

## Research article

**Determination of fish condition factor using artificial neural networks and machine learning algorithms****Tamer AKKAN<sup>1,\*</sup>, Cengiz MUTLU<sup>2</sup>, Hakan IŞIK<sup>3</sup>, Okan YAZICIOĞLU<sup>4</sup>****Ramazan YAZICI<sup>5</sup>, Mahmut YILMAZ<sup>6</sup>, Nazmi POLAT<sup>7</sup>**<sup>1</sup>Biyoloji Bölümü, Fen Edebiyat Fakültesi, Giresun Üniversitesi, Giresun, Türkiye<sup>2</sup>Çevre Mühendisliği Bölümü, Mühendislik Fakültesi, Giresun Üniversitesi, Giresun, Türkiye<sup>3</sup>Biyoloji Anabilim Dalı, Fen Bilimleri Enstitüsü, Giresun Üniversitesi, Giresun, Türkiye<sup>4</sup>Bitkisel ve Hayvansal Üretim Bölümü, Teknik Bilimler Meslek Yüksekokulu, Kırşehir Ahi Evran Üniversitesi, Kırşehir, Türkiye<sup>5</sup>Veterinerlik Bölümü, Çiçekdağı Meslek Yüksekokulu, Kırşehir Ahi Evran Üniversitesi, Kırşehir, Türkiye<sup>6</sup>Tarımsal Biyoteknoloji Bölümü, Ziraat Fakültesi, Kırşehir Ahi Evran Üniversitesi, Kırşehir, Türkiye<sup>7</sup>Biyoloji Bölümü, Fen Fakültesi, Ondokuz Mayıs Üniversitesi, Kurupelit, Samsun, Türkiye\*Corresponding author e-mail: [biyoloji@yahoo.com](mailto:biyoloji@yahoo.com)

**Abstract:** Determination of the condition factor in fish is an indispensable element in protecting fish health and improving the status of the population. In this study, the condition factor (CF) of fish was predicted using three input parameters including length, weight and sex. In this paper, the results obtained with six machine learning algorithms; Support vector machine (SVM), Neural Network/Multilayer Perceptron (MLP), Ensemble Learning, Gaussian Process Regression (GPR), Decision Tree and Linear Regression were compared with a multilayer perceptron artificial neural network (MLP-ANN), which is one of the statistical tools to predict the condition factor value obtained in this paper. As a result of the benchmarking, the Levenberg-Marquardt learning algorithm with 3-9-1 architecture neurons was found to be the best network for the hidden layer. The output of this model was the most effective for condition factor modeling with  $R^2$  values ( $R^2$ = training (1), testing (0.99), validation (1) and overall (0.99)). This value is indicative of the high quality of this model compared to other existing models. Up to now, multilayer perceptron artificial neural network (MLP-ANN) has achieved significant success in predicting the condition factor.

**Keywords:** MLP-ANN, height-weight-sex relationships, machine learning, prediction model, condition factor

**Citation:** Akkan, T., Multu, C., Işık, H., Yazıcıoğlu, O., Yazıcı, R., Yılmaz, M., & Polat, N. (2024). Determination of fish condition factor using artificial neural networks and machine learning algorithms. *Acta Biologica Turcica*, 37(1), J8:1-11.

## Yapay sinir ağı ve makine öğrenmesi algoritmaları kullanılarak balık kondisyon faktörünün belirlenmesi

**Özet:** Balıklarda kondisyon faktörünün belirlenmesi balık sağlığının korunmasında ve popülasyonun durumunun iyileştirilmesi konusunda vazgeçilmez bir ögedir. Çalışmada balıklarda boy, ağırlık ve cinsiyet gibi üç giriş parametresi bilgisi ile kondisyon faktörü (KF) tahmini yapılmıştır. Bu çalışmada elde edilen kondisyon faktörü değerini tahmin etmek amacıyla istatistiksel araçlardan biri olan çok katmanlı algılayıcı yapay sinir ağı (MLP-YSA) ile altı makine öğrenimi algoritması; Destek vektör makinesi (SVM), Sinir Ağı/Çok Katmanlı Algılayıcı (MLP), Topluluk Öğrenme (Ensemble Learning), Gauss Süreç Regresyonu (GSR), Karar Ağacı (Decision Tree) ve Lineer Regresyon ile elde edilen sonuçlar karşılaştırılmıştır. Karşılaştırma sonucunda en iyi tahminlemeyi yapan gizli katman için 3-9-1 mimarili nöronlara sahip Levenberg-Marquardt öğrenme algoritması bulunmuştur. Bu modelin çıktısı  $R^2$  ( $R^2$ = eğitim (1), test (0,99), doğrulama (1) ve tümü (0,99)) değerleri ile kondisyon faktörü modellemesi için en etkili sonucu vermiştir. Bu değer, mevcut diğer modellerle karşılaştırıldığında bu modelin yüksek kalitesini göstermektedir. Şu ana kadar çok katmanlı algılayıcı yapay sinir ağı (MLP-YSA), kondisyon faktörünü tahmin etmede önemli derecede başarı sağlamıştır.

**Anahtar kelimeler:** MLP-YSA, boy- ağırlık-cinsiyet ilişkileri, makine öğrenimi, tahmin modeli, kondisyon faktörü.

### Giriş

Balık türleri su ekosistemlerinde yer alan önemli tüketicilerdir ve çoğu izleme programı sadece kirleticilerin balıklarda birikmesinin muhtemel bir risk taşıdığı su, sediman ve askıdaki madde oranlarını belirlemektedir. Ancak bu ölçümler çevresel metal seviyelerinin anlık bir yansıması olarak kalmakta ve organizmalar açısından etkilerinin yeterince tahmin etmemizi sağlayamamaktadır. Metallerin biyoyararlanımı çeşitli faktörler tarafından ortaya konulduğundan ve balıklar tarafından besinsel metal alımı su kaynaklı metal alımı kadar hayati önem taşıdığından, çevresel metal seviyelerinin kimyasal analizlerinin yanı sıra balık topluluklarının biyolojik olarak izlenmesi de oldukça hayatidir (Bervoets ve Blust, 2003).

Boy-ağırlık ilişkisi (LWR), balık stok yapısını, vücut formundaki varyasyonu, büyüme performansını ve balıkçılık yönetimini belirlemek için balıkçılık incelemelerinin temelini oluşturmaktadır (Froese, 2006; Saberi ve ark., 2017). Boy-ağırlık modelleriyle büyümeyi (uzunluğun bir fonksiyonu olarak ağırlık açısından) tahmin etmek ve kondisyonla tanımlanan beslenme düzeyini anlamak için yararlanılmaktadır. Hem büyümeyi hem de kondisyonu tespit etmek için kullanılacak güvenilir bir modelin taşıdığı önem çok fazladır (Jones ve

ark., 1999). Kondisyon faktörü de faydalı bir indekstir beslenme yoğunluğunun, yaşın ve büyüme oranlarının değerlendirilmesi için balıkçılıkta kullanılmaktadır (Oni ve ark., 1983; Kumolu-Johnson ve Ndimele, 2010).

