerekli depolamayı azaltmadaki verimlilikleri bilinmektedir. Ayrıca, görüntü işleme, metin sınıflandırma gibi birçok farklı alanda başarıyla kullanılmaktadır [6-8]. Bunun yanında müşteri ilişkileri yönetimi ve tıbbi destek sistemleri gibi alanlarda da kullanımına başvurulmaktadır [9-12].

Doğadan ilham alan metasezgisel algoritmalar, karmaşık gerçek dünya problemleriyle başa çıkmadaki güçlü ve verimli performansları nedeniyle, son yirmi yılda ön plana çıkmıştır. Bir metasezgisel algoritma, arama uzayını keşfetmek ve sömürmek için farklı kavramları yöneten yinelemeli bir üretim sürecidir. Önerilen birçok farklı metasezgisel algoritma farklı stratejiye sahip olmasına rağmen ortak bazı temel prensiplere sahiptir. Optimizasyonun amacı, bir amaç fonksiyonunu maksimize ya da minimize edecek bir çözüm bulmak için arama yapmaktır. Tüm metasezgisel algoritmalar, mevcut optimumu dikkate almakta ve zaman ya da yineleme sayısı gibi sınıflandırma koşullarına göre sona erdirilmektedir. Bu algoritmalar, en uygun çözümleri bulmak için popülasyonun kullanışlı bilgilerinden

yararlanma yeteneğine sahiptir. Basit kavramlara dayanan ve uygulanması kolay olan metasezgisel algoritmalar, karmaşık tasarım problemleri [13, 14], kablosuz sensör ağlarda düğüm konumlandırma [15], arıza teşhisi [16], ekonomik yük dağıtımı [17], büyük boyutlu optimizasyon problemleri [18, 19], görüntü eşleştirme [20] ve sırt çantası problemi [21] gibi farklı ayrık optimizasyon problemlerinin çözümünde giderek daha popüler hale gelmiştir.

Özellik seçimi görevinin karmaşık yapısı nedeniyle güçlü ve verimli arama algoritmalarının kullanılması gerekmektedir. Metasezgisel yöntemler, kesin arama mekanizmalarının aksine, tüm arama alanını aramak zorunda olmadıkları için olağanüstü bir performans göstermektedirler. Aşında tam bir arama algoritması olmayan bu yöntemler, kabul edilebilir zaman dilimi içerisinde optimuma en yakın çözümü bulmayı hedeflemektedir. Birçok araştırmacı özellik seçimi problemini çözmek için farklı stokastik yöntemler kullanmışlardır: Benzetimli tavlama [22], tabu arama [23], parçacık sürüsü optimizasyonu (PSO) [24], yapay arı kolonisi [25] ve genetik algoritma [26].

Bu makalede, birçok farklı alanda kullanılan ve popüler bir konu haline gelen ses sinyalleri ile cinsiyet tespiti problemi için optimizasyon temelli bir özellik seçim yöntemi önerilmiştir. Bu yöntemde, karmaşık problemleri çözmek konusundaki yeteneklere sahip metasezgisel optimizasyon algoritmaları ses verilerinden özellik seçimi yapmak için kullanılmıştır. Özellik seçimi işlemi sonrasında elde edilen yeni veri kümeleri kullanılarak yapay zekâ algoritmaları ile cinsiyet tespiti yapılmıştır. Çalışma kapsamında, Parçacık Sürüsü Optimizasyonu (PSO), Karınca Koloni Optimizasyonu (KKO), Salp Sürüsü Algoritması (SSA) ve Balina Optimizasyonu Algoritması (BOA) ses verilerinden özellik seçimi için ilk kez modellenmiştir. Metasezgisel optimizasyon algoritmalarının etkinliğini ölçmek için genel erişime açık ses veri kümesi kullanılmıştır. PSO, KKO, SSA ve BOA'nın özellik seçimi üzerindeki performansları uygunluk fonksiyonu değeri, doğruluk değeri ve seçilen özellik sayısı olmak üzere üç farklı ölçüt bakımından karşılaştırılmıştır. Metasezgisel optimizasyon algoritmaları ile özellik seçimi sonrasında elde edilen yeni veri kümeleri üzerinde Naive Bayes ve Karar Ağacı algoritmaları çalıştırılarak cinsiyet tespiti yapılmıştır ve elde edilen analiz sonuçları özellik seçimi yapılmamış orijinal veri kümesi ile kıyaslanmıştır.

Bu çalışmanın literatüre katkıları aşağıdaki gibi listelenmiştir:

- Metasezgisel optimizasyon algoritmaları ses verileri üzerinden cinsiyet tespiti probleminde özellik seçimi yöntemi olarak ilk kez modellenmiştir.
- PSO, KKO, SSA ve BOA özellik seçimi sırasında elde edilen sonuçlar uygunluk fonksiyonu değeri, doğruluk değeri ve seçilen özelliklerin sayısı olmak üzere üç farklı metrik cinsinden verilmiş ve performans karşılaştırılması yapılmıştır.
- Metasezgisel optimizasyon algoritmaları ile özellik seçimi yapıldıktan sonra elde edilen yeni veri kümeleri üzerinde Naive Bayes ve Karar Ağacı algoritmaları kullanılarak ses verilerinden cinsiyet tespiti yapılmıştır.

Çalışmanın geri kalanı şu şekilde ilerlemektedir. İkinci bölümde, cinsiyet tespiti ile ilgili literatürde bulunan farklı yöntemler incelenmiştir. Üçüncü bölümde, kullanılan veri kümesi ve önerilen yöntemin tasarımı sunulmuştur. Bu kapsamda, metasezgisel optimizasyon algoritmalarının özellik seçimi problemi için modellenmesi, temsil biçimi ve optimizasyon algoritmalarında özellik seçimi için kullanılan uygunluk fonksiyonu incelenmiştir. Ayrıca, özellik seçimi için kullanılan PSO, KKO, SSA ve BOA ile ilgili temel bilgilere yer verilmiştir. Dördüncü bölümde, Naive Bayes ve Karar Ağacı algoritmalarının performanslarını değerlendirmek için

kullanılan performans değerlendirme ölçütleri verilmiştir. Beşinci bölümde, PSO, KKO, SSA ve BOA ile özellik seçimi yapılması sonucu elde edilen deneysel sonuçlar farklı metrikler cinsinden karşılaştırılmıştır. Ayrıca, özellik seçimi yapılmamış orijinal veri kümesine ve optimizasyon algoritmaları ile özellik seçimi yapılmasından sonra elde edilen yeni veri kümelerine Naive Bayes ve Karar Ağacı algoritmalarının uygulanması sonucu elde edilen cinsiyet tespiti sonuçları da bu bölümde incelenmiştir. Son bölümde ise çalışma özetlenerek sonuçlandırılmıştır.

## 2. Cinsiyet Tespiti İle İlgili Çalışmalar (Related Works Regarding Gender Detection)

Son on yıldır, makine öğrenmesi ve veri madenciliği teknikleri, sesle cinsiyetin tanınması için yaygın olarak kullanılmaktadır. Bu tahmin modelleri ile ses tellerinin uzunluğu ve konuşma biçimi gibi farklı özellikler kullanılarak bir kişinin cinsiyetini belirlenebilmektedir. Detaylı olarak, ses ve konuşma sinyallerinden elde edilen süre, yoğunluk ve frekans gibi akustik özellikler, konuşmacının cinsiyetini tanımak için kullanılmaktadır. Sesle cinsiyet tanıma problemi üzerine yapılan çalışmalardan bazıları aşağıda verilmiştir.

Maka vd. sesle cinsiyet belirleme problemi için deneylerini iç ve dış mekân içişel sahneler içeren farklı akustik ortamlarda yapmışlardır. 438 erkek ve 192 kadın, toplam 630 konuşmacıdan oluşan bir veri kümesi kullanmışlardır. Ek olarak, değerlendirme aşamasında, her cümle birkaç tür arka plan gürültüsü ile karıştırılmıştır [27]. Bisio vd. çoklu denetimsiz Destek Vektör Makinesi (DVM) sınıflandırıcısını kullanarak cinsiyet, konuşmacı ve dil tanıma için bir android konuşma işleme platformu olarak akıllı telefon uygulaması geliştirmişlerdir. Önerilen bu yaklaşımda, sistem bu platformun kurulu olduğu her kullanıcıdan çıkarılan özellikler ile dinamik olarak eğitilmektedir. Araştırmacılar, bu çalışma ile yüksek sınıflandırma doğruluğu elde etmeyi ve cinsiyetleri daha iyi tanımak için performansın artırılmasını hedeflemişlerdir [28]. Pahwa vd. cinsiyet belirlemek için konuşma özelliklerinin Mel katsayısı ve birinci ve ikinci türevlerini çıkarmışlardır. Bu yöntemde DVM ve sinir ağı sınıflandırıcısını kullanmışlardır. Önerdikleri yöntemi 46 konuşmacının konuşma örneklerini kullanarak test etmişlerdir ve deney sonuçlarından elde ettikleri doğruluk oranı %93,48'dir [29].

