

Review article**The Digital Transformation of Identification Methods in the Systematics of Aquatic Insects: from Classical Taxonomy to Deep Learning****Ayçin AKÜNAL** 

Selçuk Üniversitesi, Beyşehir Ali Akkanat Uygulamalı Bilimler Yüksekokulu, Acil Yardım ve Afet Yönetimi Bölümü, 42700 Konya, Türkiye

Author e-mail: aycinakunal@selcuk.edu.tr

Abstract: Aquatic insects are important biological indicators for freshwater ecosystems. However, species identification is often based on classical taxonomic methods that use various morphological characteristics and sexual organs. Although the use of modern molecular techniques in classification offers the advantage of high accuracy, their cost and the infrastructure required prevent their widespread application. In recent years, deep learning methods, especially convolutional neural networks (CNNs), have initiated a significant change in the systematics of aquatic insects, as they offer high accuracy in image-based automated identification processes. This study evaluates the process from classical taxonomic methods to AI-based approaches and examines current studies, datasets, and various methodological approaches. The literature shows that while datasets created under laboratory conditions offer high accuracy, datasets from natural habitats with varying conditions have shortcomings. The creation of open, standardized image databases and the development of automated identification systems are crucial for the effective monitoring and classification of aquatic ecosystems and the aquatic insects found therein.

Keywords: Aquatic insects, deep learning, convolutional neural networks (CNN), image-based diagnosis, artificial intelligence

Citing: Akünal, A. (2026). The Digital Transformation of Identification Methods in the Systematics of Aquatic Insects: from Classical Taxonomy to Deep Learning. *Acta Biologica Turcica*, 39(1), kswg20260103-10p.

Klasik Taksonomiden Derin Öğrenmeye Sucul Böcek Sistematiğinde Tanılama Metotlarının Dijital Dönüşümü

Özet: Sucul böcekler tatlı su ekosistemlerinin önemli biyolojik göstergelerini oluşturmaktadır. Ancak tür tanımlamalarında, çoğu zaman çeşitli morfolojik karakterlerin ve genital organların kullanıldığı klasik taksonomik metotlar kullanılmaktadır. Modern moleküler tekniklerin sınıflandırmada kullanılması yüksek doğruluk avantajı sunsa da hem maliyet hem de altyapı ihtiyacından dolayı geniş ölçekli uygulamalara olanak vermemektedir. Son yıllarda derin öğrenme metotları ve özellikle evrimsel sinir ağları (CNN), görüntü tabanlı otomatik tanılama süreçlerinde yüksek doğruluk sunarak sucul böcek sistematiğinde önemli bir dönüşüm başlatmıştır. Bu çalışma, klasik taksonomik metotlardan yapay zekâ tabanlı yaklaşımlara uzanan süreci değerlendirerek güncel çalışmaları, veri setlerini ve farklı metodolojik yöntemleri incelemektedir. Literatürde, laboratuvar koşullarında oluşturulan veri setlerinde yüksek doğruluklar sunarken, farklı koşullara sahip doğal habitatlara ait veri setlerinde eksiklikler olduğu görülmüştür. Sucul ekosistemler ve bu ekosistemlerde dağılım gösteren sucul böceklerin etkin bir şekilde izlenerek, sınıflandırılması için açık, standardize edilmiş görüntü veri tabanlarının oluşturulması ve otomatik tanı sistemlerinin geliştirilmesi kritik önem taşımaktadır.

Anahtar Kelimeler: Sucul böcek, derin öğrenme, evrimsel sinir ağı (CNN), görüntü tabanlı tanılama, yapay zekâ

Giriş

Tür tanımlaması tarihsel olarak morfolojik, genetik ve ekolojik metotlara dayanmaktadır. Carl Linnaeus'nin çalışmalarına dayanan klasik taksonomi; daha çok organizmaların morfolojik özelliklerine dayanılarak yapılmakta olup özellikle sibling türlerin tanımlamasında çeşitli aksaklıklara sebep olmaktadır (Montgomery, 2024; Adebayo, 2025). Moleküler metotların gelişmesi ile tür tanımlamasında DNA analizlerine bağlı genetik sınıflandırma yöntemleri gelişmiştir. Bu yaklaşım, morfolojiye dayalı taksonomiden daha yüksek hassasiyet sağlar, ancak kapsamlı genetik veri tabanları ve laboratuvarlar gerektirmekte olup, büyük ölçekli uygulamalar için erişilebilirliği sınırlamaktadır (Adebayo, 2025). Başka bir geleneksel yaklaşım olan ekolojik sınıflandırma ise, tür-çevre ilişkisi mantığına dayanmaktadır. Bu yöntemde de çevresel değişkenlerde meydana gelen değişimler, tür tanımlamasına etki ettiğinden tutarsızlıklara sebep olmaktadır. Biyoçeşitlilik verilerinin artan karmaşıklığı; manuel tanımlama metotlarını geride bırakmış, daha verimli ve ölçeklenebilir çözümlere ihtiyaç duyulmasına sebep olmuştur. Bütün bu veriler, taksonomik sınıflandırmada insan bağımlılığının azaltılarak daha hızlı ve doğruluk sunan otomatik yapay zekâ destekli

tür tanımlama metotlarına olan talebi ve gerekliliği artırmıştır (Obach ve ark., 2001; Wäldchen ve Mäder, 2018; Adebayo, 2025).

Modern teknolojik gelişmelerle birlikte, veri odaklı yaklaşımlar artık daha hızlı ve bilinçli karar vermeyi desteklemektedir. İstatistiksel ve makine öğrenimi (ML) algoritmalarındaki son gelişmeler, mevcut çevresel verilere dayalı tahmin ile modellemeyi mümkün kılarak, sucul böcek popülasyonlarının izlenmesi ve değerlendirilmesinde biyoçeşitlilik endekslerde önemli avantajlar sağlamaktadır (Sonet ve ark., 2025). Ekosistem analizi ve tahmini, ekolojik süreçlerin mekânsal olarak karmaşık ve zamansal olarak ise dinamik yapıya sahip olması sebebiyle; ampirik, istatistiksel ve analitik yöntemlerle çoğu zaman sınırlı kalmaktadır.

Bu durum, değişkenler ve türler arasındaki tipik olarak doğrusal olmayan ilişkilerin ve verilerin normal dağılıma sahip olmamasının nedenlerinden biridir. Bu nedenle, alternatif matematiksel yöntemler geliştirilmektedir. Yapay sinir ağları (ANN); doğrusal olmama, uyarlanabilirlik (yani örneklerden öğrenme), genelleme ve model bağımsızlığı (önceden bir modele ihtiyaç duyulmaması) gibi özel özellikleri nedeniyle ekolojik verilerin analizi ve modelleme için cazip bir alternatif araç sunmaktadır (Schleiter ve ark., 1999).