Balıklarda kondisyon faktörü, balıkların sağlığıyla ilgili durumunun bir göstergesi olarak işlev görür ve aynı zamanda belirli beslenme yoğunluğu, iklim ve diğer koşullarda bulunan iki popülasyonu karşılaştırmada bilgi sağlar (Weatherly ve Gills, 1987; Dan-Kishiya, 2013). Boy-ağırlık ilişkisi (LWR), büyüme paterni ve kondisyon faktörü (KF), balık kaynaklarının değerlendirilmesi ve yönetiminde hayati bir rol oynar (Dinh ve ark., 2022). Kondisyon faktörü balık popülasyonu ve stok değerlendirilmesi konusunda gerçekleştirilecek çalışmalarda bilgi verir (Ragheb, 2023).

Tatlı su ekosisteminin korunması ve onarım yönetiminde alınacak kararların kolaylaştırılmasına yönelik olarak habitat uygunluk modelleri oldukça faydalı görünmektedir. Yapay sinir ağı (YSA) gibi veriye dayalı yöntemler, zaman açısından verimli olarak geliştirilebilmesi ve nispeten yüksek güvenilirliğe sahip olması sebebiyle bu kapsamda oldukça avantajlıdır (Goethals ve ark., 2007). Yapay sinir ağı (YSA), biyolojik kavrayışın ve öğrenmenin doğasından esinlenen modellerdir (Brosse ve ark., 2001). YSA modelleri

ekolojide sıklıkla başvurulan bir yöntem olmakla birlikte, daha pek çok potansiyel kullanım alanı da mevcuttur. (Thessen, 2016).

Alternatif olarak, makine öğrenimi (ML) yöntemleri hidrolojik ve hidrolik modellerin eksikliklerinin giderilmesinde yardımcı olabilir (Wang ve ark., 2023). Yirmi yılı aşkın bir süredir ML uygulamaları, akustik verilerden balık türlerinin tanımlanmasını otomatikleştirmek amacıyla balıkçılık akustiğinde çok yaygın bir biçimde uygulanmaktadır (Yassir ve ark., 2023). Makine öğrenimi (ML) yöntemlerinin kullanımı, bu araştırmanın anlaşılmasında önemli ölçüde fayda sağlayabilecek ve kapsamını genişletebilecek umut verici bir araçtır. Makine öğrenimi yöntemlerinin benimsenmesi, yüksek maliyetli laboratuvar testlerine yönelik gerek duyulan maliyeti ortadan kaldırabilir (Kida ve ark., 2024). ML modelleri, Yapay Zeka alanındaki çalışmalar ışığında ortaya çıkarılan hesaplama modellemeleridir. ML modelleri doğrusal olmayan ilişkileri çözebilir ve değişen koşullara göre kendilerini uyarlayabilirler (Granata & Di Nunno, 2023).

Hidrolojik alanlarda yapılan araştırmalarda sinir ağları kullanılarak çeşitli kalite ve verimlilik ile ilgili olarak tahminleme çalışmaları yürütülmüştür. McKenna (2005) balık türlerinin çeşitliliğini ve Ontario Gölü'nün doğu havzasındaki akarsular için somon balığının üretimini tahmin etmek amacıyla sinir ağlarını kullanmıştır. Park ve ark. (2006) balık topluluğu türlerini belirlemek için iki farklı yapay sinir ağı algoritması ile tahminleme yapmıştır. Brey (2012) deniz ve tatlı su habitatlarındaki makrobentik popülasyonların yıllık üretim-biyokütle oranı P/B ve üretim P'sini tahmin etmek için yapay sinir ağı kullanmıştır. Rocha ve ark. (2017) çevresel verilere dayalı olarak akarsu makroalglerinin zenginliğini ve bolluğunu çok katmanlı yapay sinir ağları (YSA) ile tahmin etmişlerdir. Lalabadi ve ark. (2020) yapay sinir ağları (YSA) ve Destek Vektör Makineleri (SVM) uygulanarak balık tazeliğinin sınıflandırılması yapmışlardır. Do ve Tran (2023) balık larvalarının ve yavrularının dağılımlarını belirlemek için doğrusal regresyon, Gauss süreç modelleri, topluluk regresyonu ve yapay sinir ağı (YSA) modelleri uygulanmışlardır. Yasin ve ark. (2023) balık tazeliğinin ve kalitesinin değerlendirilmesi amacıyla derin öğrenme tekniklerini kullanmışlardır.

Bu çalışmada, boy, ağırlık ve cinsiyet değişkenlerinden elde edilen KF değerinin yapay sinir ağları ve makine öğrenimi algoritmaları ile tahminleme çalışması

gerçekleştirilmiştir. Bu yöntemlerin güvenilirlik, doğruluk ve tahmin yetenekleri karşılaştırılarak en iyi yöntem belirlenmeye çalışılmıştır.

### **Materyal ve Yöntem**

Bu çalışmada veri seti olarak İskenderun Körfezi'nde gırgır balıkçılığında elde edilen *Nemipterus randalli* (Russel, 1986)'ye ait veriler kullanılmıştır. Temin edilen balıklar üzerinde yapılan araştırmada, boy ölçümleri için standart bir cetvel kullanılarak geçerliliği kanıtlanmış bir Vernier kumpası tercih edilmiş; ağızdan kuyruk yüzgecinin sonuna kadar en yakın 0,1 cm'ye kadar ölçülen toplam uzunluk, santimetre cinsinden TL olarak kaydedilmiştir. Ağırlık ölçümleri ise, 0,01 g hassasiyetine sahip dijital bir terazi kullanılarak gerçekleştirilmiştir.

MATLAB "Neural Network Pattern Recognition Toolbox" ile MLP-YSA mimarisinin simülasyonu gerçekleştirilmiştir; özellikle verilerin eğitim, doğrulama ve test alt kümelerine bölüldüğü bu aşama, modelin etkili bir genelleştirme yeteneği kazanmasında kilit bir rol oynar. Aynı zamanda, bu sürecin model performansı üzerinde belirgin bir etkisi bulunmaktadır. Kullanılan altı makine öğrenimi algoritması MATLAB ortamında derin istatistik ve makine öğrenimi araç kutusu yazılımı ile oluşturulmuştur.

### **İstatistiksel Hesaplamalar ve Yapay Sinir Ağları Kondisyon Faktörünün Hesaplanması**

Total uzunluk – ağırlık ilişkin olarak "Le Cren" büyüme denklemi ( $W = a \cdot L^b$ ), Sparre ve Venema'nın (1998) ifadesiyle, büyümenin şeklini (izometrik veya allometrik) belirlemek amacıyla yapılan "t testi" ile b'nin istatistiksel olarak 3'ten farklı olup olmadığını belirler. Üremeye ve beslenmeye bağlı olarak değişen kondisyon faktörü (KF), Pauly'nin (1980) önerdiği  $KF = (W/L^3) \cdot 100$  formülü kullanılarak hesaplanır.

Kondisyon faktörü verileri, bu araştırmada yapay sinir ağı ve makine öğrenimi olmak üzere iki ayrı yöntemle eğitildi. Bu iki temel model, yaygın kullanım alanlarına sahip oldukları için seçilmiştir. Temel amaç, en doğru kondisyon faktörü tahmin modeline ulaşmaktır. Yapay sinir ağları, doğrusal olmayan ilişkileri başarılı bir şekilde tahmin edebilme ve üstün performans sergileme yetenekleri nedeniyle üzerinde detaylı bir şekilde çalışılmıştır.