Pribil vd. yaş ve cinsiyeti tanımak için iki seviyeli bir Gauss Karışım Modeli (Gaussian Mixture Model) algoritması önermişlerdir. Önerilen sınıflandırıcıları ilk olarak dört farklı yaş kategorisinin (çocuk, genç, yetişkin, yaşlı) tespiti ve Çek ve Slovak dillerindeki çocukların sesleri dışında herkesin cinsiyetini tanıması için doğrulamışlardır. Elde edilen sonuçlara göre yöntemin doğruluk oranını %90'ın üzerindedir [30]. Büyükyılmaz vd. cinsiyet belirlemek için seslerin ve konuşmanın akustik özelliklerini kullanan çok katmanlı bir algılayıcı derin öğrenme modeli kullanmışlardır. 3168 insan sesi örneğinden oluşan veri kümesi ile yaptıkları deneylerde %96,74 doğruluk elde etmişlerdir. Ayrıca, elde edilen bu modelden

yararlanarak ses ile cinsiyeti tespit yapan bir web sayfası tasarlamışlardır [31]. Barkana vd. yaş ve cinsiyet sınıflandırması için perde aralığına bağlı bir model sunmuşlardır. Konuşma sesini sessizlikten ayırmak için ön işleme adımları olarak enerji ve sıfır geçiş oranlarını kullanmışlardır. Sınıflandırma yöntemi olarak ise  $k$ -En Yakın Komşular ( $k$ -Nearest Neighbors -  $k$ NN) ve DVM algoritmalarını kullanarak %84,7 değerinde bir doğruluk elde etmişlerdir [32].

Ramdinmawii vd. perde, sinyal enerjisi ve Mel frekansı keprstral katsayıları (Mel-frequency cepstral coefficients) olmak üzere konuşma sinyalinin üç farklı özelliğini kullanan bir cinsiyet tanımlama sistemi sunmuşlardır. Texas Instruments Massachusetts Teknoloji Enstitüsü veri kümesi üzerinde yaptıkları deneyler sonucunda en yüksek doğruluk oranını (%69) Mel frekansı keprstral katsayıları ile elde etmişlerdir [33].

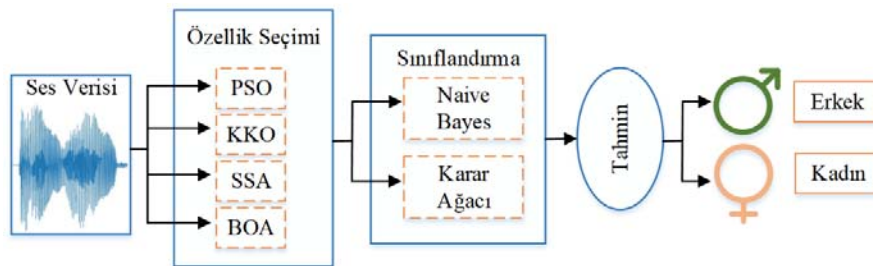
Hebbar vd. çift yönlü uzun kısa süreli bellek (Long Short-Term Memory) tabanlı ses etkinlik algılama ve ses sınıflandırma modelinden öğrenme aktarımı olmak üzere iki bileşenden oluşan ve film seslerine uygulanan bir model önermişlerdir. Ses verilerini Mel filtre bankası katsayıları özellikleriyle temsil etmiş ve sınıflandırma için üç yoğun katman kullanarak Softmax işlevi kullanmışlardır. Önerdikleri bu yöntem ile %87 doğruluk oranı elde etmişlerdir [34]. Kabil vd. ham konuşma sinyallerinde Evrişimli Sinir Ağı (Convolution Neural Network) ardından Çok Katmanlı Algılayıcı (Multi-Layer Perceptron) kullanan ve sınıflandırma için bir Softmax işlevi kullanan bir yöntem önermişlerdir [35].

## 3. Materyal ve Metot (Material and Method)

Bu çalışmada, özellik seçimi için doğadan ilham alarak geliştirilen PSO, KKO, SSA ve BOA metasezgisel optimizasyon algoritmaları ses verisine uygulanarak yeni veri kümeleri elde edilmiştir. Sonrasında elde edilen yeni veri kümelerine ve özellik seçimi yapılmayan orijinal veri kümesine, Naive Bayes ve Karar Ağacı algoritmaları uygulanarak cinsiyet tespiti yapılmıştır. Önerilen yöntemin akış diyagramı Şekil 1'de verilmiştir. Ses verileri üzerinden cinsiyet tespiti için metasezgisel optimizasyon algoritmalarını kullanan bu yeni yöntemin etkinliğini ölçmek için genel erişime açık bir ses verisi kullanılmıştır. Bu bölümde, kullanılan veri kümesi, optimizasyon algoritmalarının özellik seçimi için modelleniş biçimi ve kullanılan optimizasyon algoritmaları hakkında bilgi verilmiştir.

### 3.1. Veri Kümesi (Data Set)

Bu çalışmada kullanılan ses verisi, 1584'ü kadına, 1584'ü erkeğe ait olmak üzere toplam 3168 ses örneği içermektedir. Her bir örnek, sesin farklı akustik özelliklerini içermektedir. Veri kümesinde toplam 22 özellik bulunmaktadır. Bu özelliklerin isimleri ve tanımları Tablo 1'de verilmiştir [36].



Şekil 1. Önerilen yöntemin akış diyagramı (Flow diagram of the proposed method)

**Tablo 1.** Cinsiyet ses veri kümesinin özellikleri  
(Features of the gender voice dataset)

Akustik Özellikler	
Özellik	Tanım
duration	Sinyalin uzunluğu
meanfreq	Frekans ortalaması (kHz)
sd	Frekansın standart sapması
median	Frekansın medyanı (kHz)
Q25	İlk çeyrek (kHz)
Q75	Üçüncü çeyrek (kHz)
IQR	Çeyrekler arası aralık (kHz)
skew	Çarpıklık
kurt	Basıklık
sp.ent	Spektral entropi
sfm	Spektral düzlük
mode	Mod frekansı
centroid	Frekans ağırlık merkezi
peakf	Tepe frekansı
meanfun	Akustik sinyalde ölçülen temel frekansın ortalaması
minfun	Akustik sinyalde ölçülen minimum temel frekans
maxfun	Akustik sinyalde ölçülen maksimum temel frekans
meandom	Akustik sinyalde ölçülen baskın frekansın ortalaması
mindom	Akustik sinyal boyunca ölçülen minimum baskın frekans
maxdom	Akustik sinyal boyunca ölçülen maksimum baskın frekans
dfrange	Akustik sinyalde ölçülen baskın frekans aralığı
modindx	Modülasyon indeksi

### 3.2. Optimizasyon Yöntemleri ile Özellik Seçimi (Feature Selection with Optimization Methods)

Özellik seçimi, sınıflandırma problemlerinde en önemli ön işlemlerden biridir. Bilgi çağının hızla gelişmesiyle birlikte, sınıflandırma problemlerinde kullanılan verilerdeki toplam özellik miktarı gittikçe artmaktadır. Model oluşturma sürecinde tüm bu özelliklerin kullanılması zaman almaktadır. Ayrıca bazı özellikler gereksiz ve hatta yanıltıcı olduğu için sınıflandırma sonucunu önemli oranda azaltmaktadır. Bu nedenle, orijinal özellik kümesinden özellik seçim sürecine ihtiyaç duyulmaktadır. Özellik seçimi algoritmaları, değerlendirme süreçlerine göre üçe ayrılmaktadır. Bir algoritma, özellik seçimini herhangi bir öğrenme algoritmasından bağımsız olarak gerçekleştirirse bu yaklaşım filtre tabanlı özellik seçimi kategorisine dâhil edilmektedir. Bu yaklaşım çoğunlukla sınıflar arası ayrılabilirlik kriterlerine dayalı özelliklerin seçilmesini içermektedir [37]. Değerlendirme süreci, öğrenme algoritmasının görevine (örneğin, sınıflandırma) bağlıysa, özellik seçimi algoritması bir çeşit sarmalama tabanlı yaklaşımdır. Bu yöntem, bir tümevarım algoritmasından tahmin edilen doğruluğu kullanarak özellik alt kümesi uzayında arama yapmaktadır. Sarmalama tabanlı yaklaşımda, değerlendirme işlevi, oluşturma süreci tarafından üretilen bir özellik alt kümesinin uygunluğunu hesaplamakta ve aynı zamanda bunu önceki en iyi adayla kıyaslayarak daha iyi olduğu tespit edildiğinde onu değiştirmektedir. Özellik seçimi sürecinin devam edip etmeyeceğini belirlemek için yinelenmelerin her birinde bir durdurma kriteri test edilmektedir. Özellik seçimi ve öğrenme algoritması bir

arada kullanıldığında, özellik seçimi algoritması bir tür gömülü yaklaşım olarak kabul edilmektedir [38].

