

ULUSLARARASI 3B YAZICI TEKNOLOJİLERİ  
VE DİJİTAL ENDÜSTRİ DERGİSİ

INTERNATIONAL JOURNAL OF 3D PRINTING  
TECHNOLOGIES AND DIGITAL INDUSTRY

ISSN:2602-3350 (Online)

URL: <https://dergipark.org.tr/ij3dptdi>

## DERİN ÖĞRENME İLE BALIK TÜRLERİNİN TESPİTİ

## PREDICTION OF FISH SPECIES WITH DEEP LEARNING

**Yazarlar (Authors):** Kıyas Kayaalp<sup>ID\*</sup>, Sedat Metlek<sup>ID</sup>

**Bu makaleye şu şekilde atıfta bulunabilirsiniz (To cite to this article):** ,Kayaalp K., Metlek S., “Derin Öğrenme İle Balık Türlerinin Tespiti”, *Int. J. of 3D Printing Tech. Dig. Ind.*, 5(3): 569-576, (2021).

DOI: 10.46519/ij3dptdi.956221

Araştırma Makale/ Research Article

Erişim Linki: (To link to this article): <https://dergipark.org.tr/en/pub/ij3dptdi/archive>

# DERİN ÖĞRENME İLE BALIK TÜRLERİNİN TESPİTİ

Kıyas Kayaalp<sup>a</sup> , Sedat Metlek<sup>b</sup> 

<sup>a</sup>Isparta Uygulamalı Bilimler Üniversitesi, Teknoloji Fakültesi, Bilgisayar Mühendisliği, TÜRKİYE  
<sup>b</sup>Burdur Mehmet Akif Ersoy Üniversitesi, Teknik Bilimler Meslek Yüksekokulu, Mekatronik Bölümü,  
TÜRKİYE

\* Sorumlu Yazar: [kiyaskayaalp@isparta.edu.tr](mailto:kiyaskayaalp@isparta.edu.tr)

(Geliş/Received: 22.06.2021; Düzeltme/Revised: 27.10.2021; Kabul/Accepted: 10.12.2021)

## ÖZ

Beslenmemizde önemli bir yere sahip olan deniz ürünleri, mükemmel bir vitamin ve mineral kaynağıdır. Protein kaynakları içerisinde sindirilmesi oldukça kolay olan deniz mahsulleri, diğer yüksek proteinli kaynaklara göre oldukça az zararlı yağ içermektedir. Balıklarda bulunan omega-3 gibi yağ asitlerinin, insan sağlığını olumsuz etkileyen kalp ve damar hastalıklarından, diyabet ve kanser gibi daha birçok hastalığa iyi geldiği bilinmektedir. Bunun yanı sıra az da olsa insan sağlığını tehdit edebilecek balık türleri de bulunmaktadır. Gerçekleştirilen çalışma ile günümüzün popüler makine öğrenme yöntemlerinden birisi olan derin öğrenme algoritmaları vasıtasıyla, insanoğlunun beslenmesinde önemli bir role sahip olan balıkların, görüntüleri üzerinden türlerinin tahmin edilmesi amaçlanmıştır. Bu amaç doğrultusunda geliştirilen uygulamada, farklı ortamlardan elde edilen 4410 adet balık görüntüsü kullanılmıştır. Kullanılan balık görüntüleri, 483 adet farklı türden oluşmakla beraber, farklı koşullar altında elde edilen gerçek balık görüntüleridir. Çalışmada hazırlanan derin öğrenme algoritmasının eğitim ve test işlemleri için "QUT FISH" veri seti kullanılmıştır. Derin öğrenme yöntemlerinde sıkça kullanılan, Evrişimsel sinir ağları yöntemi ile veri setindeki görüntülerden, balık türlerine ait öznitelikler çıkartılmıştır. Çıkartılan bu öznitelikler çok katmanlı bir yapay sinir ağı modeli ile sınıflandırılmıştır. Yapılan çalışma ile sınıflandırma başarısı olarak %73,72 değeri elde edilmiştir.

**Anahtar Kelimeler:** Derin Öğrenme. Evrişimsel Sinir Ağları. Balık türlerinin tespiti.

## PREDICTION OF FISH SPECIES WITH DEEP LEARNING

### ABSTRACT

Seafood, which has an important place in our diet, is an excellent source of vitamins and minerals. Seafood, which is very easy to digest among protein sources, contains very little harmful fat compared to other high-protein sources. It is known that fatty acids such as omega-3 in fish are effective not only in cardiovascular diseases, but also in important diseases such as diabetes and cancer, which adversely affect human health. In addition, there are also fish species that can threaten human health, albeit a little. By this study, it is aimed to predict fish species by using images of fish that have an important role in human nutrition thanks to deep learning algorithms, one of today's popular machine learning methods. In the application developed for this purpose, 4410 fish images obtained from different environments are used. Fish images of 483 different species are obtained from different environments. The "QUT FISH Dataset" dataset is used for the training and testing of the deep learning algorithm prepared in the study. By means of the Convolutional Neural Networks method, which is frequently used in deep learning methods, the features of fish species are extracted from the data set. These extracted features are classified with a multilayer artificial neural network model. With the study, a value of 73.72% is obtained as classification success.