### **Yapay Sinir Ağları**

Yapay Sinir Ağı (YSA), veriye dayalı ve insan beyninin biyolojik nöron sisteminin işlevlerini yansıtan bir hesaplama ürünüdür. Bilgi işleyebilme potansiyeli ve yüksek öğrenme kabiliyeti olması nedeniyle YSA, girdi-çıkı ilişkileri konusunda ön bilgi ihtiyacı duymayan ve istatistiksel yöntemlerle çözülmesi zor olan karmaşık doğrusal olmayan modellemeleri çözebilmek için kullanılmaktadır (Pareek ve ark., 2021; Gupta ve ark., 2023).

Yapay sinir ağı (YSA), biyolojideki sinir ağlarının çalışma prensibiyle oluşturulmuş olup geleneksel ve derin formlar olarak ikiye ayrılmaktadır (Zhaove ark., 2021). Bir YSA yapısındaki toplam ve aktivasyon fonksiyonları ile işlemci elemanların öğrenme stratejisi, kullanılan öğrenme kuralı ve işlem elemanlarının birbirine bağlanmasından oluşan topoloji ağın modelini belirlemektedir. Yapay sinir hücreleri (nöronlar) bir araya gelerek YSA'yı şekillendirirler. Bu nöronlar rastlantısal olarak bir araya gelmemişlerdir (Latifoğlu, 2022). YSA iki şekilde çalışır; önce verileri öğrenir ve sonra ağırlık olarak isimlendirilen ara bağlantılarda kaydeder. YSA tekniği, giriş parametreleri, optimum topoloji ve eğitim süreci temelinde verileri tahmin etmek için oldukça değerli bir yöntem olarak öne çıkmaktadır (Ghritlahre ve Prasad, 2018).

Farklı YSA türleri bulunmaktadır. YSA'ların çeşitli uygulamalarının arasında örüntülerin tanımlanması ve bunlar hakkında basit karar verme yer almaktadır. YSA'nın çeşitli bilimsel çalışmalarda yaygın olarak uygulandığı görülmektedir (Hema ve ark., 2023). YSA'lar, yağış, akış, su seviyesi ve çeşitli su kalitesi parametrelerinin de dahil olduğu bir takım su kaynakları göstergelerinin tahmini ve öngörüsü için son yıllarda giderek daha fazla tercih edilmektedir (Maier ve Dandy, 2000).

### **Yapay Sinir Ağı (YSA) Tabanlı İçin Levenberg Marquardt (MLP-YSA)**

Bir MLP üç katmandan oluşur. Birincisi, giriş sinyalini almak için çalışan bir giriş katmanıdır ve ikincisi, giriş katmanını çıkış katmanına bağlamak ve YSA'nın daha kompleks özellikleri öğrenmesine imkan sağlamak için nöron düğümlerinden meydana gelen gizli katmandır. Üçüncüsü, giriş verilerini tahmin etmeye yarayan gizli katmandır (Imran ve ark., 2024). MLP ağları genellikle, ağırlıkları ve önyargıları düzenleyerek tahmin edilen çıktılar ile gerçek çıktılar arasındaki farkı minimize eden popüler bir denetimli öğrenme algoritması olan geri

yayılm yöntemiyle eğitilmektedir. Eğitim sırasında ağ, ilgili hedef çıktılarla ilgili bir dizi girdi verisi ile beslenir ve ağ tahminleri bir kayıp fonksiyonu yardımıyla belirlenen hedeflerle kıyaslanır (Granata ve Di Nunno, 2023).

Levenberg-Marquardt yöntemi Marquardt (1963) tarafından geliştirilmiştir ve Hessian matrisini hesaplamaya veya yaklaşık olarak hesaplamaya ihtiyaç duymadan (Newton algoritması veya Newton'un sözde algoritması gibi) ikinci dereceden eğitimin performansını yükseltmek için uygulanabilmektedir. Yapay sinir ağlarına (YSA) dayalı LM algoritması, bir girdi katmanı, bir veya daha fazla gizli katman ve bir çıktı katmanı olacak şekilde üç işlem katmanını veya düğümünü kapsamaktadır (Tarawneh, 2013).

MATLAB yazılımı, LM algoritmalarını gerçekleştirmek için bir trainlm fonksiyonu kullanılmaktadır. Yapay Sinir Ağı (YSA) tabanlı KF modeli için Levenberg Marquardt algoritması kullanılarak üç katmanlı bir yapı oluşturulmuş ve KF değerleri için eğitim, doğrulama ve test veri seti uygulanmıştır. Levenberg Marquardt algoritması için %70 eğitim, %15 doğrulama ve %15 test verisi ile tahmin edilmiştir. Elde edilen en düşük hata sonuçları, YSA modelinin doğruluğunu ve optimalliğini değerlendirmek amacıyla kullanılmıştır.

Modelde üç katman bulunmaktadır; girdi katmanı, gizli katman ve çıktı katmanıdır. Geçmiş çalışmalara baktığımızda, optimal ağ genellikle 2 ile 15 gizli düğüm arasında seçilmiş olan nöron sayılarında bulunmuştur (Najjar ve ark., 1996; Sinshaw ve ark., 2019; Chauhan ve Trivedi, 2022). Gizli nöron sayısı 2'den başlayarak 15 kadar olacak şekilde belirlenmiş ve test edilmiştir. Nöron sayısı deneme yanılma yöntemiyle bulunur. Gizli katmanda ve çıkış katmanında sırasıyla teğet sigmoid ve doğrusal aktivasyon fonksiyonları kullanılmaktadır. Önerilen YSA modeli MATLAB'da uygulanmıştır. Girdi parametresi olarak cinsiyet, ağırlık ve boy seçilmiştir. Çıkış parametresi olarak ise KF değeri seçilmiştir. Şekil 1'de YSA mimarisi gösterilmiştir.

Şekil 2'de görülen MATLAB üzerinde uygulanan Yapay Sinir Ağı'nın eğitimini, testini ve doğrulamasını gerçekleştirmek için kullanılan 9 nöronlu YSA modeli, en üstün performansı sergilemiştir.