Bu yöntemlerin dışında, metasezgisel optimizasyon yöntemleri de özellik seçimi için kullanılmaktadır. Özellik seçimi probleminin arama uzayı, bir optimizasyon yönteminde Eş. 1'de verildiği gibi, tüm olası özellik alt kümelerini içermektedir. Eş. 1'de  $n$  özelliklerin sayısı ve  $s$  mevcut özellik alt kümesinin boyutudur.

$$\sum_{s=0}^n \binom{n}{s} = \binom{n}{0} + \binom{n}{1} + \dots + \binom{n}{n} = 2^n \quad (1)$$

Bu çalışma, ses verileri ile cinsiyet tespiti problemini çözmek için etkili bir özellik seçimi yapmayı amaçlamaktadır. Özellik seçimi yöntemi olarak, PSO, KKO, SSA ve BOA olmak üzere dört farklı optimizasyon algoritması kullanılmaktadır. Bu algoritmalar ile en iyi özellikleri içeren bir özellik uzayının başarılı bir şekilde bulunması hedeflenmektedir. Optimal ve en iyi özellik, yüksek sınıflandırma doğruluğuna ve daha az sayıda seçilen özelliğe sahip olmalıdır. Kullanılan dört optimizasyon algoritması az sayıda seçilen özelliklerle daha iyi bir sınıflandırma performansı üreten en iyi özellik kümesi için özellik uzayında arama yapmaktadır. Bu amaçla seçilen özelliklerin optimizasyon algoritmaları tarafından değerlendirilmesi için Eş. 2'de verilen uygunluk fonksiyonu kullanılmaktadır.

$$Uygunluk\ Fonksiyonu = a \times HataOranı + (1 - a) \frac{N}{L} \quad (2)$$


Eş. 2'de *HataOranı* sınıflandırma hata oranıdır.  $N$  seçilen özelliklerin sayısını gösterirken,  $L$  veri kümesindeki toplam özellik sayısını göstermektedir.  $a$  ise sınıflandırma performansının ve özellik boyutunun etkisini kontrol etmek için kullanılan  $[0, 1]$  aralığında bir parametredir.

Optimizasyon algoritmalarını kullanarak bir özellik seçimi problemini çözmek için ilk adım, özellik alt kümesini ifade edecek bir temsil biçimi oluşturmaktır. Ses verilerinin özellik kümesini gösteren bir temsil biçimi Şekil 2'de verilmiştir.

Şekil 2'de görüldüğü gibi özellik seçiminde, özellik alt kümesi ikili bir vektör olarak gösterilmiştir. Vektörün uzunluğu  $d$ , veri kümesindeki tüm özelliklerin sayısıdır. Vektörün bit değerleri ise özelliklerin seçilme durumuna bağlı olarak 1 ya da 0 değerleri ile ifade edilmiştir. Eğer özellik seçilmişse ise bit değeri 1, özellik seçilmemişse 0 değeri ile gösterilmiştir.

#### 3.2.1. Parçacık sürüsü optimizasyonu (PSO) (Particle swarm optimization (PSO))

Parçacık sürüsü optimizasyonu (PSO) algoritması, hayvanlar arasındaki sosyal etkileşimin taklit edilmesiyle önerilmiş bir optimizasyon yöntemidir. PSO, Eberhart ve Kennedy tarafından sosyal davranış bilgisinin gelişiminden esinlenerek 1995 yılında önerilmiş bir algoritmadır. Algoritmada sürü, göç veya avlanma ile ilgili özel bilgilerini paylaşılırken, grup iletişim davranışını simüle edilmiştir, böylelikle sosyal davranış bilgisinin gelişimi taklit edilmiştir. Bu bakımdan bir parçacık, konumunun güncellenmesinde



Şekil 2. Özellik seçimi için temsil biçimi (Representation format for feature selection)



komşularından edindiği deneyimine güvenmektedir [39]. PSO, parçacıkların rastgele bir kümesi ile çözüme başlamaktadır. Daha sonra, PSO uygunluk işlevi gerçekleştirmek üzere her parçacığın değerlendirilmesi için bir ana döngü başlatmaktadır. Sonuçta, en iyi ve küresel en iyi değerler kontrol edilmiş olmaktadır. Eş. 4 ve Eş. 5, parçacıkların konum güncellemesi için kullanılan yöntemi ifade etmektedir. Örneğin  $i \times j$  boyutunda bir parçacık olduğunu varsayarak, varlık parçacık matrisi Eş. 3'teki gibi gösterilmektedir;

$$X = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1j} \\ x_{21} & x_{22} & \dots & x_{2j} \\ \dots & \dots & \dots & \dots \\ x_{i1} & x_{i2} & \dots & x_{ij} \end{bmatrix} \quad (3)$$

Eş. 3'te verilen matriste,  $i$ . parçacık  $x_{ij} = [x_{i1}, x_{i2}, \dots, x_{ij}]$  olarak ifade edilmektedir. Sürü,  $j$ . boyutunda, konumlarını  $x_i$ , hızlarını  $v_i$  olacak şekilde oluşturmanın yanı sıra bir dizi rastgele parçacık oluşturarak başlamaktadır. Güncellemeler ile en uygun çözüm bulunmaya çalışılırken, çıktı, her tekrarlama iki en iyi parçacığa göre güncellenmektedir. Bunlardan ilki, yerel en iyi olarak adlandırılan  $x_j^p$ , gerçek parçacıklar arasında o ana kadar elde edilen en iyi değere sahip olan parçacıktır. İkincisi ise  $x_j^g$ , tüm varlık içerisinde en iyi duruma sahip olan parçacıktır [39].

$$x_{ij}^{(t+1)} = x_{ij}^{(t)} + v_{ij}^{(t+1)} \quad (4)$$

$$v_{ij}^{(t+1)} = wv_{ij}^{(t)} + c_1r_1(x_{ij}^{p(t)} - x_{ij}^{(t)}) + c_2r_2(x_{ij}^{g(t)} - x_{ij}^{(t)}) \quad (5)$$

Mevcut tekrarlamalarda, en iyi uygunluk değerini veren  $i$ . parçacığın pozisyonu  $x_{ij}^{p(t)}$  dir ve yerel en iyi parçacık olarak tanımlanmaktadır.  $x_{ij}^{g(t)}$ ,  $j$ . boyuttaki küresel en iyi konumu tanımlamaktadır.  $v_{ij}$ ,  $j$ . boyuttaki  $i$ . hızdır,  $t$  mevcut yinelemeyi tanımlamaktadır,  $w$  bir eylemsizlik ağırlığını belirtmektedir ve varlık yakınsamasının hızını iyileştirmek için uygulanmaktadır. Burada  $c_1$  ve  $c_2$  sabitleri ivme katsayılarıdır.  $r_1$  ve  $r_2$   $[0, 1]$  aralığındaki düzgün dağılımlı rastgele parametrelerdir. Tekrarlama, sonlandırma kriteri sağlanıncaya kadar devam etmektedir. Sonlandırma kriteri sabit bir yineleme sayısı olabilmektedir. PSO algoritmasının adımları Tablo 2'de verilmiştir.

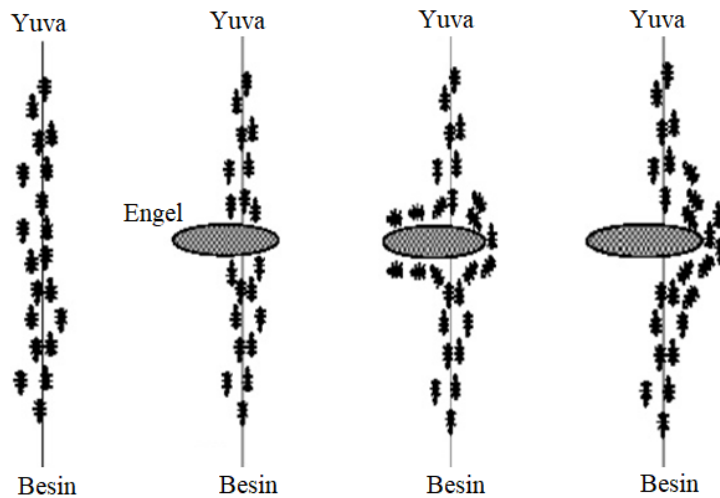
### 3.2.2. Karınca koloni optimizasyonu (KKO) (Ant colony optimization (ACO))

Karınca koloni optimizasyon (KKO) algoritması, Dorigo ve arkadaşları tarafından 2006 yılında, ilk olarak gezgin satıcı ve kuadratik atama problemleri gibi zor optimizasyon problemlerinin etkin çözümü için önerilmiştir [40]. Doğada yaşayan karıncalar, görme duyusuna ihtiyaç duymadan, besin kaynağına ulaşmada yuvalarına en yakın yolu bulma kabiliyetlerine sahiptir. KKO algoritması, bazı karınca türlerinin, yiyecek arama davranışlarından esinlenmiştir. Bu karıncalar, koloninin diğer üyeleri tarafından izlenmesi gereken uygun bir yolu işaretlemek için buldukları zemine feromon salgılamaktadırlar.

Şekil 3'te gösterildiği gibi başlangıçta karıncalar, yuva ile besin arasındaki düz bir hat boyunca salgıladıkları feromon maddesini, takip ettikleri güzergâha bırakmak suretiyle birbirlerini takip

**Tablo 2.** PSO Algoritmasının sözde kodu (Pseudo code of the PSO Algorithm)

Parçacık Sürüsü Optimizasyon (PSO) Algoritması
1: Popülasyonu başlat
2: while
3: for $i = 1 : N$ (Popülasyon sayısı) do
4: Amaç fonksiyon değerini hesaplanır.
5: if fitness değeri ( $PBest$ ) değerinden daha iyiyse
6: Mevcut değer yeni $PBest$ olarak ayarlanır.
7: $GBest$ olarak tüm parçacıkların en iyi uygunluk değerine sahip olan parçacık seçilir.
8: Eş. 5'e göre yeni bir hız hesaplanır.
9: Parçacık pozisyonu Eş. 4'e göre güncellenir.
10: end for
11: until (sonlandırma kriteri karşılanana kadar)



**Şekil 3.** Karıncaların yol tercihi (Path preference of ants)


etmektedirler. Bu davranış, kendilerinden sonraki yolu takip edecek olan türdeşlerinin, en kısa yolu bulmasını kolaylaştırmaktadır. Dış etkenlerce daha önce takip ettikleri yol artık mevcut değilse, yeni en kısa yol bulunmaya çalışılmaktadır. Şekil 3'te görüldüğü üzere karıncalar önlerine bir engel çıktığında salgılanmış olan feromonları takip edemedikleri için öncelikle tercih edebilecekleri ihtimaller rastgele olarak seçilmektedir. Engelin yarattığı güzergâh değişikliğinden, kısa engel tarafındaki geçişler birim zamanda daha fazla olacağından bu yöndeki feromon salgı birikimi daha fazla olacaktır. Bu duruma bağlı olarak, kısa engel tarafından geçen karınca sayısındaki artış, zamanla tüm karıncaların bu yolu tercih etmesine neden olmaktadır. Neticede ilk etapta rastgele olarak yön tercihinde bulunan karıncalar, feromonun daha yoğun olduğu yön doğrultusunda otokatalitik bir tercih yapmış olmaktadır [40].

