Afyon Kocatepe Üniversitesi Fen ve Mühendislik Bilimleri Dergisi
Afyon Kocatepe University – Journal of Science and Engineering
https://dergipark.org.tr/tr/pub/akufemubid

Araştırma Makalesi / Research Article
e-ISSN: 2149-3367
DOI: https://doi.org/10.35414/akufemubid.1676663
AKÜ FEMÜBİD **25** (2025) 065102 (1336-1347)
AKU J. Sci. Eng. **25** (2025) 065102 (1336-1347)

Meta-sezgisel Algoritma Destekli Makine Öğrenmesi Yöntemiyle Tiroid Hastalığının Tespitinde Yeni Bir Yaklaşım

Makale Bilgisi / Article Info
Alındı/Received: 15.04.2025
Kabul/Accepted: 17.07.2025
Yayımlandı/Published: 03.12.2025

A New Approach for Thyroid Disease Detection Using Metaheuristic Algorithm-Machine Learning Technique

Nurullah ÖZTÜRK*

Kayseri Üniversitesi, Mühendislik Mimarlık ve Tasarım Fakültesi, Bilgisayar Mühendisliği Bölümü, Kayseri, Türkiye

© 2025 The Authors | Creative Commons Attribution-Noncommercial 4.0 (CC BY-NC) International License

Öz

Tiroid hastalığı, her yaş grubunda ve cinsiyette görülebilen, kişinin tiroid bezinin yeterli düzeyde hormon üretmesini engelleyen yaygın sağlık sorunları arasında yer almaktadır. Hastalığın erken dönemde teşhis edilmesi, ilerlemesinin kontrol altına alınması ve olası komplikasyonların önlenmesi açısından büyük önem taşımaktadır. Bu çalışmanın amacı, tiroid hastalığının erken evrede teşhisinde yüksek doğruluk sağlayan yenilikçi bir makine öğrenmesi tabanlı yöntem geliştirmektir. Bu çalışmada, korelasyon tabanlı özellik seçimi, softmax sınıflandırıcı ve Yapay Arı Kolonisi algoritması bir araya getirilerek yeni bir hibrit yöntem önerilmiştir. Önerilen yöntemde, açıklanabilir özellik çıkarımı uygulanmakta, çoklu sınıflandırma yapısına sahip softmax sınıflandırıcı ve Yapay Arı Kolonisi algoritması ile hiperparametre optimizasyonu kullanılarak tiroid hastalığının teşhisi ve sınıflandırma doğruluğu artırılmıştır. Deneysel çalışmalar, UCI makine öğrenme deposunda yer alan "Thyroid Disease" veri seti kullanılarak gerçekleştirilmiştir. Ayrıca, bu çalışmada K-En Yakın Komşu, Destek Vektör Makinası, Yapay Sinir Ağları ve Saf Bayes gibi klasik sınıflandırma algoritmaları da uygulanmıştır. Elde edilen sonuçlar, önerilen hibrit yöntemin uygulanan diğer yöntemlere kıyasla ortalama en iyi doğruluk (%96.11), duyarlılık (%82.38) ve F1-başarım (%80.84) değerlerine ulaştığını göstermektedir. Sunulan bu hibrit yöntem, farklı klinik senaryolarda uygulanabilirliği sayesinde özellikle erken tanı ve tedavi süreçlerinde klinik karar alma mekanizmalarına katkı sağlayabilecek niteliktedir.

Anahtar Kelimeler: *Tiroid Hastalığı Tespiti; Açıklanabilir Özellik Çıkarımı; Makine Öğrenmesi; Meta-sezgisel Algoritma; Klinik Karar Mekanizması.*

Abstract

Thyroid disease is a common health issue that can affect individuals of all ages and genders, often impairing the thyroid gland's ability to produce adequate levels of hormones. Early diagnosis of thyroid disease is of great importance for controlling the progression and preventing potential complications. The aim of this study is to develop an innovative, machine learning-based method with high accuracy for the early diagnosis of thyroid disease. In this study, a novel hybrid method is proposed by integrating correlation-based feature selection, a softmax classifier, and the Artificial Bee Colony algorithm. The proposed method enhances diagnostic and classification performance by applying explainable feature extraction, multi-class classification via the softmax classifier, and hyperparameter optimization using the Artificial Bee Colony algorithm. Experimental evaluations were conducted using the "Thyroid Disease" dataset available in the UCI Machine Learning Repository. In addition, traditional classification algorithms such as K-Nearest Neighbors, Support Vector Machines, Artificial Neural Networks, and Naive Bayes were applied for comparative analysis. The results indicate that the proposed hybrid method outperforms other approaches, achieving the highest accuracy (96.11%), precision (82.38%), and F1-score (80.84%). Owing to its applicability in different clinical scenarios, the proposed hybrid method supports clinical decision making, especially in early diagnosis and treatment processes.

Keywords: *Thyroid Disease Detection; Explainable Feature Extraction; Machine Learning; Meta-heuristic Algorithm; Clinical Decision System.*

1. Giriş

Tiroid hastalıkları ve bozuklukları, günümüzde dünya genelinde nüfusun çoğunluğunu etkileyen yaygın hormonal bir sorundur. Tiroid bezi, boynun ön tarafında bulunan trakeayı çevreleyen ve yalnızca hormon salgılama görevine sahip olan saf endokrin bezlerinden biridir (Beynon ve Pinneri 2016). Bu bezin temel işlevi, tiroid hormonlarının (T3 ve T4) üretimi yoluyla vücudun metabolik dengesini düzenlemektir. Tiroid hormonları, yağ, protein ve karbonhidratların metabolizmasının düzenlemesinin yanı sıra, kan basıncı, vücut sıcaklığı ve kalp atış hızı gibi temel yaşamsal fonksiyonların sürdürülmesinde önemli rol almaktadır. Tiroid hormon düzeylerinde meydana gelen herhangi bir dengesizlik, çeşitli sistemik belirti ve klinik tablolarla kendini gösterebilmektedir. Bu durum, beyin sisi, periferik

*Sorumlu Yazar/Corresponding Author: Nurullah ÖZTÜRK e-posta/e-mail: nurullahozturk@kayseri.edu.tr

nöropati, guatr ve depresyon gibi pek çok fizyolojik ve psikolojik komplikasyonlara neden olabilmektedir (Islam vd. 2022).

En yaygın karşılaşılan iki tiroid sorunu hipotiroidizm ve hipertiroidizmdir (Taylor vd. 2018). Tiroid bezi aşırı tiroid hormonu ürettiğinde hipertiroidizm gelişirken, tiroid hormonu yeterince salgılanmadığında hipotiroidizm ortaya çıkmaktadır. Tiroid hastalığının erken teşhisi, tıbbi masrafları azaltmak ve uygun tedaviye zamanında başlanması için oldukça önemlidir. Hastalığın doğru ve erken teşhisi için, hastanın tıbbi geçmişi incelenmeli, kan testleri, tiroid hormon düzeyleri ve semptomlar gibi biyolojik belirteçlerin analiz edilmesi gerekmektedir (Pichardo 2021, Nguyen vd. 2015). Bu belirteçlerin doğru yorumlanması, tedavi sürecinin yönetilmesinde en önemli aşamadır.

Tıp alanında bilgisayar bilimi ve veri işleme yöntemlerinin uygulanması ile tiroid hastalıklarının tanısı daha doğru ve etkili bir şekilde gerçekleştirilebilmektedir. Özellikle hastalıkların daha doğru tanımlanması ve sınıflandırılması için makine öğrenmesi teknikleri yaygın olarak kullanılmaktadır (Lee ve Park 2022, Taha vd. 2024, Parveen vd. 2024). Son yıllarda yapılan çalışmalarda, tiroid hastalıklarının teşhisinde makine öğrenmesi tabanlı yöntemlerin etkinliği ortaya çıkarılmış ve çeşitli algoritmalar geliştirilmiştir. Chaganti vd. (2022) çalışmasında, Rastgele Orman (Random Forest), Karar Ağaçları (Decision Tree), Yapay Sinir Ağları ve K-En Yakın Komşular (K-Nearest Neighbour) algoritmaları kullanarak tiroid hastalığının tahmini için hibrit yöntemler oluşturmuş ve bu yöntemlerin başarımlarını karşılaştırmıştır. Yapılan çalışmada, Rastgele Orman algoritmasını kullanan yöntem, en yüksek (0.99) doğruluk oranı ile karşılaştırılan yöntemler arasında en iyi sonucu vermiştir.

Garcia vd. (2020) çalışmasında, Gradient Artırma (Gradient Boosting), Derin Sinir Ağları (Deep Neural Networks), Lojistik Regresyon (Logistic Regression) ve Destek Vektör Makineleri (Support Vector Machines) gibi çeşitli makine öğrenimi yöntemlerini kullanarak, tiroid hormonu fonksiyonunu bozan bileşikleri tespit etmektedir. Çalışma sonucunda Rastgele Orman algoritmasıyla, en iyi ortalama F1-başarımı 0.83 ve 0.81 olarak elde edilmiştir. Yöntemde, tiroid hormonu reseptörü ile tiroid peroksidaz enziminin tiroid fonksiyon bozukluklarında en belirleyici faktörler olduğunu saptanmıştır.