### **Makine Öğrenimi (ML) Modelleri**

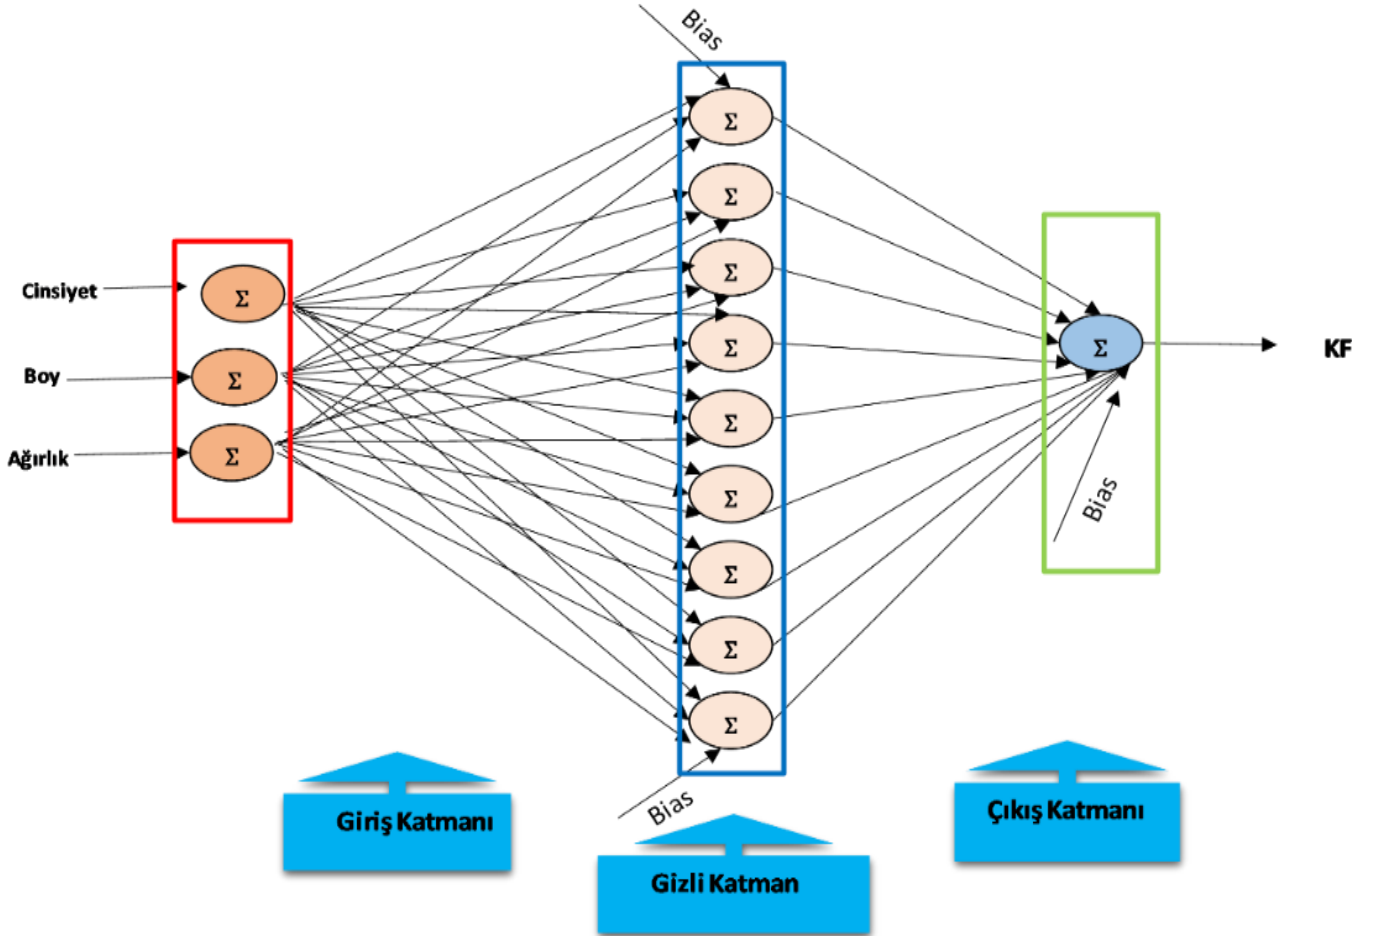
Makine öğrenimi, bilgisayarların önceki sonuçlardan otomatik olarak öğrenmesini mümkün kılan bir uygulamadır. Makine öğrenimi, geçmiş verilere bakarak tahminler yürüten bir tahmine dayalı analitik çeşidir. Makine öğreniminde veri ve algoritmalar önemli bir yer tutmaktadır (Kelleher, 2019; Kalaivanan & Vellingiri, 2022). Yapay zeka/makine öğrenimi (ML) algoritmaları, girdi değişkenleri ve çıktılar arasındaki doğrusal olmayan ilişkileri algılayabilen yapısal yaklaşımlardır (Maier ve ark., 2014).

KF değerinin tahmini için, doğruluklarını karşılaştırmak ve en uygun tahmin modelini belirlemek amacıyla altı makine öğrenimi algoritması Destek Vektör Makinesi (SVM), Sinir Ağı/Çok Katmanlı Algılayıcı (MLP), Topluluk Öğrenme (Ensemble Learning), Gauss Süreç Regresyonu (GSR), Karar Ağacı (Decision Tree) ve Lineer Regresyon kullanılmıştır. Karşılaştırılan altı ML


modelinin performans değerlendirmesine göre, Gauss Süreç Regresyonunun (GSR) minimum eğitim hatası ürettiği ve KF giriş veri kümesini tahmin etmek için en iyi uyumu sağladığı bulunmuştur. Kullanılan modeller MATLAB ortamında regresyon öğrenimi araç kutusu yazılımı ile oluşturulmuştur.

### **Gauss Süreç Regresyonu (GSR)**

Gauss sürecinin regresyon modelleri, ayarlama gözlemlerinin birbirleriyle ilgili bilgi içerecek şekilde olması gerekliliği hipotezine dayandırılmaktadır. Bu süreç, ortalama vektör ve kovaryans matrisine sahip Gauss fonksiyonunun doğal bir uzantısı olarak nitelendirilen fonksiyon uzayı kapsamındaki öncelikleri doğrudan açıklamaktadır. Gauss dağılımının vektörler için geçerli olduğu, Gauss sürecinin ise fonksiyonlar için uygun görüldüğü belirtilmelidir (Tao ve ark., 2023).



Şekil 1. Basit YSA Şeması



Şekil 2. Levenberg Marquardt (trainlm) metodunun işleyişine ilişkin genel şema.

Gauss süreç regresyonu (GSR), son zamanlarda makine öğreniminde fazlasıyla ilgi çeken yeni ve gelecek vaat eden bir yöntemdir. Belirsizlik tahminlerindeki avantajlarından dolayı GSR, doğrusal olmayan, karmaşık sınıflandırma ve regresyon problemlerini çözümlmek için iyi bir adaptasyon sağlayabilmektedir (Katipoğlu, 2023). Ayrıca, GSR'nin Bayes teorisine dayanmasından dolayı, tahmin sonuçları olasılık tabanlı olarak kolaylıkla uygulanabilir. Dahası, GSR'nin performansı esas olarak bir ortalama fonksiyonu ve bir kovaryans fonksiyonu çerçevesinde şekillendirildiğinden, GSR'nin yapısı basit yapıdadır (Li ve ark., 2016; Liu ve ark., 2019; Wang ve ark., 2022).

### Modelin Doğruluğunun Belirlenmesi

Modelleri değerlendirmek belirleme katsayısı ( $R^2$ ), ortalama kare hata (RMSE) ve ortalama mutlak yüzde hata (MAPE) kriterleri kullanılarak karşılaştırılmıştır. RMSE, MAPE ve  $R^2$  (1), (2) ve (3) 'te verilen denklemler kullanılarak sırasıyla hesaplanmıştır. Model eğitimi, parametrelerin istatistiksel analizi, korelasyon katsayılarının hesaplanması, hata analizi vb. ağırlıklı olarak MATLAB üzerinden gerçekleştirilmiştir.