Algoritma süresince, karıncaların karşılıklı sinerjik etkileşimleriyle ortaya çıkan davranışlar ile güncellenen feromon izlerine bağlı olarak iyi bir çözüm için bilgi oluşturulmakta ve her iterasyonda bu bilgiler güncellenmektedir. Bu bakımdan, yapay karıncalardan oluşan algoritmada, yapay feromon değerlerinin güncellenmesine ait döngü Tablo 3'te verilmiştir;

### 3.2.3. Salp sürüsü algoritması (SSA) (Salp swarm algorithm (SSA))

Salp sürü algoritması (SSA), Mirjalili ve arkadaşları tarafından 2017 yılında, Salp'lerin doğadaki davranışlarından esinlenerek ortaya çıkmıştır ve farklı birçok optimizasyon probleminin çözümünde yeni bir teknik olarak sıklıkla kullanılmaktadır [41].

Salpidae ailesine ait Salp'ler fiçiyı andıran saydam bir yapıya sahiptir ve planktonik tunikalar olarak adlandırılmaktadır. Salp'lerin en ilginç davranışlarından biri okyanus derinliklerinde Salp zinciri adı verilen bir sürü davranışına sahip olmalarıdır. Sürü zekâsı mantığı, yapay ya da doğal şekillerde kendini organize edebilen sistemlerin, merkezi bir kontrol sistemi bulunmadan gösterdiği toplu davranış biçimi olarak nitelendirilmektedir. Bu davranışlar, hızlı ve uyumlu değişikliklerin gerçekleştirilmesiyle daha iyi hareket etme ve yiyeceklerin aranması konusunda Salp'lere avantaj sağlamaktadır. Temeli bu davranışa dayanan algoritmada, Salp zincirleri matematiksel bir biçimde Mirjalili ve arkadaşları tarafından modellenmiş ve optimizasyon problemlerinde test edilmiştir [41]. Şekil 4'te Salp canlısı ve Salp zinciri olarak adlandırılan sürü şeklinde davranışları gösterilmektedir.



Şekil 4. Salp canlısı ve Salp zinciri (Salp alive and Salp chain)

SSA, popülasyonu lider ve takipçiler olmak üzere iki gruba ayırmakla başlamaktadır. Zincirin en ön sırasında yer alan Salp lider, geri kalan diğer tüm Salp'ler ise takipçi olarak nitelendirilmektedir. Salp'in pozisyonu bir problemin arama uzayının temsil edildiği ve değişken sayısını ifade eden  $n$  boyutunda belirlenmektedir. Sürünün hedefi besin kaynağının aranmasıdır. Bu bakımdan arama uzayındaki besin kaynağının konumu  $F$ , Salp lideri tarafından gerçekleştirilmek üzere Eş. 6 yardımıyla sık sık güncellenmektedir. Liderin pozisyonunun güncellenmesi için gerekli matematiksel ifade Eş. 6'da verilmiştir [41].

$$x_j^1 = \begin{cases} F_j + c_1 \left( (ub_j - lb_j)c_2 + lb_j \right), & c_3 \leq 0 \\ F_j - c_1 \left( (ub_j - lb_j)c_2 + lb_j \right), & c_3 > 0 \end{cases} \quad (6)$$

burada  $x_j^1$ , lider Salp'in  $j$ 'inci boyuttaki konumunu ve  $F_j$ , bu boyuttaki besin kaynağının pozisyonunu göstermektedir.  $ub_j$  ve  $lb_j$ , sırasıyla boyutun üst ve alt sınırlarını ifade etmektedir,  $c_1$ ,  $c_2$  ve  $c_3$ , arama alanını korumak için oluşturulmuş  $[0, 1]$  aralığındaki rassal sayılardır. Ayrıca  $c_1$  parametresi, besin keşfi ile sömürü aşamaları arasında dengeleme rolü nedeniyle SSA algoritmasında çok önemli bir katsayıdır ve Eş. 7 ile hesaplanmaktadır;

$$c_1 = 2e^{-\left(\frac{4t}{t_{max}}\right)^2}, \quad (7)$$

burada  $t$ , geçerli iterasyonu ve  $t_{max}$  ise maksimum iterasyon sayısını ifade etmektedir. Liderin konumu güncellendikten sonra, SSA Eş. 8 ile takipçilerin konumunu güncellemeye başlamaktadır;

$$x_j^i = \frac{1}{2}(x_j^i + x_j^{i-1}), \quad (8)$$

burada  $x_j^i$ ,  $j$ 'inci boyut içerisindeki  $i$ 'inci takipçinin konumudur ve  $i$  değeri 1'den büyüktür. SSA'nın mantığına göre Salp'lerin bulunduğu zincirdeki lider Salp, hareketli ya da sabit bir besin kaynağının bulunduğu arama uzayında, konumunu besin kaynağının çevresine göre değiştirmektedir ve takipçi Salp'ler her iterasyon boyunca kademeli olarak lider Salp'i takip etmektedirler [42]. SSA algoritmasının adımları Tablo 4'te verilmiştir.

### 3.2.4. Balina optimizasyon algoritması (BOA) (Whale optimization algorithm (WOA))

Balinalar, dünya üzerinde yaşayan en büyük memeli hayvan olarak bilinmektedir. Balinalarda, insan beyninde bulunan, sosyal davranışlardaki yargılama ve duygularıyla ilgili olan hücrelere benzeyen hücreler bulunduğu, bu da onlara düşünebilme, öğrenebilme, iletişim kurabilme ve duygu değişimi yeteneği kazandırdığı kanıtlanmıştır [43]. Balina optimizasyon algoritması (BOA) bir metasezgisel optimizasyon algoritmasıdır. Bu algoritma, Kambur balinaların avlanma davranışlarından esinlenerek ortaya çıkarılmış bir yöntemdir [44]. Kambur balinalar, genelde küçük balık sürülerini avlayarak beslenirler, bu nedenle kendilerine has bir

Tablo 3. KKO'nun sözde kodu (Pseudo code of the ACO)

Karıncı Koloni Algoritması (KKA)
1: Başlangıçtaki feromon değeri belirlenir.
2: while
3: Her bir düğüme karıncalar rastgele olarak yerleştirilir.
4: Lokal arama olasılığına bağlı olarak her karınca sonraki şehirleri seçerek turunu tamamlar.
5: Her bir karıncanın turuna bağlı toplam kat ettiği mesafe hesaplanır ve lokal feromon güncellemesi yapılır.
6: En iyi çözüm değerine ulaşılır ve global feromon bu değerle güncellenir.
7: until ( $t < t_{max}$ )


avlanma stratejisine sahiplerdir. Kullandıkları bu teknikte, balinalar suyun altında, avlarının etrafında yaptıkları dairesel hareket sırasında soluk vererek çıkardıkları hava kabarcıkları, suyun yüzeyine doğru yükselirken sütun şeklinde kabarcık bulutlarını meydana getirmektedir. Oluşan bu kava kabarcıklarıyla birlikte, avlarının etrafında yaptığı dairesel hareketleri, suyun yüzeyine ulaşmaya kadar, yine kabarcık çıkararak ve yaklaştıkça da kabarcık çemberini daraltarak sürdürürler. Balinalar bu sayede hem kendilerini avlarından gizlemeyi, hem de avlarının kabarcıklar içerisinde topluca kalmasını sağlamaktadır. Şekil 5'te kambur balinaların avlanma stratejisi gerçek ve temsili olarak gösterilmiştir. Balinaların avlanma davranışı, avın bulunmasıyla başlamakta, avın hareketsiz hale getirilmesi ve şaşırtılarak onların ele geçirilmesiyle sonlanmaktadır.

**Tablo 4.** SSA'nın sözde kodu (Pseudo code of the SSA)

Salp Sürü Algoritması (SSA)
1: X popülasyonu tanımlama. $ub$ ve $lb$ için $x_i(i=1,2,\dots,n)$ belirlenir.
2: while
3: Her $x_i$ çözümü için amaç fonksiyonu hesaplanır.
4: En iyi Salp güncellenir, ( $F = X^p$ ) çözümü.
5: Eş. 2 kullanılarak $c_1$ güncellenir.
6: for $i = 1 : N$ do (her Salp için)
7: if $i == 1$ then (Eş. 1 ile lider Salp konumu güncelle)
8: else (Eş. 3 ile takipçi Salp konumu güncelle)
9: end if
10: end for
11: until ( $t < t_{max}$ )
12: return en iyi $F$ çözümü.

