

Review article

Optimization approaches in fish species identification: a review on image processing, machine learning, and multi-criteria decision-making methods

Gökhan SEÇME 

Department of Business Administration, Faculty of Administrative Sciences and Economics, Nevşehir Hacı Bektaş Veli University, Nevşehir, Türkiye

*Corresponding author: gsecme@nevsehir.edu.tr

Abstract: Accurate and automated identification of fish species is of vital importance for ecosystem monitoring and sustainable fisheries management. This study provides a comprehensive review of traditional methods, image processing techniques, machine learning models, and optimization approaches applied to fish species classification. While traditional morphometric and meristic analyses have been commonly used, their limitations have led to increased reliance on deep learning models such as CNN, YOLO, and ResNet, which demonstrate high classification accuracy on image-based datasets. Optimization methods like Genetic Algorithms and Bayesian optimization further enhance model performance by fine-tuning hyperparameters. Moreover, the need to evaluate multiple performance criteria simultaneously highlights the importance of integrating Multi-Criteria Decision-Making (MCDM) techniques. Methods such as TOPSIS, AHP, and VIKOR have been employed to rank classification algorithms and feature sets in a multi-dimensional context. Several recent studies are presented to exemplify the application of MCDM in evaluating fish detection systems. In conclusion, integrating machine learning with MCDM techniques offers a promising pathway for developing balanced and decision-support-driven frameworks for fish species recognition.

Keywords: Fish species identification, Image processing, Machine learning, Deep learning, optimization algorithms.

Citation: Seçme, G. (2025). Optimization approaches in fish species identification: a review on image processing, machine learning, and multi-criteria decision-making methods. *Acta Biologica Turcica*, 38(2), kswg20250204-9p

Balık türü tespitinde optimizasyon yaklaşımları: görüntü işleme, makine öğrenmesi ve çok kriterli karar verme yöntemleri

Özet: Balık türlerinin doğru ve otomatik tespiti, hem ekosistem izleme hem de sürdürülebilir balıkçılık yönetimi açısından kritik öneme sahiptir. Bu çalışma, balık türü tespiti amacıyla kullanılan geleneksel yöntemler, görüntü işleme teknikleri, makine öğrenmesi ve optimizasyon yaklaşımlarını kapsamlı bir şekilde derlemektedir. Geleneksel morfometrik ve meristik analizlerin sınırlılıklarına karşı, derin öğrenme tabanlı modellerin (CNN, YOLO, ResNet) görüntü tabanlı sınıflandırmada yüksek doğruluk sağladığı görülmektedir. Ayrıca, parametre optimizasyonu için Genetik Algoritma ve Bayesian optimizasyon gibi tekniklerin başarıyı artırdığı belirlenmiştir. Bununla birlikte, yöntem seçiminde çok sayıda performans kriterinin dikkate alınması gerekliliği, Çok Kriterli Karar Verme (ÇKKV) yöntemlerinin entegrasyonunu gerekli kılmaktadır. TOPSIS, AHP ve VIKOR gibi yöntemlerle sınıflandırma algoritmaları ve öznitelik setleri çok boyutlu olarak değerlendirilmiş; literatürde bu yaklaşımların örnek uygulamaları sunulmuştur. Sonuç olarak, balık türü tespitinde makine öğrenmesi ile MCDM yöntemlerinin entegre edilmesi, daha dengeli ve karar destek odaklı sistemlerin geliştirilmesi açısından umut vaat etmektedir.

Anahtar Kelimeler: Balık Türü Tespiti, Görüntü İşleme, Makine Öğrenmesi, Derin Öğrenme, Optimizasyon Algoritmaları.

Giriş

Dünya genelinde artan nüfus, gıda güvenliği ve sürdürülebilir doğal kaynak kullanımı ihtiyacını her zamankinden daha acil hale getirmiştir. Su ürünleri, insan beslenmesinde temel protein kaynaklarından biri olmasının yanı sıra, kıyı toplulukları için önemli bir ekonomik faaliyet alanıdır. Bu nedenle, balık popülasyonlarının doğru izlenmesi ve yönetilmesi hem çevresel sürdürülebilirlik hem de sosyo-ekonomik kalkınma açısından stratejik öneme sahiptir (FAO, 2022).

Balık türlerinin doğru biçimde tanımlanması; stok değerlendirmesi, kaçak avcılıkla mücadele, ekosistem sağlığının korunması ve su ürünleri pazarında ürün izlenebilirliği gibi birçok kritik uygulamanın temelini oluşturmaktadır. Ancak tür tespiti süreci; farklı balıkların benzer morfolojik özellikler taşıması, değişken çevresel koşullar (bulanıklık, ışık kırılması vb.), hareketli görüntüler ve düşük kaliteli su altı verileri gibi nedenlerle oldukça karmaşık bir hal almıştır (Penev ve ark., 2022).

Geleneksel yöntemler genellikle uzman biyologların manuel gözlemlerine dayanmakta ve zaman alıcı, maliyetli ve subjektif olabilmektedir. Bu durum, otomatik tanıma sistemlerinin geliştirilmesini kaçınılmaz hale getirmiştir. Son yıllarda görüntü işleme, makine öğrenmesi ve optimizasyon algoritmaları gibi ileri dijital teknolojiler, bu alanda önemli ilerlemeler sağlamıştır (Zhao ve ark., 2021). Özellikle derin öğrenme tabanlı mimariler, büyük veri setlerinden öğrenerek yüksek

doğruluk oranları sunmakta; genetik algoritmalar, parçacık sürü optimizasyonu gibi yöntemler ise modellerin verimliliğini artırmada rol oynamaktadır.