**Keywords:** Deep learning. Convolutional neural network. Prediction of fish types

## 1. GİRİŞ

İnsanlar teknolojinin gelişmesiyle birlikte, doğayı daha iyi tanımaya ve keşfetmeye çalışmaktadır. Doğayı kara, deniz ve hava olarak üç bölümde sınıflandırmak mümkündür. Bu üç bölümden biri olan denizler, dünya yüzeyinin yaklaşık üçte ikisini oluşturmaktadır. Okyanus ekosistemlerinde yaklaşık olarak 22.000'den fazla balık türü bulunmakta ve bu da dünya üzerinde bulunan omurgalı türünün neredeyse yarısını oluşturmaktadır [1]. Sınırlı olan okyanus kaynaklarımızı bilinçsiz olarak tüketmemizin bir sonucu olarak, deniz ekosistemindeki biyolojik çeşitlilik, özellikle balık türleri için çok büyük bir tehdit oluşturmaktadır [2-4]. Ayrıca, balıkları doğal ortamlarında izlemek, sürdürülebilir balıkçılığa doğru atılan önemli bir adımdır. Etkili izleme, hem insan tüketimi hem de çevrenin korunması açısından sağlıklı balık popülasyonlarının sürdürülebilmesi için, hangi alanların korunmaya ihtiyaç duyduğunu hakkında bilgiler sağlayabilmektedir [5].

Balık, deniz ekosisteminin önemli bir faktörü olmakla birlikte, teknolojinin gelişmesi balık türlerinin yetiştirilmesiyle ilgili teknolojilerinde gelişimini, deniz ekosistemlerinin de korunmasını beraberinde getirmiştir. Balık türlerinin tanınması araştırmacılar için çok önemli bir süreçtir. Geçmişte, insanlar balık türlerini tanımlamak için çeşitli yöntemler geliştirmişlerdir [6]. Geleneksel olarak tanımlanan yöntemler, profesyonel yetenek gerektiren ve uzun zaman alan yöntemlerdir. Bu yüzden, balık görüntülerinin verimli bir şekilde, kısa zamanda ve insandan kaynaklı hataları da ortadan kaldırmak için, görüntü işleme teknolojilerine dayalı özellik çıkarma yöntemlerine başvurulmaktadır [7-9].

Yakın geçmişte ise, su içerisindeki nesnelerin ve balık türlerinin tanınması için esnek hesaplama yöntemlerine dayalı birçok çalışma yapılmıştır [10]. Görüntüden balıkların ayırt edilebilmesi için, balıkların ana hatlarını gösterebilen şekil ve doku özelliklerinin yanında [11], renk temelli bilgilerin kullanılması gerekmektedir [12]. Ayrıca literatürde, balık görüntülerinin sınıflandırılması için Destek Vektör Makineleri [13-14], YOLO ve Paralel Korelasyon filtreleri [15], hiperspektral görüntüleme sistemleri [16], Naive Bayesian sınıflandırıcı [17], K-en yakın komşuluk ( K-Nearest Neighbors, KNN) [12], karar ağacı [18] ve geri yayılım sınıflandırıcılarının [19] kullanıldığı çalışmalarda bulunmaktadır. Gerçekleştirilen çalışmada, 483 farklı balık türünün bulunduğu QUT FISH veri seti kullanılmıştır. Çalışmada balık türlerinin sınıflandırılması için, ilk olarak Evrişimsel Sinir Ağları (ESA) yöntemi kullanılarak balık türlerinin öz nitelikleri çıkartılmıştır. Her balık için bu yöntem ile 1000 adet öz nitelik çıkartılmış olup Çok Katmanlı Yapay Sinir Ağı (ÇKYSA) ile sınıflandırılmıştır.