Özer (2024), Yapay Sinir Ağı (Artificial Neural Network) kullanarak, tiroid hastalığının doğru teşhise yönelik azaltılmış öznitelik kullanan bir model geliştirmiştir. Bu modelde, kullanılan öznitelik sayısı minimum tutulmuş; azaltılmış öznitelik veri seti ile eğitimde 0.67, doğrulamada 0.99 ve testte 0.80 başarım elde edilmiştir. Önerilen yöntemde, hem veri setinde özellik azaltımı ile hesaplama maliyetini azalttığı hem de sınıflandırma başarımını koruyarak etkili bir tanı sürecinin sağlandığını ortaya koymuştur.

Kumar vd. (2022), tiroid hastalığını sınıflandırmada etkin öznitelik seçimini sağlamak amacıyla Kelebek Optimizasyon Algoritması ile Diferansiyel Gelişim Algoritmasını birleştiren hibrit bir yöntem önermiştir. Çalışmasında, Diferansiyel Gelişim Algoritması 0.884, Kelebek Optimizasyon algoritması 0.906 doğruluk oranına sahipken; önerilen hibrit yöntemin 0.943 doğruluk oranı ile daha yüksek bir başarım elde ettiği gösterilmiştir.

Lee ve Park (2022), güncel makine öğrenmesi yöntemlerini kullanarak, tiroid hastalığının erken teşhisine yönelik kapsamlı araştırma yapmıştır. Çalışmasında, hastalığın erken teşhisinde önemli öznitelik değişkenlerinin belirlenmesinde makine öğrenmesi yöntemlerinin etkili bir destek aracı olduğu vurgulanmıştır. Gupta vd. (2024), tiroid hastalığının tespitinde uygulanan makine öğrenmesi yöntemlerinde parametre optimizasyonu için Diferansiyel Gelişim Algoritmasına dayalı bir yöntem sunmuştur. Bu yöntem ile parametre seçiminde daha iyi performans elde edildiğini göstermiştir. Yapılan karşılaştırmalar sonucunda, AdaBoost algoritmasıyla birlikte kullanılan Diferansiyel Gelişim yöntemi, 0.998 doğruluk oranı ile diğer makine öğrenmesi yöntemlerine kıyasla daha başarılı sonuçlar vermiştir. Riajuliislam vd. (2021), hipotiroidizm tespitine yönelik farklı makine öğrenmesi yöntemleri ile tekrarlayan özellik seçimi, tek değişkenli özellik seçimi ve temel bileşen analizi kullanılarak özellik seçimi yöntemlerini karşılaştıran bir çalışma yapmıştır. Çalışmasında, tekrarlayan özellik seçimi yöntemiyle uygulanan makine öğrenmesi algoritmalarının 0.993 doğruluk oranı ile en iyi sonuçları verdiği; temel bileşen analizi ile elde edilen sonuçların ise en düşük doğruluğa sahip olduğu belirtilmiştir.

Hosseinzadeh vd. (2021), tiroid hastalığı teşhisi için sınıflandırma doğruluğunu artırmak ve yavaş yakınsama problemini çözmek amacıyla altı ağdan oluşan çoklu katmanlı algılayıcı ağlar kullanan bir Yapay Sinir Ağı modeli önermiştir. Yapılan çalışmada, tek ağdan oluşan çoklu katmanlı algılayıcı ağı ile 0.983 doğruluk elde edilirken, önerilen altı ağlı yapı ile 0.99 doğruluk oranı ile daha yüksek başarım elde etmiştir.

Dörterler vd. (2024) tiroid hastalığının teşhisi için K-ortalamalar algoritması ile meta-sezgizel algoritmalardan

Karga Arama Algoritması, Ağaç Tohum ve Harris Hawks algoritmasını birleştirerek hibrit bir kümeleme yöntemleri oluşturmuştur. Çalışmasında, K-ortalamalar algoritması tek başına 0.434 doğruluk oranına sahipken, önerilen hibrit yöntemlerle başarının 0.96'ya kadar çıkarıldığı gösterilmiştir. Harris Hawks algoritmasıyla oluşturulan hibrit yöntemde ise 0.969 en yüksek doğruluk başarımı elde edilmiştir.

Dörterler vd. (2022) tarafından yapılan diğer bir çalışmada kalp hastalığının teşhisi için K-ortalamalar algoritmasının başarımını artırmak amacıyla Diferansiyel Gelişim Algoritması ve harmoni arama algoritması ile hibrit modeller geliştirilmiştir. Yapılan çalışmada, K-ortalamalar algoritması tek başına 0.55 doğruluk sağlarken, Harmoni Arama algoritması ile 0.66 doğruluk sağlamıştır. Ancak Diferansiyel Gelişim algoritması ile 0.85 doğruluk değeriyle en yüksek başarım elde etmiştir.

Dörterler (2023), lenfografi ve meme kanseri hastalıklarının daha doğru ve etkili şekilde teşhis edilmesi amacıyla, K-ortalamalar algoritması ile Ölüm Oyunu Optimizasyon algoritmasını birleştirerek hibrit bir model sunmuştur. Lenfografi veri setinde, K-ortalamalar algoritması 0.759 doğruluk değeri elde ederken; önerilen model, eğitim veri setinde 0.913, test verisinde ise 0.853 doğruluk değeri elde etmiştir. Benzer şekilde, meme kanseri veri setinde K-ortalamalar algoritması 0.957 doğruluk sağlarken, önerilen hibrit model eğitimde 0.973 ve testte 0.961 doğruluk değeriyle yüksek başarım sağlanmıştır. Önerilen hibrit yöntemler, hastalığın tanı başarımını önemli ölçüde artırmıştır.

Ayrıca, son yıllarda derin öğrenme tabanlı modellerle yapılan çalışmalar, farklı türdeki hastalıkların teşhisinde yüksek doğruluk oranlarıyla etkili çözümler sunmaktadır (Sarakhsi vd. 2022, Wani vd. 2022). Karadağ ve Özdemir (2022) tarafından gerçekleştirilen bir çalışmada, böbrek tümörlerinin tespiti için bilgisayarlı tomografi (BT) görüntüleri kullanılarak VGG16, VGG19 ve ResNet50 gibi derin öğrenme mimarileri karşılaştırılmıştır. Bu modellerin, böbrek tümörlerini 0.85'e varan doğruluk oranlarıyla başarılı bir şekilde tespit edebildiği gösterilmiştir. Ayyıldız vd. (2024) periodontitis hastalığının farklı evrelerinin radyografik görüntüler üzerinden tespiti için derin öğrenme yöntemlerini değerlendirmiştir. Bu çalışmada, çeşitli derin öğrenme modellerinin periodontitisin evrelerini ayırt etmede etkili olduğu bulunmuştur. Tiroid hastalıklarının sınıflandırılması, hem yüksek boyutlu özellik uzayına, hem de sınıflar arası dengesizlik gibi zorluklara sahiptir. Klasik makine öğrenmesi algoritmaları ile tatmin edici sınıflandırma performansı elde etmek her zaman mümkün olmamaktadır. Bu çalışmada, tiroid hastalığının teşhis edilmesi amacıyla yeni bir hibrit yöntem geliştirilmiştir. Geliştirilen yöntemde, korelasyona dayalı özellik seçimiyle veri setindeki öznitelik sayısı azaltılmış, sınıflandırma aşamasında softmax sınıflandırıcı uygulanmış ve model optimizasyonu için Yapay Arı Kolonisi (YAK) algoritması kullanılmıştır. Öznitelik değişkenlerin azaltılması ön işlem adımıyla modelin hesaplama yükü düşürülmüş ve daha hızlı, yalın bir öğrenme yapısı elde edilmiştir. Böylece hem modelin eğitim süresi kısaltılmış hem de aşırı öğrenme riski azaltılmıştır. Ayrıca softmax tabanlı sınıflandırıcının parametrelerinin optimize edilmesi amacıyla YAK algoritması uygulanmış; bu sayede öğrenme sürecinde sabit parametreler yerine, YAK algoritması ile optimize edilmiş yapılar kullanılmıştır. Önerilen yöntem, UCI makine öğrenme veri deposunda yer alan "Thyroid Disease" veri seti üzerinde test edilmiştir. Ayrıca, yöntemin başarımı, literatürde yaygın olarak uygulanan makine öğrenmesi yöntemlerinden K-En Yakın Komşu algoritması, Destek Vektör Makinası, Yapay Sinir Ağı, Saf Bayes metotlarıyla karşılaştırılmıştır. Yapılan deneysel çalışma sonucunda elde edilen başarım sonuçları kapsamlı bir şekilde karşılaştırmalı olarak incelenmiştir.