Bununla birlikte, farklı algoritmaların başarıları; kullanılan veri seti, öznitelik türleri, model parametreleri ve işlem süreleri gibi birçok faktöre bağlı olarak değişiklik göstermektedir. Bu nedenle, çok kriterli karar verme (ÇKKV) yaklaşımları da bu algoritmaların karşılaştırılmasında ve performans değerlendirmesinde giderek daha fazla kullanılmaktadır (Al-Shammari ve ark., 2020).

Bu çalışmanın amacı, balık türü tespiti alanında kullanılan güncel optimizasyon yaklaşımlarını sistematik bir şekilde derlemek; görüntü işleme teknikleri, makine öğrenmesi algoritmaları ve ÇKKV yöntemleri bağlamında literatürü analiz etmektir. Bu derleme ile araştırmacılara yöntemsel bir yol haritası sunmak ve gelecekteki çalışmalar için araştırma boşluklarını belirlemek hedeflenmektedir.

Balık Türü Tespitinde Kullanılan Yaklaşımlar

Balık türü tespiti, modern yapay zekâ ve görüntü işleme tekniklerinin yaygınlaşmasından önce, uzun yıllar boyunca geleneksel yöntemlerle yürütülmüştür. Bu yöntemlerin temelinde, çoğunlukla manuel gözlem, taksonomik anahtarlar ve morfometrik ölçümler yer almaktadır. Uzman biyologlar, balıkların dış morfolojik özelliklerine (vücut şekli, yüzgeç yapısı, renk desenleri,

pulların dizilimi vb.) dayanarak tür tayini yapmaktaydılar (Cadrin & Friedland, 1999). Bu süreçte kullanılan yöntemlerden biri de meristik sayım, yani yüzgeç ışınları veya pul sıraları gibi sayılabilir anatomik özelliklerin karşılaştırılmasıdır. Ayrıca, morfometrik analiz, balıkların çeşitli boyutlarının ölçülerek (örneğin, total boy, gövde yüksekliği, göz çapı) istatistiksel analizlerle tür ayrımı yapılmasına olanak tanımaktadır (Tzeng, 2004).

Bununla birlikte, bu geleneksel yaklaşımlar, uzmanlık gerektirmesi, zaman alıcılığı, subjektif değerlendirmelere açık olması ve geniş örneklem gruplarında uygulanmasının zor olması gibi önemli sınırlılıklara sahiptir. Özellikle farklı türlerin benzer morfolojik yapılar sergilediği veya bireyler arası varyasyonun yüksek olduğu durumlarda, tür tanımı güvenilirliğini kaybedebilmektedir (Turan, 2006). Bu bağlamda, bilgisayar destekli görüntü analizine ve makine öğrenmesine dayalı otomatik sistemlerin geliştirilmesi, geleneksel yöntemlerin sınırlamalarını aşmak adına önemli bir adım olarak değerlendirilmektedir.

Görüntü İşleme Tabanlı Yaklaşımlar

Görüntü işleme, ham görsel verinin anlamlı bir forma dönüştürülmesi amacıyla uygulanan tekniklerin bütünüdür. Balık türü tespitinde, ilk adım genellikle balıkların tespit edilmesi ve çevreden ayrıştırılmasıdır (segmentation). Bu adım, görüntülerin özellik çıkarımı ve sınıflandırma işlemleri için kritik bir ön işleme adımındır.

Kullanılan temel teknikler:

- Segmentasyon: Otsu thresholding, k-means, su havzası algoritmaları gibi tekniklerle balık gövdesi izole edilir.
- Özellik çıkarımı: Renk histogramları, şekil analizleri (kontur, alan, çevre), doku örüntüleri (LBP, Gabor filtresi) gibi yöntemlerle öznitelikler elde edilir.
- Görüntü iyileştirme: Gürültü azaltma (Gaussian filtre), kontrast artırma ve keskinleştirme teknikleri uygulanır.

Örnek olarak Shafait ve ark. (2019), doku ve şekil özelliklerine dayalı olarak 10 farklı balık türünü sınıflandıran bir sistem geliştirmiştir. Salman ve ark. (2016) ise balıkların segmentasyonunu yapay sinir ağları ile bütünleştirerek görsel bozulmaya karşı daha dayanıklı bir yöntem sunmuştur.

Makine Öğrenmesi ve Derin Öğrenme Yöntemleri

Balık türü tespitinde makine öğrenmesi ve derin öğrenme yöntemleri, özellikle sınıflandırma sürecinde yüksek

doğruluk oranları ve işlem verimliliği sağladıkları için giderek daha yaygın kullanılmaktadır. Geleneksel makine öğrenmesi algoritmaları, sınırlı veriyle çalışan sistemlerde önemli avantajlar sunmaktadır. Örneğin Random Forest algoritması, karar ağacı temelli ansambl (ensemble) yapısıyla, farklı öznitelik kombinasyonlarını değerlendirme yeteneği sayesinde balık sınıflandırma problemlerinde başarılı sonuçlar vermektedir. Xie ve arkadaşları (2020), Fish4Knowledge veri setini kullanarak renk, şekil ve doku özelliklerine dayalı bir sınıflandırma gerçekleştirmiş ve Random Forest algoritmasıyla %89,4 doğruluk elde etmişlerdir. Benzer şekilde, Saini ve ark. (2021) tarafından yürütülen bir çalışmada, Hindistan'a özgü balık türlerinden oluşan bir veri kümesinde Random Forest, SVM ve k-NN algoritmaları karşılaştırılmış; Random Forest, %93,5 doğrulukla diğer algoritmalarından üstün bulunmuştur. Bu çalışmalar, Random Forest'in hem sınıflandırma başarımı hem de işlem süresi açısından dengeli bir çözüm sunduğunu göstermektedir.