## 2. MATERYAL VE METOT






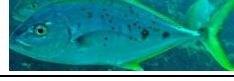















### 2.1. Veri Kaynağı

Queensland Robotik Teknoloji Üniversitesi çalışanlarının literatüre kazandırdığı QUT FISH veri setinde, farklı ortamlardaki 483 balık türünden oluşan 4410 adet görüntü bulunmaktadır. Görüntüler arka planlarına göre üç farklı kategoriye ayrılmıştır. İlk kategori kontrollü ortam olarak tanımlanan, sabit bir arka planla çekilmiş balık görüntülerini içerir. İkinci kategori, su dışında sabit arka planı olmayan balık görüntülerini içerir. Üçüncü kategori ise, doğal ortamında çekilmiş balık görüntülerini içerir. Kontrollü ortam görüntüleri, kontrollü aydınlatma ile sabit bir arka plan üzerinde yüzgeçleri yayılmış çeşitli balık örneklerinden oluşur. Su dışı ortam görüntüleri, sudan çıkarılan balık türlerinin farklı arka plan ve sınırlı aydınlatma koşulları altında alınan görüntülerden oluşur. Yerinde ortam görüntüleri ise, arka plan veya aydınlatma üzerinde herhangi bir kontrol olmaksızın, balığın doğal ortamında su altında çekilmiş görüntüleridir. Veri setinden alınan bazı örnek görüntüler, Çizelge 1'de sunulmuştur. Balıkların birbirine oldukça benzer olması balık türlerinin belirlenmesini oldukça zorlaştırmaktadır.

### 2.2. Evrişimsel Sinir Ağı (ESA)

Veri miktarının çok hızlı bir ivme ile arttığı günümüz bilgi çağında, var olan bilgilerden anlamlı bilgileri elde etmenin bir yolu da, derin öğrenme modellerinin kullanılmasıdır [20]. Günümüzün popüler konularından birisi olan derin öğrenme, yapay sinir ağlarının geliştirilmiş bir versiyonudur. Derin öğrenmenin gelişim basamakları, Perceptron modeli ile başlamış, Tek Katmanlı ve Çok Katmanlı Yapay Sinir Ağları (YSA) ile devam etmiş, günümüzde ise Derin Öğrenme yöntemleri olarak kullanılmaya devam etmektedir.

**Çizelge 1.** QUT FISH veri setinde bulunan balık adı, alt türü ve görüntülerin elde edildiği ortamlara ait örnek görüntüler.


Balık Adı	Alt Türü	Kontrollü Ortam	Su Dışı Ortam	Yerinde
acanthopagrus	australis			
carangoides	fulvoguttatus			
lethrinus	olivaceus			
plectropomus	areolatus			
pseudocaranx	dentex			
ruvettus	pretiosus			
scomberomorus	commerson			

İnsan sinir hücrelerini temel alarak geliştirilen YSA'lar, sinyal işleme uygulamalarından, bilgisayar destekli kontrol uygulamalarına kadar birçok farklı alanda kullanılabilir. YSA'ların günümüzde gelişimi hâlâ devam ettirilmektedir ve görüntü işleme uygulamalarında kullanılan ESA modellerinin gelişmesine öncülük etmiştir [21].

ESA'lar insan görme sisteminin modellenmesi ile geliştirilmiştir. Var olan bilgilerin özneliklerinin çıkarılmasında ve özelliklerin arasındaki ilişkileri modelleyebilmesi nedeni ile ESA'lar birçok alanda tercih edilmektedir [22]. Şekil 1'de sunulan katmanlı mimariye sahip olan ESA'larda öznelik çıkarma işlemleri otomatik olarak gerçekleştirilebilmektedir. ESA algoritmalarında bulunan katmanların işlevleri ve özellikleri ise kısaca şöyledir;

- Giriş katmanı; algoritmaya aktarılan, farklı tür, boyut ve içerikte olabilen görüntülerin oluşturduğu katmandır. Bu katmanda görüntülerin belli bir standarda getirilmesi için Normalizasyon işlemi gerçekleştirilir.
- Evrişim katmanı; verilerin özneliklerinin çıkartılması amacı ile girdi verisi üzerinde boyutları önceden belirlenen (AlexNet'te 11x11, GoogleNet ve VggNet'te 5x5, 3x3, 2x2 gibi) matrisler dolaştırılmaktadır [23-25].
- Aktivasyon katmanı; ReLU, sigmoid, hiperbolik, tanjant ve adım gibi farklı aktivasyon fonksiyonları ile evrişim katmanından elde edilen matris değerlerindeki doğrusalsızlıkların artırılmasıdır [26].
- Havuzlama katmanı; en büyük, en küçük ve ortalama değer matrisleri ile ağın daha hızlı çalışması için veri indirgeme işleminin yapıldığı katmandır [27].
- Unutma katmanı; bazı ağlarda çıkış değerlerini, güçlü olan giriş değerleri etkileyebilmektedir. Bu tür ağlarda eğitim seti ağ tarafından ezberlenebilmektedir, ağın ezberleme işlemini engellemek için kullanılır [28].
- Tam bağlantı katmanı; Sınıflandırma katmanına tüm verileri tek boyutlu bir matris olarak sunmak için kullanılan katmandır.
- Sınıflandırma katmanı; Genellikle Softmax sınıflandırıcısının kullanıldığı bu katmanda, tam bağlantı katmanından gelen veriler değerlendirilerek ağın çıkışı oluşturulur.