DNA tabanlı metodolojilerle eş zamanlı olarak, bilgisayar görüşü ve makine öğrenimi alanındaki yeni araştırmalar, çeşitli biyotik grupları otomatik olarak tanımlamaya yönelik yöntemler öneren ve karşılaştıran çok sayıda çalışma sunulmuştur (Simović ve ark., 2024a). Sinirbilimden ilham alan derin öğrenme, makine öğrenme teknikleri alanında çok katmanlı sinir ağlarının bir sınıfıdır (Xu ve Jackson, 2019). Derin öğrenme ve bilgisayar görüşü yöntemleri ile görüntü işleme alanındaki en son gelişmeler, artık sahada manuel gözlemi ve laboratuvarında rutin örnek işlemeyi destekleyecek veya tamamlayacak kadar olgunlaşmıştır (Høye ve ark., 2021; Jaballah ve ark., 2023). Görüntülerle başa çıkmak için özel olarak tasarlanmış derin öğrenme modelleri, görüntülerden veya içlerindeki nesnelere otomatik olarak özellikler çıkarabilir ve uçtan uca öğrenme yoluyla bunları yüksek doğrulukla sınıflandırabilir. Derin öğrenme alanında, CNN, görüntü sınıflandırması için en sık kullanılan algoritmadır. Önceki derin öğrenme mimarilerinin aksine, CNN'nin temel avantajı, insan gözetimi olmadan ilgili özellikleri otomatik olarak tanımlamasıdır (Simović ve ark., 2024a).

Derin öğrenme omurgasız izleme ve biyoçeşitlilik araştırmalarında yavaş bir şekilde uygulanmaya başlanmıştır. Derin öğrenme modelleri, manuel özellik çıkarımına gerek kalmadan örnek veriler üzerinde yinelemeli olarak eğitim yaparak bir veri kümesinin özelliklerini öğrenir. Bu şekilde, derin öğrenme, tahmin için geleneksel istatistiksel yaklaşımlardan niteliksel olarak farklıdır. Görüntülerle başa çıkmak için özel olarak tasarlanmış derin öğrenme modelleri, bir dizi görüntünün veya içindeki nesnelere çeşitli yönlerinin özelliklerini çıkarabilir ve aralarında ayırım yapmayı öğrenebilir. Eğitimli CNN'lerle video veya zaman atlamalı görüntülerde böceklerin otomatik olarak tespit edilmesi ve sınıflandırılmasında büyük bir potansiyel vardır. Derin öğrenme ve bilgisayar görüşü; türlerin tespiti, sayımı, sınıflandırılması ve keşfi için yeni, yüksek verimli sistemler geliştirmektedir. Ayrıca biyomonitöring amacıyla biyokütle gibi fonksiyonel özellikler elde etmek için kullanılarak, ekoloji ve biyoçeşitlilik çalışmalarında uzun süredir devam eden zorlukların ve böcek popülasyonu izlemesindeki acil sorunların çözülmesine yardımcı olabilecek potansiyeldedir (Høye ve ark., 2021; Ong ve Hamid, 2022).

Otomatik görüntü tabanlı taksonomik tanımlama, bitkiler, örümcekler, kelebekler, sivrisinekler, toprak böcekleri, planktonlar, balıklar, mercanlar gibi birçok

grup için kullanılmaktadır ve son yıllarda farklı sucul makro omurgasız gruplarının görsel sınıflandırılması için bilgisayar görüş yöntemleri geliştirilmiştir (Simović ve ark., 2024a). Raitoharju ve ark. (2018), hem kategori sayısı hem de görüntü sayısı bakımından en büyük halka açık makro omurgasız veri tabanını (FIN-Benthic) oluşturmuştur.

Sucul böcekler, tatlı su ekosistemlerinin temel bileşenleridir ve biyolojik çeşitliliği ve ekosistem istikrarını destekleyen ekolojik süreçleri etkilerler. Ayrıştırıcılar olarak organik maddeyi parçalayarak besin döngüsüne katkıda bulunurlar, besin zinciri boyunca temel besin maddelerinin aktarımını kolaylaştırırlar ve birincil üretimi desteklerler. Ayrıca, balıklar, amfibiler ve su kuşları da dahil olmak üzere çok çeşitli su organizmaları için birincil besin kaynağı görevi görerek daha yüksek trofik seviyeleri sürdürürler ve tatlı su besin ağlarının dengesini sağlarlar (Sonet ve ark., 2025; Thaware, 2023). Bollukları ve çeşitlilikleri; habitat yapısı, kaynak mevcudiyeti, biyotik etkileşimler, dağılım mekanizmaları, yaşam öyküsü özellikleri ve tarihsel rastlantılar dahil olmak üzere ekolojik, biyolojik, fiziksel ve kimyasal faktörlerin karmaşık bir etkileşimiyle şekillenir. Sucul böcek popülasyonlarını ve biyoçeşitlilik indekslerini değerlendirmek için kullanılan geleneksel izleme ve değerlendirme teknikleri, alan tabanlı ve laboratuvar yöntemlerinin bir kombinasyonunu içerir. Kepçe ağları, Surber örnekleyicileri ve ayakla yakalama ağları gibi standart örnekleme yöntemleri, çeşitli sucul yaşam alanlarından makro omurgasız örnekleri toplamak için kullanılır. Toplanan bu örnekler daha sonra tanımlanır ve mikroskop altında sayılarak türlerin bileşimi ve bolluğu belirlenir. Teşhis anahtarları ve taksonomik kılavuzlar, böcekleri farklı taksonomik seviyelerde sınıflandırmak için yaygın olarak kullanılır. Bu geleneksel yöntemler etkili olmakla birlikte, önemli miktarda zaman, çaba ve uzmanlık gerektirmeleri sebebiyle büyük ölçekli ekolojik değerlendirmeler için uygulanabilirlikleri sınırlı kalmaktadır (Sonet ve ark., 2025).

Sucul ekosistemlerin etkili bir biçimde izlenmesi, güvenilir ve hızlı taksonomik sınıflandırmaya bağlıdır. Ancak mevcut uygulamalar büyük ölçüde uzman temeline dayalı, zaman alıcı ve ölçeklenebilirliği sınırlı klasik metotlara dayanmaktadır. Gelişen teknoloji ile derin öğrenme tabanlı otomatik sınıflandırma sistemleri, yüksek hacimli veri setini standartlaştırılmış ve tekrarlanabilir bir biçimde işleyebilme potansiyeline sahiptir. Bu nedenle görüntü

tabanlı yapay zekâ uygulamaları yalnızca metodolojik açıdan değil aynı zamanda ekosistem açısından da stratejik bir gerekliliğin parçasını oluşturmaktadır.