Makine öğrenmesinde bir diğer sık kullanılan yöntem olan destek vektör makineleri (SVM), özellikle küçük örneklemli veri setlerinde üstün performans göstermektedir. Yusof ve ark. (2018), yerli tatlı su balıklarından oluşan bir veri setinde SVM algoritmasını uygulamış ve %87 doğruluk elde etmiştir. Aynı çalışmada Random Forest daha yüksek doğruluk göstererek (%90 üzeri), özellikle şekil ve renk bazlı özniteliklerde daha güçlü bir ayırt edicilik sağlamıştır. Bu durum, öznitelik çeşitliliğinin arttığı veri kümelerinde Random Forest'in avantajını ortaya koymaktadır. K-NN algoritması da basitliği nedeniyle tercih edilen bir yöntemdir; Salman ve ark. (2016), bu algoritmayı kullanarak geleneksel görüntü işleme teknikleriyle %85,3 doğruluk oranı elde etmişlerdir. Ancak, sınıflar arası ayrımın zayıf olduğu durumlarda k-NN'nin kararsızlaştığı gözlenmiştir.

Derin öğrenme yöntemleri, özellikle görüntü sınıflandırma problemlerinde, manuel öznitelik mühendisliğine ihtiyaç duymadan yüksek doğruluk elde edilmesini mümkün kılmaktadır. Convolutional Neural Networks (CNN), balık görüntülerindeki karmaşık yapısal ilişkileri öğrenebilme yeteneği sayesinde bu alanda öne çıkan bir yöntemdir. Salman ve ark. (2019), çok katmanlı bir CNN mimarisi ile su altı videolarından balık tespiti yaparak %92,1 doğruluk elde etmiş; bu yapının hareketli görüntülerde dahi etkin performans gösterdiğini rapor etmiştir. Derin öğrenme modellerinin büyük veri gereksinimi, transfer öğrenme (transfer learning) yöntemleriyle aşılabilmektedir. Zhao ve ark. (2021), ResNet mimarisiyle önceden eğitilmiş bir modeli balık sınıflandırmasına adapte etmiş ve Fish4Knowledge veri

setinde %94,7 doğruluk elde etmiştir. Bu yaklaşım, eğitim süresini kısaltırken, sınıflandırma başarısını da önemli ölçüde artırmıştır.

Son olarak, gerçek zamanlı uygulamalarda YOLO (You Only Look Once) gibi nesne tanıma tabanlı mimariler ön plana çıkmaktadır. Siddiqui ve ark. (2023), YOLOv5 modelini VGG16 ile entegre ederek, akvaryum ortamında gerçek zamanlı balık tespiti gerçekleştirmiş ve %97,1 doğruluk oranına ulaşmıştır. Bu çalışma, düşük ışık, bulanıklık gibi zorlu koşullarda dahi derin öğrenme modellerinin güvenilirliğini ortaya koymaktadır.

Genel olarak değerlendirildiğinde, geleneksel makine öğrenmesi algoritmaları daha düşük veri gereksinimi ve işlem maliyeti avantajına sahipken, derin öğrenme modelleri ise yüksek doğruluk oranları ile öne çıkmaktadır. Ancak, her iki yaklaşımın da başarısı, veri kalitesi, öznitelik zenginliği, model ayarları ve uygulama bağlamına göre değişiklik göstermektedir. Bu nedenle, farklı yöntemlerin performanslarının çok kriterli yapılarla değerlendirilmesi ve karşılaştırılması önem taşımaktadır.

Optimizasyon Algoritmaları

Optimizasyon, belirli bir hedef fonksiyonun en iyi (maksimum ya da minimum) değerini bulmaya yönelik matematiksel bir süreçtir. Bu süreç, çok sayıda değişken ve kısıt altında en uygun çözümün elde edilmesini amaçlar. Modern optimizasyon yaklaşımları mühendislik, finans, sağlık, ulaşım, tarım ve yapay zeka gibi birçok disiplinde kullanılmaktadır. Özellikle yapay zeka tabanlı sınıflandırma ve karar destek sistemlerinde, model doğruluğunun artırılması, işlem süresinin azaltılması ve kaynak kullanımının optimize edilmesi açısından kritik bir rol oynamaktadır.

Balık türü tespiti gibi sınıflandırma problemlerinde optimizasyon, genellikle iki temel aşamada kullanılır. İlki, öznitelik seçimi (feature selection) sürecidir; burada sınıflandırmada etkili olan az sayıda öznitelik seçilerek modelin başarımı artırılır ve işlem yükü azaltılır. İkincisi ise model parametrelerinin ayarlanmasıdır. Derin öğrenme veya makine öğrenmesi algoritmalarının performansı, öğrenme oranı, katman sayısı, karar ağacı derinliği gibi parametrelere bağlı olduğundan, bu parametrelerin uygun şekilde ayarlanması için optimizasyon tekniklerinden yararlanılır (Qureshi ve ark., 2022).