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (output_t - target_t)^2} \quad (1)$$

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{output_t - target_t}{target_t} \right| \quad (2)$$

$$R^2 = 1 - \frac{(\sum_{t=1}^n (output_t - target_t)^2)}{(\sum_{t=1}^n (output_t - \bar{output})^2)} \quad (3)$$

Modellerin güvenilirliğini ve uyumunu yansıtan RMSE ve MAE ölçümleri ile açıkça karakterize edilmiştir.  $R^2$  değerleri 0 ile 1 arasında değişmektedir. Bu, veri tabanının varyansıyla karesi alınmış artık hatayı normalleştirir. Modelin sırasıyla 1 sağlam ve 0'a yakın olduğunda ise zayıf tahmin kapasitesine sahip olduğunu göstermektedir (El-Mir ve ark., 2022).

## Sonuçlar

### İstatistiksel Analiz Sonuçları

Bu bölümde MLP-YSA ve çeşitli ML algoritmasının tahmin performansları karşılaştırılmıştır. Tüm bu algoritmaların programlanması MATLAB'da tamamlanmıştır. Ardından, KF tahmin sonuçlarının doğruluk değerleri karşılaştırmalı olarak değerlendirilmiştir.

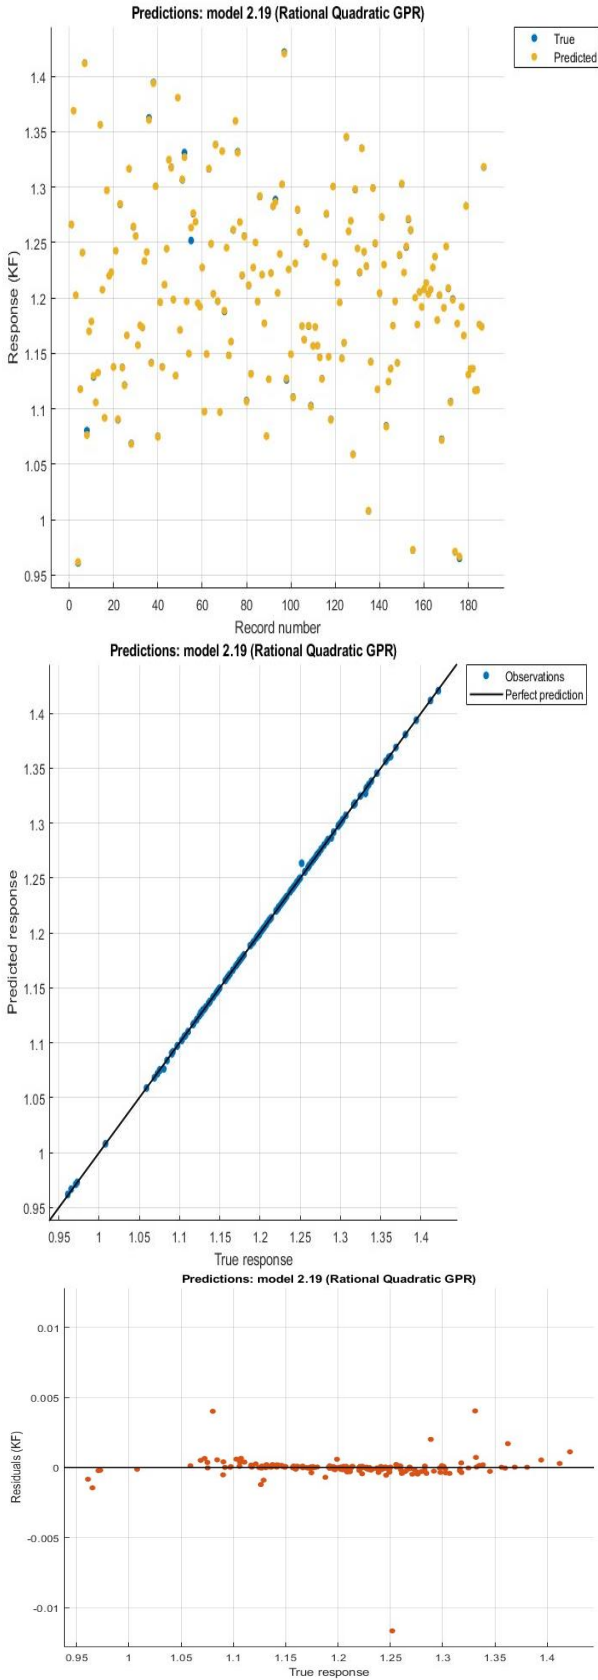
### KF Tahmini İçin Makine Öğrenimi (ML) Algoritmaları Sonuçları

Çeşitli performans değerlendirmeleri, en iyi modeli seçebilmek amacıyla farklı algoritmaları karşılaştırmada dikkate alınmıştır. Makine öğrenmesi algoritmalarının incelenmesinin ardından, Gaussian Process Regression sonuçları; RMSE: 0,00100, MSE: 0,000001,  $R^2$ : 0,99985, MAE: 0,00029 MAE ile en başarılı algoritma olduğu tespit edilmiştir (Tablo 1).

Gauss süreç regresyonu (GSR) modelinin KF'nin tahmin performansı değeri  $R^2$  grafikleri ve tahmin edilen KF değerleri ile gerçek değerler arasındaki artık verilerin gösterimi Şekil 3'te verilmiştir. Analiz edilen tüm ML algoritmaları arasında en iyi tahmin performansı Gauss süreç regresyonu (GSR) ile elde edilmiştir. Literatürde Gauss Süreç Regresyonu (GSR), balıkların mekansal dağılımlarının ortaya çıkarılması için başvurulan başarılı çekirdek tabanlı ML yöntemlerinden bir tanesidir (Ranganathan ve ark., 2011; Juntunen ve ark., 2012).

### MLP-YSA modelinin KF Tahmini

Çalışmada kullanılan YSA modellemesi tahmin performansına ilişkin grafikler ve regresyon modelleri Şekil 4'te gösterilmiştir. KF tahmininde öngörücü bir araç olarak MLP-YSA algoritmasının daha iyi değerlendirilmesi için istatistiksel ve grafiksel ölçütlerden yararlanılmıştır.



**Şekil 3.** En iyi performans sergileyen GSR modelinin KF tahmin performansı (Üst), gerçek KF'ye karşı tahmin edilen değerleri karşılaştırma sonuçları; (Orta), tahmin edilen KF değerleri ile gerçek değerleri arasındaki artık sonuçlar (Alt).