Bu çalışma, sucul böceklerin görüntü tabanlı otomatik tanımlanmasında mevcut literatürdeki veri standardizasyonu, taksonomik çözünürlük ve genellenebilirlik eksikliklerini gidermeyi amaçlanmaktadır. Bunun yanı sıra incelenen çalışmalarda derin öğrenme tabanlı CNN mimarilerinin tür/ cins/ altfamilya/familya düzeyindeki sınıflandırma performansı; saha koşullarına bağlı değişkenlerin metodolojik zorluklarının belirlenmesi ve tekrarlanabilir bir otomatik tanıma hattının oluşturulması için kullanılan farklı algoritmaların değerlendirildiği görülmüştür. Özellikle yaşam alanlarının küresel ısınma sebebi ile hızla yok olduğu pek çok sucul böceğin doğal yaşam alanları giderek azalmaktadır. Bununla birlikte, sucul türler değişen yaşam koşullarına uyum sağlamaya çalışmakta ve buna bağlı olarak türlerde çeşitli morfolojik ve fizyolojik değişimler meydana gelmektedir. Bu da türlerin klasik metotlarla sınıflandırılmasında çeşitli zorluklara sebep olmaktadır. Bütün bu veriler ışığında sucul böceklerin tür tanımlanmasında yapay zekâ destekli karar destek sistemlerinin geliştirilmesi büyük bir ihtiyaç haline gelmiştir.

Materiyal ve Metod

Bu derleme; derin öğrenme, sucul böceklerin biyomonitöring çalışmaları, CNN ve görüntü tabanlı taksonomik sınıflandırma anahtar kelimeleri temel alınarak güncel literatürde bildirilen çalışmaların analiz edilmesi ile hazırlanmıştır. Buna göre çalışmalar; görüntü tabanlı taksonomik sınıflandırma, ekolojik tabanlı tahmin ve bolluk modelleme ve Türkiye’de böcekler üzerine yapılan derin öğrenme uygulamaları olmak üzere üç ana başlık altında toplanmıştır. Her çalışma; veri seti büyüklüğü, kullanılmış olan mimari algoritma ve performans metriği açısından karşılaştırılmalı olarak değerlendirilmiştir.

Sucul Böcek Sistematiğinde Derin Öğrenme Metotlarının Kullanımına Ait Örnekler

Görüntü Tabanlı Taksonomik Sınıflandırma

Biyolojik izleme için toplanan sucul taksonların genç yaşam evrelerini kullanarak tür düzeyinde tanımlama yapmak oldukça zordur. Güvenilir tanımlamanın zorluğu özellikle bilinmeyen taksonlar için, karmaşık ve zaman alıcı bir tanımlama sürecine ihtiyaç gerektirmekte, biyoçeşitlilik ve koruma çalışmalarında

bu türler sıklıkla değerlendirme dışında bırakılmaktadır (Milošević ve ark., 2020). Derin öğrenme sinir ağları, su altı deniz örneklerinin sınıflandırılmasından (balıklar, zooplankton ve mercanlar gibi) böcekler (güveler ve karıncalar gibi) ve büyük memelilere kadar çok çeşitli hayvan taksonlarında model performansını büyük ölçüde geliştirmiştir (Wäldchen ve Mäder, 2018). CNN mimarisinin en büyük avantajı, manuel denetime ihtiyaç duymadan kendi kendine öğrenme ve kendi kendine organize olma yeteneğidir (Simovic ve ark., 2024b). Yapay sinir ağları (ANN) modellerinin su kalitesi dinamikleri, bentik makro omurgasızlarla kimyasal ve hidromorfolojik habitat özelliklerinin biyolojik gösterimi ve sucul böceklerin popülasyon dinamiklerinin tahmininde uygulanabilirliği klasik istatistiksel modellerle kıyaslandığı zaman ANN’nin daha yüksek oranlarda doğru sonuç verdiği görülmüştür (Schleiter ve ark., 1999).

Bilgisayar görüşü ile derin öğrenme algoritmaları, özellikle yeni nesil böcek izleme araçlarının tasarımında, böcek taksonomistleri için böcek verilerini toplamak adına mükemmel bir alternatiftir. DL algoritmaları, sinir ağı katmanlarında özellik çıkarma ve sınıflandırma katmanlarından oluşur ve otomatik sistemin uçtan uca tanıma görevlerini gerçekleştirmesine olanak tanır. DL, destek vektör makinesi, karar ağacı ve lojistik regresyon yöntemleri gibi diğer makine öğrenme algoritmalarına göre avantajlara sahiptir. Ong ve Hamid (2022); böceklerin taksonomik sıralarına (takım, aile ve cins) göre sınıflandırma görevlerini tasarlayarak sınıflandırmada dört derin öğrenme modelinin (InceptionV3, VGG19, MobileNetV2 ve Xception) performanslarını karşılaştırmışlardır. Sonuç olarak, farklı taksonomik sıraların yüksek performanslı modeller oluşturmak için farklı derin öğrenme algoritmaları gerektirdiğini gözlemlemişlerdir. Bu da otomatik sistematik bir sınıflandırma hattının tasarımının farklı algoritmaların entegrasyonunu gerektirdiğini ortaya koymuştur.

Milošević ve ark. (2020); CNN kullanımına dayalı bir sınıflandırma yöntemi kullanarak Chironomidae familyasına ait türleri tanımlamıştır. Gelecekteki biyolojik izleme çalışmalarında kullanılmak üzere yüksek taksonomik çözünürlüğe sahip göstergeleri üretmek amacıyla; filogenetik olarak ilişkili taksonları kapsayan kironomid görüntü veri kümelerini kullanarak derin öğrenme modelleri oluşturmuşlar, CNN’ler tarafından seçilen morfolojik özellikleri belirleyerek bunları geleneksel tanımlama belirteçleriyle karşılaştırarak modelin doğruluğunu

taksonomik çözünlük tanımlayıcıları ile test etmişlerdir. Yapay sinir ağının eğitilmesinin ardından, ağın eğitim aşamasında görmediği görüntülerde tür düzeyinde tanımlama doğruluğu %99,5'e ulaşırken, cins ve alt familya düzeyinde tüm görüntüler doğru şekilde sınıflandırılmıştır.

Hoye ve ark. (2022); omurgasız örneklerinin görüntü tabanlı sınıflandırılması ve biyokütle tahmini için geliştirilen BIODISCOVER görüntüleme sistemini kullanarak, eğitim verisi miktarı arttıkça sınıflandırma doğruluğunun nasıl arttığını incelemişlerdir. Tatlı su makro omurgasızlarının 16 taksonunun her birinden 60 örnekten oluşan dengeli bir veri seti kullanılarak, bir CNN sınıflandırma performansının, eğitim için kullanılan örnek sayısı arttıkça bireysel taksonlar ve genel topluluk için nasıl arttığı sistematik olarak ölçümlenmiştir. CNN (EfficientNet-B6) her taksonun 50 örneği üzerinde eğitildiğinde %99,2'lik çarpıcı bir sınıflandırma doğruluğu göstermiş ve ayrıca daha az veri üzerinde eğitilen modellerin daha düşük sınıflandırma doğruluğunun, aynı taksonomik düzene yerleştirilen morfolojik olarak benzer türler için özellikle belirgin olduğunu ortaya koymuşlardır. Eğitim için sadece 15 örnek kullanıldığında bile, sınıflandırma doğruluğu %97'ye ulaşmıştır.