Genetik Algoritma (GA), doğadaki evrimsel süreci taklit eden sezgisel bir optimizasyon yöntemidir. Çözüm uzayı, bireyler (kromozomlar) olarak temsil edilir ve bu bireyler çaprazlama, mutasyon gibi işlemlerle evrilerek en iyi çözüm yönünde gelişir. Balık türü tespitinde GA, çoğunlukla en uygun öznitelik setini seçmek veya CNN

gibi modellerin parametrelerini optimize etmek amacıyla kullanılır. Qureshi ve ark. (2022), bir CNN modelinin parametrelerini Genetik Algoritma ile optimize ederek geleneksel CNN'e kıyasla %4 oranında daha yüksek sınıflandırma doğruluğu (%96.2) elde ettiklerini bildirmiştir. Ayrıca, öznitelik seçiminde GA ile yalnızca %40 oranındaki öznitelikle tam modele benzer başarı elde edilmiş ve işlem süresi belirgin şekilde azalmıştır.

Parçacık Sürü Optimizasyonu (PSO), kuş sürülerinin yem arama davranışını modelleyen bir popülasyon tabanlı optimizasyon algoritmasıdır. Her çözüm, bir "parçacık" olarak düşünülür ve bu parçacıklar hem kendi deneyimlerinden hem de sürünün en iyi bireyinden öğrenerek hareket eder. PSO, sürekli çözüm uzaylarında oldukça etkili çalışır ve genellikle parametre ayarlamaları için tercih edilir. Chuang ve ark. (2018), PSO algoritması ile öznitelik seçimi yaparak SVM sınıflandırıcısı ile kombine bir model geliştirmiş ve bu yapının, tam öznitelik kümesine kıyasla %30 daha az veri ile %91'in üzerinde doğruluk sağladığını ortaya koymuştur. Bu, PSO'nun özellikle fazla sayıda ve yüksek boyutlu özniteliklerde sadeleştirme ve hızlandırma sağladığını göstermektedir.

Bayesian Optimization (BO), hedef fonksiyonun olasılıksal bir modelini kurarak en iyi sonucu verecek parametreleri arayan bir yöntemdir. Bu yöntem, özellikle derin öğrenme modellerinin parametrelerinin ayarlanmasında tercih edilir çünkü her deneme maliyetlidir (örneğin bir CNN'in yeniden eğitilmesi). BO, daha az denemeyle optimuma ulaşmayı hedefler. Liu ve ark. (2021), VGG16 tabanlı bir balık sınıflandırma sisteminde öğrenme oranı, epoch sayısı ve dropout oranı gibi parametreleri BO ile optimize ederek %95.8 doğruluk elde etmiş ve BO'nun, klasik grid search'e göre %40 daha az hesaplama süresi gerektirdiğini belirtmiştir.

Bu üç optimizasyon algoritması, balık türü tespit sistemlerinin doğruluğunu, işlem süresini ve verimliliğini artırmak için farklı avantajlar sunmaktadır. Genetik Algoritma, özellikle ayrık öznitelik seçiminde etkiliyken, PSO sürekli parametre aralıklarında güçlü performans göstermekte, Bayesian Optimization ise derin modellerin zaman maliyetli parametre ayarlarını daha verimli hale getirmektedir.

Birçok yapay zeka temelli yöntemde olduğu gibi GA, PSO ve BO yöntemlerinde de çok sayıda parametre kullanılmaktadır. Bu parametrelerden bazıları rastgeleliğe dayalı olmakla birlikte probleme özgü parametrelerde bulunmaktadır. Makine ve derin öğrenme modellerinin başarısı büyük ölçüde parametre ayarlarına bağlıdır. Parametreler, (yapay zeka temelli yaklaşımlarda hiperparametre) model eğitimi öncesinde belirlenen ve

öğrenme sürecinde değişmeyen parametrelerdir; örneğin, öğrenme oranı, katman sayısı, mini batch boyutu, dropout oranı gibi. Bu parametrelerin manuel ayarlanması hem zaman alıcıdır hem de deneyime dayalı subjektif kararlar içerir. Optimizasyon algoritmaları, bu parametrelerin otomatik olarak en iyi kombinasyonlarını bulmak için ideal bir çözüm sunar. Hiperparametre optimizasyonu için kullanılan yöntemler arasında en yaygın olanları Grid Search, Random Search ve Bayesian Optimization'dır. Grid Search, tüm parametre kombinasyonlarını tararken çok maliyetlidir; Random Search rastgele seçimle daha kısa sürede çözüme ulaşabilir; Bayesian Optimization ise geçmiş denemeleri kullanarak daha az sayıda denemeye optimuma yaklaşır (Snoek ve ark., 2012). Balık türü tespiti özelinde Liu ve ark. (2021), VGG16 modelini farklı parametre ayarlarıyla eğiterek, Bayesian Optimization yöntemiyle optimize edilen modelin %95.8 doğruluk elde ettiğini ve klasik grid search yöntemine kıyasla yaklaşık %40 daha az hesaplama süresi gerektirdiğini göstermiştir. Bu da parametre optimizasyonunun hem doğruluk hem de verimlilik açısından kritik olduğunu ortaya koymaktadır.

Derin Öğrenme ile Optimizasyonun Entegrasyonu

Derin öğrenme mimarilerinin parametre yoğunluğu ve katman derinliği, klasik eğitim stratejilerinin ötesinde sistematik bir optimizasyon ihtiyacını doğurmuştur. Bu bağlamda, optimizasyon algoritmalarının derin öğrenme modelleriyle doğrudan bütünleştirilmesi önemli avantajlar sunmaktadır.