Bu makalenin devam eden bölümleri şu şekilde özetlenmiştir: Bölüm 2'de, çalışmada kullanılan makine öğrenmesi yöntemleri, Yapay Arı Kolonisi (YAK) algoritması ve veri seti özetlenmektedir. Bölüm 3'te, önerilen yöntemin detayları sunulmakta; öznitelik seçimi, softmax sınıflandırıcı ve YAK algoritmasının entegrasyonu ayrıntılı bir şekilde açıklanmaktadır. Bölüm 4'te, gerçekleştirilen deneysel çalışmalara ait bulgular sunulmakta ve elde edilen sonuçlar tartışılmaktadır. Son olarak, Bölüm 5'te çalışma sonuçlandırılmakta ve gelecekte gerçekleştirilebilecek olası çalışmalar ele alınmaktadır.

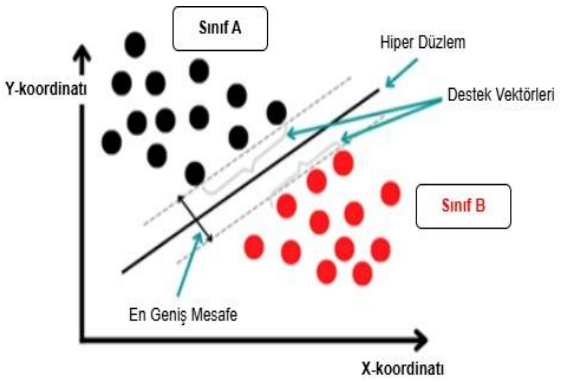
2. Materyal ve Metot

Bu çalışmada, tiroid hastalığının erken aşamalarda teşhisinde yüksek doğruluk sağlayan, yenilikçi bir makine öğrenmesi tabanlı yöntem geliştirilmesi amaçlanmıştır. Bu bölümde, uygulanan makine öğrenmesi yöntemleri, Yapay Arı Kolonisi algoritması, çalışmada kullanılan veri seti ve değerlendirme kriterlerine ilişkin ayrıntılı bilgiler sunulmaktadır.

2.1 Destek Vektör Makineleri

Destek Vektör Makinesi (Support Vector Machines, SVM), sınıflandırma ve regresyon görevleri için kullanılan güçlü bir makine öğrenmesi algoritmasıdır. Şekil 1'de örnek SVM yapısı gösterilmiştir. Yöntem, yüksek boyutlu

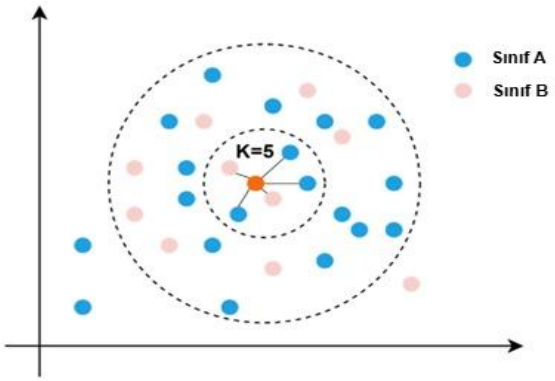
uzaylarda çalışarak verileri ayıran bir hiperdüzlem oluşturur. Bu düzlem, sınıflar arası boşluğu maksimize ederek verileri sınıflara ayırmaya çalışmaktadır. Doğrusal, polinom, radyal tabanlı fonksiyon (RBF) ve sigmoid gibi çekirdek fonksiyonları sayesinde, doğrusal olmayan sınıflandırmalarda yapılabilmektedir (Akter ve Mustafa 2024, Sarker 2021). Ancak, yüksek hesaplama maliyeti ve hiperparametre ayarlamalarına olan duyarlı nedeniyle dikkatli yapılandırması gerekmektedir.



Şekil 1. SVM algoritması

2.2 K-En Yakın Komşu Algoritması

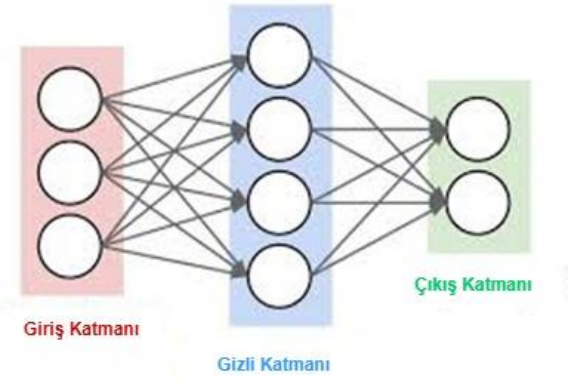
K-En Yakın Komşu (K Nearest Neighbour, KNN) algoritması, yeni bir veri noktasının sınıfı, K en yakın komşunun eğitim verilerine olan benzerliğine göre belirlenmektedir. En yakın komşularıyla olan benzerliği, genellikle Öklid mesafesi kullanılarak hesaplanmakta ve elde edilen mesafeye göre sınıflandırma yapılmaktadır (Sandlu vd. 2023, Sultana ve Islam 2023). Veri özelliklerin ölçeklendirilememesi durumunda, mesafe hesaplamalarında hata oranının artması ve yüksek hesaplama maliyeti gibi sınırlamaları bulunmaktadır. Örnek bir KNN yönteminin yapısı Şekil 2'de gösterilmiştir.



Şekil 2. KNN algoritması

2.3 Yapay Sinir Ağı

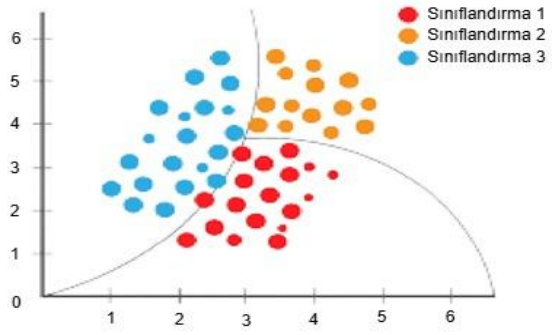
Yapay Sinir Ağı (Artificial Neural Networks, ANN), insan beynindeki sinir hücrelerinin yapısını matematiksel olarak modelleyerek öğrenme süreçlerini taklit etmeyi amaçlayan yapay zeka tabanlı bir makine öğrenmesi yöntemidir. Giriş katmanı, çıkış katmanı ve girişi çıkış katmanın kullanabileceği yapıya dönüştüren gizli katman olmak üzere üç katmandan oluşmaktadır. Giriş katmanı, ANN'a verilen verileri almakta; gizli katman, verileri çıkış katmanına uygun şekilde veriyi işlemektedir. Çıkış katmanı ise işlenmiş veri sonucunda elde edilen çıktıyı vermektedir (Sarker 2021). Şekil 3'te örnek bir ANN yapısı gösterilmektedir. Yüksek hesaplama maliyeti, aşırı öğrenme ve yorumlanabilirliğin sınırlı olması gibi dezavantajları vardır.



Şekil 3. ANN algoritması

2.4 Saf Bayes

Saf Bayes (Naive Bayes, NB) algoritması, herhangi bir sınıflandırma yapmadan önce hangi sınıfın olasılık biçiminde daha yüksek değere sahip olduğunu ortaya koyan en temel makine öğrenmesi yöntemlerinden birisidir. Şekil 4'te genel yapısı gösterilmiştir (Sarkar 2023). Tüm özniteliklerin birbirinden bağımsız olduğu varsayımına dayalı işlem yapmaktadır. Diğer yöntemlere göre eğitim süresi kısadır, hesaplama maliyeti düşüktür ve daha hızlı çalışmaktadır. Ancak, bağımsızlık varsayımına dayalı olasılık hesaplamasından dolayı mutlak güvenilirlik taşımamaktadır.



Şekil 4. NB algoritması

2.5 Yapay Arı Kolonisi Algoritması

Yapay Arı Kolonisi (YAK) algoritması, merkezi bir otorite olmadan arıların doğadaki yiyecek arama, iyi kaynakları hafızada tutma ve iyi kaynak bilgilerini diğer arılarla paylaşma davranışlarını temel alan bir optimizasyon

yaklaşımıdır (Karaboğa 2005). YAK algoritması üç temel bileşenden oluşmaktadır; görevli arılar, gözcü arılar ve kâşif arılar. Bu arı türleri, algoritmanın keşif, sömürü ve bilgi güncelleme süreçlerini temsil etmektedir. Bir optimizasyon probleminde yiyecek kaynakları, arama uzayındaki olası çözüm adaylarını temsil etmektedir. Her kaynağın bir görevli arısı vardır. Görevli arılar, yiyecek kaynağının kalitesine göre kaynak bilgisini gözcü arılara aktarmaktadır. Ayrıca gözcü arılar, ilgili kaynak çevredeki daha zengin yiyecek kaynaklarını aramakla da görevlidir. Eğer bir görevli arının kaynağı tükenirse, o arı kâşif arıya dönüşür ve keşfedilmemiş yeni kaynak arayışına geçer (Karaboğa vd. 2014, Karaboğa 2005). YAK algoritmasının adımları şu şekildedir:

1. **Başlangıç yiyecek kaynağının belirlenmesi:** Başlangıçta, rastgele seçilmiş yiyecek kaynağı yerleri ve bu yerlere gönderilen görevli arılardan oluşan bir başlangıç çözüm kümesi oluşturulur.
2. **Çözümün uygunluk değerinin hesaplanması:** Her bir görevli arı tarafından temsil edilen çözümün (yiyecek kaynağının) uygunluk fonksiyonu değeri hesaplanır. Elde edilen uygunluk değeri ne kadar yüksekse, o çözüm daha iyi bir yiyecek kaynağı olarak kabul edilir.
3. **Görevli Arıların Hareketi:** Görevli arılar, önceden keşfedilmiş yiyecek kaynaklarını değerlendirir. Bu yiyecek kaynaklarının yeri ve nektar kalitesi bilgilerini gözcü arılarla paylaşmaktadır. Bu bilgi aktarımı, gözcü arıların seçim yapmasında etkilidir.
4. **Gözcü Arıların Hareketi:** Görevli arıların paylaştığı bilgiler doğrultusunda bir yiyecek kaynağı bölgesini seçer. Daha sonra, bu seçilen yiyecek kaynağının yakın çevresinde daha verimli kaynakları aramakla görevlidir.
5. **En İyi Çözümlerin Bulunması:** Popülasyon içindeki uygunluk değeri en yüksek olan çözüm seçilir ve bu çözüm nihai çözüm olarak kabul edilir.
6. **Kaşif Arıların Hareketi:** Keşfedilmemiş potansiyel olarak zengin yiyecek kaynaklarını arama hareketidir. Rastgele arama stratejisi uygulanır.
7. **Kaynaktan Ayrılma Kriteri:** Sonlandırma koşulu kontrol edilir. Eğer belirlenen koşul sağlanırsa durur, aksi takdirde işlem 3.adıma geri döner ve arama süreci devam eder.

Rastgele yiyecek kaynağı üretimi, her bir parametrenin tanımlı alt ve üst sınırları arasında rastgele değerler oluşturularak gerçekleştirilir (Karaboğa vd. 2014):

$$x_{ij} = x_j^{min} + rand(0,1)(x_j^{max} - x_j^{min}) \quad (1)$$

Burada x_{ij} başlangıçta rastgele oluşturulan yiyecek kaynaklarını temsil etmektedir i. yiyecek kaynağının sayısı j ise optimize edilmesi gereken parametre sayısıdır. j için belirlenen alt ve üst sınırlar sırasıyla x_j^{max} ve x_j^{min} ile ifade edilmektedir. Rastgele olarak yeni bir yiyecek kaynağı bulan kâşif arı, bundan sonra görevli arı haline gelir ve kovana besin taşımaya başlar. Algoritmanın her adımında görevli arılar kendisine atanmış yiyecek kaynaklarının yakın çevresinde yeni kaynaklar bulur ve bu kaynağın besin değerlerini değerlendirir. Bulunan yeni kaynağın besin miktarı mevcut kaynaktan yüksekse yeni kaynak bellekte tutulur. Yeni yiyecek kaynağı ϑ_{ij}, aşağıdaki denklem ile hesaplanır:

$$\vartheta_{ij} = x_{ij} + \phi_{ij}(x_{ij} - x_{kj}) \quad (2)$$

Burada ϑ_{ij}, ϑ_i. aday yiyecek kaynağının j. Parametresini temsil etmektedir. x_i, mevcut görevli arının temsil ettiği çözüm noktasını, ϑ_i ise x_i'in komşuluğunda oluşturulan yeni bir çözüm adayını ifade etmektedir. i, mevcut yiyecek kaynağını, k ise rastgele seçilen farklı yiyecek kaynağını belirtmektedir. j değeri {1, 2, …, D} kümesinden, k değeri ise {1, 2, …, SN} aralığından rastgele seçilmektedir. ϕ_{ij} [-1, 1] aralığında rastgele üretilen bir sayı olup arama süresine çeşitlilik katmak amacıyla kullanılmaktadır. Mevcut çözüm x_i ile yeni üretilen aday çözüm ϑ_i arasındaki seçim ise açgözlü seçim yöntemi ile gerçekleştirilir. Daha yüksek uygunluk değerine sahip olan çözüm tercih edilerek bellekte tutulmaktadır. Çözümlerin uygunluk değeri aşağıdaki denklem ile hesaplanır.

$$fit(x_i) = \begin{cases} \frac{1}{1+obj(x_i)} & eğer\ obj(x_i) > 0 \\ 1 + |obj(x_i)| & eğer\ obj(x_i) < 0 \end{cases} \quad (3)$$

Burada $obj(x_i)$, i. Nektarının çıkarılma maliyetini, $fit(x_i)$ ise bu kaynağın uygunluk değerini vermektedir. Görevli arıların kovana gelerek bilgi aktardığı gözcü arılar, bu bilgilerden yararlanarak yiyecek kaynaklarının besin miktarıyla orantılı bir olasılıkla kaynak seçerler. Bu yöntemle daha iyi kaynaklara gözcü arıların gitme ihtimali artmaktadır.

$$P_{ij} = \frac{fit(x_i)}{\sum_{j=1}^{SN} fit(x_j)} \quad (4)$$

2.6 Veri Seti

UCI Makine Öğrenme Deposunda yer alan tiroid hastalığı veri seti, tiroid sağlığının sınıflandırılma ve tahmini amacıyla yapılan makine öğrenmesi tabanlı araştırmalarda yaygın olarak kullanılan, çok sayıda özelliğe ve çoklu sınıfa sahip bir veri kümesidir. Garvan Enstitüsü tarafından oluşturulan veri tabanları, tiroid hastalığı olan bireylerden elde edilen tıbbi verileri içermektedir. Bu veri tabanı toplam 10 farklı veri kümesini kapsamaktadır. Her bir veri kümesi yaklaşık 2.800 eğitim örneği ve 972 test örneğinden oluşmaktadır (Quinlan, 1986). Her veri kümesinde Boole veya sürekli değişkenler

olarak sınıflandırılan yaklaşık 29 özellik bulunmaktadır. Bu çok yönlü veri seti, tiroid hastalığının teşhisi, tedavi etkinliğinin değerlendirilmesi ve maliyet etkinliği analizi gibi çeşitli görevleri desteklemekte olup; klinik uygulama ve araştırma için önemli bir kaynak sağlamaktadır. Bu çalışmada kullanılan tiroid veri setine ait tüm öznitelikler, özellik türleri ve açıklamalarıyla birlikte Çizelge 1'de detaylı olarak sunulmuştur.

Çizelge 1. Tiroid veri setinde yer alan öznitelikler (Attributes found in thyroid dataset)

Öznitelik	Tipi	Açıklama
Age	Continuous	Hastanın yaşı
Sex	Categorical (M/F)	Cinsiyet
On thyroxine	Binary (f/t)	Hasta T4 alıyor mu?
Query on thyroxine	Binary (f/t)	Hasta T4 hakkında soru sordu mu?
On antithyroid medication	Binary (f/t)	Anti-tiroid ilaç kullanıyor mu?
Sick	Binary (f/t)	Hasta mı?
Pregnant	Binary (f/t)	Hamile mi?
Thyroid surgery	Binary (f/t)	Tiroid ameliyatı oldu mu?
I131 treatment	Binary (f/t)	Radyoaktif iyot tedavisi aldı mı?
Query hypothyroid	Binary (f/t)	Hipotiroid hakkında soru sordu mu?
Query hyperthyroid	Binary (f/t)	Hipertiroid hakkında soru sordu mu?
Lithium	Binary (f/t)	Hasta lityum kullanıyor mu?
Goiter	Binary (f/t)	Guatr var mı?
Tumor	Binary (f/t)	Tiroid tümörü var mı?
Hypopituitary	Binary (f/t)	Hipopituitarizm var mı?
Psych	Binary (f/t)	Psikolojik hastalık var mı?
TSH	Continuous	TSH seviyesi
T3	Continuous	T3 seviyesi
TT4	Continuous	TT4 seviyesi
T4U	Continuous	T4U seviyesi
FTI	Continuous	FTI seviyesi
Referral source	0,1,2	Hastalık sınıfı (class label)

Bu çalışmada, 3772 eğitim ve 3428 test örneğinden oluşan kullanılan ANN tiroid veri seti kullanılmıştır. Eğitim veri setinde hasta dağılımı; normal=93, hipertiroid=191 ve hipotiroid=3488 kişi şeklindedir. Test veri setindeki dağılımı ise; normal=73, hipertiroid=177 ve hipotiroid=3178 kişiden oluşmaktadır. Ayrıca, farklı makine öğrenmesi algoritmaları da aynı eğitim verisiyle eğitilmiş; ardından bu algoritmaların sınıflandırma başarımları test veri seti üzerinde değerlendirilerek karşılaştırmalı bir analiz gerçekleştirilmiştir.