Milosavljević ve ark. (2021); DL tabanlı bir tür tanımlama yöntemi geliştirilmesi için, mevcut çeşitli kamuya açık veri kümeleri (FIN-Benthic, STONEFLY9 ve EPT29) ve Chironomidae veri kümeleri (CHIRO10) üzerinde değerlendirmeler yapmıştır. Önerilen yöntem, nispeten küçük bir veri kümesi üzerinde eğitim yapıldığında sağlamlığı artırmak için kullanılan üç DL tekniğine dayanmaktadır: transfer öğrenme, veri artırma ve özellik düşürme. Transfer öğrenmeyi, ImageNet 2012 veri kümesi üzerinde önceden eğitilmiş bir ResNet-50 derin evrimsel sinir ağı (CNN) kullanılarak uygulanmıştır. Sonuçlar, orijinal FIN-Benthic, STONEFLY9 ve EPT29 katkılarına kıyasla önemli bir iyileşme göstermekte ve örnek başına birden fazla görüntü olduğunda doğrulukta önemli bir artış olduğunu doğrulamıştır.

Đurđević ve ark. (2023); chironomid larvalarının morfolojileri ile beslenme davranışı arasındaki ilişkiyi belirlemek için Chironomidae larvalarının ağız parçalarına (mandibula) uygulanan geometrik morfometrik analiz (GMA), derin öğrenme CNN ve bilgisayar görüşü (derin CNN) kullanımını incelemişlerdir. Farklı cinslerden, alt familyalardan ve Fonksiyonel Beslenme Gruplarından (FFG) 23 farklı Chironomidae larva taksonunun çene

morfolojisindeki değişkenliği belirlenmiştir. GMA kullanılarak yapılan analiz, incelenen beş farklı FFG'nin, şekil ve boyut bakımından önemli ölçüde farklılık gösteren farklı çene özelliklerine sahip olduğunu göstermiştir. Çalışmada 23 taksonu %92,31 doğrulukla otomatik olarak ilgili FFG'lerine sınıflandırabilen derin bir CNN modeli oluşturulmuştur. Derin evrimsel sinir ağı (CNN) modellerine üç ek tür daha ekleyerek, otomatik sınıflandırmanın taksonomik tanımlamadan bağımsız olarak örneklerin özelliklerini doğrudan ve otomatik olarak tanımlayıp tanımlayamayacağı test edilmiştir. Derin CNN süreci, hem taksonomik tanımlama hem de belirli bir taksonun beslenme özelliği hakkındaki önceki bilgilerle ilgili verilerden kaçınarak, tüm durumlarda taksonları çene özelliklerine göre doğru şekilde sınıflandırmıştır.

Başka bir çalışmada, evrimsel sinir ağları kullanılarak *Aedes* (Diptera: Culicidae) cinsine ait yedi türün yalnızca kanat resimleri kullanılarak tür teşhisleri yapılmaya çalışılmıştır. Veri seti, yedi *Aedes* türünden 1155 kanat görüntüsünün yanı sıra farklı (*Aedes* olmayan) sivrisineklerden 554 kanattan oluşmuştur. Bir CNN, *Aedes* cinsi sivrisinekler ve diğer sivrisinek türleri arasında ayırım yapmak ve yedi *Aedes* türünü gri tonlamalı ve RGB görüntülere göre sınıflandırmak için eğitilmiştir. Görüntü işleme, veri artırma, eğitim, doğrulama ve test, derin öğrenme çerçevesi PyTorch kullanılarak Python'da gerçekleştirilmiştir. En iyi performans gösteren CNN konfigürasyonu, *Aedes* cinsine ait sivrisinek türlerinden ayırt etmek için %99'luk bir makro F1 puanı elde etmiştir. *Aedes* türünü tahmin etmek için kullanılan makro F1 puanının ortalaması, gri tonlamalı görüntülerde %90, RGB görüntülerde ise %91 olarak bulunmuştur (Sauer ve ark., 2024).

Optik veya akustik görüntüleme, sinir ağlarıyla birleştirildiğinde, ekologlar tarafından hayvan davranışlarını ve hareketlerini, bireysel kimliği, popülasyon dinamiklerini ve türlerin morfolojisini ve çeşitliliğini incelemek için yaygın olarak kullanılmaktadır. Odaklanılan taksonların kimliğine ve yaşam alanlarına (yani, sucul veya karasal) bağlı olarak, görüntü yakalama ve işleme yöntemleri buna göre uyarlanır. Örneğin, akustik kameralar kullanılarak yapılan video takibi, esas olarak denizanası da dahil olmak üzere büyük sucul organizmaların incelenmesinde kullanılır. Plankton ve bentik makro omurgasızlar gibi daha küçük sucul organizmaların, yerinde veya laboratuvarında kullanılan görüntüleme

cihazları ile elde edilen görüntüleri ise optik fotoğraf tanımlama yöntemiyle incelenmektedir. Bilgisayar görüşü kullanılarak makro omurgasızların incelenmesi henüz başlangıç aşamasındadır ve yıkıcı örnekleme, düşük sinyal-gürültü oranları ve mevcut birçok algoritma arasından model algoritması seçmenin karmaşıklığı gibi birçok zorlukla karşı karşıyadır. Bu zorlukların üstesinden gelmek için, burada canlı sucul makro omurgasızların izlenmesi, yani morfolojik tür düzeyinde tespiti ve tanımlanması için 'MacroNet' olarak adlandırılan yeni bir çerçeve önerilmiştir. Bu çerçeve, geliştirilmiş bir RetinaNet modeline dayanmaktadır. Orijinal algoritmanın karakterizasyon özelliğini geliştirmek için ön işleme adımları uygulanarak görüntüler, küçük makro omurgasızları daha iyi tespit etmek ve tanımlamak için sabit boyutlu parçalara ayrılır. Parçalar daha sonra modele girdi olarak verilir ve ortaya çıkan sınırlayıcı kutu oluşturulur. Orijinal RetinaNet modelinin yerelleştirme doğruluğunu artırmak için, standart kayıp fonksiyonunun yerine, tam kesişim/birleşim kaybı, regresyon kaybı olarak entegre edilmiştir. Deneysel sonuçlar, MacroNet'in veritabanında orijinal RetinaNet modelinden daha iyi performans gösterdiğini ve takson kimliğine bağlı olarak ortalama %74,93 ortalama hassasiyet elde edebildiğini göstermiştir. Veritabanındaki taksonlar, türden takıma kadar çeşitli taksonomik seviyelerde tanımlanmıştır (Jaballah ve ark., 2023).