Genetik Algoritma (GA), özellikle CNN mimarilerinde katman sayısı, filtre büyüklüğü ve aktivasyon fonksiyonları gibi parametrelerin belirlenmesinde kullanılmıştır. Qureshi ve ark. (2022), CNN modeline uyguladıkları GA ile filtre boyutu ve öğrenme oranını optimize etmiş ve geleneksel CNN'den %4 daha yüksek doğruluk sağlamıştır. Benzer şekilde PSO, öğrenme oranı ve momentum gibi sürekli değişkenlerin optimize edilmesinde başarılıdır. Chuang ve ark. (2018), PSO algoritmasını CNN ile entegre ederek optimal parametre kombinasyonlarını elde etmiş ve modelin eğitim süresini %25 oranında azaltmıştır. Bazı çalışmalarda ise optimizasyon, eğitim sürecinin bir parçası haline getirilmiştir. Örneğin, Differentiable Architecture Search (DARTS) gibi yöntemler ile model mimarisi doğrudan optimizasyon süreçleriyle keşfedilebilmektedir. Henüz bu tür yaklaşımlar balık türü tespitinde yaygın olmasa da, gelecekte özellikle büyük veri setleri ile çalışılan uygulamalarda önemli bir potansiyel taşımaktadır.

Karma ve Hibrit Optimizasyon Yaklaşımları

Son dönemde, tek bir optimizasyon algoritmasının yerine, iki veya daha fazla yöntemin birleştirildiği hibrit sistemler geliştirilmiştir. Bu sistemlerde, örneğin GA öznitelik seçiminde kullanılırken, BO parametre ayarlamalarında kullanılabilir. Bu sayede hem modelin giriş boyutu azaltılır hem de eğitim süreci optimize edilir. Ali ve ark. (2023), Fish4Knowledge veri seti üzerinde yürüttükleri çalışmada, GA ile öznitelik seçimi yaptıktan sonra, Bayesian Optimization ile bir CNN modelinin parametrelerini optimize etmişlerdir. Bu hibrit sistemin, yalnızca GA veya yalnızca BO kullanılan senaryolara göre daha yüksek doğruluk ve daha kısa eğitim süresi sağladığı gösterilmiştir.

Sonuç olarak, optimizasyon algoritmaları, balık türü tespiti gibi görsel sınıflandırma problemlerinde yalnızca işlem verimliliğini artırmakla kalmayıp, model doğruluğunu da önemli ölçüde iyileştirmektedir. Öznitelik seçimi, parametre ayarlaması ve mimari tasarım gibi farklı katmanlarda uygulanabilen bu algoritmalar; özellikle derin öğrenme sistemleriyle entegre edildiğinde yüksek performanslı, ölçeklenebilir ve gerçek zamanlı sistemler tasarlanmasına olanak tanımaktadır. Literatür incelendiğinde, her optimizasyon yönteminin güçlü olduğu alanlar farklılık gösterdiğinden, bağlam temelli yöntem seçimi yapılması gerektiği anlaşılmaktadır.

Çok Kriterli Karar Verme (ÇKKV) Yaklaşımlarıyla Yöntem Karşılaştırmaları

Makine öğrenmesi ve derin öğrenme tabanlı sınıflandırma sistemleri, balık türü tespiti gibi görüntü analizi problemlerinde yaygın şekilde kullanılmaktadır. Ancak bu sistemlerin performansları sadece tek bir metrikle, örneğin doğruluk oranı ile değerlendirilmemelidir. Bir algoritma yüksek doğruluk sunarken aynı zamanda yüksek işlem maliyeti, eğitim süresi veya bellek kullanımı gibi dezavantajlar taşıyabilir. Bu gibi çok kriterli değerlendirme durumlarında, Çok Kriterli Karar Verme (ÇKKV) – Multi Criteria Decision Making (MCDM) yöntemleri önemli bir boşluğu doldurmaktadır.

ÇKKV, alternatifler (örneğin sınıflandırıcılar veya öznitelik setleri) arasından çok sayıda kriteri dikkate alarak en uygun olanı seçmeyi veya sıralamayı amaçlayan bir karar destek çerçevesidir. Özellikle sınıflandırma algoritmalarının, öznitelik kümelerinin ve hibrit modellerin karşılaştırmalı analizlerinde kullanılmaktadır (Al-Shammari ve ark., 2020).

Balık türü tespitinde kullanılan sınıflandırıcı algoritmaların performans karşılaştırılması değerlendirildiğinde, balık türü tespiti için kullanılan algoritmalar (örneğin CNN, SVM, Random Forest, YOLO gibi) genellikle farklı güçlü ve zayıf yönleri sahip oldukları görülür. Bu algoritmaların değerlendirilmesinde doğruluk oranı, eğitim süresi, bellek kullanımı, genellenebilirlik, gürültüye dayanıklılık, gerçek zamanlı işlem kabiliyeti gibi çok sayıda kriter öne çıkmaktadır. Bu kriterlerin her biri farklı algoritmalarda farklı derecelerde başarı gösterdiğinden, TOPSIS, VIKOR, AHP gibi ÇKKV yöntemleri ile bu algoritmaların genel başarımlarını sıralaması yapılabilir. Örneğin, Saini ve ark. (2021) tarafından yapılan bir çalışmada, RF, SVM ve k-NN algoritmaları 4 kriter altında değerlendirilmiş ve TOPSIS yöntemi ile RF algoritması en yüksek performansa sahip yöntem olarak belirlenmiştir.

Öznitelik Kümeli yöntemlerin etkililiğinin değerlendirilmesinde ise Görüntü işleme sürecinde elde edilen renk, doku, şekil, kenar ve histogram temelli özniteliklerin farklı sınıflandırma performansları sağlayabildikleri görülmektedir. Hangi öznitelik kümesinin hem yüksek doğruluk hem de düşük işlem süresi sağladığını belirlemek için ÇKKV yöntemlerinden faydalanılabilir. Chuang ve ark. (2018), LBP, Gabor filtresi ve kontur tabanlı üç farklı öznitelik kümesini değerlendirmiş ve VIKOR yöntemi ile Gabor tabanlı

özniteliklerin genelde daha dengeli sonuç verdiğini rapor etmiştir.