**Tablo 1.** Makine öğrenmesi algoritmalarının performans sonuçları

Model Tipi		RMSE	MSE	R <sup>2</sup>	MAE
<b>Gauss</b>	<b>süreç</b>	<b>0,00100</b>	<b>0,00000</b>	<b>0,99985</b>	<b>0,00029</b>
<b>regresyonu</b>		<b>807</b>	<b>1</b>	<b>4664</b>	<b>9407</b>
Sinir Ağı/Çok Katmanlı		0,00814	0,00006	0,99051	0,00303
Algılayıcı		3126	6	6366	6437
		0,01023	0,00010	0,98501	0,00597
Destek vektör makinesi		7128	4799	1824	1377
		0,01548	0,00023	0,96572	0,00983
Lineer Regresyon		1225	9668	297	033
		0,05930	0,00351	0,49699	0,04626
Karar Ağacı		4997	7083	1765	156
		0,07053	0,00497	0,28846	0,06037
Topluluk Öğrenme		472	5147	1493	6001

Bu araştırmada model mimarisi, gizli katman için 3-9-1 mimari nöronlara sahip Sigmoid aktivasyon fonksiyonu, Levenberg-Marquardt öğrenme algoritması en iyi ağ olarak bulunmuştur. Şekil 4'de verilen uygulamada Levenberg Marquardt algoritması için %70 eğitim, %15 doğrulama ve %15 test kullanılarak veri setinin regresyonunu hem ayrı ayrı hem de bir bütün olarak sergilenmektedir. Görüldüğü üzere hesaplanan değerlerin büyük oranda uyum sağlamış olması modelin güvenilirliğini ortaya çıkarmaktadır. Şekil 4'te belirtildiği gibi YSA R<sup>2</sup> (R<sup>2</sup>= eğitim (1), test (0,99), doğrulama (1) ve tümü (0,99)) değerleri ile KF modellemesi için etkili bir yöntem olduğu sonucuna varılmıştır. LM yöntemi, en iyi sonuca ulaşmadan önce sayısız yinleme yaparak, en iyi sonuca ulaşmadan eğitimi bitirmeyecektir.

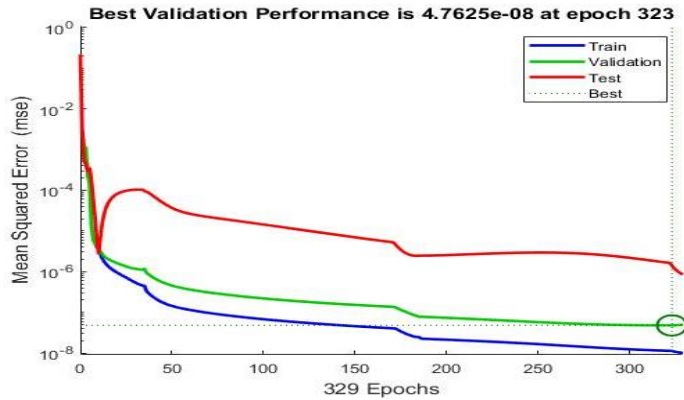

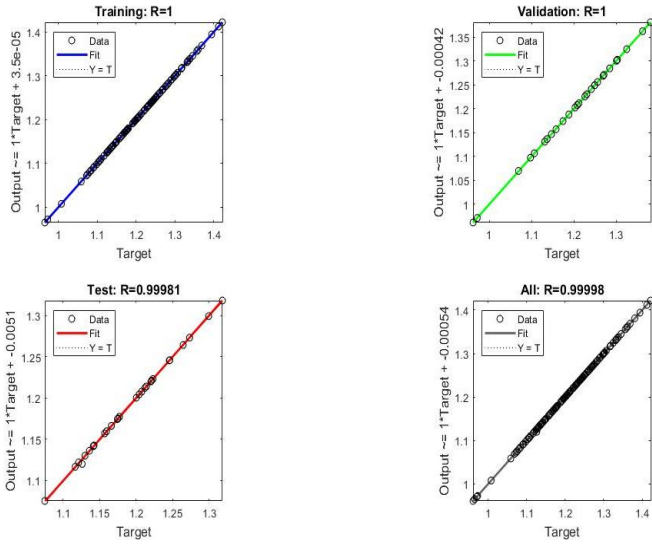
Levenberg Marquardt algoritması uygulanarak KF'nin yapay sinir ağı tabanlı doğrulama değerlendirilmesi RMSE, MAPE ve R<sup>2</sup> Tablo 2'de sunulmuştur. Modellenen çıktı ile gözlemlenen veri seti arasındaki hata, bu algoritmanın performansını hakkında fikir sağlaması amacıyla kullanılır. En iyi performansı 9 gizli nöronlu YSA modelin düşük RMSE, MAPE ve 1'e yakınlığı ile R<sup>2</sup> açısından en iyi model olarak tespit edilmiştir.

### **KF Tahmin Modellerinin Karşılaştırmalı Performansı**

Levenberg-Marquardt algoritması bu çalışmada ele alınan modeller arasında en iyi tahmin doğruluğunu sağlamıştır. KF'yi tahmin etmek için önemli bir araç olduğunu göstermektedir. Modellerin karşılaştırmalı sonuçları Tablo 3'de verilmiştir.

Çalışmamıza benzer sonuç olarak Çetinkaya ve Baykan (2020) kullandıkları YSA modelleri, literatürdeki iyi bilinen regresyon yöntemlerinden daha iyi performans göstermiştir. Bu sonuçlardan YSA'nın tahmin gücü

bakımından güçlü performans sergilemiş olduğu sonucuna ulaşılmıştır.



Son olarak Levenberg-Marquardt algoritması için diğer Makine Öğrenimi (ML) Algoritmalarına kıyasla mükemmel  $R^2$  değeri ve çok düşük RMSE değeri sergilemiştir. İkinci olarak ise GSR modeli makine öğrenimi yöntemleri içerisinde mükemmel tahmin yeteneği göstermiştir. Ayrıca GSR modelinin üstün regresyon ve genelleme yapma becerisini ortaya koymuştur (Tablo 3). Bu sonuçlara bakılarak kondisyon faktörünün tahmini için YSA'nın ve makine öğrenme algoritmalarının kullanılabilir olması balıkçılık popülasyonu yönetimi konusunda katkı sağlamış olacaktır.

### Tartışma

Bu çalışma balıklarda besililik derecesinin en iyi göstergelerinden biri olan kondisyon faktörünün yapay sinir ağları ve makine öğrenimi algoritmaları ile tahmininin gerçekleştirilmesi amacıyla yapılmıştır. Kondisyon faktörü değerinin tespit edilmesi balıkçılık yönetiminde önemli bir görev görmektedir. Karşılaştırma sonuçları MLP-YSA modelinin kondisyon faktörünün tahmininde büyük potansiyel taşıdığını ve bu algoritmanın, kondisyon faktörünün farklı yöntemler kullanılarak tahmin etmek için yüksek doğrulukta bir model olarak kullanılabilir olduğunu göstermiştir. Bu çalışma sayesinde YSA'nın yanıt yüzeyi metodolojisi ve makine öğrenimi algoritmalarına göre en iyi optimizasyon yöntemi olduğu sonucuna ulaşılmıştır. Literatür katkısı sunacak olan bu çalışma ile küresel çapta yapılacak olan kondisyon faktörü tahmini çalışmalarına öncülük etmesi beklenmektedir.

**Şekil 4.** Levenberg-Marquardt algoritması (LMA) sonuçları; regresyon grafiğini (Üst), hata histogramını (Orta) ve en iyi doğrulama performansını (Alt) göstermektedir.