Ekolojik Tabanlı Tahmin ve Bolluk Modelleme

Simovic ve ark. (2024b) yapmış oldukları çalışmada sucul ekosistemlerde biyomonitör olarak kullanılan Ephemeroptera, Plecoptera ve Tricophtera takımlarına ait toplam 90 EPT taksonunun derin öğrenme teknikleri ile tanımlanması için algoritma geliştirmişlerdir. Buna göre her takson için 21 ila 300 arasında değişen görüntünün yer aldığı (toplam 16.650) veri tabanı oluşturulup eğitim tamamlandıktan sonra, bu taksonları %98,7 doğrulukla uygun taksonomik kategorilerine otomatik olarak sınıflandırabilen bir evrişimsel sinir ağı modeli oluşturmuşlardır.

Theivaprakasham ve ark. (2022), Odonata takımına ait 256 türden oluşan ve 54.176 görüntü içeren kapsamlı bir veri seti üzerinde farklı derin öğrenme mimarilerini karşılaştırmıştır. Transfer öğrenme yaklaşımı kullanılarak AlexNet, DenseNet (121, 161, 201), ResNet (18, 101, 152), SqueezeNet v1.1 ve VGG19 modelleri değerlendirilmiştir. Sonuçlar, model performansının hem mimariye hem de giriş

çözünürlüğüne bağlı olarak değiştiğini göstermiştir. DenseNet161 (450×450 px) en yüksek Top-1 doğruluğunu (%93,53) sağlarken, ResNet152 (224×224 px) en yüksek Top-3 doğruluğunu (%98,07) elde etmiştir. En yüksek Top-5 doğruluğu (%98,85) DenseNet121 ve ResNet152 modellerinde gözlenmiş, en yüksek F1 skoru ise DenseNet201 (550×550 px) ile (%86,17) rapor edilmiştir. Buna karşılık SqueezeNet v1.1 en düşük performansı göstermiştir. Bu bulgular, yüksek çözünürlüklü girişler ve derin mimarilerin, çok sınıflı entomolojik veri setlerinde daha üstün sınıflandırma performansı sağlayabileceğini ortaya koymaktadır.

Edia ve ark. (2010), Güneydoğu Fildişi sahillerinde beş ana sucul böcek takımının (Diptera, Ephemeroptera, Coleoptera, Trichoptera ve Odonata) modellenmesi için yapay sinir ağı (ANN) ve özdüzenleyeci harita (SOM) algoritmalarını kullanmışlardır. Bu, örnekleme alanlarının yerel çevresel durumuyla esas olarak ilgili kümelerin belirlenmesine olanak sağlamıştır. Daha sonra, beş böcek takımının zenginliğini tahmin etmek için, Geri Yayılım algoritması (BP) ile eğitilmiş çok katmanlı algılayıcı sinir ağı (MLP) kullanarak, alanların çevresel özelliklerini değerlendirilmiştir. BP, Diptera ve Trichoptera için 0,90, Coleoptera ve Odonata için 0,84, Ephemeroptera için 0,69 oranları ile yüksek tahmin edilebilirlik göstermiştir.

Bir diğer çalışmada, Orta Almanya'daki Breitenbach'ta *Baetis rhodani* ve *Baetis vernus* (Ephemeroptera) türlerinin bolluğunu tahmin etmek için uzun vadeli bir tür ve çevresel değişken veri setini klasik yöntemleri ve yapay sinir ağlarını karşılaştırarak belirlemeye çalışılmıştır. İstatistiksel yöntemler ve kanonik uyum analizi, ortaya çıkan böceklerin bolluğunu, larva gelişimleri sırasında değişen çevre koşullarının etkili olduğunu ortaya koymakla birlikte veri setinin sınırlı kaldığını göstermiştir. Alternatif olarak kullanılan yapay sinir ağları kullanarak hedef ayda tür bolluğunu tahmin etmek için önceki 12 ayın yağış (P), deşarj (D), su sıcaklığı (T) ve bolluk (A) verilerinin tümü kullanılmıştır. Sonuç olarak yapay sinir ağı modellerinin kullanımının türlerin dağılımında etkili olan çevre faktörünün belirlenmesinde daha yüksek oranlara doğru sonuç verdiğini ortaya koymuştur (Wagner ve ark., 2000).

Park ve ark. (2003), ekolojik verilerin analizi için pratik yaklaşımlar önermek amacıyla, denetimli ve denetimsiz öğrenme algoritmaları olmak üzere iki yapay sinir ağı kullanmışlardır. Modelleri uygulamak için dört ana sucul böcek takımı (Ephemeroptera,

Plecoptera, Trichoptera ve Coleoptera, yani EPTC) ve dört çevresel değişken (yükseklik, akarsu derecesi, kaynağa uzaklık ve su sıcaklığı) kullanılmıştır. İlk olarak, EPTC zenginliğini kullanarak örnekleme alanlarını sınıflandırmak için denetimsiz bir yapay sinir ağı olan öz düzenleyeci harita uygulaması (SOM) uygulanmıştır. İkinci olarak, dört çevresel değişken kümesi kullanılarak EPTC zenginliğini tahmin etmek için denetimli bir yapay sinir ağı olan geri yayılım algoritması (BP) uygulanmıştır. SOM örnekleme alanları, biyolojik özellikler ve çevresel değişkenler arasındaki ilişkileri analiz etmede uygun bulunmuştur. Veri kümelerindeki ilişkiler dikkate alındıktan sonra, dört çevresel değişken kümesiyle EPTC zenginliğini tahmin etmek için kullanılan BP, yüksek bir doğruluk göstermiştir.

Türkiye’de Entomoloji Alanında Derin Öğrenme Metotları ile Yapılan Uygulamalar

Türkiye’de entomoloji alanında derin öğrenme uygulamaları sınırlı sayıda olup çoğunlukla tarımsal zararlıların sınıflandırılmasına odaklanmıştır. Sucul makro omurgasızlar ve biyomonitöring kapsamında tür düzeyinde CNN tabanlı sistematik çalışmalar bulunmamaktadır. Bunun yanı sıra standardize edilmiş bir görüntü veri tabanı eksikliği dikkat çekmektedir. Bu durum, Türkiye ekosistemleri için ölçeklenebilir ve otomatik biyomonitöring sistemlerinin geliştirilmesini gerekli kılmaktadır. Bunun yanı sıra makine öğrenme tekniklerine bağlı olarak geliştirilmiş olan modellerde daha büyük veri setleri daha hızlı şekilde analiz edilebilmektedir. Bu da özellikle zararlı olan böcek türlerine karşı geliştirilecek olan mücadele ve koruma çalışmalarında; daha az pestisit kullanılması sağlanarak sürdürülebilir ekosistem ve sürdürülebilir tarım politikalarına katkı sağlayacaktır.