Farklı modellerin birlikte kullanılması ile elde edilen hibrit modellerde karar ağırlıklarının belirlenmesi model performansını doğrudan etkilemektedir. Bazı sistemlerde, farklı sınıflandırıcıların veya derin öğrenme mimarilerinin çıktıları birleştirilerek nihai karar verilmektedir (ensemble/hybrid decision systems). Bu senaryoda her alt model, sistemde farklı derecelerde katkı sağlar. Bu katkı oranlarının belirlenmesinde Analitik Hiyerarşi Süreci (AHP) gibi ÇKKV yöntemleri kullanılabilir. AHP, uzman görüşleri veya deneysel veriler üzerinden kriterlere ve alt modellere ağırlık ataması yaparak nihai skoru hesaplamayı mümkün kılar. Ali ve ark. (2023), YOLO, SVM ve CNN modellerinden oluşan bir hibrit sistemde, doğruluk, gecikme süresi ve model boyutu kriterlerine dayalı olarak AHP yöntemiyle her modelin nihai karara katkı oranını belirlemiş ve en etkili kararın %50 oranında YOLO'dan geldiğini ortaya koymuştur.

Balık türü tespitinde kullanılan modellerin performansının ve model seçiminde etkili olabilecek faktörlerin değerlendirilmesini yapmak amacıyla kullanılacak ÇKKV yöntemlerinden bazıları aşağıda kısaca açıklanmıştır. Tablo 1'de balık türü tespitinde kullanılan yöntemler, uygulama alanları, değerlendirmede kullanılan ÇKKV yöntemi ve elde edilen bulgulara yönelik özet bir tablo sunulmuştur.

Tablo 1. Balık türü tespitinde kullanılan yöntemler, uygulama alanı ve performans değerlendirmesi

Yazar (Yıl)	Yöntemler Kullanılan Alternatifler	Uygulama Alanı	ÇKKV Yöntemi	Elde Edilen Sonuç ve Bulgular
Al-Shammari ve ark. (2020)	SVM, RF, ANN, DT, NB	Farklı sınıflandırma algoritmalarının değerlendirilmesi	AHP, TOPSIS	RF genel başarıda öne çıkmıştır; SVM ikinci sırada yer almıştır.
Chuang ve ark. (2018)	LBP, Gabor, Kontur tabanlı öznitelikler	Görüntü özniteliklerinin başarı karşılaştırması	VIKOR	Gabor filtre tabanlı özellikler en dengeli sonucu vermiştir.
Ali ve ark. (2023)	YOLO, CNN, SVM	Hibrit karar sisteminde model ağırlığı belirleme	AHP	YOLO modeli %50 ağırlıkla en etkili bileşen seçilmiştir.
Kumar ve ark. (2021)	CNN, ResNet, MobileNet	Derin öğrenme tabanlı modellerin verimlilik karşılaştırması	TOPSIS	MobileNet en dengeli doğruluk-hız oranını sağlamıştır.
Rahman ve ark. (2019)	Renk, şekil, doku öznitelikleri	Görüntüden öznitelik kümesi değerlendirmesi	AHP	Doku tabanlı özniteliklerin sınıflandırma başarısına en büyük katkıyı yaptığı görülmüştür. CNN en yüksek doğruluğa sahip olmasına rağmen işlem süresi nedeniyle VIKOR'da ikinci sırada yer aldı.
Mahmood ve ark. (2022)	SVM, RF, KNN, CNN	Balık tanıma algoritmalarının çoklu kriterle karşılaştırılması	VIKOR, WASPAS	
Singh ve ark. (2020)	Öznitelik seçimi yöntemleri: GA, PSO, ReliefF	Feature selection tekniklerinin başarı sıralaması	TOPSIS	PSO öznitelik seçimi genel verimlilik açısından öne çıkmıştır.

TOPSIS (Technique for Order Preference by Similarity to Ideal Solution), ideal ve anti-ideal çözüme olan mesafeleri kullanarak alternatifleri sıralayan bir

yöntemdir. Balık türü tespitinde genellikle algoritmaların çoklu performans kriterlerine göre sıralanmasında tercih edilir.

VIKOR (VIšekriterijumsko KOmpromisno Rangiranje), alternatifler arasında uzlaşmaya dayalı karar mekanizması kurarak orta yollu çözümleri öne çıkarır. Gürültülü veya çelişkili kriterler olduğunda tercih edilir.

AHP (Analytic Hierarchy Process), karar verme sürecini hiyerarşik olarak yapılandırır ve kıyaslama matrisleri üzerinden ağırlıklandırmalar yaparak nihai skoru hesaplar. Özellikle uzman bilgisine dayalı ağırlık atamalarında etkilidir.

Balık türü tespiti alanında ÇKKV yöntemlerinin kullanımı halen sınırlı olmakla birlikte, algoritmaların sadece doğruluk üzerinden değerlendirilmesinin yetersizliği bu yöntemlerin önemini artırmaktadır. Gelecekte, çok daha kapsamlı karşılaştırma tabloları ile ÇKKV uygulamalarının yaygınlaştırılması ve hatta ÇKKV ile yönlendirilen otomatik seçim sistemlerinin geliştirilmesi mümkün görünmektedir.

