



Konferans Bildirisi

Derin Yapay Sinir Ağı ile Endüstriyel Balık Sınıflandırıcı

Mahamat Ahmat Issamadine¹, Yasemin Erkan², Ersin Alaybeyoğlu³

¹ Bartın Üniversitesi, <https://orcid.org/0009-0006-3534-3136>, issamadinemahamat@gmail.com,

² Bartın Üniversitesi, <https://orcid.org/0000-0002-5825-2177>, yerkan@bartin.edu.tr,

³ Bartın Üniversitesi, <https://orcid.org/0000-0002-8318-4081>, ealaybeyoglu@bartin.edu.tr

Received 11 October 2024

Received in revised form 28 November 2024

In final form 21 December 2024

4th International Conference on Design, Research and Development
(RDCONF 2024)
December 19 - 20, 2024

Reference: Issamadine, M. A., Erkan, Y., & Alaybeyoğlu, E. (2024). Industrial fish classifier with deep artificial neural network. *Orclever Proceedings of Research and Development*, 5(1), 99-109.

Özet

Günümüzde makine öğrenmesi tabanlı karar destek sistemleri hayatın hemen her alanında kolaylaştırıcı bir rol oynamaktadır. Bu akıllı sistemlerin endüstriyel üretim sistemlerine entegrasyonu ile hızlı ve etkili üretim çözümleri ortaya çıkmaktadır. Günümüzde makine öğrenmesi tabanlı yapay zekâ teknolojileri çoğunlukla görüntü işleme yaklaşımını temel alan çözümler sunmaktadır. Bu çalışmada da görüntü işleme yaklaşımını temel alan, derin bir yapay sinir ağı olan YOLO görüntü işleme algoritması ile farklı balık türlerini etkili bir şekilde sınıflandırabilen yeni bir yapay zekâ modeli önerilmektedir. Çözümün bir balık veri seti ile eğitilen model ile endüstriyel uygulamalara kolayca entegre edilebilecek gerçek zamanlı bir karar destek çözümü sunulmaktadır.

Anahtar: Görüntü Sınıflandırma, Akıllı Teknoloji, YOLO, Endüstriyel Uygulamalar.



Conference Article

Industrial Fish Classifier with Deep Artificial Neural Network

Abstract

Today, machine learning-based decision support systems play a facilitating role in almost every aspect of life. With the integration of these intelligent systems into industrial production systems, fast and effective production solutions emerge. Today, machine learning-based artificial intelligence technologies mostly offer solutions based on the image processing approach. In this study, a new artificial intelligence model that can effectively classify different fish species is proposed with the YOLO image processing algorithm, a deep artificial neural network based on the image processing approach. A real-time land support solution that can be easily integrated into industrial applications is presented with the model trained with an original fish data set.

Keywords: *Image Classification, Smart Technology, YOLO, Industrial Applications.*



1. Giriş

Rosenblat'ın Perceptron'u [1] ile 1958 yılında ortaya çıkan yapay sinir ağı (YSA), biyolojik bir nöronun matematiksel karşılığı olan birimlerin bir veya daha fazla katmana yerleştirilmesi ile oluşturulmaktadır. YSA zaman zaman popüleritesini kaybetse de 2009 ve 2012 yıllarında konuşma tanıma problemi için geliştirilen geri yayımlı YSA çalışması [2] ve görüntüdeki baskın nesneyi tahmin etmeyi amaçlayan görüntü sınıflandırma çalışması AlexNet [3] ile popüleritesini tekrar kazanmıştır. Bu popülerlikle birlikte YSA'lar başta görüntü işleme [6]-[9] olmak üzere Elektroensefalografi (EEG) [10], [11] ve ses sınıflandırma [12], [13] gibi birçok çalışmada [3]-[5] kullanılmıştır.