Türkiye’deki Kastamonu Orman Bölge Müdürlüğü’ne bağlı Daday bölgesinde Kırım çam ormanlarıyla kaplı alanda, çam ağacı zararlısı olan çam kabuk böceğinin (*Ips sexdentatus*) yakalanma durumu sınıflandırılmış ve yakalanan birey sayısı derin sinir ağları modelleme yöntemleriyle tahmin edilmeye çalışılmıştır. Hedef türün yetişkinlerinin durumunu sınıflandırmak ve kaç yetişkinin yakalanacağını tahmin etmek için Python programında Keras kütüphanesi kullanılarak DNN modelleri geliştirilmiştir. Hedef türün yakalanma zamanlarına ve bu zamanlardaki sıcaklık, nem, rüzgâr hızı ve yağış değişkenlerine bağlı olarak DNN modelleri oluşturularak yenilikçi bir yaklaşım

geliştirilmesi amaçlanmıştır. DNN-1 modeli, türün yakalanma durumunu yüksek hassasiyetle sınıflandırmaktadır. DNN-2 modelleri, DNN-1 modelinin sınıflandırma sonucunu doğrulamaktadır. DNN-3 modeli, hedef türün yakalanma sayısını tahmin etmektedir. Çalışma, yerel ve ülke düzeyinde DNN kullanarak hedef türler için yapılan ilk modelleme araştırması olma özelliği taşımaktadır (Özcan ve ark., 2022).

Uzun ve ark. (2022), yapışkan tuzak yöntemi ile yakalanmış olan meyve sineklerinin tür tespitlerinin bölge tabanlı evrimsel sinir ağı (Fastter R-CNN) modeli kullanarak yeniden tanımlamışlardır. Yapışkan tuzağa meyve sinekleri ve diğer böcekler yapıştıkları zaman kurtulmak için hareket ettiklerinden; teşhiste kullanılan kanat, bacak ve vücut parçalarında bozulmalar olmaktadır. Derin öğrenme sistemi ile bu bozulmuş olan bütün resimler değerlendirildiğinde tür teşhislerini %94 oranında doğru tespit ettiği görülmüştür.

Tarımsal üretimi olumsuz etkileyen ve küresel gıda güvenliğinde kritik rol oynayan zararlı böcek türlerini tespit etmek için tasarlanmış yeni bir hibrit evrişim ve görsel dönüştürücü modeli (ConvViT) Utku ve ark. (2025) tarafından değerlendirilmiştir. Çalışmada 15 farklı böcek türünün görüntülerinden oluşan bir veri kümesi kullanılarak, önerilen yaklaşım, geleneksel evrişimsel sinir ağlarının güçlü yönlerini görsel dönüştürücü (ViT) mimarileriyle birleştirmiştir. Sonuçlar, ConvViT modelinin EfficientNetB0, DenseNet201, ResNet-50, VGG-16 ve bağımsız ViT gibi yaygın olarak kullanılan kıyaslama mimarilerinden daha iyi performans gösterdiğini ve %93,61’lik bir sınıflandırma doğruluğuna ulaştığını göstermiştir. Ölçeklenebilir yapay zekâ uygulamalarının, zararlıların erken ve doğru bir şekilde tanımlanmasını sağlayarak, yoğun pestisit kullanımına olan ihtiyacı azaltarak sürdürülebilir tarım uygulamalarını destekleyeceği bildirilmiştir.

Almryad ve Kutucu (2020); Türkiye’de yayılış gösteren 104 kelebek türüne ait toplam 44.659 görsel toplamışlardır. Birçok türün az sayıda görüntü örneği olduğundan, 10 tür içeren 17.769 kelebekten oluşan saha tabanlı bir veri seti oluşturulmuştur. Kelebek türlerinin tanımlanması için evrişimsel sinir ağları kullanılmıştır. Üç farklı ağ yapısı kullanılarak elde edilen deneysel sonuçlar karşılaştırıldığında, 10 yaygın kelebek türünü başarıyla tanımladığını bildirilmiştir.

Kırmızı palmye böceği (RPW), palmye ağaçlarına saldıran ve varlıklarını tehdit eden istilacı bir zararlı

böcektir. Buna göre, RPW son yirmi yılda önemli ve büyük ekonomik kayıplara neden olmuştur. Saleh ve Ertunç, 2022; görüntü işlemeyle dayalı sinir ağı modeli geliştirerek kırmızı palmye böceklerini tanımlamaya çalışmışlardır. Modelde görüntü ön işleme (görüntü iyileştirme), özellik çıkarma (doku ve renk momentleri özellikleri) ve sınıflandırma (yapay sinir ağı) basamakları oluşturulmuş, 913 görüntüden oluşan bir veri seti kullanılmıştır. Önerilen model %92,22 oranlarında kırmızı palmye böceğini doğru teşhis etmiştir.

Şahin ve ark. (2023); Türkiye’de ve dünyanın çeşitli yerlerinde dağılışı gösteren 11 farklı bitki zararlısı çekirge türünü evrimsel sinir ağı modelleri kullanarak sınıflandırmışlardır. Çalışmada 11 farklı çekirge türünün otomatik olarak sınıflandırılması için açık kaynaklı derin öğrenme kütüphanesi olan Keras kütüphanesinde bulunan ve görüntü sınıflandırmasında yaygın olarak kullanılan VGG16, VGG19, ResNet50, DenseNet121, EfficientNet, MobileNet kullanmışlardır. Ayrıca, ülkemizde bitki zararlısı olan 11 çekirge türüne ait GHCD11 adında yeni bir veri seti oluşturmuşlardır. Öğrenme aktarımı ile GHCD11 veri seti üzerinde yapılan deneysel çalışmalar sonucunda, %95 ile %99 aralığında kayda değer sınıflandırma doğrulukları elde etmişlerdir.

Kıraç ve Tokmak (2022); Ichneumonidae familyasına ait alt familyaların otomatik sınıflandırılması amacıyla derin öğrenme temelli bir model benimsemişlerdir. Bu kapsamda evrimsel sinir ağı mimarilerinden ResNet-50 modeli kullanmışlardır. Gerçekleştirilen deneysel analizler sonucunda modelin genel sınıflandırma doğruluğu %91,35 olarak hesaplanmıştır.