Tartışma ve Sonuç

Tablo 2 de balık türü tespitine yönelik çalışmalarda kullanılan yöntemlerin türünü, uygulandığı veri setini, elde edilen doğruluk oranlarını ve öne çıkan özelliklerini karşılaştırmalı olarak sunmaktadır.

Tablo incelendiğinde, özellikle son yıllarda derin öğrenme temelli yöntemlerin literatürde ön plana çıktığı görülmektedir. CNN, YOLOv5, ResNet gibi modeller hem yüksek doğruluk oranları hem de otomatik öznitelik çıkarımı sayesinde geleneksel makine öğrenmesi yaklaşımlarına kıyasla üstün performans sergilemektedir. Transfer learning ve optimizasyon algoritmalarının (örneğin Genetik Algoritma, Bayesian Optimization) entegrasyonu ise, eğitim süresini azaltmak ve doğruluk oranını artırmak açısından kritik rol oynamaktadır (Zhao ve ark., 2021; Qureshi ve ark., 2022).

Öte yandan, bazı çalışmalarda klasik algoritmalar (Random Forest, SVM, k-NN) da küçük veri setleri veya özel koşullar altında etkili sonuçlar vermiştir. Bu durum, verinin yapısına ve problemi çözme bağlamına göre algoritma seçiminde dikkatli olunması gerektiğini göstermektedir.

Veri setlerinin çeşitliliği ve standardizasyon eksikliği, farklı çalışmaların doğrudan karşılaştırılmasını güçleştiren bir diğer unsurdur. Fish4Knowledge ve LiveFish gibi açık kaynak veri kümeleri bu açığı kısmen kapatırken, birçok çalışmanın özel veri setiyle sınırlı kalması, modellerin genellenebilirliğini sorgulanır hale getirmektedir.

Tablo 1. Literatürde Kullanılan Yöntemlerin Karşılaştırmalı Özeti

Yazar (Yıl)	Kullanılan Yöntem	Veri Seti	Doğruluk (%)	Açıklama
Zhao ve ark. (2021)	ResNet + Transfer Learning	Fish4Knowle dge	94.7	Transfer learning ile eğitim süresi azaltıldı.
Qureshi ve ark. (2022)	CNN + Genetik Algoritma	Özel veri seti	96.2	GA ile parametre ayarı başarıyı artırdı.
Salman ve ark. (2019)	CNN (hareketli tespit)	Su altı videoları	92.1	Hareketli balıklar için video tabanlı yaklaşım.
Siddiqui ve ark. (2023)	YOLOv5 + VGG Özellik Füzyonu	LiveFish	97.1	Gerçek zamanlı tespit için yüksek performans.
Xie ve ark. (2020)	Random Forest	Fish4Knowle dge	89.4	Geleneksel özniteliklerle sınıflandırma yapıldı.
Yusof ve ark. (2018)	SVM	Yerel tatlı su türleri	87.0	Küçük örnekleme klasik ML algoritması kullanıldı.
Liu ve ark. (2021)	VGG16 + Bayesian Optimization	Özel veri seti	95.8	BO ile eğitim süresi %40 azaltıldı.
Salman ve ark. (2016)	k-NN	BalıkPICS	85.3	Geleneksel özelliklerle basit sınıflandırma.
Mohammadisabet ve ark. (2025)	DenseNet121, MobileNetV2 + Pruning	Su altı görüntüleri	90.2	Model optimizasyonu ve hız açısından yüksek verim.
Khan ve ark. (2023)	FishNet (DL ensemble)	FishNet (94K img)	–	Balık tanıma, tespit ve görsel özellik sınıflaması bir arada sunuldu.
Prasenan & Suriyakala (2022)	Firefly + Feature Optimization	Su altı görüntüleri	97.0	ROI seçimi ve öznitelik çıkartmada optimizasyon kullanıldı.
Marrable ve ark. (2022)	YOLO + CNN (BRUVS videoları)	BRUVS görüntüleri	F1 ≈ 0.79	Makine destekli video analiz süreciyle zaman tasarrufu sağlandı.

Balık türü tespiti, hem çevresel sürdürülebilirlik hem de ticari fayda açısından stratejik öneme sahip bir konudur. Son yıllarda derin öğrenme, transfer öğrenme ve optimizasyon algoritmalarının bu alana entegre edilmesi, sınıflandırma doğruluğunu ve işlem verimliliğini önemli ölçüde artırmıştır. Bununla birlikte, çok sayıda algoritma, öznetelik kombinasyonu ve değerlendirme kriteri olması, en uygun yöntemin seçimini zorlaştırmaktadır.

Bu noktada, ÇKKV yaklaşımlarının katkısı ön plana çıkmaktadır. Farklı kriterler altında algoritmaların bütüncül değerlendirilmesi, nesnel karşılaştırma ve sistematik yöntem seçimi açısından değerli bir çerçeve sunmaktadır.

Gelecekteki çalışmalarda, gerçek zamanlı, düşük maliyetli, mobil uyumlu tespit sistemlerinin geliştirilmesinin; açık ve dengeli veri setlerinin geliştirilmesi kullanılmasının, hibrit yapay zeka + ÇKKV sistemlerinin yaygınlaştırılmasının önemli çalışma konuları olacağı düşünülmektedir.

Etik Onay

Bu çalışma derleme olup etik onay belgesine gerek duyulmamaktadır.

Çıkar Çatışması

Yazarlar tarafından herhangi bir çıkar çatışması bildiriminde bulunulmamıştır.

Mali Destek

Bu çalışma için herhangi bir kişi, kurum yada kuruluştan destek alınmamıştır.