Bazı çalışmalarda tam bağlantı katmanından gelen öznelikler, farklı sınıflandırma algoritmaları kullanılarak sınıf tahmin bilgisi elde edilebilmektedir. Bu çalışmada, sınıf tahmini için çok katmanlı bir YSA modeli kullanılmıştır.



Şekil 1. ESA temel mimarisi [24].

### 2.3. Çok Katmanlı Yapay Sinir Ağı (ÇKYSA)

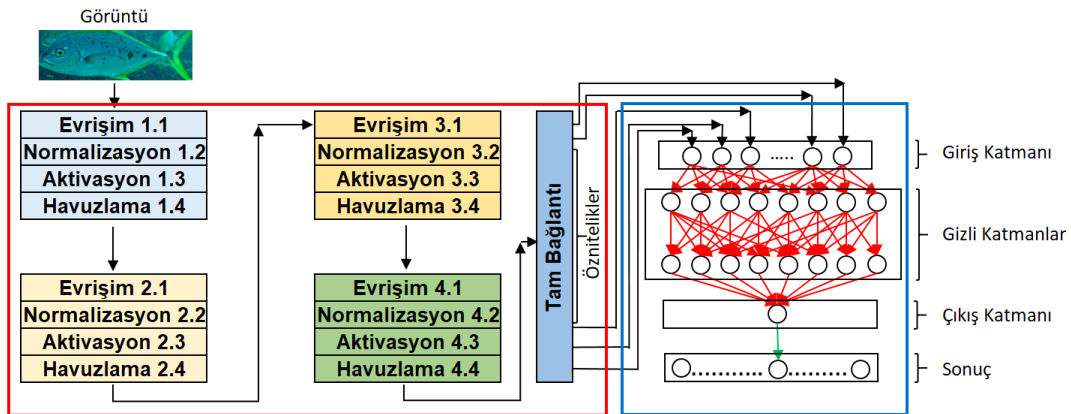
Yapay sinir ağları, günümüzde tekstilden [29], tarıma [30], ekonomiden [31], eğitime [32] kadar birçok alanda tercih edilen bir hesaplama yöntemi olmuştur. Birbirine bağlı hücrelerden oluşan YSA modelleri, insan sinir hücrelerinden ilham alınarak geliştirilmiştir. Bu hücreler, kendilerine aktarılan verilerin arasındaki ilişkiyi öğrenebilen ve kendisinden sonrakine aktarabilen bir yapıya sahiptirler. YSA'nın kendi iç yapısında bulunan giriş ve çıkış değerleri arasında bir bağıntı kurabilmesi için, sisteme yeterli miktarda verinin sunulması gerekmektedir. YSA'ya verilen giriş ve çıkış bilgileri arasındaki ilişkinin öğrenilmesi işlemine ise, ağı eğitme işlemi denir. Ağ, eğitildikten sonra ağı eğitildiği konu ile ilgili önceden hiç görmediği veriler verildiğinde, eğitilme düzeyine göre çıkış değerleri hakkında tahminde bulunabilir [33].

YSA giriş, gizli ve çıkış katmanı olmak üzere üç katmandan oluşmaktadır. Giriş katmanında, veri setinden veya sensörlerden gelen veriler ağı aktarılır. Gizli katmanda, giriş katmanından gelen bilgiler ağırlık katsayıları ile çarpılıp aktivasyon fonksiyonlarından geçirilerek çıkış katmanına aktarılır. Çıkış katmanında ise hata hesaplama fonksiyonları kullanılarak, YSA'ya önceden verilen çıkış değerleri ile YSA'nın üretmiş olduğu değerler arasındaki hata değeri hesaplanır. Hata değeri istenilen oranda değilse, ağıda kullanılan ağırlık katsayıları tekrar güncellenir [34].

ÇKYSA modelinde kullanılan veriler ilk önce eğitim ve test olarak ikiye ayrılmaktadır. Eğitim işlemi için ayrılan veriler kullanarak sistem eğitilmektedir. Eğitim işlemi istenilen hata seviyesine ininceye kadar ya da belirlenen iterasyon sayısına kadar devam ettirilmektedir. Eğitim işleminin tamamlanmasından sonra ise sistemin test edilmesi için ayrılan veriler ile test edilmektedir. Böylece, eğitimi tamamlanmış ÇKYSA'nın başarısı ölçülmektedir [35].