BOA'daki avlanma stratejisi, avın aranması, avın etrafının sarılması ve ava doğru hareket edilmesi olarak üç farklı evrede modellenmiştir. Av aramadaki matematiksel modelde, global arama yaklaşımı için çözüm adaylarının mevcut konumları bilinen en ideal nokta yerine, çözüm adaylarının etrafındaki seçeneklerden rastgele seçilerek belirlenmektedir. Aramaların yerel ya da global olmasına, belirlenen bir ( $A$ ) vektörünün değerine bakılarak karar verilmektedir. Kambur balinalar avının bulunduğu yeri tahmin edebildiklerinden avlarının etrafını her zaman kabarcıkları ile sarmak durumunda değildiler.

BOA'da av, ulaşılacak en ideal nokta olarak kabul edilmektedir. Ancak optimum çözüm optimizasyon problemleri için bilinmeyen olduğundan bu nokta için ya ulaşılabilen mevcut en iyi çözüm ya da etrafındaki bir nokta tercih edilir. Arama için en iyi çözüm belirlendikten sonraki arama çözümleri mevcut çözümler kullanılarak güncellenir. Ava doğru hareket etme davranışı, spiral hareket etme ve avın etrafındaki çemberin daraltılması olarak iki kısımda modellenmektedir. Spiral hareketi oluşturmak için hedef konum (en iyi ajan) ve arama ajanı arasındaki mesafe hesaplanmaktadır. Avın etrafındaki çemberin daraltılmasında, arama ajanının spiral hareketi ve en iyi ajanın konumuna bağlı olarak bir ( $a$ ) değerinin azaltılmasıyla mümkün olabilmektedir. BOA'nın adımları Tablo 5'te verilmiştir.



**Şekil 5.** Kambur balinaların avlanma stratejisi, gerçek ve temsili (Humpback whales' hunting strategy, real and representation)

**Tablo 5.** BOA'nın sözde kodu (Pseudo code of the WOA)

Balina Optimizasyon Algoritması (BOA)
1: Başlangıç popülasyonunu ayarla $X_i (i = 1, 2, \dots, n)$
2: Her bir arama ajanının uygunluk değerini hesapla
3: $X^* =$ Mevcut en iyi arama ajanı
4: while ( $t < t_{max}$ )
5: for (her bir arama ajanı için)
6: Rastgele bir arama ajanı seç
7: if ( $ A  < 1$ )
8: Arama ajanı konumu güncelle
9: end if
10: end for
11: Kısıt dışına çıkan bireylere sınır değeri ver
12: Amaç fonksiyonun değerlerini hesapla
13: En iyi ajanı güncelle ( <i>Daha iyi bir çözüm bulunursa</i> )
14: $t = t + 1$
15: end while
16: Sonuç $X^*$

#### 4. Performans Değerlendirme Ölçütleri (Performance Evaluation Criteria)

Ses verileri ile cinsiyet tespit etmek için metasezgisel optimizasyon algoritmaları ile özellik seçimi yapılmış yeni veri kümeleri ve orijinal veri kümesine uygulanan Naive Bayes ve Karar Ağacı algoritmalarının başarılarını değerlendirmek için birçok farklı performans değerlendirme kriteri bulunmaktadır. Bu çalışmada, algoritmaların performanslarının değerlendirmek için doğruluk, kesinlik, duyarlılık ve ROC eğrisi altında kalan alan ölçütleri kullanılmıştır. Doğruluk, kesinlik ve duyarlılık ölçütlerine ait formüller Eş. 9 - Eş. 11'de verilmiştir.

$$\text{Doğruluk} = \frac{|DN| + |DP|}{|YN| + |YP| + |DN| + |DP|} \quad (9)$$

Bir algoritmanın doğruluğu, algoritma tarafından doğru bir şekilde tahmin edilen veri kümesinin yüzdesi olarak hesaplanmaktadır. Eş. 9'da, DP doğru pozitif, YP yanlış pozitif, DN doğru negatif ve YN yanlış negatifi ifade etmektedir. Pozitif ve negatif ifadeleri sınıflandırma algoritmasının tahminini gösterirken doğru ve yanlış ifadeleri sınıflandırıcının beklentisini göstermektedir.

$$\text{Kesinlik} = \frac{|DP|}{|YP| + |DP|} \quad (10)$$

Kesinlik değeri, pozitif olarak sınıflandırılan örneklerin sayısını göstermektedir.

$$\text{Duyarlılık} = \frac{|DP|}{|YN| + |DP|} \quad (11)$$

Duyarlılık değeri, bir sistemin pozitifleri algılama oranını göstermektedir.



Bu çalışmada ROC eğrisi altında kalan alan, ses verilerinden cinsiyet tespiti yaparken iki durumun ne kadar doğru bir şekilde ayrıldığını ölçmek için kullanılmaktadır. ROC eğrisi altında kalan alan, DP oranının YP oranına göre değişiminin çizilmesiyle elde edilmektedir. Eğrinin altında kalan alanın fazlalığı tanı testinin başarısını göstermektedir.

## 5. Deneysel Sonuçlar (Experimental Results)

Ses verileri ile cinsiyet tespiti için özellik seçiminin optimizasyon algoritmaları ile yapıldığı bu yöntemin etkinliğini ölçmek için deney sonuçları iki bölüm olarak incelenmiştir. İlk bölümde PSO, KKO, SSA ve BOA algoritmalarının özellik seçimi için performansları uygunluk fonksiyonu değeri, seçilen özelliklerin sayısı ve doğruluk olmak üzere üç farklı ölçütün sonuçları dikkate alınarak değerlendirilmiştir. İkinci bölümde ise, ses verisi üzerinde özellik seçimi yapıldıktan sonra elde edilen yeni veri kümeleri ve özellik seçimi yapılmamış orijinal veri kümesine Naive Bayes ve Karar ağacı algoritmaları uygulanarak elde edilen sonuçlar doğruluk, kesinlik, duyarlılık ve ROC eğrisi altında kalan alan ölçütleri bakımından değerlendirilerek deney sonuçları karşılaştırılmaları olarak verilmiştir.

### 5.1. Optimizasyon Algoritmaları ile Özellik Seçimi için Elde Edilen Sonuçlar (Results for Feature Selection with Optimization Algorithms)

Optimizasyon algoritmalarının önerilen yöntem için başarılarını test etmek için, her bir algoritma veri kümesi üzerinde 30 kez çalıştırılmıştır. Ayrıca her bir algoritma için maksimum iterasyon sayısı 100 ve başlangıç popülasyon sayısı ise 10 olarak belirlenmiştir. PSO, KKO ve SSA algoritmaları için belirlenen başlangıç parametreleri Tablo 6'da verilmiştir.

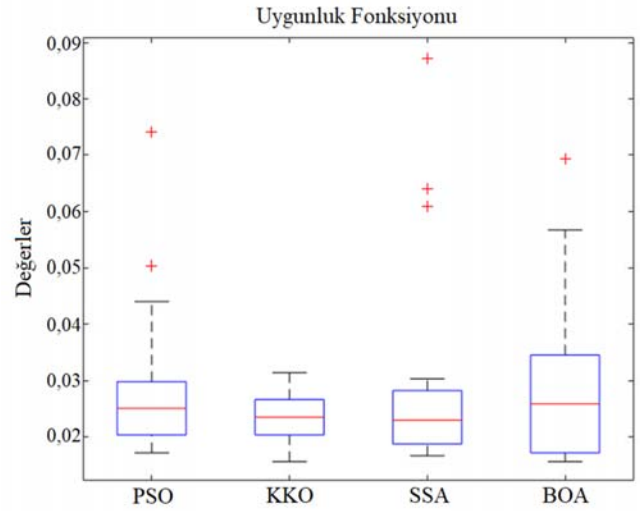
**Tablo 6.** Önerilen yöntemin parametre ayarları (Parameter settings of the proposed method)

Algoritma	Parametre	Değer
PSO	$c_1$	2
	$c_2$	2
	$w$	1
KKO	$\alpha$	1
	$\beta$	1
	$Rho$	0,2
	Maksimum iterasyon sayısı	100
SSA	Popülasyon sayısı	10
	Deneysel sayısı	30

Önerilen yöntemin etkinliğini ölçmek için, PSO, KKO, SSA ve BOA ile özellik seçimi sonucunda elde edilen uygunluk fonksiyonu, seçilen

özellik sayısı ve doğruluk değerleri hesaplanmıştır. Bu ölçütlerinin her biri için en iyi, medyan, en kötü, ortalama ve standart sapma değerleri hesaplanmıştır. Tablo 7'de dört optimizasyon algoritmasının ses verileri üzerinde 30 kez çalıştırılması ile elde edilen değerler verilmiştir.

Tablo 7'de verilen sonuçlar incelendiğinde, uygunluk fonksiyonun en iyi değerlerine göre KKO ve BOA 0,0157 değeri ile diğer algoritmalarından daha iyi sonuç vermişlerdir. Uygunluk fonksiyonun en kötü değerini ise 0,0873 ile SSA vermiştir. Uygunluk fonksiyonun ortalama değerlerine göre KKO algoritması 0,0233 değeri ile diğer optimizasyon algoritmalarına göre daha iyi sonuç vermiştir. PSO, KKO, SSA ve BOA algoritmaları ile elde edilen uygunluk fonksiyonu değerlerine ait detaylı bilgi Şekil 6'daki kutu grafiğinde verilmiştir.