2.7 Değerlendirme Kriteri

Uygulanan makine öğrenmesi yöntemlerinin, tiroid hastalığı teşhisindeki başarımlarını değerlendirmek amacıyla; doğruluk, duyarlılık, kesinlik ve F1-başarım gibi standart sınıflandırma değerlendirme kriterleri temel alınmıştır (Carrinton vd. 2022).

$$\text{Doğruluk} = \frac{(\text{DP}+\text{DN})}{(\text{DP}+\text{DN}+\text{YP}+\text{YN})} \quad (5)$$

$$\text{Duyarlılık} = \frac{\text{DP}}{\text{DP}+\text{YN}} \quad (6)$$

$$\text{Kesinlik} = \frac{\text{DP}}{\text{DP}+\text{YP}} \quad (7)$$

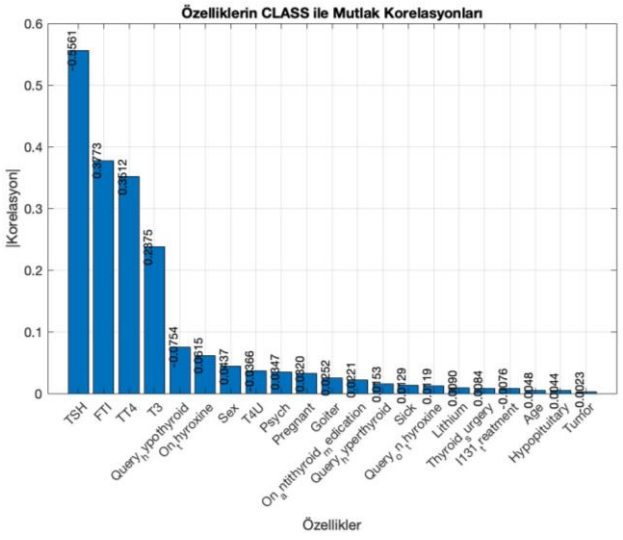
$$\text{F1} - \text{başarım} = \frac{2 \times \text{Kesinlik} \times \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (8)$$

Burada, DP, DN, YP ve YN sırasıyla doğru pozitif, doğru negatif, yanlış pozitif ve yanlış negatif sınıflandırma sonuçlarını temsil etmektedir.

3. Önerilen Yöntem

Bu bölümde, tiroid hastalığının doğru ve etkili bir şekilde teşhisine yönelik olarak; korelasyon tabanlı özellik azaltımı, softmax sınıflandırıcı ve Yapay Arı Kolonisi (YAK) algoritması kullanılarak hibrit bir makine öğrenmesi yöntemi geliştirilmiştir. Tiroid hastalıklarının sınıflandırılması, yüksek boyutlu özellik uzayı ve sınıflar arası dengesizlik gibi zorluklara sahip karmaşık bir problemdir. Geleneksel makine öğrenmesi algoritmaları genellikle yerel optimumda takılma ve ağırlıkların uygun şekilde ayarlanamaması ve parametre hassasiyeti gibi zorluklara sahiptir. Ancak, önerilen yöntemde YAK algoritmasının popülasyon tabanlı arama stratejisi sayesinde, geniş bir çözüm uzayında arama yapılarak global optimuma ulaşma olasılığı artırılmaktadır. Softmax tabanlı sınıflandırıcının ağırlıklarının rastgele ya da manuel seçilmesi, yöntemlerin performansını olumsuz etkilemektedir. YAK algoritması ile bu ağırlıklar otomatik ve veri odaklı bir şekilde optimize edilmektedir. Ayrıca, çalışmada açıklanabilir özellik çıkarımı uygulanarak korelasyon tabanlı öznitelik seçimi ile öznitelik sayısı azaltılmıştır. Bu sayede, sınıflayıcı modelin karar sürecinde hangi özniteliklerin ne ölçüde etkili olduğu ortaya konulmuş; böylece çalışmada kullanılan özniteliklerin seçimi açıklanabilir ve yorumlanabilir şekilde yapılmıştır. Ayrıca, modelin hesaplama yükü azaltılarak daha hızlı bir öğrenme yapısı oluşturulmuştur.

Tiroid hastalığında kullanılan ANN veri seti 3 sınıflı ve 21 öznitelikten (15 öznitelik ikili ve 6 öznitelik sürekli) oluşmaktadır. Hasta verileri, 1 = normal, 2 = hipertiroid ve 3 = hipotiroid olarak sınıflandırılmıştır. Yapılan çalışmada öz nitelikleri azaltmak için korelasyon tabanlı özellik azaltımı yöntemi uygulanmıştır. Veri setinde bulunan tüm öznitelikler, tek tek 'Class' değişkeniyle karşılaştırılmış ve korelasyon katsayısı (Pearson) hesaplanmıştır. Özniteliklerin korelasyon sonuçlarının mutlak değeri, en yüksekten düşüğe doğru Şekil 5'te gösterilmiştir.



Şekil 5. Tiroid veri setindeki özniteliklerin korelasyon değerleri

Korelasyon analizi yaparken eşik değer seçimi, uygulamanın amacına göre olarak belirlenmektedir. Eşik değerin çok düşük seçilmesi, modelde karmaşıklığa sebep olarak genelleme yeteneğini azaltmaktadır. Ayrıca, anlamsız ilişkilerin anlamlı olarak değerlendirilmesine ve hatalı sonuçlara sebep olabilmektedir. Yüksek eşik değer seçimi ise anlamlı korelasyonların göz ardı edilmesine ve modelin aşırı basitleşmesine sebep olabilmektedir. Yapılan deneysel çalışmalar sonucunda, bu çalışmada eşik değeri 0.04 olarak belirlenmiştir. Böylece açıklanabilir öznitelik çıkarımı sağlanmıştır. Korelasyon tabanlı öznitelik seçimi sonucu belirlenen öznitelikler Çizelge 2'te sunulmuştur.

Çizelge 2. Korelasyon tabanlı öznitelik seçimi

Öznitelik	Değerleri
Sex	0.0436
On_throxine	0.0615
Query_hypothroid	0.0754
TSH	0.5561
T3	0.2374
TT4	0.3521
FTI	0.3773

Korelasyon tabanlı öznitelik seçimi ile makine öğrenmesi modelleri için daha sade ve etkili özniteliklerin seçilmesi sağlanmıştır. Öznitelik seçiminde, otokodlayıcı (autoencoders) yaygın olarak kullanılmaktadır. Ancak bu yöntem tiroid verilerde açıklanabilirlik ve hesaplama maliyeti gibi dezavantajlarından dolayı kullanılmamıştır. Korelasyon tabanlı öznitelik seçimi, makine öğrenmesi yöntemlerinin daha hızlı çalışmasını, aşırı öğrenme riskini azaltmasını ve açıklanabilir bir yapı oluşturmasını sağlamaktadır.

Softmax sınıflandırıcı, çok sınıflı sınıflandırma problemlerinde her bir sınıfa ait olasılığı hesaplamak için kullanılan yaygın bir yöntemdir. Bu çalışmada kullanılan veri seti, hasta etiketleri normal, hipotiroid ve hipertiroid, olmak üzere çoklu sınıf yapısına sahiptir. Önerilen yöntemde, softmax sınıflandırıcı çapraz entropi kaybı (cross-entrpy loss) fonksiyonu ile uygulanmıştır. Çapraz entropi kaybı fonksiyonu, yöntemin tahmin ettiği olasılıkların doğru etiketlerle olan uyumunu değerlendirmektedir. Softmax sınıflandırıcının ağırlıkları optimize edildikten sonra yöntem, öğrenilmiş bir model gibi sınıflandırma yapmaktadır.

YAK algoritması, daha az parametreye duyarlı olması, dengeli keşif yapabilmesi ve daha etkili yakınsama sağlamasından dolayı etkili bir optimizasyon yöntemidir. Önerilen yöntemde, YAK algoritması sınıflandırma işlemini gerçekleştiren softmax sınıflandırıcının ağırlık matrisi ve bias vektörünü optimize etmektedir. Önerilen hibrit yöntemin akış şeması Şekil 6'da verilmiştir.

Ayrıca, yöntemde kullanılan YAK algoritmasının başlangıç parametreleri Çizelge 3'te verilmiştir.