### 3. ÖNERİLEN METOT

Gerçekleştirilen çalışma, Matlab ortamında uygulanmış ve test edilmiştir. "QUT FISH Dataset" veri setinde bulunan ve örnek görüntüleri Çizelge 1'de sunulan, üç farklı ortamdan elde edilen 483 adet balık türüne ait toplam 4410 adet balık görüntüsü kullanılmıştır. Sunulan çalışma görüntü işleme tabanlı bir çalışma olmasından dolayı, ESA yöntemi kullanılarak görüntülerden öznetelik çıkartılması amaçlanmıştır. Bu amaç doğrultusunda, kullanılan veriler arka arkaya dört adet evrişimsel yapıya gönderilmiştir. Kullanılan ESA'nın katmanları ve özellikleri Şekil 2'de kırmızı çerçeve içerisinde detaylı olarak gösterilmiştir. Kullanılan evrişimsel yapının içeriği ise Çizelge 2'de sunulmuştur.



Şekil 2. Gerçekleştirilen ESA ve Çok Katmanlı YSA mimarisi.

Evrişimsel yapıya veriler sunulmadan önce ön işlem olarak 650×361×3 boyutlarındaki resimler, 224×224×3 boyutlarına indirgenmiştir. İlk evrişim katmanında 3×3 boyutunda 36 filtre 1 atlmalı, ikinci evrişim katmanında 3×3 boyutunda 12 filtre 2 atlmalı, üçüncü evrişim katmanında 4×4 boyutunda 12 filtre 2 atlmalı ve son evrişim katmanında 4×4 boyutunda 12 filtre 1 atlmalı olarak dolaştırılmıştır. Tüm evrişim katmanlarında sigmoid aktivasyon fonksiyonu kullanılmıştır.

**Çizelge 2.** Evrişimsel yapının katman ve özellikleri

	<b>Katman</b>	<b>Özellikleri</b>
Ön İşlem	Giriş Ebatları	650x361x3
	Boyutlandırma	224x224x3
1. Evrişimsel Yapı	Evrişim	36x[3x3]
	Atlama	1
	Normalizasyon	0-1
	Aktivasyon	sigmoid
	Havuzlama	En büyük
2. Evrişimsel Yapı	Evrişim	12x[3x3]
	Atlama	2
	Normalizasyon	0-1
	Aktivasyon	sigmoid
	Havuzlama	En büyük
3. Evrişimsel Yapı	Evrişim	12x[4x4]
	Atlama	1
	Normalizasyon	0-1
	Aktivasyon	sigmoid
	Havuzlama	En büyük
4. Evrişimsel Yapı	Evrişim	12x[4x4]
	Atlama	1
	Normalizasyon	0-1
	Aktivasyon	sigmoid
	Havuzlama	En büyük

ESA mimarinin son katmanında ise, tam bağlantı katmanı bulunmaktadır ve tam bağlantı katmanında her bir görüntü için 1000 adet öznitelik çıkartılması sağlanmıştır.

Öznitelik çıkarma işlemi için Intel(R) Core(TM), i7-4702MQ CPU@ 2.20 Ghz (İşlemci), 16GB (RAM), Intel(R) HD Graphics 4600 (GPU), Lenovo Z510 Type 20287 AILZA NM-A181 (Anakart) ve 500GB SSD (HDD) özelliklerinde bir bilgisayar kullanılmıştır. 4410 adet görüntüden öznitelik çıkarma işlemi, özellikleri verilen bilgisayar ile 289,46 dakikada gerçekleştirilmiştir.

Literatürde çoğu çalışmada, Derin Öğrenme algoritmalarından elde edilen öznitelikler softmax, hidden markov gibi sınıflandırıcılar kullanılarak sınıflandırma işlemleri gerçekleştirilir. Yapılan çalışmada ise, sınıflandırma işlemi için Şekil 2’de sunulan mavi çerçeve içindeki ÇKYSA modeli kullanılmıştır. Tasarlanan hibrit yapının eğitilmesinde, verilerin %80’i eğitim (3528), %20’si test verisi (882) olarak kullanılmıştır. Çalışmada, 3528 adet görüntü eğitim için kullanıldığından dolayı Tam bağlantı katmanından 3528x1000 boyutunda bir matris elde edilmiştir. Modellenen sistemin eğitim işlemi 5 kat çapraz doğrulama değerine göre, özellikleri verilen donanım ile yaklaşık olarak 216,79 saatte tamamlanmıştır.