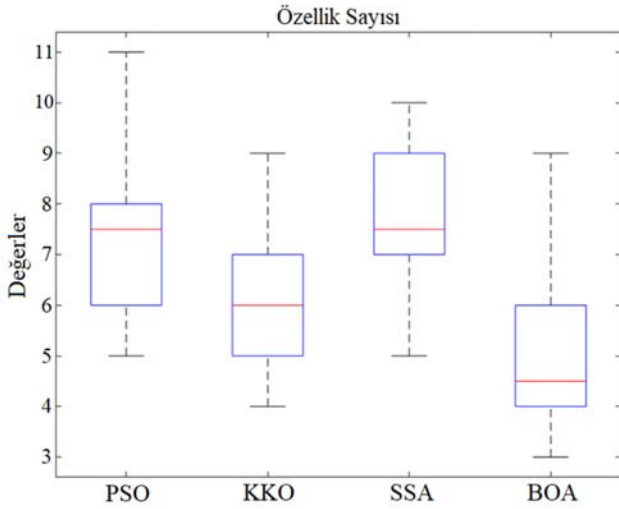


**Şekil 6.** PSO, KKO, SSA ve BOA için uygunluk değerlerinin kutu grafiği (Box plot of fitness values for PSO, ACO, SSA, and WOA)

Tablo 7'de görüldüğü üzere seçilen özellik sayısına göre, en iyi değer BOA ile 3 olarak elde edilmiştir, bu yöntemi, 4 değeri ile KKO algoritması izlemektedir. Dört metasezgisel algoritma içerisinde, seçilen özellik sayısının ortalama değeri dikkate alındığında BOA ile 5 değeri elde edilmiştir. PSO, KKO, SSA ve BOA algoritmaları ile elde edilen özellik sayılarına ait detaylı bilgi Şekil 7'deki kutu grafiğinde verilmiştir.

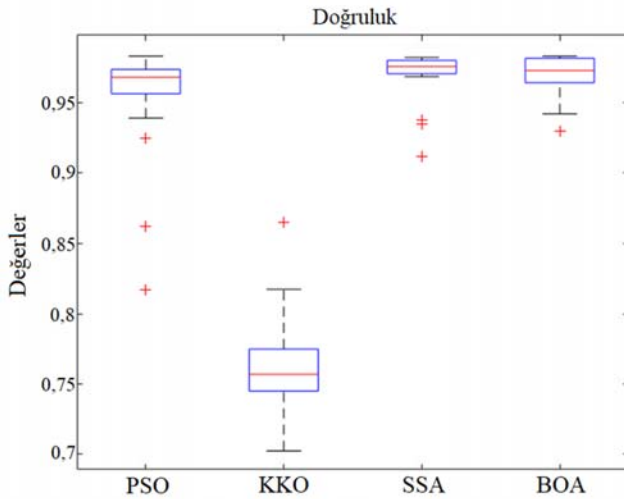
**Tablo 7.** PSO, KKO, SSA ve BOA ile özellik seçimi yapıldıktan sonra elde edilen sonuçlar (Results obtained after feature selection with PSO, ACO, SSA, and WOA)

Metrikler		PSO	KKO	SSA	BOA
Uygunluk Fonksiyonu	En iyi	0,0173	0,0157	0,0168	0,0157
	Medyan	0,0252	0,0236	0,0231	0,0260
	En kötü	0,0742	0,0315	0,0873	0,0695
	Ortalama	0,0281	0,0233	0,0277	0,0289
	Standart Sapma	0,0116	0,0041	0,0156	0,0135
Özellik Sayısı	En iyi	5	4	5	3
	Medyan	7,5	6	7,5	4,5
	En kötü	11	9	10	9
	Ortalama	7,3333	6,0666	7,6666	5
	Standart Sapma	1,4223	1,3879	1,3729	1,6400
Doğruluk	En iyi	0,9842	0,8657	0,9832	0,9842
	Medyan	0,9692	0,7576	0,9768	0,9739
	En kötü	0,8183	0,7030	0,9126	0,9305
	Ortalama	0,9570	0,7630	0,9702	0,9710
	Standart Sapma	0,0351	0,0356	0,0156	0,0135



Şekil 7. PSO, KKO, SSA ve BOA için özellik sayılarının kutu grafiği (Box plot of feature numbers for PSO, ACO, SSA, and WOA)

Tablo 7'ye göre, doğruluk bakımından en iyi değeri %98,42 ile BOA ve PSO algoritmaları vermiştir. Ortalama değerlere göre ise %97,10 ile BOA'nın diğerlerinden daha iyi olduğu gözlenmiştir. Algoritmaların 30 kez çalıştırılması sonucunda doğruluğun standart sapması değeri, BOA için 0,0135'tir. Bu değer, diğer üç algoritma ile elde edilen standart sapma değerlerinden düşüktür. Bu sonuç, BOA algoritmasının iterasyonlar boyunca diğer algoritmalara kıyasla daha istikrarlı sonuçlar verdiğini ifade etmektedir. PSO, KKO, SSA ve BOA algoritmalarına ait doğruluk değerleri için kutu grafiği Şekil 8'de verilmiştir.



Şekil 8. PSO, KKO, SSA ve BOA için doğruluk değerlerinin kutu grafiği (Box plot of accuracy values for PSO, ACO, SSA, and WOA)

Tablo 8. Naive Bayes algoritması ile %66 eğitim - %34 test koşulunda elde edilen sonuçlar  
(Results obtained with Naive Bayes algorithm in 66% training - 34% test condition)

	Doğruluk	Kesinlik	Duyarlılık	ROC Alanı
Özellik Seçiminden Önce	0,889	0,890	0,890	0,938
PSO	0,951	0,953	0,952	0,983
KKO	0,953	0,954	0,954	0,986
SSA	0,957	0,958	0,958	0,985
BOA	0,960	0,961	0,960	0,992

## 5.2. Özellik Seçimi Öncesi ve Sonrası Sınıflandırma Performansının Karşılaştırılması (Comparison of Classification Performance Before and After Feature Selection)

Bu bölümde, dört farklı optimizasyon algoritması ile ses verileri üzerinde özellik seçimi yapıldıktan sonra elde edilen yeni veri kümelerine ve özellik seçimi yapılmamış orijinal veri kümesine Naive Bayes ve Karar Ağacı algoritmaları uygulanmış ve elde edilen sonuçlar farklı test seçeneklerine göre karşılaştırılmıştır.

Özellik seçimi yapılmamış orijinal veri kümesi ve PSO, KKO, SSA ve BOA metasezgisel yöntemleri ile özellik seçimi yapıldıktan sonra elde edilen veri kümeleri %66 eğitim - %34 test olarak ayrılarak Naive Bayes algoritması uygulanmıştır. Naive Bayes algoritması ile elde edilen sonuçlar Tablo 8'de verilmiştir. Sonuçlar doğruluk, kesinlik, duyarlılık ve ROC eğrisi altında kalan alan ölçütü bakımından değerlendirilmiştir.

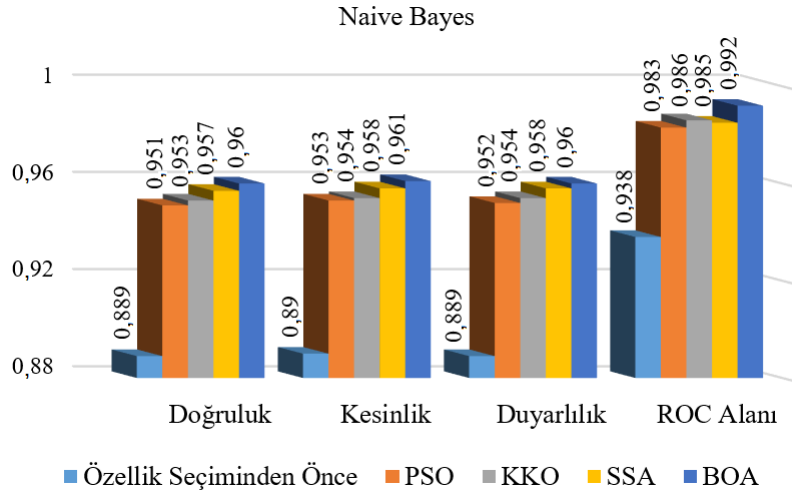
Tablo 8'e göre orijinal veri kümesi ile elde edilen doğruluk, kesinlik, duyarlılık ve ROC eğrisi altında kalan alan değerleri, PSO, KKO, SSA ve BOA metasezgisel algoritmaları ile özellik seçimi yapıldıktan sonraki veri kümelerindeki değerlerden oldukça düşüktür. Naive Bayes algoritması en yüksek doğruluk, kesinlik, duyarlılık ve ROC eğrisi altında kalan alan değerleri, BOA ile özellik seçimi yapılmış veri kümesinden elde edilmiştir. Bu değerlerin grafiksel gösterimi Şekil 9'da verilmiştir.

Özellik seçimi yapılmamış orijinal veri kümesi ve PSO, KKO, SSA ve BOA metasezgisel algoritmaları ile özellik seçimi yapıldıktan sonra elde edilen veri kümeleri %66 eğitim - %34 test olarak ayrılarak Karar Ağacı algoritması uygulanmıştır. Karar Ağacı algoritması ile elde edilen sonuçlar Tablo 9'da verilmiştir. Sonuçlar doğruluk, kesinlik, duyarlılık ve ROC eğrisi altında kalan alan ölçütü bakımından değerlendirilmiştir.

