

Konvolüsyonel Sinir Ağları ile Ichneumonidae (HYMENOPTERA) Alt Familyasının Belirlenmesi

Akın Kıracı*¹, Mahmut Tokmak*²

Özet: Teknolojik gelişmeler; akıllı mobil cihazlar, dijital kameralar gibi gereçlerin artmasına ve yaygın olarak kullanımına vesile olmuştur. Bu gelişmeler Derin Öğrenme gibi modern makine öğrenimi yöntemleriyle birlikte biyolojik görüntü verilerindeki artış da beraberinde getirmiştir. Bu hızlı artış, otomatikleştirilmiş tür tanımlaması için araştırmacılara fırsatlar sunmaktadır. Bu çalışmada; Ichneumonidae alt familyalarının belirlenmesi için Derin Öğrenme yöntemlerinden biri olan konvolüsyonel sinir ağlarına odaklanılmıştır. Bu işlem için ResNet-50 konvolüsyonel sinir ağı mimarisi kullanılmıştır. Deneysel çalışmalar sonucunda %91.35 oranında doğruluk elde edilmiştir.

Anahtar Kelimeler: Alt Familya, Ichneumonidae, Konvolüsyonel Sinir Ağları, ResNet-50

Determination of Ichneumonidae (HYMENOPTERA) Subfamilies with Convolutional Neural Networks

Abstract: Technological developments; It has led to the increase and widespread use of devices such as smart mobile devices and digital cameras. These developments have brought about the increase in biological image data along with modern machine learning methods such as Deep Learning. This rapid increase offers researchers opportunities for automated species identification. In this study; Convolutional neural networks, one of the Deep Learning methods, have been focused on to determine Ichneumonidae subfamilies. ResNet-50 convolutional neural network architecture is used for this process. As a result of experimental studies, an accuracy of 91.35% was obtained.

Keywords: Convolutional Neural Networks, Ichneumonidae, Subfamily, ResNet-50

¹**Adres:** Çanakkale Onsekiz Mart Üniversitesi, Teknik Bilimler MYO, Çanakkale, Türkiye

²**Adres:** Burdur Mehmet Akif Ersoy Üniversitesi, Bucak Zeliha Tolunay Uygulamalı Teknoloji ve İşletmecilik Yüksekokulu, Burdur, Türkiye.

***Sorumlu Yazar:** akinkirac@comu.edu.tr

Atıf: Kıracı, A., Tokmak, M. (2022). Konvolüsyonel Sinir Ağları ile Ichneumonidae (HYMENOPTERA) Alt Familyasının Belirlenmesi. 21. Yüzyılda Fen ve Teknik Dergisi, 9(18): 85-88.

1. GİRİŞ

Taksonomi, tür adları ve dağılımları hakkındaki bilgiler bilimsel çalışmalar ve çevresel izleme programları için gerekli olduğundan, biyoçeşitlilik yönetimi için bir mihenk taşıdır (Marques et al., 2018). Ekosistemlerin anlaşılmasındaki ilerleme, kısmen, içinde yaşayan böcekleri bulma ve tanımlama yeteneğimize bağlıdır. Böcekler, gezegenimizdeki biyolojik çeşitliliğin büyük bir bölümünü oluşturur ve nüfusları son yıllarda önemli ölçüde azalmaktadır. Ekosistemdeki besin zincirinin

restorasyonunda önemli bir rol oynayan böceklerin, insanların hayatta kalmasıyla hem doğrudan hem de dolaylı olarak ilişkili oldukları için kolay ve doğru bir şekilde tanımlanmasına da ihtiyaç vardır (Theivaprakasham, 2021). Böceklerde olduğu gibi organizmaların doğru teşhisi, sürdürülebilir tarım, ormancılık ve balıkçılık, zararlı böcekler ve insan hastalıkları ile mücadele, afet yönetimi, biyolojik ürünlerin sürdürülebilir ticareti ve yabancı istilacı türlerin yönetimi için büyük önem taşımaktadır. Bu nedenle tür teşhisi yapabilen sistematikçilere (taksonomistlere) ihtiyaç duyulmaktadır (Tokmak & Şen, 2021).