Çizelge 3. YAK algoritmasının parametreleri ve değerleri

Parametreler	Değerleri
Popülasyon sayısı	40
Limit	50
İterasyon (y)	200
phi	rand()*2-1

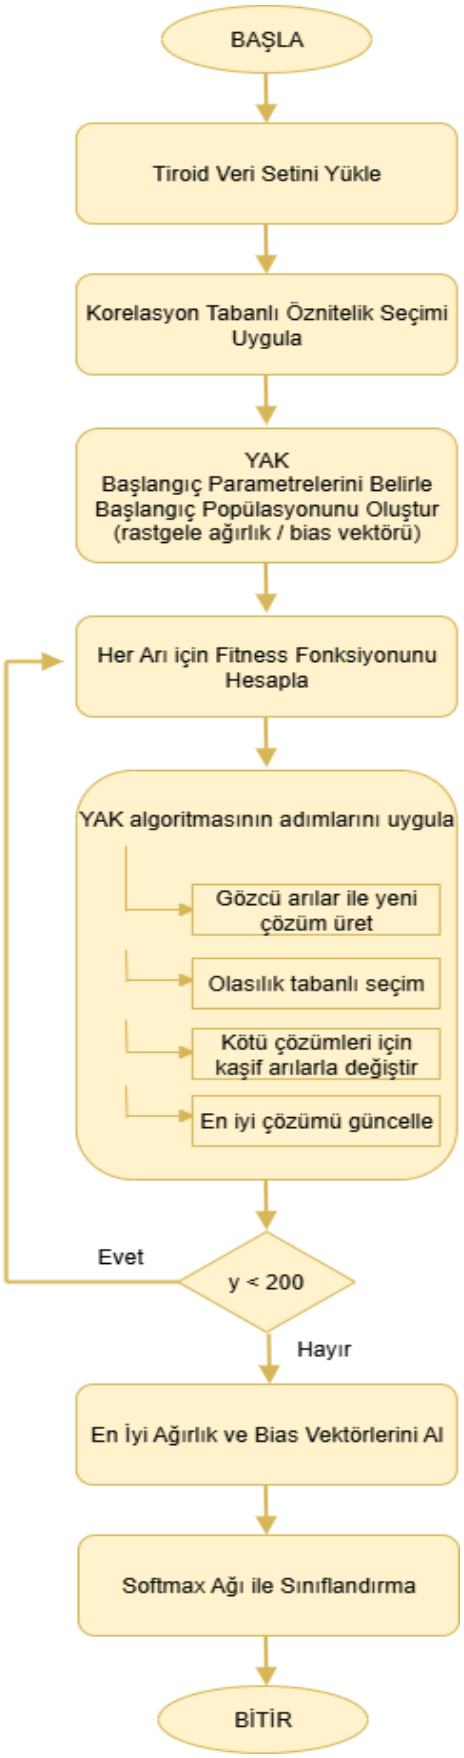
Önerilen hibrit yöntemde kullanılan tüm hiperparametreler Çizelge 4'te gösterilmiştir. Korelasyon tabanlı öznitelik seçiminde kullanılan eşik değer ve YAK algoritmasının parametre değerleri, deneysel çalışmalar sonucu belirlenmiştir. Softmax sınıflandırıcısının ağırlık matrisi ve bias vektörü ise YAK algoritması ile optimize edilerek en iyi sınıflandırma başarımının elde edilmesi sağlanmaktadır. Bunun için, çapraz entropi (cross-entropy) kayıp fonksiyonunu minimize eden ağırlık matrisi (W) ve bias vektörü (b) değeri YAK algoritması ile hesaplanmaktadır. Bu parametrelerinin değerleri YAK algoritması ile deterministik olmayan yöntemle belirlendiği için Çizelge 4'te değeri verilmemiştir.

Çizelge 4. Önerilen hibrit yöntemin hiperparameteleri

Grup	Parametre	Değer
Korelasyon	Eşik değeri	0.04
YAK algoritması	Koloni büyüklüğü	40
	Limit	50
	İterasyon	200
Softmax Ağ	Ağırlık matrisi	
Sınıflandırıcı	Bias vektörü	

Önerilen hibrit yöntemde, korelasyon tabanlı öznitelik seçimi, softmax sınıflandırıcı ve YAK algoritmasının birlikte kullanılmasından dolayı, hesaplama karmaşıklığı klasik yöntemlere kıyasla daha yüksektir. Ancak uygulanan yöntemin sınıflandırma başarımı dikkate alındığında, bu artan maliyet kabul edilebilir düzeydedir. Yöntemde her

döngüde, tüm popülasyon için fitness fonksiyonu hesaplanmakta ve tüm eğitim verisi üzerinde gerçekleştirilmektedir.



Şekil 6. Önerilen hibrit yöntemin akış şeması

Bu nedenle, zaman karmaşıklığı $Big - O(SN \times C \times N \times D)$ şeklinde ifade edilmektedir. Burada SN, popülasyondaki arı sayısını, C döngü sayısını, N her çözüm için fitness değerinin hesaplandığı örnek sayısını, D ise ağırlık matrisi ile bias vektörünün toplam parametre sayısını ifade etmektedir.

Softmax fonksiyonu, giriş verilerini çok sınıflı sınıflandırma problemlerinde olasılık dağılımına dönüştürerek, hangi sınıfa ait olduğunu hesaplamak için kullanılmaktadır. Softmax fonksiyonu, girdi vektörünü normalize ederek her sınıf için [0,1] aralığında olasılık değerli üretmektedir.

$$\mathrm{P}(\mathrm{y} = \mathrm{c} \mid \mathrm{x}) = \frac{e^{z_c}}{\sum_{j=1}^{C} e^{z_j}} \quad (9)$$

Burada; C sınıf sayısını ve x, giriş vektörünü ifade etmektedir.

$$z = x \cdot W + b \quad (10)$$

Burada W_c, b_c değerleri, sınıf c için ağırlık matrisi ve bias vektörü değerleridir. Çapraz entropi kaybı, yöntemin tahmin ettiği olasılık dağılımı ile gerçek etiketlerinin dağılımı arasındaki farkı ölçmektedir. Bu fonksiyon aşağıdaki gibi tanımlanır:

$$L = -\sum_{i=1}^{N} \sum_{c=1}^{C} y_{ic} \log(p_{ic}) \quad (11)$$

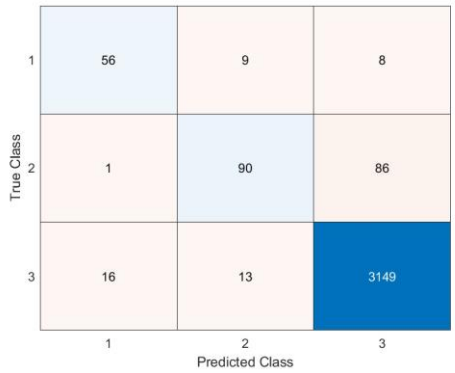
Burada y_{ic} değeri, gerçek etiketi ve p_{ic} ise softmax sonucu tahmin edilen olasılık değerini ifade etmektedir.

4. Bulgular

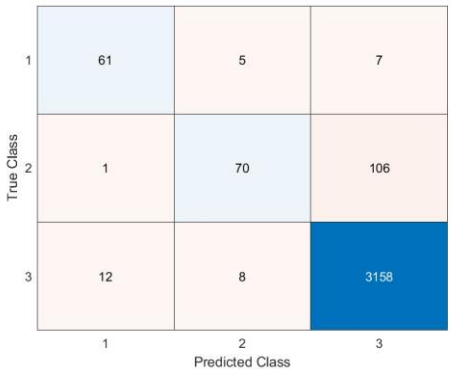
Tiroid hastalığının teşhisi için önerilen hibrit yöntem, literatürde kullanılan SVM, KNN, NB ve ANN yöntemleri ile karşılaştırılmıştır. Uygulanan yöntemler, Intel Core i5, 2.30 Ghz işlemciye ve 8 GB RAM'a sahip, Windows 11 işletim sistemi yüklü kişisel bilgisayarda MATLAB 2023b platformunda çalıştırılmıştır. Çalışmada 3772 eğitim ve 3428 test örneğinden oluşan veri seti kullanılmıştır.

Kullanılan eğitim ve test veri setlerinde ciddi bir sınıf dengesizliği bulunmaktadır. Vakaların yaklaşık %90'ı hipotiroid tanısından oluşmaktadır. Bu nedenle, yöntem başarımlarının yalnızca doğruluk değerleriyle değerlendirmesi yanıltıcı olabilmektedir. Bu yüzden başarımların değerlendirilmesinde kesinlik, duyarlılık ve F1- başarımları birlikte incelenmesi gerekmektedir.

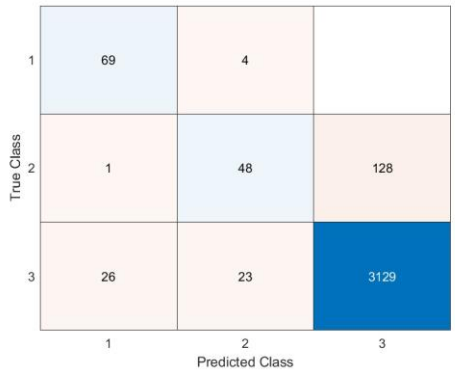
Önerilen hibrit yöntemin parametre değerleri Çizelge 4'te verilmiştir. Çalışmada kullanılan makine öğrenmesi yöntemleri ve önerilen yöntem, 20 kez tekrarlanarak çalıştırılmıştır. Çizelge 5'te yöntemlerin en iyi uygunluk, en kötü uygunluk, ortalama uygunluk, standart sapma ve ortalama çalışma zamanın istatistiksel sonuçları sunulmuştur. Elde edilen en iyi sonuçlar kalın olarak gösterilmiştir.