**Tablo 2.** MLP-YSA (Levenberg-Marquardt %70-%15-%15) için eğitim, doğrulama ve testlerde modelin performansı

Gizli düğüm sayısı	MLP-YSA (Levenberg-Marquardt)			R <sup>2</sup>
	Veri Seti	RMSE	MAPE	
3-2-1-1	Validation	0,0104	0,6196	0,9963
	Training	0,0072	0,4664	0,9960
	Testing	0,0076	0,4690	0,9946
3-3-1-1	Validation	0,0223	0,9765	0,9598
	Training	0,0092	0,5047	0,9939
	Testing	0,018	0,8619	0,9824
3-4-1-1	Validation	0,0111	0,4559	0,9924
	Training	0,0025	0,1553	0,9994
	Testing	0,0184	0,4659	0,9850
3-5-1-1	Validation	0,0259	1,1843	0,9606
	Training	0,0120	0,6723	0,9897
	Testing	0,0490	1,4696	0,8776
3-6-1-1	Validation	0,0027	0,1632	0,9994
	Training	0,0017	0,0933	0,9998
	Testing	0,0016	0,0980	0,9997
3-7-1-1	Validation	0,0179	1,1183	0,9845
	Training	0,0123	0,7250	0,9895
	Testing	0,0187	0,7432	0,9635
3-8-1-1	Validation	0,0036	0,2319	0,9990
	Training	0,0064	0,3362	0,9972
	Testing	0,0068	0,3646	0,9959
<b>3-9-1-1</b>	<b>Validation</b>	<b>0,0002</b>	<b>0,0111</b>	<b>1,0000</b>
	<b>Training</b>	<b>0,0001</b>	<b>0,0060</b>	<b>1,0000</b>
	<b>Testing</b>	<b>0,0012</b>	<b>0,0269</b>	<b>0,9998</b>

**Tablo 3.** MLP-YSA (Levenberg-Marquardt %70-%15-%15) ve En İyi Makine Öğrenimi (ML) Algoritma Performansı

	KF için Tahmin Yöntemleri			En İyi Makine Öğrenimi ve Derin Öğrenme Yöntemi (Gauss Süreç Regresyonu (GSR))
	Levenberg-Marquardt %70-%15-%15	Doğrulama	Eğitim	
<b>RMSE</b>	0,0002	0,0002	0,0005	0,001008
<b>MAPE</b>	0,0179	0,0128	0,0269	MAE= 0,000299 MSE=0,000010
<b>R<sup>2</sup></b>	<b>1</b>	<b>1</b>	<b>0,9999</b>	0,999855

### Teşekkür

Örneklerin toplanmasında yardımlarını esirgemeyen İskenderun Körfezi'nde ticari faaliyette bulunan Hüseyin Oğulları-6 Balıkçı Teknesi sahibi merhum Hüseyin AKKAN'a saygı ve minnetle teşekkürü bir borç biliriz. Hakan IŞIK 100/2000 YÖK Doktora bursu programı kapsamında çalışmalarını sürdürmektedir.

### Etik Onay

Bu çalışma için etik onaya gerek yoktur.

### Çıkar Çatışması

Yazarlar herhangi bir çıkar çatışması yaşamadıklarını beyan etmişlerdir.

### Mali Destek

Yazarlar tarafından herhangi bir mali destek beyan edilmemiştir.

**Kaynaklar**

- Bervoets, L., & Blust, R. (2003). Metal concentrations in water, sediment and gudgeon (*Gobio gobio*) from a pollution gradient: relationship with fish condition factor. *Environmental Pollution*, 126(1), 9-19.
- Brey, T. (2012). A multi-parameter artificial neural network model to estimate macrobenthic invertebrate productivity and production. *Limnology and Oceanography: Methods*, 10(8), 581-589.
- Brosse, S., Lek, S., & Townsend, C. R. (2001). Abundance, diversity, and structure of freshwater invertebrates and fish communities: an artificial neural network approach. *New Zealand Journal of Marine and Freshwater Research*, 35(1), 135-145.
- Chauhan, S. S., & Trivedi, M. K. (2023). Artificial neural network-based assessment of water quality index (WQI) of surface water in Gwalior-Chambal region. *International Journal of Energy and Environmental Engineering*, 14(1), 47-61.
- Çetinkaya, A., & Baykan, Ö. K. (2020). Prediction of middle school students' programming talent using artificial neural networks. *Engineering Science and Technology, an International Journal*, 23(6), 1301-1307.
- Dan-Kishiya, A. S. (2013). Length-weight relationship and condition factor of five fish species from a tropical water supply reservoir in Abuja, Nigeria. *American Journal of Research Communication*, 1(9), 175-187.
- Dinh, Q. M., Nguyen, T. H. D., Nguyen, T. T. K., Van Tran, G., & Truong, N. T. (2022). Spatiotemporal variations in length-weight relationship, growth pattern and condition factor of *Periophthalmus variabilis* Eggert, 1935 in Vietnamese Mekong Delta. *PeerJ*, 10, e12798.
- Do, A. N. T., & Tran, H. D. (2023). Potential application of artificial neural networks for analyzing the occurrences of fish larvae and juveniles in an estuary in northern Vietnam. *Aquatic Ecology*, 57(4), 813-831.
- El-Mir, A., El-Zahab, S., Sbartai, Z. M., Homsy, F., Saliba, J., & El-Hassan, H. (2022). Machine learning prediction of concrete compressive strength using rebound hammer test. *Journal of Building Engineering*, 105538.
- Froese, R. (2006). Cube law, condition factor and weight-length relationships: history, meta-analysis and recommendations. *Journal of Applied Ichthyology*, 22(4), 241-253.
- Ghritlahre, H. K., & Prasad, R. K. (2018). Exergetic performance prediction of solar air heater using MLP, GRNN and RBF models of artificial neural network technique. *Journal of Environmental Management*, 223, 566-575.
- Goethals, P. L., Dedecker, A. P., Gabriels, W., Lek, S., & De Pauw, N. (2007). Applications of artificial neural networks predicting macroinvertebrates in freshwaters. *Aquatic Ecology*, 41, 491-508.
- Granata, F., & Di Nunno, F. (2023). Neuroforecasting of daily streamflows in the UK for short-and medium-term horizons: A novel insight. *Journal of Hydrology*, 624, 129888.
- Hema, M., Toghraie, D., & Amoozad, F. (2023). Prediction of viscosity of MWCNT-Al<sub>2</sub>O<sub>3</sub> (20: 80)/SAE40 nanolubricant using multi-layer artificial neural network (MLP-ANN) modeling. *Engineering Applications of Artificial Intelligence*, 121, 105948.
- Imran, M., Dai, H. L., Zaidi, F. S., Hu, X., Tran, K. P., & Sun, J. (2024). Analyzing out-of-control signals of T2 control chart for compositional data using artificial neural networks. *Expert Systems with Applications*, 238, 122165.
- Jones, R. E., Petrell, R. J., & Pauly, D. (1999). Using modified length-weight relationships to assess the condition of fish. *Aquacultural Engineering*, 20(4), 261-276.
- Juntunen, T., Vanhatalo, J., Peltonen, H., & Mäntyniemi, S. (2012). Bayesian spatial multispecies modelling to assess pelagic fish stocks from acoustic-and trawl-survey data. *ICES Journal of Marine Science*, 69(1), 95-104.
- Kalaivanan, K., & Vellingiri, J. (2022). Survival Study on Different Water Quality Prediction Methods Using Machine Learning. *Nature Environment & Pollution Technology*, 21(3), 1259-1267.
- Katipoğlu, O. M. (2023). Evaluation of the performance of data-driven approaches for filling monthly precipitation gaps in a semi-arid climate conditions. *Acta Geophysica*, 71(5), 2265-2285.
- Kelleher, J. D. (2019). *Deep Learning*. MIT Press, Cambridge, MA
- Kida, M., Pochwat, K., & Ziembowicz, S. (2024). Assessment of machine learning-based methods predictive suitability for migration pollutants from microplastics degradation. *Journal of Hazardous Materials*, 461, 132565.
- Kumolu-Johnson, C. A., & Ndimele, P. E. (2010). Length-weight relationships and condition factors of twenty-one fish species in Ologe Lagoon, Lagos, Nigeria. *Asian Journal of Agricultural Sciences*, 2(4), 174-179.
- Lalabadi, H. M., Sadeghi, M., & Mireei, S. A. (2020). Fish freshness categorization from eyes and gills color features using multi-class artificial neural network and support vector machines. *Aquacultural Engineering*, 90, 102076.
- Latifoğlu, L. (2022). The performance analysis of robust local mean mode decomposition method for forecasting of hydrological time series. *Iranian Journal of Science and Technology, Transactions of Civil Engineering*, 46(4), 3453-3472.
- Li, L., Wang, P., Chao, K. H., Zhou, Y., & Xie, Y. (2016). Remaining useful life prediction for lithium-ion batteries based on Gaussian processes mixture. *PLoS ONE*, 11(9), e0163004.