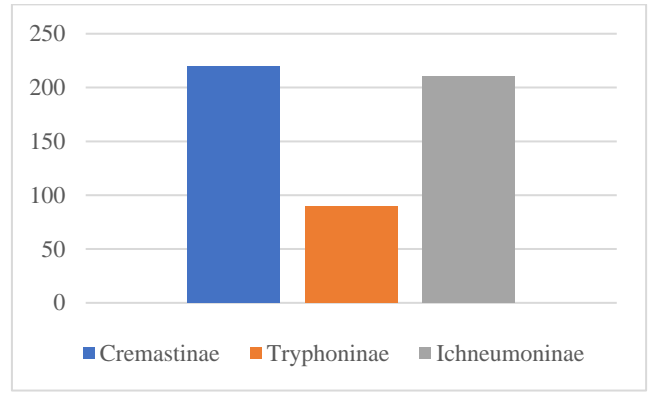
Uzmanlar tarafından tanımlama, örnekleri tanımlamanın tercih edilen yolu olsa da, zeki sistemler, taksonomik tanımlama için alternatif araçlar sağlayabilir ve aynı zamanda, sistematikçiler tarafından gerçekleştirilen rutin tanımlamaların sayısını azaltabilir. Makine öğrenmesi alanındaki gelişmeler, görüntü analizi ile taksonomik tanımlama çalışmalarının önünü açmıştır. Özellikle Derin Öğrenme (Deep Learning: DL) yöntemleri bu alanda sıkça kullanılmaktadır (Barbedo, 2020; Tokmak & Şen, 2021; Wäldchen & Mäder, 2018). Son yıllarda derin öğrenme kullanarak otomatik tür teşhisi üzerinde araştırma yapan çok sayıda çalışma bulunmaktadır (Barbedo, 2020; Marques et al., 2018; Rajeena PP et al., 2022; Theivaprakasham, 2021; Tokmak & Kıraç, 2021; Tokmak & Şen, 2021; Wäldchen & Mäder, 2018). Bu çalışmalarda, derin öğrenme yöntemlerinden biri olan Konvolüsyonel Sinir Ağları (KSA) modelleriyle görüntü işlemeden ses tanımaya kadar çeşitli örüntü tanıma alanlarında başarılı sonuçlar elde edildiği ortaya konulmuştur. KSA, görüntü bölütleme, örüntü tanıma ve sınıflandırma süreçlerinde yaygın olarak kullanılan bir derin öğrenme yöntemi olarak tür teşhisinde de kullanılmaktadır. Bitkiler, suda yaşayan omurgasızlar, memeliler ve böcekler için güvenilir derecede sonuçlar elde edildiği çalışmalarda gösterilmiştir (Chen, Han, He, Kays, & Forrester, 2014; Dyrmann, Karstoft, & Midtby, 2016; Marques et al., 2018).

Bu çalışmada; Ichneumonidae (HYMENOPTERA) familyasının alt türlerini belirlemeye yönelik Konvolüsyonel Sinir Ağları, Resnet-50 mimarisi ile otomatik bir sistematik yöntemi önerilmiştir.

2. MATERYAL VE METOT

Çalışmada kullanılan resimler iNaturalist internet sitesinden indirilmiştir ('iNaturalist', 2022). Dünyanın en popüler doğa uygulamalarından biri olan iNaturalist, California Bilimler Akademisi ve National Geographic Society'nin ortak girişimidir ayrıca çevredeki bitki ve hayvanları insanlar tarafından tanınmasına yardımcı olmayı amaçlamaktadır. Doğa hakkında daha fazla bilgi edinilmesine yardımcı olabilecek bir milyondan fazla bilim adamı ve doğa bilimciden oluşan bir topluluktan yapısına sahiptir. Bu topluluğun üyeleri gözlemlerini kaydedip paylaşarak, doğayı daha iyi anlamak ve korumak için çalışan bilim adamlarına ve doğa gönüllülerine veriler sunmaktadır ('iNaturalist', 2022).


Bu siteden indirilen veriler hazır veri setleri olmadığı için tür isimleri ile arama yapılmış ve çıkan sonuçlar arasından, seçilen resimler indirilmiştir. İndirilen resim dosyaları tasnif edilerek bir veri seti oluşturulmuştur. Oluşturulan veri seti 520 adet resimden oluşmaktadır ve Şekil 1'de gösterilmiştir. Cremastinae için 220 tane resim, Tryphoninae için 90 tane resim, Ichneumoninae için 210 tane resim seçilmiştir.