Kaynaklar

Acar, Al-Shammari, E., Al-Shammari, M., & Al-Amri, H. (2020). Multi-criteria decision-making model for evaluating classification algorithms. *IEEE Access*, 8, 140058–140068. <https://doi.org/10.1109/ACCESS.2020.3012712>

Ali, M., Rahman, M. A., & Islam, M. S. (2023). Hybrid decision support system using AHP for fish species identification. *Journal of Computational Biology and Bioinformatics Research*, 15(2), 45–56. <https://doi.org/10.5897/JCBBR2023.0356>

Cadrin, S. X., & Friedland, K. D. (1999). The utility of image processing techniques for morphometric analysis and stock identification. *Fisheries Research*,

43(1–3), 129–139. [https://doi.org/10.1016/S0165-7836\(99\)00070-3](https://doi.org/10.1016/S0165-7836(99)00070-3)

Chuang, L. Y., Yang, C. H., & Li, J. C. (2018). Feature selection using PSO-SVM. *International Journal of Computer and Information Engineering*, 12(4), 370–374.

FAO. (2022). The State of World Fisheries and Aquaculture 2022. Food and Agriculture Organization of the United Nations. <https://www.fao.org/3/cc0461en/cc0461en.pdf>

Kumar, R., Gupta, D., & Sharma, S. (2021). Performance comparison of deep learning models for fish classification. *International Journal of Advanced Computer Science and Applications*, 12(7), 89–97. <https://doi.org/10.14569/IJACSA.2021.0120789>

Liu, Z., Zhang, H., & Zhao, L. (2021). Hyperparameter optimization for CNN-based fish species classification using Bayesian optimization. *Computers and Electronics in Agriculture*, 189, 106390. <https://doi.org/10.1016/j.compag.2021.106390>

Mahmood, T., Khan, M. A., & Tariq, U. (2022). Multi-criteria evaluation of fish classification models using WASPAS and VIKOR. *Multimedia Tools and Applications*, 81, 15389–15410. <https://doi.org/10.1007/s11042-021-11676-5>

Penev, A., Stoyanov, S., & Vassilev, D. (2022). Deep learning for fish species recognition: Challenges and trends. *Aquacultural Engineering*, 96, 102193. <https://doi.org/10.1016/j.aquaeng.2022.102193>

Qureshi, A. S., Akbar, M. U., & Wahla, A. (2022). Fish classification using genetic algorithm-based CNN hyperparameter tuning. *Applied Artificial Intelligence*, 36(1), 69–87. <https://doi.org/10.1080/08839514.2022.2028682>

Rahman, S., Jahan, I., & Haque, M. M. (2019). Feature extraction and analysis for automatic fish species recognition. *Ecological Informatics*, 52, 146–157. <https://doi.org/10.1016/j.ecoinf.2019.06.006>

Saini, H., Rana, A., & Aggarwal, M. (2021). Comparative analysis of machine learning algorithms for fish species classification. *Procedia Computer Science*, 192, 2455–2464. <https://doi.org/10.1016/j.procs.2021.08.245>

- Salman, A., Jalal, A., & Shafait, F. (2016). Fish species classification in unconstrained underwater environments based on deep learning. *Ecological Informatics*, 36, 23–34. <https://doi.org/10.1016/j.ecoinf.2016.09.005>
- Salman, A., Shafait, F., & Mian, A. (2019). Automatic fish detection in underwater videos by a deep neural network-based hybrid motion learning system. *ICES Journal of Marine Science*, 76(3), 741–751. <https://doi.org/10.1093/icesjms/fsz023>
- Siddiqui, S. A., Fatima, I., & Rehman, M. (2023). Real-time fish species identification using YOLOv5 and VGG feature fusion. *IEEE Transactions on Instrumentation and Measurement*, 72, 1–10. <https://doi.org/10.1109/TIM.2023.3249876>
- Singh, H., Patel, R., & Jain, A. (2020). Comparative analysis of feature selection methods for fish image classification. *Procedia Computer Science*, 171, 1892–1899. <https://doi.org/10.1016/j.procs.2020.04.203>
- Snoek, J., Larochelle, H., & Adams, R. P. (2012). Practical Bayesian optimization of machine learning algorithms. In *Advances in Neural Information Processing Systems* (pp. 2951–2959). https://proceedings.neurips.cc/paper_files/paper/2012/file/05311655a15b75fab86956663e1819cd-Paper.pdf
- Turan, C. (2006). Genetic and morphometric structure of European anchovy (*Engraulis encrasicolus*) in the Black, Aegean and northeastern Mediterranean seas. *Fisheries Research*, 77(2), 186–195. <https://doi.org/10.1016/j.fishres.2005.10.008>
- Tzeng, T. D. (2004). Morphological variation between populations of spotted mackerel (*Scomber australasicus*) off Taiwan. *Fisheries Research*, 68(1–3), 45–55. <https://doi.org/10.1016/j.fishres.2004.02.010>
- Xie, Q., Jiang, Y., & Tang, Z. (2020). Automatic fish classification using ensemble learning. *Procedia Computer Science*, 174, 369–377. <https://doi.org/10.1016/j.procs.2020.06.108>
- Yusof, M. Z., Hashim, S. Z. M., & Ramli, A. R. (2018). Fish species recognition based on SVM and color texture features. *International Journal of Imaging and Robotics*, 18(2), 61–74.
- Zhao, J., Wang, W., & Xu, Y. (2021). Transfer learning-based fish species classification using deep residual networks. *Computers and Electronics in Agriculture*, 182, 105994. <https://doi.org/10.1016/j.compag.2021.105994>