Son yıllarda makine öğrenme tekniklerinin gelişmesi; bu tekniklerin, entomoloji alanında da sıklıkla tercih edilen metotlardan birisi haline getirmiştir. Küçüktopçu ve ark. (2023); yapmış oldukları çalışmada yapay sinir ağlarının entomoloji alanında böceklerin tür teşhisinden, böcek popülasyonlarının takibine, zararlı olan böceklerin belirlenmesine ve davranış modellerinin geliştirilmesine oldukça büyük bir skalada kullanıldığını bildirmişlerdir. Özellikle tarım alanlarında yapılan ölçümlere dayalı büyük veri setlerinin hızlı ve hassas bir şekilde değerlendirilebileceğini vurgulamışlardır.

Yapılmış olan mevcut çalışmalar, derin öğrenme ve özellikle CNN tabanlı modellerin sucul böceklerin ve makro omurgasızların görüntü temelli tanımlanmasında oldukça yüksek oranlarda doğruluk

oranlarına sahip olduğunu açıkça göstermektedir. Ancak ilgili literatür incelendiğinde çalışmaların büyük bir kısmının sınırlı sayıda takson ya da belli veri setleri üzerinde olduğu görülmektedir. Özellikle gerçek saha koşullarında farklı habitatlarda çekilmiş farklı ışık ve çözünürlüklere ait daha geniş ölçekli ve herkese açık veri tabanı sınırlı olup Türkiye’de herhangi bir veri tabanı bulunmamaktadır. Yine tahminlerin yüksek doğruluk oranlarının familya, takım gibi üst taksonomik seviyelerde olduğu rapor edilmiştir. Özellikle morfolojik olarak benzer olan ikiz türlerde algoritmaların uygulanmasında performans düşüşleri gözlenmektedir. Bu da uygulanan model ve algoritmaların genellenebilirliğini etkilemektedir. Yine farklı mimarilerin (ResNet, DenseNet, EfficientNet, ViT vb.) performansları çoğu çalışmada tekil veri setleri üzerinde değerlendirilmiştir. Ancak farklı taksonomik seviyelerde, veri dengesizliği koşullarında ve farklı giriş çözünürlüklerinde sistematik karşılaştırmalar sınırlıdır.

Sonuç

Türkiye’de sucul ekosistemlere ait sucul böceklerin sınıflandırılmasına ait standardize edilmiş görüntü veri tabanları ve CNN tabanlı sistematik biyomonitöring çalışmaları oldukça sınırlıdır. Ülkemizdeki derin öğrenme metotlarının böcek grupları arasındaki uygulama alanlarına bakıldığında daha çok tarım ya da orman zararlısı türler üzerine olduğu görülmektedir. Oysa sucul böcekler yayılışı gösterdikleri farklı sucul habitatlarda meydana gelen değişimlerden direkt etkilenmekte olan temel biyolojik göstergelerdir. Bu canlıların bolluk ve yayılışlarında meydana gelen değişimler, yer almış oldukları ekosistemlerde meydana gelen bozulmaların doğrudan göstergeleri olma özelliği taşımaktadır.

Sucul böcek sistematğinde yapay zekâ uygulamalarının kullanımının kısıtlı olması, yalnızca metodolojik bir eksiklik değil aynı zamanda ekosistemlerin korunması ve sürdürülebilirliği açısından da önemli bir boşluk oluşturmaktadır. Dolayısıyla, sucul böcek sistematğinde yerel ekosistemlerde habitat bozulmalarından kaynaklı tür kayıplarının önüne geçilmesi adına otomatik tanıma sistemlerinin geliştirilmesi, standardize edilmiş ulusal bir görüntü veri tabanı oluşturulması ve derin öğrenme metotlarının geliştirilmesi önemli bir ihtiyaç haline gelmiştir.

Derin öğrenme tekniklerindeki gelişmeler, böcek sistematğinde tür tanımlama süreçlerinin geliştirilmesine katkılar sunmaktadır. Bunun yanı sıra

gelecekte yapılacak olan derin öğrenme temelli görüntü tanıma sistemlerinin farklı gruplar ve farklı ekolojik bölgelerden elde edilecek daha kapsamlı veri setlerinin kullanılması ile uygulanabilirliği ve güvenilirliği artacaktır. Bu noktada yapay zekâ uygulamaları destekli taksonomik çalışmaların sürdürülmesi hem biyoçeşitlilik hem de ekolojik izleme çalışmalarının faaliyetlerinin güçlendirilmesi açısından büyük katkılar sunacaktır.

Etik İzin

Bu çalışma için etik kurul belgesine ihtiyaç duyulmamaktadır.

Çıkar Çatışması

Yazar herhangi bir çıkar çatışması beyanında bulunmamıştır.

Finansal Destek

Bu çalışma için herhangi bir kişi ya da kurum tarafından finansal destek sağlanmamıştır.

References

- Adebayo, A. S. (2025). AI driven species recognition and digital systematics: Applying artificial intelligence for automated organism classification in ecological and environmental monitoring. *International Journal of Research Publication and Reviews*, 6(2), 31–49.
- Almryad, A. S., & Kutucu, H. (2020). Automatic identification for field butterflies by convolutional neural networks. *Engineering Science and Technology, an International Journal*, 23(1), 189–195. <https://doi.org/10.1016/j.jestch.2019.07.003>
- Đurđević, A., Medeiros, A., Žikić, V., Milosavljević, A., Savić-Zdravković, D., Lazarević, M., & Milošević, D. (2023). Mandibular shape as a proxy for the identification of functional feeding traits of midge larvae (Diptera: Chironomidae). *Ecological Indicators*, 147, 109908. <https://doi.org/10.1016/j.ecolind.2023.109908>
- Edia, E. O., Gevrey, M., Ouattara, A., Brosse, S., Gourène, G., & Lek, S. (2010). Patterning and predicting aquatic insect richness in four West-African coastal rivers using artificial neural networks. *Knowledge and Management of Aquatic Ecosystems*, 398, 06. <https://doi.org/10.1051/kmae/2010031>
- Høye, T. T., Ärje, J., Bjerge, K., Hansen, O. L., Iosifidis, A., Leese, F., & Raitoharju, J. (2021). Deep learning and computer vision will transform entomology. *Proceedings of the National Academy of Sciences*, 118(2), e2002545117. <https://doi.org/10.1073/pnas.2002545117>
- Høye, T. T., Dyrmann, M., Kjær, C., Nielsen, J., Bruus, M., Mielec, C. L., & Melvad, C. (2022). Accurate image-