Şekil 1. Veri seti tür sayıları

Konvolüsyonel Sinir Ağları

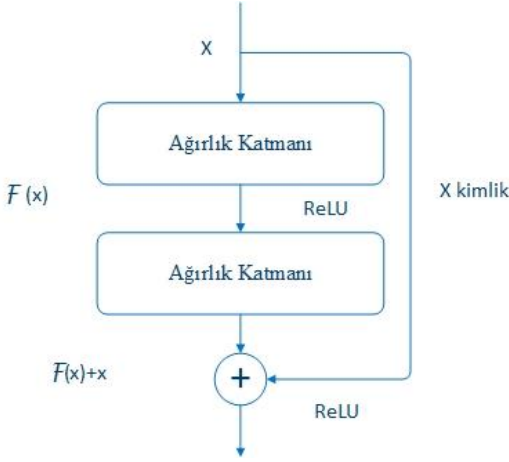
Konvolüsyonel Sinir Ağları (KSA), öğrenme yoluyla kendilerini optimize eden nöronlardan oluşması ve bir tür çok katmanlı algılayıcı olması bakımından geleneksel yapay sinir ağlarına benzemektedir. Şekil 2'de verilen klasik bir KSA, giriş katmanı, çıkış katmanı ve çok sayıda gizli katmandan oluşmaktadır. Gizli katmanlar tipik olarak konvolüsyonel katman, havuzlama katmanı, tam bağlantılı katman ve normalleştirme katmanlarından (normalleştirme katmanı, ReLU) oluşur. Daha karmaşık modeller için ek katmanlar kullanılabilir (Hussain, Bird, & Faria, 2018; O'Shea & Nash, 2015). KSA'da, katmanların en az bir tanesinde konvolüsyon yani filtrelerin giriş verisi üzerinde öznitelik çıkarma amaçlı dolaştırılması işlemi uygulanmaktadır. Ağın ilk katmanlarındaki giriş verisinin üzerinde, filtreler yoluyla öznitelik çıkarımı yapılır. Bunun yanı sıra hesaplama maliyetini azaltmak ve giriş verisinden öğrenilen özniteliklere ait özet verisini diğer katmanlara aktarmak amacıyla boyut düşürme fonksiyonları kullanılır. Sonrasında elde edilen bu öznitelikler tek boyutlu bir vektör haline getirilir ve tam bağlantılı katmana aktarılıp sınıflandırma işlemi gerçekleştirilir (Gülcü & Kuş, 2019).



Şekil 2. Klasik KSA

Yapay sinir ağındaki gizli katman sayısı, görüntü özniteliklerinin çıkarılması için çok önemlidir. Ancak, eklenen katmanların ağ derinliğini artırmasıyla birlikte gradyan kaybolma ve beklenmedik bozulma sorunları ortaya çıkabilmektedir. Bu sorun, kısayol bağlantılarıyla ve eğitimi hızlandıran artık bloklar (Residual block) tarafından başarılı bir şekilde çözülebilmektedir. (Zhang, Li, Zhu, & Du, 2022). Şekil 3'te verilen artık blok yapısında, girişten çıkışa bir bağlantı yapılarak, x değeri $F(x)$ fonksiyonuna eklenmektedir. Ekleme işleminden sonra $F(x)+x$ fonksiyonu

birlikte ReLU aktivasyon fonksiyonundan geçirilmektedir. Böylece önceki katmanlarda eğitilen verilerin bir sonraki katmana daha güçlü olarak iletilmesi amaçlanmaktadır. ResNet, 177 katmanlı bir sinir ağıdır. Bu model, $224 \times 224 \times 3$ boyutunda fotoğraflar üzerinde eğitilmiştir (O'Shea & Nash, 2015; Rajeena PP et al., 2022).



Şekil 3. Artık blok

Bu çalışmada; standart KSA olarak önceden eğitilmiş Resnet-50 mimarisi kullanılmıştır. Modelde verilerin %80'i eğitim için %20'si test için rastgele olarak ayrılmıştır. Learning rate 0.0001 olarak ayarlanmış ve modelde kullanılan epoch değeri 100 olarak belirlenmiştir.

3. BULGULAR

Çalışmada kullanılan; üç alt familyaya ait veri setinde 520 tane resim eğitim için kullanılmış, 104 tanesi test için ayrılmıştır. Kurulan modelde veri seti gerekli klasörlerden okunduktan sonra, veri seti içindeki sınıflardan rastgele seçilen örnek görüntüler Şekil 4'te gösterilmiştir.



Şekil 4. Örnek görüntüler

Önerilen KSA Resnet-50 mimarisi ile kurulan modelde %91.35 doğruluk değerine, %91.35 kesinlik değerine, %91.35 duyarlılık değerine, %91.34 F1-skoru değerine erişilmiştir ve Tablo 1'de gösterilmiştir.