Nesne tespiti, bilgisayarla görmede en zorlu problemlerden biri olarak kabul edilir. Son zamanlarda, derin sinir ağlarının, özellikle YOLO (You Only Look Once) [14] gibi modellerle diğer yaklaşımlara kıyasla üstün nesne algılama performansı elde ettiği kanıtlanmıştır. Bu çalışmalara örnek olarak Huang ve arkadaşlarının gerçek zamanlı nesne tespiti yapabilen cihaz çeşitliliğini artırmak için geliştirdikleri YOLO-LITE, YOLOV2'yi temel almaktadır [15]. Bir başka çalışmada Lan vd. orijinal YOLO algoritmasına 3 yeni katman ekleyerek geliştirdikleri YOLO-R'yi INRIA yaya veri kümesi üzerinde test etmişler ve önerilen yaklaşımın algılama hızının saniyede 25 kareye ulaşabildiğini göstermişlerdir [16]. Wong ve arkadaşları YOLO'yu mobil platformlara taşımak için YOLO Nano algoritmasını önermiş ve Jetson AGX Xavier gömülü modülünde çıkarım hızı ve güç verimliliği üzerine yapılan deneyler YOLO Nano'nun gömülü senaryolar için etkinliğini göstermiştir [17].

Türkiye'de balık avcılığı çoğunluğu Karadeniz bölgesinden yapılmaktadır. Aynı anda avlanan Barbun, Hamsi ve Mezgıt balıkları balıkçılar tarafından manuel olarak sınıflandırılmaktadır. Barbun, hamsi ve mezgıt balıklarını ayırt eden derin YSA tabanlı, akıllı bir sistem önerilen bu çalışma ile balıkçılık endüstrisindeki bu sınıflandırma sürecini iyileştirme, işgücünü azaltma ve sürecin hızlandırılması amaçlanmaktadır. Bu amaç doğrultusunda öncelikle barbun, hamsi ve mezgıt balık türlerinden oluşan bir veri seti ile eğitilen sisteme geleceğe yönelik başarılı tahminler yapabilme yeteneği kazanmıştır. Çalışmada geliştirilen model, YOLOv8 algoritmasının sağladığı hız sayesinde gerçek zamanlı endüstriyel uygulamalara kolaylıkla adapte edilebilmektedir.

2. Materyal ve Yöntem

2.1. Veri Setleri

Veri seti, Türkiye'nin Bartın ilçesinden toplanan 900 barbun, 900 hamsi ve 900 mezigit olmak üzere toplam 3700 balık görüntüsünden oluşturulmuştur. Her bir sınıf için veri setinin %90'i eğitim verisi, geri kalanı ise test verisi olarak ayrılmıştır. Barbun, hamsi ve mezigit türü balık görüntü örnekleri sırasıyla Şekil 1 A, B ve C'de verilmiştir.



Şekil 1: Barbun, hamsi ve mezigit balıkları için örnekler.

A) Barbun balığı, B) Hamsi balığı, C) Mezigit balığı

2.2. Değerlendirme Metrikleri

Bu çalışmada değerlendirme metrikleri kullanılmıştır Doğruluk (Acc), Recall (Re), Precision (Pr), F1-Score (F1). Çok sınıflı problemin doğruluğu şu şekilde değerlendirilir:

$$Acc = \frac{T_{pos} + T_{neg}}{T_{pos} + T_{neg} + F_{pos} + F_{neg}}$$

Burada T_{pos}, F_{pos}, T_{neg} ve F_{neg} sırasıyla doğru pozitifleri, yanlış pozitifleri, doğru negatifleri ve yanlış negatifleri göstermektedir. Doğruluk, doğru sınıflandırılan örneklerin toplam örnek sayısına oranını temsil eder [18]. Diğer performans metrikleri aşağıdaki gibi hesaplanır:

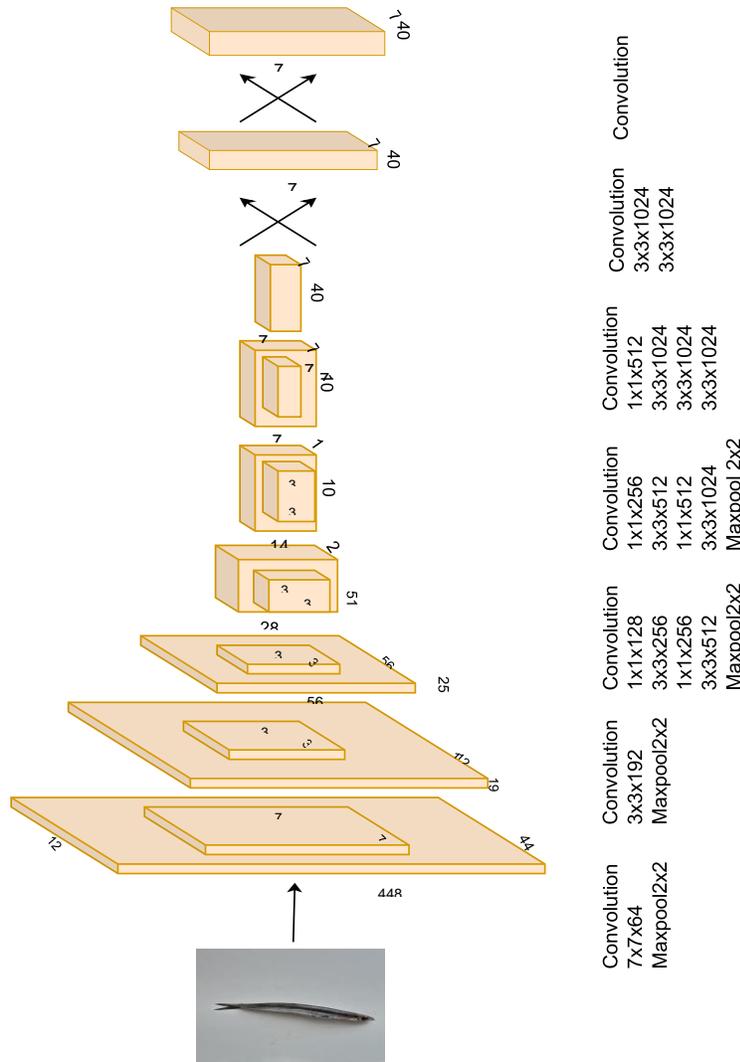
$$Re = \frac{T_{pos}}{T_{pos} + F_{neg}}$$

$$Pr = \frac{T_{pos}}{T_{pos} + F_{pos}}$$

$$F_1 = \frac{2 \times P_r \times R_e}{P_r \times R_e}$$

2.3. Alt Nesne Algılama Algoritması

YOLOv8, önceki YOLO sürümlerinin sınırlamalarının üstesinden gelen günümüzün en güçlü ve etkili nesne algılama algoritmalarından biridir. YOLOv8, gerçek zamanlı nesne algılama gerçekleştirebilir. Bu, YOLO'nun otonom araçlar ve endüstriyel uygulamalar tarafından ihtiyaç duyulan gerçek zamanlı görüntü işleme görevlerini yerine getirme potansiyelini göstermektedir. YOLOv8 mimarisinin katmanları Şekil 2'de verilmiştir.



Şekil 2: YOLO Mimarisi.



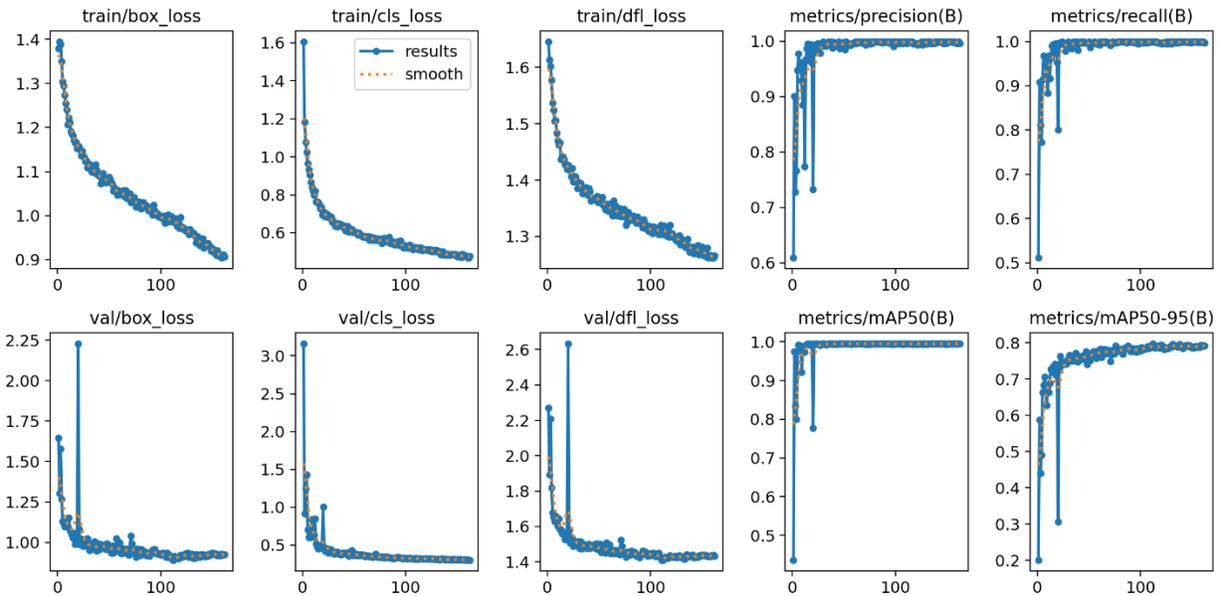
YOLO ağında 24 konvolüsyonel katman ve ardından 2 tam bağlı katman bulunmaktadır. Balıklarını içeren görüntüler bu ağa girdi olarak uygulanmıştır.