Derin Öğrenme algoritmalarıyla gerçekleştirilen sınıflandırma işlemlerinde genellikle, sistem başarısını ölçmek için karmaşıklık matrisi kullanılır. Karmaşıklık matrisinden elde edilen ölçümler ile kesinlik (Eş.1) , duyarlılık (Eş.2), doğruluk (Eş. 3) ve F1-skor (Eş. 4) değerleri hesaplanabilmektedir.

$$\begin{aligned} \text{Kesinlik} &= \text{TP}/(\text{TP}+\text{FP}) & (1) \\ \text{Duyarlılık} &= \text{TP}/(\text{TP}+\text{FN}) & (2) \\ \text{Doğruluk} &= (\text{TP}+\text{TN})/(\text{TP}+\text{TN}+\text{FP}+\text{FN}) & (3) \\ \text{F1 skoru} &= 2/(1/\text{Duyarlılık}+1/\text{Kesinlik}) & (4) \end{aligned}$$

Eşitlik 1, 2 ve 3’de verilen TP; tahmin ve gerçek değer pozitif olanını, TN; tahmin ve gerçek değer negatif olanını, FP; tahmin edilen değer pozitif ama gerçek değer ise negatif olduğunu, FN; tahmin edilen değer negatif ama gerçek değer ise pozitif olanını ifade etmektedir. Gerçekleştirilen çalışmada, Kesinlik değeri 0,7582, Duyarlılık değeri 0,7579, Doğruluk değeri 0,7372 ve F1-skor değeri ise 0,7565 olarak elde edilmiştir.

#### 4. TARTIŞMA VE SONUÇ

Gerçekleştirilen çalışmada, üç farklı ortamdan elde edilen balık görüntülerinden oluşturulan QUT FISH veri setindeki görüntüler kullanılarak balık türlerinin tahmini üzerine bir uygulama gerçekleştirilmiştir. Veri setinde bulunan görüntüler, derin öğrenme algoritmasındaki farklı yapıdaki dört evrişim katmanından geçirilerek, görüntülere ait öznelikler elde edilmiştir. Derin öğrenme algoritmasından elde edilen öznelikler ÇKYSA ile sınıflandırılmıştır. Tasarlanan hibrit sistem, öznelik çıkarma ve sınıflandırma olmak üzere iki bölümden oluşmaktadır. Öznelik çıkarma işlemi 289,46 dakika sürerken, sınıflandırma işlemi 216,79 saat sürmüştür.

**Çizelge 3.** Literatürde yapılan balık görüntülerinin sınıflandırılması çalışmaları

Yazar	Model	Sınıf Sayısı	Görüntü Sayısı	Başarı Oranı	Yıl
Iqbal vd. [36]	CNN	6	1334	%90,48	2019
Ju and Xue [37]	Fish_AlexNet	6	338	%97,43	2020
Baloch vd. [38]	Fish Image Segmentation Algorithm	30	369	%87,50	2017
Qiu vd. [39]	B-CNNs + rSE blocks	30	1123	%71,80	2018
Mathur ve Goel [40]	ResNet	37	600	%84,92	2021
Hridayami vd. [1]	VGG16	50	750	%96,40	2019
Adiwinata vd. [41]	Faster R-CNN	50	750	%80,40	2020
Guo vd. [42]	ResNet	200	1000	%42,40	2020
Sarıgül ve Avcı [43]	CNN	468	3960	%52,19	2017
<b>Önerilen Metot</b>	<b>CNN + ÇKYSA</b>	<b>483</b>	<b>4410</b>	<b>%73,72</b>	<b>2021</b>

Literatüre göre farklı balık görüntüsü içeren veri tabanları kullanılarak yapılan çalışmalar incelendiğinde birçok farklı modelin ayrı ayrı veya hibrit olarak kullanıldığı Çizelge 3’de görülmektedir. Yapılan sınıflandırma çalışmalarında %42,40 ile %97,43 arasında başarı oranları elde edilmiştir. Başarı oranları, kullanılan görüntülerin sınıf sayısına ve görüntü sayısına göre farklılıklar göstermektedir. Sınıf sayısının azaldığı çalışmalarda, başarı oranlarının arttığı görülmektedir. Yapılan çalışmada karmaşıklık matrisi hesaplamasına göre %73,72 başarı oranı ile balık türlerinin sınıflandırma işlemi gerçekleştirilmiştir. Yapılan çalışma diğer benzer çalışmalar ile karşılaştırıldığında sınıf sayısı hemen hemen aynı olan çalışmalara [43] göre daha iyi sınıflandırma başarısı elde ettiği görülmektedir. Ayrıca diğer çalışmalarda genellikle tek bir yöntem tercih edilirken, bu çalışma ESA ve YSA’nın birlikte kullanıldığı hibrit bir yaklaşım sunmaktadır.