Tablo 1. ResNet-50 performans ölçütleri

	Kesinlik	Duyarlılık	f1-skor	Sayı
Cremastinae	0.9302	0.9091	0.9195	44
Tryphoninae	0.8333	0.8333	0.8333	18
Ichneumoninae	0.9302	0.9524	0.9412	42
Doğruluk			0.9135	104
Ortalama	0.9135	0.9135	0.9134	104

4. TARTIŞMA VE SONUÇLAR

Önerilen çalışma aynı familyanın aynı cinsine ait birbirinden ayrılması uzmanlar tarafından bile güçlüklerle yapılabilen, aynı habitatta aynı anda karşılaşılabileceğimiz üç böcek alt familyası üzerine yapılmıştır. Deneysel çalışmalar sunucunda %91.35'lik doğruluk değeri, %91.35 kesinlik değeri, %91.35 duyarlılık değeri, %91.34 F1-skoru değerlerine erişilmiştir. Elde edilen görüntülerin arka planı, fotoğraflardaki ışık koşulları ve resmedilen böceklerin duruş özelliklerinin sonuçlara etki ettiği tespit edilmiştir. Bu bağlamda; KSA, ResNet-50 mimarisinin böcek alt familya sınıflandırılması için oldukça kullanışlı olduğu ortaya konmuştur. Önerilen yöntemle insan faktörünü en aza indirerek alt familya sınıflandırmasının doğuya yakın ve pratik bir şekilde yapılması amaçlanmıştır. Böylece emek ve zaman tasarrufu sağlanmıştır. İlerleyen çalışmalarda, daha çok böcek familya/alt familyası için veri toplanıp farklı modellerle çalışmalar yapılması hedeflenmektedir.

KAYNAKLAR

- Barbedo, J. G. A. (2020). Detecting and classifying pests in crops using proximal images and machine learning: A review. *AI*, 1(2), 312–328.
- Chen, G., Han, T. X., He, Z., Kays, R., Forrester, T. (2014). Deep convolutional neural network based species recognition for wild animal monitoring. 2014 IEEE International Conference on Image Processing (ICIP), 858–862. IEEE.
- Dyrmann, M., Karstoft, H., Midtby, H. S. (2016). Plant species classification using deep convolutional neural network. *Biosystems Engineering*, 151, 72–80. doi: 10.1016/j.biosystemseng.2016.08.024
- Gülcü, A., Kuş, Z. (2019). Konvolüsyonel Sinir Ağlarında Hiper-Parametre Optimizasyonu Yöntemlerinin İncelenmesi. *Gazi Üniversitesi Fen Bilimleri Dergisi Part C: Tasarım ve Teknoloji*, 7(2), 503–522. doi: 10.29109/gujsc.514483
- Hussain, M., Bird, J. J., Faria, D. R. (2018). A study on cnn transfer learning for image classification. *UK Workshop on Computational Intelligence*, 191–202. Springer.
- INaturalist. (2022). Retrieved 8 February 2022, from INaturalist website: <https://www.inaturalist.org/>
- Marques, A. C. R., M. Raimundo, M., B. Cavalheiro, E. M., FP Salles, L., Lyra, C., J. Von Zuben, F. (2018). *Ant*

- genera identification using an ensemble of convolutional neural networks. *Plos One*, 13(1), e0192011.
- O'Shea, K., Nash, R. (2015). An introduction to convolutional neural networks. *ArXiv Preprint ArXiv:1511.08458*.
- Rajeena PP, F., Orban, R., Vadivel, K. S., Subramanian, M., Muthusamy, S., Elminaam, D. S. A., ... Ali, M. A. (2022). A novel method for the classification of butterfly species using pre-trained CNN models. *Electronics*, 11(13), 2016.
- Theivaprakasham, H. (2021). Identification of Indian butterflies using deep convolutional neural network. *Journal of Asia-Pacific Entomology*, 24(1), 329–340.
- Tokmak, M., Kır aç, A. (2021). Evriřimsel Sinir Ađları ile  r mcek Kuřugillerin Bazı T rlerinin Sınıflandırılması. *Bilge International Journal of Science and Technology Research*, 5(1), 72–79.
- Tokmak, M., řen, İ. (2021). The Genus-Level Identification of Leaf Beetles (Coleoptera: Chrysomelidae) From Habitus Images with Convolutional Neural Network Classification. *International Journal of Applied Mathematics Electronics and Computers*, 9(4), 91–96.
- W ldchen, J., M der, P. (2018). Machine learning for image based species identification. *Methods in Ecology and Evolution*, 9(11), 2216–2225.
- Zhang, L., Li, H., Zhu, R., Du, P. (2022). An infrared and visible image fusion algorithm based on ResNet-152. *Multimedia Tools and Applications*, 81(7), 9277–9287. doi: 10.1007/s11042-021-11549-w