Tablo 1: Eğitim sonucunda elde edilen değerlendirme metrikleri

Sınıf	Resim	Örnekler	P _r	R _e	mAP50	mAP50-95
Tüm	300	300	0.999	1	0.995	0.777
Barbun	100	100	0.999	1	0.995	0.740
Hamsi	100	100	0.999	1	0.995	0.782
Mezgit	100	100	0.998	1	0.995	0.809

3. Sonuçlar

Bu çalışmada, YOLOv8 modeli orijinal veri setimiz üzerinde 100 epoch boyunca eğitilmiş ve modelin performansı doğruluk, geri çağırma, kesinlik, F1 puanı, karışıklık matrisi açısından değerlendirilmiştir. Model Google Colab pro ortamında T4 GPU mikroişlemci ile eğitilmiştir. Eğitim sonucunda elde edilen değerlendirme metrikleri Tablo 1'de sunulmuştur. Balıkları için yapılan sınıflandırmanın performans sonuçları Şekil 3'te verilmiştir.



Şekil 3: YOLOv8'in performansını değerlendirmek için kullanılan göstergeler.

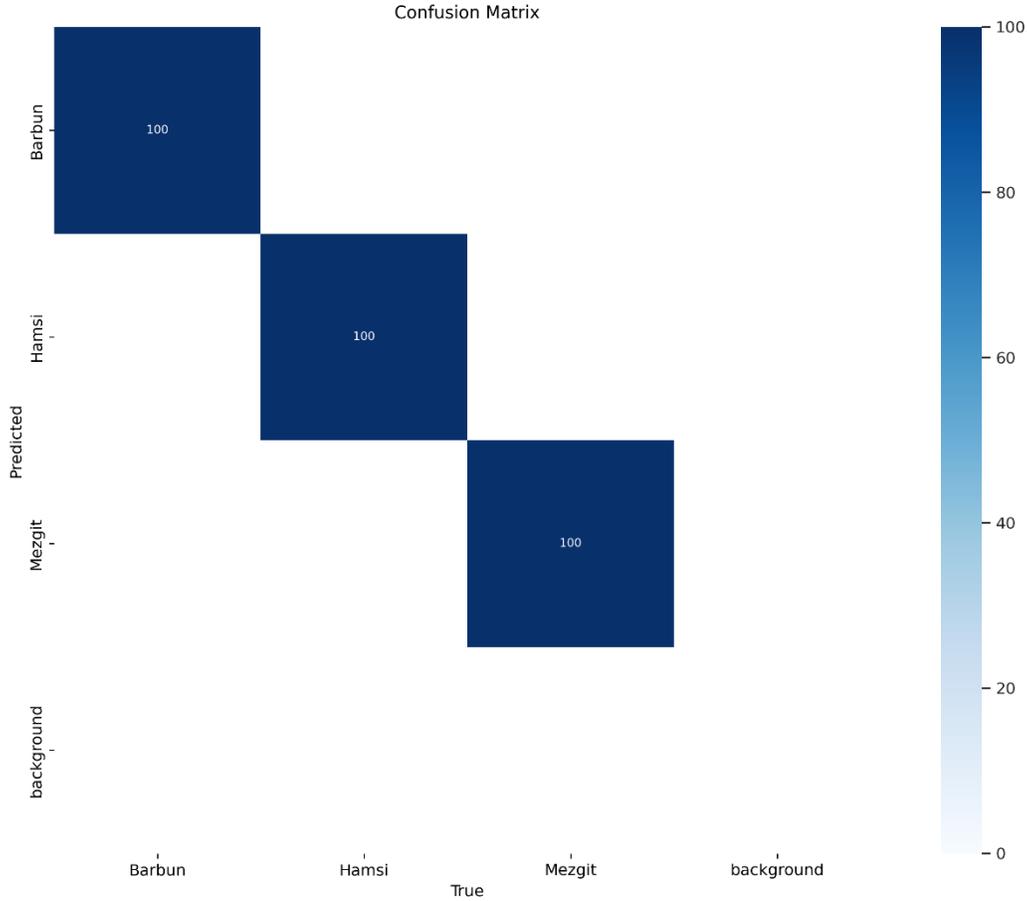