#### KAYNAKLAR

- Hridayami, P., Putra, I. K. G. D., and Wibawa, K. S., “Fish species recognition using VGG16 deep convolutional neural network”, J. Comput. Sci. Eng., Vol. 13, No. 3, Pages 124–130, 2019.
- Meissa, B., and Gascuel, B., “Overfishing of marine resources: some lessons from the assessment of demersal stocks off Mauritania”, ICES J. Mar. Sci., Vol. 72, No. 2, Pages 414–427, 2015.
- Le Pape, O., Bonhommeau, S., Nieblas, A.-E. and Fromentin, J.-M. “Overfishing causes frequent fish population collapses but rare extinctions”, Proc. Natl. Acad. Sci., Vol. 114, No. 31, Pages 6274–6284, 2017.
- Davidson, L. N. K., Krawchuk, M. A., and Dulvy, N. K., “Why have global shark and ray landings declined: improved management or overfishing?”, Fish, Vol. 17, No. 2, Pages 438–458, 2016.



5. Hussain, M. A., Saputra, T., Szabo, E. A., and Nelan, B., "An overview of seafood supply, food safety and regulation in New South Wales, Australia", *Foods*, Vol. 6, No. 7, Pages 52-59, 2017.
6. Partis, L. and Wells, R. J., "Identification of fish species using random amplified polymorphic DNA (RAPD)", *Mol. Cell. Probes*, Vol. 10, No. 6, Pages 435-441, 1996.
7. Saitoh, T., Shibata, T., and Miyazono, T., "Feature points based fish image recognition", *Int. J. Comput. Inf. Syst. Ind. Manag. Appl.*, Vol. 8, Pages 12-22, 2016.
8. Hasija, S., Buragohain, M. J., and Indu, S., "Fish species classification using graph embedding discriminant analysis", in *2017 International Conference on Machine Vision and Information Technology (CMVIT)*, 2017, Pages 81-86.
9. Meng, L., Hirayama, T., and Oyanagi, S., "Underwater-drone with panoramic camera for automatic fish recognition based on deep learning", *IEEE Access*, Vol. 6, Pages 17880-17886, 2018.
10. Kılınç, E. E., and Metlek, S., "Su Altı Görüntülerinden Nesne Tespiti", *Avrupa Bilim ve Teknol. Derg.*, No. 23, Sayfa 368-375, 2021.
11. Larsen, R., Olafsdottir, H., and Ersbøll, B. K., "Shape and texture based classification of fish species", in *Scandinavian Conference on Image Analysis*, Pages 745-749, 2009.
12. Badawi, U. A., and Alsmadi, M. K., "A General fish classification methodology using meta-heuristic algorithm with back propagation classifier", *J. Theor. Appl. Inf. Technol.*, Vol. 66, No. 3, Pages 76-87, 2014.
13. Qin, H., Li, X., Liang, J., Peng, Y., and Zhang, C., "DeepFish: Accurate underwater live fish recognition with a deep architecture", *Neurocomputing*, Vol. 187, Pages 49-58, 2016.
14. Roberts, P. L. D., Jaffe, J. S., and Trivedi, M. M., "Multiview, broadband acoustic classification of marine fish: a machine learning framework and comparative analysis", *IEEE J. Ocean. Eng.*, Vol. 36, No. 1, Pages 90-104, 2011.
15. Liu, S., "Embedded online fish detection and tracking system via YOLOv3 and parallel correlation filter", in *OCEANS 2018 MTS/IEEE Charleston*, Pages 1-6, 2018.
16. Pettersen, R., Braa, H. L., Gawel, B. A., Letnes, P. A., Sæther, K., and Aas, L. M. S., "Detection and classification of *Lepeophtheirus salmonis* (Krøyer, 1837) using underwater hyperspectral imaging", *Aquac. Eng.*, Vol. 87, Pages 102-125, 2019.
17. İşçimen, B., Kutlu, Y., Reyhaniye, A. N., and Turan, C., "Image analysis methods on fish recognition", in *2014 22<sup>nd</sup> Signal Processing and Communications Applications Conference (SIU)*, Pages 1411-1414, 2014.
18. Robotham, H., Castillo, J., Bosch, P., and Perez-Kallens, J., "A comparison of multi-class support vector machine and classification tree methods for hydroacoustic classification of fish-schools in Chile", *Fish. Res.*, Vol. 111, No. 3, Pages 170-176, 2011.
19. Pornpanomchai, C., Lursthut, B., Leerasakultham, P., and Kitiyanan, V., "Shape-and texture-based fish image recognition system", *Agric. Nat. Resour.*, Vol. 47, No. 4, Pages 624-634, 2013.
20. Kayaalp, K. and Süzen, A. A., "Derin Öğrenme ve Türkiye'deki Uygulamaları", *Yayın Yeri IKSAD Int. Publ. House*, Basım sayısı, Vol. 1, 2018.
21. Goodfellow, I., Bengio, Y., Courville, A., and Bengio, Y., "Deep learning", Vol. 1, no. 2. MIT Press Cambridge, 2016.
22. Kemaloğlu, N., and Seveli, O., "Evrşimsel Sinir Ağları ile İşaret Dili Tanıma", *Proceedings on 2nd International Conference on Technology and Science*, Sayfa 942-948, Burdur, 2019.
23. Rao, B. S., "Accurate leukocoria predictor based on deep VGG-net CNN technique", *IET Image Process.*, Vol. 14, No. 10, Pages 2241-2248, 2020.
24. Tang, P., Wang, H., and Kwong, S., "G-MS2F: GoogLeNet based multi-stage feature fusion of deep CNN for scene recognition", *Neurocomputing*, Vol. 225, Pages 188-197, 2017.
25. Minhas, R. A., Javed, A., Irtaza, A., Mahmood, M. T., and Joo, Y. B., "Shot classification of field sports