- Liu, K., Hu, X., Wei, Z., Li, Y., & Jiang, Y. (2019). Modified Gaussian process regression models for cyclic capacity prediction of lithium-ion batteries. *IEEE Transactions on Transportation Electrification*, 5(4), 1225-1236.
- Maier, H. R., & Dandy, G. C. (2000). Neural networks for the prediction and forecasting of water resources variables: a review of modelling issues and applications. *Environmental Modelling & Software*, 15(1), 101-124.
- Maier, H. R., Kapelan, Z., Kasprzyk, J., Kollat, J., Matott, L. S., Cunha, M. C., ... & Reed, P. M. (2014). Evolutionary algorithms and other metaheuristics in water resources: Current status, research challenges and future directions. *Environmental Modelling & Software*, 62, 271-299.
- Marquardt, D. W. (1963). An algorithm for least-squares estimation of nonlinear parameters. *Journal of the Society for Industrial and Applied Mathematics*, 11(2), 431-441.
- McKenna Jr, J. E. (2005). Application of neural networks to prediction of fish diversity and salmonid production in the Lake Ontario basin. *Transactions of the American Fisheries Society*, 134(1), 28-43.
- Najjar, Y. M., Basheer, I. A., & Naouss, W. A. (1996). On the identification of compaction characteristics by neuronets. *Computers and Geotechnics*, 18, 167-187.
- Oni, S. K., Olayemi, J. Y., & Adegboye, J.D. (1983). Comparative physiology of three ecologically distinct freshwater fishes, *Alestes nurse* (Ruppell), *Synodontis schall* (Bloch), *S. schneider* and *Tilapia zilli* (Gervais). *Journal of Fish Biology*, 22, 105-109.
- Pareek, C. M., Tewari, V. K., Machavaram, R., & Nare, B. (2021). Optimizing the seed-cell filling performance of an inclined plate seed metering device using integrated ANN-PSO approach. *Artificial Intelligence in Agriculture*, 5, 1-12.
- Park, Y. S., Grenouillet, G., Esperance, B., & Lek, S. (2006). Stream fish assemblages and basin land cover in a river network. *Science of the Total Environment*, 365(1-3), 140-153.
- Pauly, D. (1980). *A selection of simple methods for the assesment of tropical fish stocks*. FAO Fish. Circ. No: 729, Rome
- Ragheb, E. (2023). Length-weight relationship and well-being factors of 33 fish species caught by gillnets from the Egyptian Mediterranean waters off Alexandria. *The Egyptian Journal of Aquatic Research*, 49(3), 361-367.
- Ranganathan, A., Yang, M. H., & Ho, J. (2010). Online sparse Gaussian process regression and its applications. *IEEE Transactions on Image Processing*, 20(2), 391-404.
- Rocha, J. C., Peres, C. K., Buzzo, J. L. L., de Souza, V., Krause, E. A., Bispo, P. C., ... & Branco, C. C. (2017). Modeling the species richness and abundance of lotic macroalgae based on habitat characteristics by artificial neural networks: a potentially useful tool for stream biomonitoring programs. *Journal of Applied Phycology*, 29, 2145-2153.
- Saberi, M., Paighambari, S. Y., Darvishi, M., & Farkhondeh Shilsar, G. (2017). Length-weight relationships of six fish species from the Coastal Waters of Jask, Iran. *Journal of Applied Ichthyology*, 33(6), 1226-1228.
- Sinshaw, T. A., Surbeck, C. Q., Yasarer, H., & Najjar, Y. (2019). Artificial neural network for prediction of total nitrogen and phosphorus in US lakes. *Journal of Environmental Engineering*, 145(6), 04019032.
- Sparre, P., & Venema, S. C. (1998). *Introduction to tropical fish stock assessment*. FAO Fisheries Technical Paper, 306/1, Rev.2, Rome
- Tao, H., Hameed, M. M., Marhoon, H. A., Zounemat-Kermani, M., Heddami, S., Kim, S., ... & Yaseen, Z. M. (2022). Groundwater level prediction using machine learning models: A comprehensive review. *Neurocomputing*, 489, 271-308.
- Tarawneh, B. (2013). Pipe pile setup: Database and prediction model using artificial neural network. *Soils and Foundations*, 53, 607-615.
- Thessen, A. E. (2016). Adoption of machine learning techniques in ecology and earth science. *PeerJ PrePrints*, (No. e1720v1).
- Wang, J., Deng, Z., Yu, T., Yoshida, A., Xu, L., Guan, G., & Abudula, A. (2022). State of health estimation based on modified Gaussian process regression for lithium-ion batteries. *Journal of Energy Storage*, 51, 104512.
- Wang, M., Fu, X., Zhang, D., Lou, S., Li, J., Chen, F., ... & Tan, S. K. (2023). Urban agglomeration waterlogging hazard exposure assessment based on an integrated Naive Bayes classifier and complex network analysis. *Natural Hazards*, 118(3), 2173-2197.
- Weatherly, A.H., & Gill, H.S. (1987). *The biology of fish growth*. London, Academic Press. 433-443.
- Yasin, E. T., Ozkan, I. A., & Koklu, M. (2023). Detection of fish freshness using artificial intelligence methods. *European Food Research and Technology*, 1-12.
- Yassir, A., Andaloussi, S. J., Ouchetto, O., Mamza, K., & Serghini, M. (2023). Acoustic fish species identification using deep learning and machine learning algorithms: A systematic review. *Fisheries Research*, 266, 106790.
- Zhao, S., Zhang, S., Liu, J., Wang, H., Zhu, J., Li, D., & Zhao, R. (2021). Application of machine learning in intelligent fish aquaculture: A review. *Aquaculture*, 540, 736724.