Şekil 4: Balık türünü ve sınıflandırmanın güven düzeyini gösteren örnekler.

Modelin performansını daha fazla değerlendirmek için Şekil 3, eğitim sürecinde kullanılan değerlendirme göstergelerinin 0'dan 100'e kadar olan model iterasyonlarını kapsayan görsel bir analizini sunmaktadır. Şekil 3 incelendiğinde her bir eğitim iterasyonunda elde edilen eğitim ve test kayıpları, hassasiyet ve geri çağırma değerleri

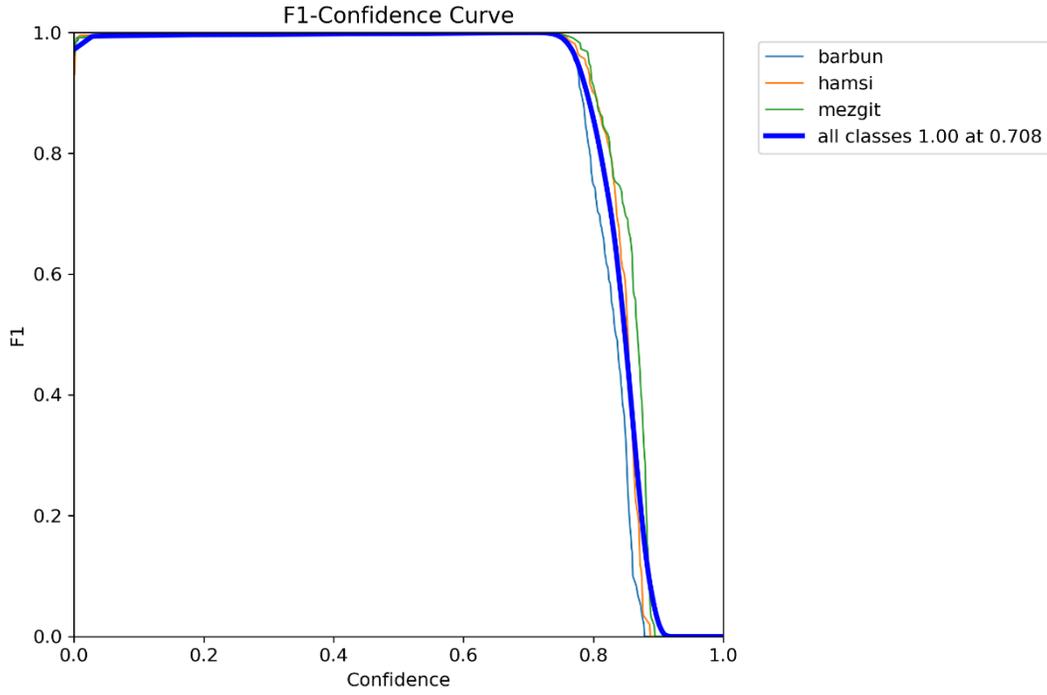


ile mAP50 deęerleri grlmektedir. Modelin sonuları, tahmin sonuları ve adlandırılmıř kategorilere sınıflandırmadaki gven seviyelerinin rneklerini veren Őekil 4'te gsterilmektedir. Őekil 5, eęitilmif YOLOv8 modelimizin barbun, hamsi ve mezigit balıkları doęru bir Őekilde sınıflandırma yeteneęini temsil eden karifıklik matrisini sunmaktadır.