- based identification of macroinvertebrate specimens using deep learning—How much training data is needed? *PeerJ*, 10, e13837. <https://doi.org/10.7717/peerj.13837>
- Jaballah, S., Garcia, G. F., Martignac, F., Parisey, N., Jumel, S., Roussel, J. M., & Dézerald, O. (2023). A deep learning approach to detect and identify live freshwater macroinvertebrates. *Aquatic Ecology*, 57(4), 933–949. <https://doi.org/10.1007/s10452-023-10040-6>
- Kıraç, A., & Tokmak, M. (2022). Konvolüsyonel sinir ağları ile Ichneumonidae (Hymenoptera) alt familyalarının belirlenmesi. *Science and Technique in the 21st Century*, 9(18), 85–88.
- Küçüktopcu, Y., Saruhan, İ., Tuncer, C., & Akça, İ. (2023). Entomolojide yapay sinir ağlarının kullanımı. *Ordu Üniversitesi Bilim ve Teknoloji Dergisi*, 13(2), 131–145.
- Milošević, D., Milosavljević, A., Predić, B., Medeiros, A. S., Savić-Zdravković, D., Piperac, M. S., & Leese, F. (2020). Application of deep learning in aquatic bioassessment: Towards automated identification of non-biting midges. *Science of the Total Environment*, 711, 135160. <https://doi.org/10.1016/j.scitotenv.2019.135160>
- Milosavljević, A., Milošević, Đ., & Predić, B. (2021). Species identification for aquatic biomonitoring using deep residual CNN and transfer learning. *Facta Universitatis, Series: Automatic Control and Robotics*, 20(1), 001–019.
- Montgomery, R. M. (2024). *The evolution of zoological classification: From Linnaean taxonomy to an ecological and interactive framework* [Unpublished manuscript].
- Obach, M., Wagner, R., Werner, H., & Schmidt, H. H. (2001). Modelling population dynamics of aquatic insects with artificial neural networks. *Ecological Modelling*, 146(1–3), 207–217. [https://doi.org/10.1016/S0304-3800\(01\)00307-1](https://doi.org/10.1016/S0304-3800(01)00307-1)
- Ong, S. Q., & Hamid, S. A. (2022). Next generation insect taxonomic classification by comparing different deep learning algorithms. *PLOS ONE*, 17(12), e0279094. <https://doi.org/10.1371/journal.pone.0279094>
- Özcan, G. E., Karacı, A., & Enez, K. (2022). Application of deep neural networks in modeling the capture of *Ips sexdentatus* in pheromone trap. *Environmental Engineering & Management Journal*, 21(1). <https://doi.org/10.30638/eemj.2022.008>
- Park, Y. S., Céréghino, R., Compin, A., & Lek, S. (2003). Applications of artificial neural networks for patterning and predicting aquatic insect species richness in running waters. *Ecological Modelling*, 160(3), 265–280. [https://doi.org/10.1016/S0304-3800\(02\)00258-2](https://doi.org/10.1016/S0304-3800(02)00258-2)
- Raitoharju, J., Riabchenko, E., Ahmad, I., Iosifidis, A., Gabbouj, M., Kiranyaz, S., & Meissner, K. (2018). Benchmark database for fine-grained image classification of benthic macroinvertebrates. *Image and Vision Computing*, 78, 73–83. <https://doi.org/10.1016/j.imavis.2018.07.000>

- Saleh, R. A. A., & Ertunç, H. M. (2022). Development of a neural network model for recognizing red palm weevil insects based on image processing. *Kocaeli Journal of Science and Engineering*, 5(1), 1–4. <https://doi.org/10.34088/kojose.946704>
- Sauer, F. G., Werny, M., Nolte, K., Villacañas de Castro, C., Becker, N., Kiel, E., & Lühken, R. (2024). A convolutional neural network to identify mosquito species (Diptera: Culicidae) of the genus *Aedes* by wing images. *Scientific Reports*, 14(1), 3094. <https://doi.org/10.1038/s41598-024-53256-6>
- Schleiter, I. M., Borchardt, D., Wagner, R., Dapper, T., Schmidt, K. D., Schmidt, H. H., & Werner, H. (1999). Modelling water quality, bioindication and population dynamics in lotic ecosystems using neural networks. *Ecological Modelling*, 120(2–3), 271–286. [https://doi.org/10.1016/S0304-3800\(99\)00108-4](https://doi.org/10.1016/S0304-3800(99)00108-4)
- Simović, P., Milosavljević, A., Stojanović, K., Radenković, M., Savić-Zdravković, D., Predić, B., & Milošević, D. (2024a). Automated identification of aquatic insects: A case study using deep learning and computer vision techniques. *Science of the Total Environment*, 935, 172877. <https://doi.org/10.1016/j.scitotenv.2024.172877>
- Simović, P., Milosavljević, A., Stojanović, K., Savić-Zdravković, D., Petrović, A., Predić, B., & Milošević, D. (2024b). The effects of data quality on deep learning performance for aquatic insect identification: Advances for biomonitoring studies. *Water*, 17(1), 21. <https://doi.org/10.3390/w17010021>
- Sonet, S. S., Basak, J. K., Akter, S., Paudel, B., Rumman, R., & Jhan, P. K. (2025). Modeling aquatic insect populations and biodiversity indices in freshwater bodies using machine learning algorithms. *Hydrobiologia*, 1–21. <https://doi.org/10.1007/s10750-025-05781-z>
- Şahin, N., Alpaslan, N., İlçin, M., & Hanbay, D. (2023). Evrişimsel sinir ağı mimarileri ve öğrenim aktarma ile bitki zararlısı çekirge türlerinin sınıflandırması. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 35(1), 321–331.
- Thaware, V. H. (2023). Study of aquatic insects, their role in improving biodiversity and balancing the food web of a freshwater ecosystem at Karadkhed Dam in Nanded, Maharashtra. *Journal of Entomology and Zoology Studies*, 11, 173–176.
- Theivaprakasham, H., Darshana, S., Ravi, V., Sowmya, V., Gopalakrishnan, E. A., & Soman, K. P. (2022). Odonata identification using customized convolutional neural networks. *Expert Systems with Applications*, 206, 117688. <https://doi.org/10.1016/j.eswa.2022.117688>
- Utku, A., Kaya, M., & Canbay, Y. (2025). A new hybrid ConvViT model for dangerous farm insect detection. *Applied Sciences*, 15(5), 2518. <https://doi.org/10.3390/app15052518>
- Uzun, Y., Tolun, M. R., Eyyuboglu, H. T., & Sarı, F. (2022). An intelligent system for detecting Mediterranean fruit fly [medfly; *Ceratitis capitata* (Wiedemann)]. *Journal of Agricultural Engineering*, 53(3). <https://doi.org/10.4081/jae.2022.1333>
- Wagner, R., Dapper, T., & Schmidt, H. H. (2000). The influence of environmental variables on the abundance of aquatic insects: A comparison of ordination and artificial neural networks. *Hydrobiologia*, 422, 143–152. <https://doi.org/10.1023/A:1017094632598>
- Wäldchen, J., & Mäder, P. (2018). Machine learning for image based species identification. *Methods in Ecology and Evolution*, 9(11), 2216–2225. <https://doi.org/10.1111/2041-210X.13075>
- Xu, C., & Jackson, S. A. (2019). Machine learning and complex biological data. *Genome Biology*, 20(1), 76. <https://doi.org/10.1186/s13059-019-1689->