Tablo 9'a göre orijinal veri kümesi için elde edilen doğruluk, kesinlik, duyarlılık ve ROC eğrisi altında kalan alan değerleri, PSO, KKO, SSA ve BOA metasezgisel algoritmaları ile özellik seçimi yapılmış veri kümeleri için elde edilen değerlerden oldukça düşüktür. Karar Ağacı algoritması en yüksek doğruluk, kesinlik, duyarlılık ve ROC eğrisi altında kalan alan değerleri, KKO algoritması ile özellik seçimi yapılmış veri kümesinden elde edilmiştir. Bu değerlerin grafiksel gösterimi Şekil 10'da verilmiştir.

Özellik seçimi yapılmamış orijinal veri kümesi ve PSO, KKO, SSA ve BOA metasezgisel algoritmaları ile özellik seçimi yapıldıktan sonra elde edilen veri kümelerine 10-kat çapraz doğrulama test koşulunda Naive Bayes algoritması uygulanmıştır. Naive Bayes algoritması ile elde edilen sonuçlar Tablo 10'da verilmiştir. Sonuçlar doğruluk, kesinlik, duyarlılık ve ROC eğrisi altında kalan alan ölçütü bakımından değerlendirilmiştir.

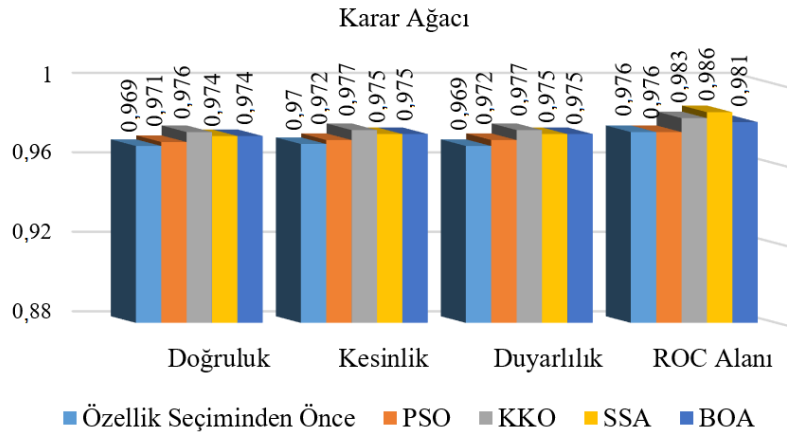
Tablo 10'a göre özellik seçimi yapılmamış orijinal veri kümesi elde edilen doğruluk, kesinlik, duyarlılık ve ROC eğrisi altında kalan alan değerleri, PSO, KKO, SSA ve BOA metasezgisel algoritmaları ile



**Şekil 9.** Özellik seçimi öncesi ve sonrası Naive Bayes ile elde edilen sonuçlar (%66 eğitim - %34 test)  
(Results obtained with Naive Bayes before and after feature selection (66% training - 34% test))

**Tablo 9.** Karar Ağacı algoritması ile %66 eğitim - %34 test koşulunda elde edilen sonuçlar  
(Results obtained in 66% training - 34% test condition with Decision Tree algorithm)

	Doğruluk	Kesinlik	Duyarlılık	ROC Alanı
Özellik Seçiminden Önce	0,969	0,970	0,969	0,976
PSO	0,971	0,972	0,972	0,976
KKO	0,976	0,977	0,977	0,983
SSA	0,974	0,975	0,975	0,986
BOA	0,974	0,975	0,975	0,981



**Şekil 10.** Özellik seçimi öncesi ve sonrası Karar Ağacı ile elde edilen sonuçlar (%66 eğitim - %34 test)  
(Results obtained with Decision Tree before and after feature selection (66% training - 34% testing))


**Tablo 10.** Naive Bayes algoritması ile 10-kat çapraz doğrulama test koşulunda elde edilen sonuçlar  
(Results obtained with Naive Bayes algorithm in 10-fold cross-validation test condition)

	Doğruluk	Kesinlik	Duyarlılık	ROC Alanı
Özellik Seçiminden Önce	0,889	0,890	0,890	0,946
PSO	0,949	0,951	0,951	0,984
KKO	0,953	0,954	0,953	0,985
SSA	0,954	0,955	0,955	0,986
BOA	0,954	0,954	0,954	0,990

özellik seçimi yapılmış veri kümelerinden elde edilen değerlerden oldukça düşüktür. Naive Bayes algoritması en yüksek doğruluk değeri olan 0,954 değerini SSA ve BOA metasezgisel algoritmaları ile özellik seçimi yapılmış veri kümesinden elde etmiştir. Kesinlik ve duyarlılık ölçütlerine göre en yüksek değeri, 0,955 ile SSA vermiştir.

ROC alanı için en yüksek değer ise BOA ile elde edilmiştir. Bu değerlerin grafiksel gösterimi Şekil 11'de verilmiştir.


Özellik seçimi yapılmamış orijinal veri kümesi ve PSO, KKO, SSA ve BOA metasezgisel algoritmaları ile özellik seçimi yapıldıktan



Şekil 11. Naive Bayes Algoritması ile 10-kat çapraz doğrulama (10-fold cross validation with Naive Bayes Algorithm)

Tablo 11. Karar Ağacı Algoritması ile 10-kat çapraz doğrulama test koşulunda elde edilen sonuçlar (Results obtained in 10-fold cross-validation test condition with Decision Tree Algorithm)

	Doğruluk	Kesinlik	Duyarlılık	ROC Alanı
Özellik Seçiminden Önce	0,968	0,968	0,968	0,971
PSO	0,972	0,972	0,972	0,976
KKO	0,973	0,973	0,973	0,975
SSA	0,969	0,968	0,968	0,971
BOA	0,968	0,968	0,968	0,975



Şekil 12. Karar Ağacı Algoritması ile 10-kat çapraz doğrulama (10-fold cross-validation with Decision Tree Algorithm)

sonra elde edilen veri kümelerine 10-kat çapraz doğrulama test koşulunda Karar Ağacı algoritması uygulanmıştır. Karar Ağacı algoritması ile elde edilen sonuçlar Tablo 11'de verilmiştir. Sonuçlar doğruluk, kesinlik, duyarlılık ve ROC eğrisi altında kalan alan ölçütü bakımından değerlendirilmiştir.

Tablo 11'e göre özellik seçimi yapılmamış orijinal veri kümesi elde edilen doğruluk, kesinlik, duyarlılık ve ROC eğrisi altında kalan alan değerleri, PSO, KKO, SSA ve BOA metasezgisel algoritmaları ile özellik seçimi yapılmış veri kümelerinden elde edilen değerlerden oldukça düşüktür. Karar Ağacı algoritması en yüksek doğruluk, kesinlik, duyarlılık değerlerini KKO algoritması ile özellik seçimi yapılmış veri kümesinden elde etmiştir. ROC alanı için en yüksek değeri 0,976 değeri ile BOA vermiştir. Bu değerlerin grafiksel gösterimi Şekil 12'de verilmiştir.

## 6. Simgeler (Symbol)

### 6.1. Yunan Harfleri (Greek Letters)

- $w$  : Eylemsizlik ağırlığı  
 $c_1, c_2$  : İvme katsayıları  
 $\alpha, \beta$  : Feromon değerinin kontrol parametreleri  
 $Rho$  : Feromon değeri

### 6.2. Kısaltmalar (Abbreviations)

- ACO : Ant Colony Optimization  
BOA : Balina Optimizasyonu Algoritması  
DVM : Destek Vektör Makinesi  
KKO : Karınca Koloni Optimizasyonu



kNN	: $k$ -Nearest Neighbors
PSO	: Parçacık Sürüşü Optimizasyonu, Particle Swarm Optimization
SSA	: Salp Sürüşü Algoritması, Salp Swarm Algorithm
WOA	: Whale Optimization Algorithm

## 7. Sonuçlar (Conclusions)

Bu çalışmada, son yıllarda oldukça ilgi çeken ve aktif bir araştırma alanı halen gelen konuşma sinyallerinin işlenerek konuşmacının cinsiyetinin belirlenmesi probleminin çözümü için metasezgisel optimizasyon algoritmalarını temel alan bir özellik seçimi yöntemi önerilmiştir. Bu amaçla, PSO, KKO, SSA ve BOA metasezgisel optimizasyon algoritmaları cinsiyet tespiti için konuşma verilerinden uygun bir özellik uzayı elde etmek için ilk kez modellenmiştir. Kullanılan dört optimizasyon algoritması farklı akustik özellikler içeren bir ses verisi üzerinde test edilmiş ve elde edilen sonuçlar uygunluk fonksiyonu değeri, seçilen özellik sayısı ve doğruluk değerlerine göre karşılaştırılarak en uygun özellik alt kümesi belirlenmiştir. Veri kümesi üzerinde özellik seçimi yapılmamış orijinal veri kümesi ve PSO, KKO, SSA ve BOA metasezgisel optimizasyon algoritmaları ile özellik seçimi yapılmış veri kümeleri Naive Bayes ve Karar ağacı algoritmaları farklı test koşullarında çalıştırılmıştır. Naive Bayes ve Karar ağacı algoritmalarının sonuçları incelendiğinde; PSO, KKO, SSA ve BOA metasezgisel optimizasyon algoritmaları ile özellik seçimi yapıldıktan sonra elde edilen sonuçların doğruluk, kesinlik, duyarlılık ve ROC eğrisi altında kalan alan ölçütlerine göre özellik seçimi yapılmadan önceki değerlere kıyasla oldukça yüksek olduğu görülmüştür.