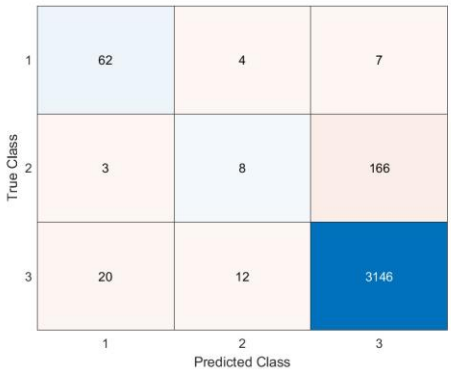
(a) SVM



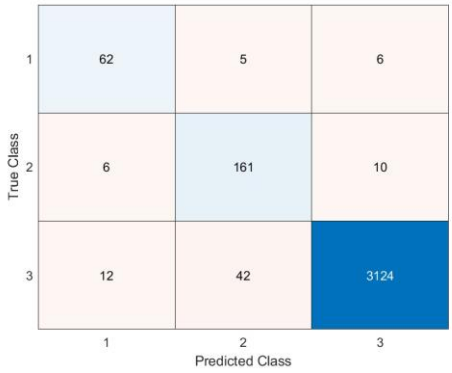
(b) KNN



(c) NB

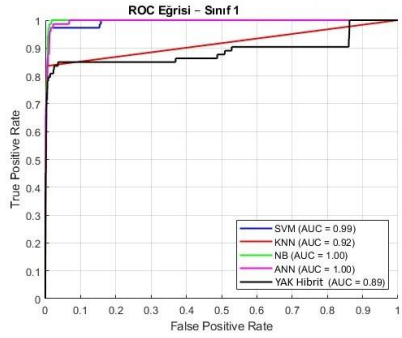


(d) ANN

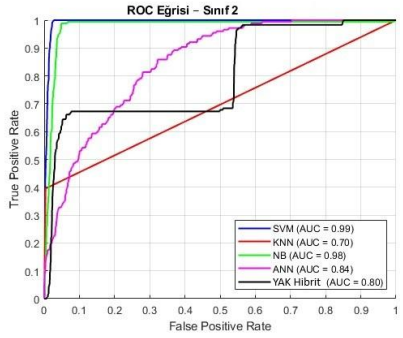


(e) Önerilen yöntem

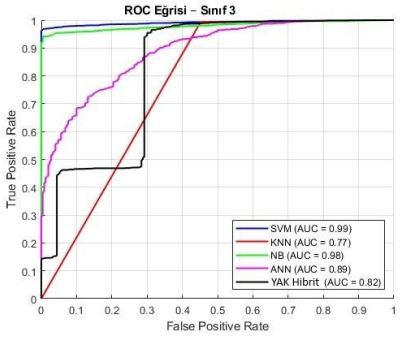
Şekil 7. Uygulanan yöntemlerin karmaşıklık matrisleri



(a) Sınıf 1 için ROC



(b) Sınıf 2 için ROC



(c) Sınıf 3 için ROC

Şekil 8. Uygulanan yöntemlerin sınıflara göre ROC eğrileri

Çizelge 5. Uygulanan yöntemlerinin başarımları

Yöntem	SVM	KNN	NB	ANN	Önerilen
En İyi Doğruluk	96.149	95.945	94.690	94.486	**97.637**
En Kötü Doğruluk	**95.945**	**95.945**	94.690	93.348	93.844
Ort. Doğruluk	96.096	95.945	94.690	93.941	**96.114**
Std. Doğruluk	0.049	**0**	**0**	0.290	0.758
En İyi Kesinlik	85.183	**87.771**	77.315	84.897	84.798
En Kötü Kesinlik	84.471	**87.771**	77.315	58.489	69.959
Ort. Kesinlik	84.861	**87.771**	77.315	70.785	80.572
Std. Kesinlik	0.186	**0**	**0**	8.565	3.756
En İyi Duyarlılık	76.005	74.160	73.365	66.160	**92.490**
En Kötü Duyarlılık	**74.241**	74.160	73.365	54.975	70.513
Ort. Duyarlılık	75.341	74.160	73.365	61.543	**82.381**
Std. Duyarlılık	0.397	**0**	**0**	2.440	5.626
En İyi F1-Başarım	79.378	78.259	72.333	67.794	**87.858**
En Kötü F1-Başarı	77.926	**78.259**	72.333	57.658	74.354
Ort. F1-Başarım	78.877	78.259	72.333	60.786	**80.848**
Std. F1-Başarı	0.325	**0**	**0**	2.763	3.289
Çalışma Süresi	1.386	**0.054**	1.242	0.544	7.238

Önerilen yöntem, ortalama değerlere bakıldığında en iyi doğruluk (96.114), duyarlılık (82.381) ve F1-başarım (80.848) değerlerini elde etmiştir. KNN yöntemi ise ortalama en yüksek kesinlik (87.772) değerine ulaşmıştır. Önerilen yöntemin çalışma süresi ortalaması, karşılaştırılan yöntemler içerisinde en uzun süredir.

En iyi durumlar incelendiğinde, önerilen yöntem doğruluk (97.637), duyarlılık (92.490) ve F1-başarım (87.858) değerleri açısından diğer yöntemlerden daha üstün performans göstermiştir. En kötü durumlar değerlendirildiğinde, doğruluk değeri açısından KNN (95.945) ve SVM (95.945), kesinlik değeri açısından SVM (87.771), duyarlılık değeri açısından KNN (74.241), F1-başarım değeri açısından KNN (78.259) ile en iyi sonuçları elde etmiştir. Standart sapma açısından ise KNN ve NB yöntemleri, 0 olarak en iyi sonucu vermiştir.

Önerilen hibrit yöntem, meta-sezgizel algoritmaların doğası gereği karşılaştırılan diğer yöntemlere kıyasla daha yavaş çalışmaktadır. Ancak elde ettiği yüksek doğruluk, duyarlılık ve F1-başarımları sayesinde, işlem maliyeti kabul edilebilir düzeydedir.

Test veri seti üzerinde elde edilen tahmin sonuçlarına ilişkin karmaşıklık (confusion) matrisleri Şekil 7'de verilmektedir. Elde edilen sonuçlar, önerilen yöntemin sınıflandırma doğruluğu açısından diğer geleneksel makine öğrenmesi yöntemlerine kıyasla yüksek performans sergilemiştir. Ayrıca, uygulanan yöntemlerin üç sınıf (1 = normal, 2 = hipertiroid, 3 = hipotiroid) için durumlarına ait ROC eğrileri Şekil 8'de verilmiştir. ROC (Receiver Operating Characteristic) eğrisinin altında kalan alan AUC (Area Under the Curve) olarak ifade edilir. AUC değeri, sınıflandırma yönteminin genel performansını yansıtmaktadır; bu alanın büyüklüğü, modelin pozitif ve negatif sınıfları ayrıt etme başarısını göstermektedir (Carrington, 2022). SVM yöntemi karşılaştırılan yöntemlerde tüm sınıflar için (1=normal, 2=hipertiroid ve 3=hipotiroid) daha yüksek performans sergilemiştir.

5. Sonuçlar ve Tartışma

Yapılan çalışmada, tiroid hastalığının doğru teşhis edilmesine yönelik yeni hibrit bir yöntem önerilmiştir. Önerilen yöntemde, korelasyon tabanlı öznitelik seçimi, softmax sınıflandırıcı ve Yapay Arı Kolonisi Algoritması kullanılarak yeni bir model geliştirilmiştir. Modelin başarımı, UCI makine öğrenme deposunda yer alan "Thyroid Disease" veri seti üzerinde değerlendirilmiştir. Veri setinde ciddi bir sınıf dengesizliği bulunması rağmen, doğruluk, duyarlılık, kesinlik ve F1-başarım metriklerinde geleneksel makine öğrenmesi algoritmalarına kıyasla önerilen hibrit yöntem üstün başarım göstermiştir. Bu sonuçlar, yöntemin azınlık sınıflarını da doğru şekilde sınıflandırabildiğini ve genelleme kabiliyetinin yüksek olduğunu göstermektedir. Ayrıca, önerilen hibrit yöntem hiperparametre optimizasyonu açısından esnek olup hastalığın teşhisinde etkili ve alternatif bir çözüm olarak değerlendirilebileceğini göstermektedir.

Gelecek çalışmalarda, mevcut hibrit yöntemin farklı sınıflandırma yöntemleri ve bu yöntemlere ait parametreler ile çeşitli meta-sezgizel algoritmalarla entegre edilerek başarımlarının değerlendirilmesi mümkündür. Ayrıca, geliştirilen yöntemin farklı klinik senaryolarda uygulanmasına yönelik çalışmalar yapılabilir.

Etik Standartlar Bildirgesi

Yazarlar tüm etik standartlara uyduklarını beyan ederler.

Yazarlık Katkı Beyanı

Yazar 1: Kaynaklar, Araştırma, Deney, Yazma – orijinal taslak Görselleştirme, Yazma – orijinal taslak

Çıkar Çatışması Beyanı

Yazarların bu makalenin içeriğiyle ilgili olarak beyan edecekleri hiçbir çıkar çatışması yoktur.

Verilerin Kullanılabilirliği

Bu çalışma sırasında oluşturulan veya analiz edilen tüm veriler, yayınlanan bu makaleye dahil edilmiştir.