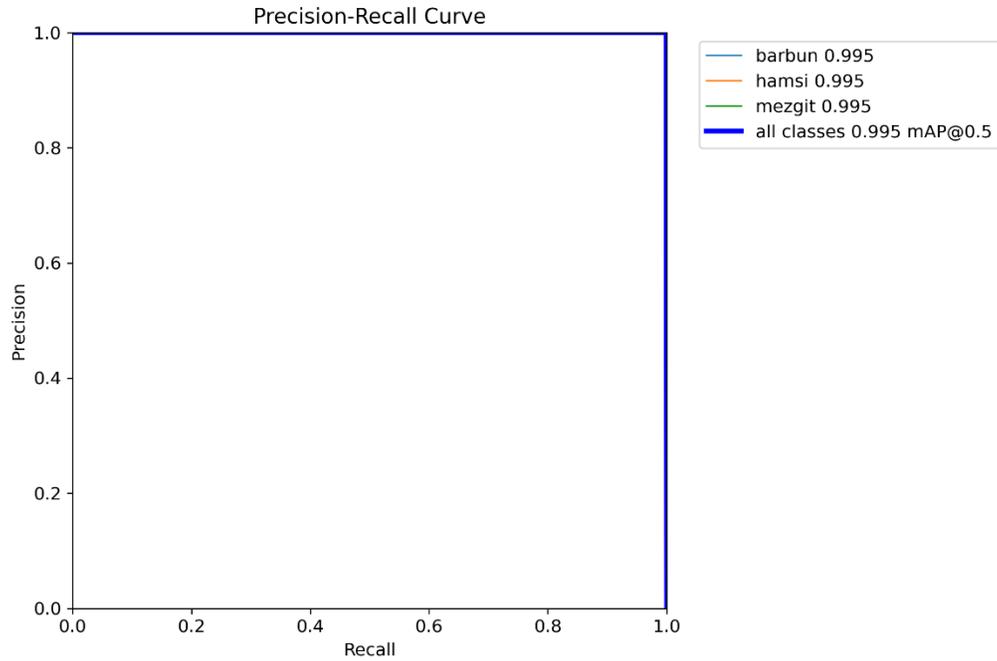


Őekil 5: Sınıflandırmanın karifıklik matrisi.

F1, hassasiyet ve geri aęırma eęrileri sırasıyla Őekil 6 ve 7'de verilmiřtir.



Şekil 6: Sınıflandırmanın F1 eğrisi.



Şekil 7: Hassasiyet ve geri çağırma.



YOLOv8, gerçek zamanlı endüstriyel uygulamalarda etkili sonuçlar üretebilen bir derin öğrenme algoritmasıdır. Bu çalışmada bölgesel ihtiyaçlardan dolayı balık sınıflandırma görevinde YOLOv8 algoritması kullanılmış ve etkili sonuçlar elde edilmiştir. Gelecek çalışmalarda, ortaya çıkan modelin endüstriyel uygulamalara uyarlanarak geliştirilmesi ve akıllı otomasyon sistemlerinde kullanılması hedeflenmektedir.

4. Tartışma

Çalışmada, balıkları YOLOv8 kullanılarak barbun, hamsi ve mezigit olarak sınıflandırılmıştır. Sınıflandırmalar Google Colab pro ortamında T4 GPU mikroişlemci ile gerçekleştirilmiştir. Elde edilen sonuçlar, balıkçılık alanında, klasik insan gücüne dayalı sınıflandırmaların yerini endüstriyel yapay zekâ tabanlı makinelere bırakacağını göstermektedir. Çalışmada elde edilen sonuçlar bütünleşmiş bölge uygulamaları kapsamında sınıflandırma makinesinde kullanılacaktır.

5. Teşekkür

Çalışmamız, Bartın Üniversitesi (BARÜ) Bilimsel Araştırma Projeleri (BAP) Koordinasyon Biriminin 2021K12-169131-05 numaralı projesi ile desteklenmektedir.