Ses verilerinden cinsiyet tespiti problemi için özellik seçimini metasezgisel optimizasyon algoritmaları kullanarak ilk kez gerçekleştiren bu çalışma, araştırmacılar için temel bir çalışma olarak kabul edilebilir. Elde edilen sayısal sonuçlar oldukça ümit verici olduğundan deneyler genişletilebilir ve önerilen yöntem farklı ses veri kümeleri üzerinde uygulanabilir. Ayrıca, gelecek çalışmalarda, özellik seçimi için daha iyi sonuçlar elde etmek için aynı algoritmaların adaptif ve melez yöntemleri geliştirilerek ses verilerinden cinsiyet tespiti için modellenebilir.

## Kaynaklar (References)

- Karasulu B., Yücalar F., Borandağ E., A hybrid approach based on deep learning for gender recognition using human ear images, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 37 (3), 1579-1594, 2022.
- Gamit M.R., Dhameliya K., Bhatt N.S., Classification techniques for speech recognition: a review, *International Journal of Emerging Technology and Advanced Engineering*, 5 (2), 58-63, 2015.
- Zhong N., Dong J., Ohsuga S., Using rough sets with heuristics for feature selection, *Journal of intelligent information systems*, 16 (3), 199-214, 2001.
- Guyon I., Elisseeff A., An introduction to variable and feature selection, *Journal of machine learning research*, 3, 1157-1182, 2003.
- Doğan Y., Improvement of recurrent deep neural networks algorithm by feature selection methods and its usage of automatic identification system data evaluated as time series, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 35 (4), 1897-1911, 2020.
- Chen C.H., A hybrid intelligent model of analyzing clinical breast cancer data using clustering techniques with feature selection, *Applied Soft Computing*, 20, 4-14, 2014.
- Rui Y., Huang T.S., Chang S.F., Image retrieval: Current techniques, promising directions, and open issues, *Journal of visual communication and image representation*, 10 (1), 39-62, 1999.
- Yang Y., Pedersen J.O., A comparative study on feature selection in text categorization, In: *Proceedings of the fourteenth international conference on machine learning*, 412-420, Temmuz, 1997.
- Ng K., Liu H., Customer retention via data mining, *Artificial Intelligence Review*, 14 (6), 569-590, 2000.
- Ben-Dor A., Bruhn L., Friedman N., Nachman I., Schummer M., Yakhini Z., Tissue classification with gene expression profiles, In *Proceedings of the fourth annual international conference on Computational molecular biology*, 54-64, Nisan, 2000.
- Golub T.R., Slonim D.K., Tamayo P., Huard C., Gaasenbeek M., Mesirov J.P., Lander E.S., Molecular classification of cancer: class discovery and class prediction by gene expression monitoring, *Science*, 286 (5439), 531-537, 1999.
- Yu Z., Li L., Gao Y., You J., Liu J., Wong H.S., Han G. Hybrid clustering solution selection strategy, *Pattern Recognition*, 47 (10), 3362-3375, 2014.
- Rizk-Allah R.M., El-Sehiemy R.A., Deb S., Wang G.G., A novel fruit fly framework for multi-objective shape design of tubular linear synchronous motor, *The Journal of Supercomputing*, 73 (3), 1235-1256, 2017.
- Yang X.S., Firefly algorithm, stochastic test functions and design optimisation, *International journal of bio-inspired computation*, 2 (2), 78-84, 2010.
- Arora S., Singh S., Node localization in wireless sensor networks using butterfly optimization algorithm, *Arabian Journal for Science and Engineering*, 42 (8), 3325-3335, 2017.
- Yi J.H., Wang J., Wang G.G., Improved probabilistic neural networks with self-adaptive strategies for transformer fault diagnosis problem, *Advances in Mechanical Engineering*, 8 (1), 1687814015624832, 2016.
- Rizk-Allah R.M., El-Sehiemy R.A., Wang G.G., A novel parallel hurricane optimization algorithm for secure emission/economic load dispatch solution, *Applied Soft Computing*, 63, 206-222, 2018.
- Wang G.G., Chu H.E., Mirjalili S., Three-dimensional path planning for UCAV using an improved bat algorithm, *Aerospace Science and Technology*, 49, 231-238, 2016.
- Wu G., Pedrycz W., Li H., Ma M., Liu J., Coordinated planning of heterogeneous earth observation resources, *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 46 (1), 109-125, 2015.
- Zhang J.W., Wang G.G., Image matching using a bat algorithm with mutation, In *Applied Mechanics and Materials*, 203, 88-93, 2012.
- Feng Y.H., Wang G.G., Binary moth search algorithm for discounted {0-1} knapsack problem, *IEEE Access*, 6, 10708-10719, 2018.
- Jensen R., Shen Q., Semantics-preserving dimensionality reduction: rough and fuzzy-rough-based approaches, *IEEE Transactions on knowledge and data engineering*, 16 (12), 1457-1471, 2004.
- Hedar A.R., Wang J., Fukushima M., Tabu search for attribute reduction in rough set theory, *Soft Computing*, 12 (9), 909-918, 2008.
- Bello R., Gomez Y., Nowe A., Garcia M.M., Two-step particle swarm optimization to solve the feature selection problem, In *Seventh International Conference on Intelligent Systems Design and Applications*, 691-696, Ekim, 2007.
- Wang J., Li T., Ren R., A real time IDSs based on artificial bee colony-support vector machine algorithm, In *Third International Workshop on Advanced Computational Intelligence*, 91-96, Ağustos, 2010.
- Kabir M.M., Shahjahan M., Murase K., A new local search based hybrid genetic algorithm for feature selection, *Neurocomputing*, 74 (17), 2914-2928, 2011.
- Maka T., Dziuranski P., An analysis of the influence of acoustical adverse conditions on speaker gender identification, In *XXII Annual Pacific Voice Conference*, Krakow, Polonya, 1-4, Nisan, 2014.
- Bisio I., Lavagetto F., Marchese M., Sciarone A., Frà C., Valla M., Spectra: A speech processing platform as smartphone application, *IEEE international conference on communications*, Londra, UK, 7030-7035, 8-12 Haziran, 2015.
- Pahwa A., Aggarwal G., Speech feature extraction for gender recognition, *International Journal of Image, Graphics and Signal Processing*, 8 (9), 17, 2016.
- Přibil J., Přibilová A., Matoušek J., GMM-based speaker gender and age classification after voice conversion, *First International Workshop on Sensing, Processing and Learning for Intelligent Machines*, Aalborg, Danimarka, 1-5, 6-8 Temmuz, 2016.
- Buyukyılmaz M., Cibikdiken A.O., Voice gender recognition using deep learning, *International Conference on Modeling, Simulation and Optimization Technologies and Applications*, 409-411, Aralık, 2016.
- Barkana B.D., Zhou J., A new pitch-range based feature set for a speaker's age and gender classification, *Applied Acoustics*, 98, 52-61, 2015.
- Ramdimawati E., Mittal V.K., Gender identification from speech signal by examining the speech production characteristics, *International*

- Conference on Signal Processing and Communication, 244-249, Aralık, 2016.
34. Hebbar R., Somandepalli K., Narayanan S.S., Improving Gender Identification in Movie Audio Using Cross-Domain Data, In INTERSPEECH, 282-286, 2018.
  35. Kabil S.H., Muckenhirn H., Magimai-Doss M., On Learning to Identify Genders from Raw Speech Signal Using CNNs, In INTERSPEECH, 287-291, 2018.
  36. Kaggle. Gender Recognition by Voice. <https://www.kaggle.com/primaryobjects/voicegender>. Erişim tarihi Nisan 21, 2021.
  37. Duda R.O. ve Hart P.E., Pattern classification and scene analysis, 3, 731-739, Wiley, New York, 1973.
  38. Mladenović D., Feature selection for dimensionality reduction, In International Statistical and Optimization Perspectives Workshop” Subspace, Latent Structure and Feature Selection”, Berlin, Almanya, 84-102, Şubat, 2005.
  39. Eberhart R., Kennedy J., A new optimizer using particle swarm theory, Proceedings of the Sixth International Symposium on Micro Machine and Human Science, 39-43, Ekim, 1995.
  40. Dorigo M., Birattari M., Stutzle T., Ant colony optimization, IEEE computational intelligence magazine, 1 (4), 28-39, 2006.
  41. Mirjalili S., Gandomi A.H., Mirjalili S.Z., Saremi S., Faris H., Mirjalili S.M., Salp Swarm Algorithm: A bio-inspired optimizer for engineering design problems, Advances in Engineering Software, 114, 163-191, 2017.
  42. Henschke N., Everett J.D., Richardson A.J., Suthers I.M., Rethinking the role of salps in the ocean, Trends in Ecology & Evolution, 31 (9), 720-733, 2016.
  43. Hof P.R., Van der Gucht E., Structure of the cerebral cortex of the humpback whale, Megaptera novaeangliae (Cetacea, Mysticeti, Balaenopteridae), The Anatomical Record: Advances in Integrative Anatomy and Evolutionary Biology, 290 (1), 1-31, 2007.
  44. Mirjalili S. ve Lewis A., The whale optimization algorithm, Advances in engineering software, 95, 51-67, 2016.