6. Kaynaklar

Akter, S., ve Mustafa, H. A. (2024). Analysis and interpretability of machine learning models to classify thyroid disease. Plos one, **19(5)**, e0300670. https://doi.org/10.1371/journal.pone.0300670

Arslan, N. N., ve Ozdemir, D. (2024). Analysis of CNN models in classifying Alzheimer's stages: comparison and explainability examination of the proposed separable convolution-based neural network and transfer learning models. Signal, Image and Video Processing, 18(Suppl 1), 447-461. https://doi.org/10.1007/s11760-024-03166-5

Beynon ME, Pinneri K. 2016. An overview of the thyroid gland and thyroid-related deaths for the forensic pathologist. Academic Forensic Pathology **6(2)**:217–236. https://doi.org/10.23907/2016.024

Carrington, A. M., Manuel, D. G., Fieguth, P. W., Ramsay, T., Osmani, V., Wernly, B., Bennett, C., Hawken, S., Magwood, O., Sheikh, Y., Mclnnes, M., & Holzinger, A. (2022). Deep ROC analysis and AUC as balanced average accuracy, for improved classifier selection, audit and explanation. IEEE Transactions on Pattern Analysis and Machine Intelligence, **45(1)**, 329-341. https://doi.org/10.1109/TPAMI.2022.3145392

Chaganti, R., Rustam, F., De La Torre Díez, I., Mazón, J. L. V., Rodríguez, C. L., & Ashraf, I. (2022). Thyroid disease prediction using selective features and machine learning techniques. Cancers, **14(16),** 3914. https://doi.org/10.3390/cancers14163914

D. Karaboga (2005). An idea based on honey bee swarm for numerical optimization, Technical report-tr06, Erciyes University, Engineering Faculty, 2005.

D. Karaboga, B. Gorkemli, C. Ozturk, N. Karaboga (2014). A comprehensive survey: Artificial bee colony (ABC) algorithm and applications, Artificial Intelligence Review. **42**, 21–57. https://doi.org/10.1007/s10462-0129328-0

Dörterler, S. (2023). Kanser hastalığı teşhisinde ölüm oyunu optimizasyon algoritmasının etkisi. Mühendislik Alanında Uluslararası Araştırmalar, 8, 15. ISBN: 978-625-6382-17-6

Dörterler, S., Dumlu, H., Özdemir, D., & Temurtaş, H. (2022). Hybridization of k-means and meta-heuristics algorithms for heart disease diagnosis. New Trends in Engineering and Applied Natural Sciences, 55. ISBN: 978-625-8109-42-9

Dörterler, S., Dumlu, H., Özdemir, D., & Temurtaş, H. (2024). Hybridization of meta-heuristic algorithms with k-means for clustering analysis: Case of medical datasets. Gazi Journal of Engineering Sciences, 10(1), 1-11. https://doi.org/10.30855/gmbd.0705N01

Garcia de Lomana, M., Weber, A. G., Birk, B., Landsiedel, R., Achenbach, J., Schleifer, K. J., Mathea, M., & Kirchmair, J. (2020). In silico models to predict the perturbation of molecular initiating events related to thyroid hormone homeostasis. Chemical research in toxicology, **34(2**), 396-411. https://doi.org/10.1021/acs.chemrestox.0c00304

Guler Ayyildiz, B., Karakis, R., Terzioglu, B., & Ozdemir, D. (2024). Comparison of deep learning methods for the radiographic detection of patients with different periodontitis stages. Dentomaxillofacial Radiology, 53(1), 32-42. https://doi.org/10.1093/dmfr/twad003

Gupta, P., Rustam, F., Kanwal, K., Aljedaani, W., Alfarhood, S., Safran, M., & Ashraf, I. (2024). Detecting thyroid disease using optimized machine learning model based on differential evolution. International Journal of Computational Intelligence Systems, **17(1)**, 3. https://doi.org/10.1007/s44196-023-00388-2

Hosseinzadeh, M., Ahmed, O. H., Ghafour, M. Y., Safara, F., Hama, H. K., Ali, S., Vo, B., & Chiang, H. S. (2021). A multiple multilayer perceptron neural network with an adaptive learning algorithm for thyroid disease diagnosis in the internet of medical things. The Journal of Supercomputing, **77**, 3616-3637. https://doi.org/10.1007/s11227-020-03404-w

Islam, S. S., Haque, M. S., Miah, M. S. U., Sarwar, T. B., & Nugraha, R. (2022). Application of machine learning algorithms to predict the thyroid disease risk: an experimental comparative study. PeerJ Computer Science, **8**, e898. https://doi.org/10.7717/peerj-cs.898

Khojaste-Sarakhsi, M., Haghighi, S. S., Ghomi, S. F., & Marchiori, E. (2022). Deep learning for Alzheimer's disease diagnosis: A survey. Artificial intelligence in medicine, 130, 102332. https://doi.org/10.1016/j.artmed.2022.102332

Kumar, S. J. K., Parthasarathi, P., Masud, M., Al-Amri, J. F., & Abouhawwash, M. (2023). Butterfly Optimized Feature Selection with Fuzzy C-Means Classifier for Thyroid Prediction. Intelligent Automation & Soft Computing, **35(3)**. https://doi.org/10.32604/iasc.2023.030335

Lee, K. S., & Park, H. (2022). Machine learning on thyroid disease: a review. Frontiers in Bioscience-Landmark, **27(3)**, 101. https://doi.org/10.31083/j.fbl2703101

Nguyen QT, Lee EJ, Huang MG, Park YI, Khullar A, Plodkowski RA. 2015. Diagnosis and treatment of patients with thyroid cancer. American Health & Drug

Benefits **8(1):**30–40. PMID: 25964831; PMCID: PMC4415174.

Özer, E. (2024). Thyroid Disease Diagnosis: A Study on the Efficacy of Feature Reduction and Biomarker Selection in Artificial Neural Network Models. International Journal of Multidisciplinary Studies and Innovative Technologies, **8(2)**, 59-62. https://doi.org/10.36287/ijmsit.8.2.2

Parveen, H. S., Karthik, S., & MS, K. (2024). Neural harmony: revolutionizing thyroid nodule diagnosis with hybrid networks and genetic algorithms. Computer Methods in Biomechanics and Biomedical Engineering, 1-18. https://doi.org/10.1080/10255842.2024.2341969

Pichardo G. 2021. Thyroid cancer: symptoms, causes, diagnosis, treatment, WebMD. Available at https://www.webmd.com/cancer/what-is-thyroid-cancer

Quinlan, R. (1986). Thyroid Disease [Dataset]. UCI Machine Learning Repository. https://doi.org/10.24432/C5D010

Riajuliislam, M., Rahim, K. Z., & Mahmud, A. (2021, February). Prediction of thyroid disease (hypothyroid) in early stage using feature selection and classification techniques. In 2021 International conference on information and communication technology for sustainable development (ICICT4SD) (pp. 60-64). IEEE. https://doi.org/10.1109/ICICT4SD50815.2021.9397052

Sandhu, G., Singh, A., Lamba, P. S., Virmani, D., & Chaudhary, G. (2023). Modified Euclidean-Canberra blend distance metric for kNN classifier. Intelligent Decision Technologies, **17(2)**, 527-541. https://doi.org/10.3233/idt-220223

Sarker, I. H. (2021). Deep cybersecurity: a comprehensive overview from neural network and deep learning perspective. SN Computer Science, **2(3)**, 154. https://doi.org/10.1007/s42979-021-00535-6

Sarker, I. H. (2021). Machine learning: Algorithms, real-world applications and research directions. SN computer science, 2(3), 160. https://doi.org/10.1007/s42979-021-00592-x

Sarkar P. (2023). Naive Bayes in Machine Learning [Examples, Models, Types], https://www.knowledgehut.com/blog/data-science/naive-bayes-in-machine-learning

Sultana, A., & Islam, R. (2023). Machine learning framework with feature selection approaches for thyroid disease classification and associated risk factors identification. Journal of Electrical Systems and Information Technology, **10(1)**, 32. https://doi.org/10.1186/s43067-023-00101-5

Taha, A., Saad, B., Taha-Mehlitz, S., Ochs, V., El-Awar, J., Mourad, M. M., Neuman, K., Glaser, C., Rosenberg, R., & Cattin, P. C. (2024). Analysis of artificial intelligence in thyroid diagnostics and surgery: a scoping review. The American Journal of Surgery, **229**, 57-64. https://doi.org/10.1016/j.amjsurg.2023.11.019

Taylor PN, Albrecht D, Scholz A, Gutierrez-Buey G, Lazarus JH, Dayan CM, Okosieme OE. 2018. Global epidemiology of hyperthyroidism and hypothyroidism. Nature Reviews Endocrinology **14(5):**301–316. https://doi.org/10.1038/nrendo.2018.18

Wani, J. A., Sharma, S., Muzamil, M., Ahmed, S., Sharma, S., & Singh, S. (2022). Machine learning and deep learning based computational techniques in automatic agricultural diseases detection: Methodologies, applications, and challenges. Archives of Computational methods in Engineering, 29(1), 641-677. https://doi.org/10.1007/s11831-021-09588-5