Referanslar

- [1] F. Rosenblatt, "The perceptron: a probabilistic model for information storage and organization in the brain." *Psychological review*, vol. 65, no. 6, p. 386, 1958.
- [2] A.-r. Mohamed, G. Dahl, G. Hinton et al., "Deep belief networks for phone recognition," in *Nips workshop on deep learning for speech recognition and related applications*, vol.1, no. 9, 2009, p. 39.
- [3] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "Imagenet classification with deep convolutional neural networks," *Advances in neural information processing systems*, vol. 25, 2012.
- [4] B. Hou, C. Yang, B. Ren, and L. Jiao, "Decomposition-feature-iterative clustering-based superpixel segmentation for polsar image classification," *IEEE Geoscience and Remote Sensing Letters*, vol. 15, no. 8, pp. 1239–1243, 2018.
- [5] K. U. Akdemir and E. Alaybeyoğlu, "Classification of red mullet, bluefish and haddock caught in the black sea by" single shot multibox detection", in *2021 International Conference on INnovations in Intelligent SysTems and Applications (INISTA)*. IEEE, 2021, pp. 1–4.



- [6] M. J. Shafiee, S. A. Haider, A. Wong, D. Lui, A. Cameron, A. Modhafar, P. Fieguth, and M. A. Haider, "Apparent ultra-high b-value diffusion weighted image reconstruction via hidden conditional random fields," *IEEE Transactions on Medical Imaging*, vol. 34, no. 5, pp. 1111–1124, 2015.
- [7] M. Luengo-Oroz, E. Faure, B. Lombardot, R. Sance, P. Bourgine, N. Peyrieras, and A. Santos, "Twister segment morphological filtering. a new method for live zebrafish embryos confocal images processing," in *2007 IEEE International Conference on Image Processing*, vol. 5, 2007, pp. V–253–V–256.
- [8] W. Yang, L. Zhong, Y. Chen, L. Lin, Z. Lu, S. Liu, Y. Wu, Q. Feng, and W. Chen, "Predicting ct image from mri data through feature matching with learned nonlinear local descriptors," *IEEE Transactions on Medical Imaging*, vol. 37, no. 4, pp. 977–987, 2018.
- [9] G. Bannerjee, U. Sarkar, S. Das, and I. Ghosh, "Artificial intelligence in agriculture: A literature survey," *International Journal of Scientific Research in Computer Science Applications and Management Studies*, vol. 7, no. 3, pp. 1–6, 2018.
- [10] J. M. Antelis, L. E. Falcón et al., "Spiking neural networks applied to the classification of motor tasks in eeg signals," *Neural networks*, vol. 122, pp. 130–143, 2020.
- [11] Y. Luo, Q. Fu, J. Xie, Y. Qin, G. Wu, J. Liu, F. Jiang, Y. Cao, and X. Ding, "Eeg-based emotion classification using spiking neural networks," *IEEE Access*, vol. 8, pp. 46007–46016, 2020.
- [12] Wu, Y. Chua, and H. Li, "A biologically plausible speech recognition framework based on spiking neural networks," in *2018 International Joint Conference on Neural Networks (IJCNN)*. IEEE, 2018, pp. 1–8.
- [13] Wu, E. Yilmaz, M. Zhang, H. Li, and K. C. Tan, "Deep spiking neural networks for large vocabulary automatic speech recognition," *Frontiers in neuroscience*, vol. 14, p. 199, 2020.
- [14] M. J. Shafiee, B. Chywł, F. Li, and A. Wong, "Fast yolo: A fast you only look once system for real-time embedded object detection in video," *arXiv preprint arXiv:1709.05943*, 2017.
- [15] R. Huang, J. Pedoeem, and C. Chen, "Yolo-lite: a real-time object detection algorithm optimized for non-gpu computers," in *2018 IEEE international conference on big data (big data)*. IEEE, 2018, pp. 2503–2510.
- [16] W. Lan, J. Dang, Y. Wang, and S. Wang, "Pedestrian detection based on yolo network model," in *2018 IEEE international conference on mechatronics and automation (ICMA)*. IEEE, 2018, pp. 1547–1551.
- [17] A. Wong, M. Famuori, M. J. Shafiee, F. Li, B. Chywł, and J. Chung, "Yolo nano: A highly compact you only look once convolutional neural network for object detection," in *2019 Fifth Workshop on Energy Efficient Machine Learning and Cognitive Computing-NeurIPS Edition (EMCC2-NIPS)*. IEEE, 2019, pp. 22–25.
- [18] A. T. Azar and S. A. El-Said, "Performance analysis of support vector machines classifiers in breast cancer mammography recognition," *Neural Computing and Applications*, vol. 24, pp. 1163–1177, 2014.