- videos using AlexNet Convolutional Neural Network”, *Appl. Sci.*, Vol. 9, No. 3, Pages 483-495, 2019.
26. Metlek, S., and Kayaalp, K., “Derin Öğrenme ve Destek Vektör Makineleri İle Görüntüden Cinsiyet Tahmini”, *Düzce Üniversitesi Bilim ve Teknol. Derg.*, Vol. 8, No. 3, Pages 2208–2228, 2020.
  27. Ma, Z., “Fine-grained vehicle classification with channel max pooling modified CNNs”, *IEEE Trans. Veh. Technol.*, Vol. 68, No. 4, Pages 3224–3233, 2019.
  28. Wang, S.-H., and Chen, Y., “Fruit category classification via an eight-layer convolutional neural network with parametric rectified linear unit and dropout technique”, *Multimed. Tools Appl.*, Vol. 79, No. 21, Pages 15117–15133, 2020.
  29. Yıldırım, P., Birant, D., and Alpyıldız, T., “Data mining and machine learning in textile industry,” *Wiley Interdiscip. Rev. Data Min. Knowl. Discov.*, Vol. 8, No. 1, Pages 1228-1239, 2018.
  30. Abdullahi, H. S., Sheriff, R., and Mahieddine, F., “Convolution neural network in precision agriculture for plant image recognition and classification” in *2017 Seventh International Conference on Innovative Computing Technology (INTECH)*, Vol. 10, Pages 256-272, 2017.
  31. Mason, K., Duggan, J., and Howley, E., “A multi-objective neural network trained with differential evolution for dynamic economic emission dispatch”, *Int. J. Electr. Power Energy Syst.*, Vol. 100, Pages 201–221, 2018.
  32. Zermane, H., and Aitouche, S., “Digital learning with covid-19 in Algeria”, *Int. J. 3D Print. Technol. Digit. Ind.*, Vol. 4, no. 2, Pages 161–170, 2020.
  33. Elmas, Ç., “Yapay sinir ağları”, Sayfa 10-50, Seçkin Yayınları, İstanbul, 2003.
  34. Emeksiz, C., Doğan, Z., Gökrem, L., and Yavuz, A. H., “Tokat bölgesi rüzgar karakteristiğinin istatistiksel yöntemler ile incelenmesi”, *Politek. Derg.*, Vol. 19, No. 4, Sayfa 481–489, 2016.
  35. Metlek, S., and Yılmaz, T., “Analysis of Perceived Service Quality and Customer Satisfaction in the Aviation Sector with Artificial Neural Networks, 2”, in *Techno-Science, 2nd Internatioanl Conference on Technology and Science*, Pages 853–864, 2019.
  36. Iqbal, M. A., Wang, Z., Ali, Z. A., and Riaz, S., “Automatic fish species classification using deep convolutional neural networks”, *Wirel. Pers. Commun.*, Vol. 116, no. 2, Pages 1043–1053, 2021.
  37. Ju, Z. and Xue, Y., “Fish species recognition using an improved AlexNet model,” *Optik (Stuttg.)*, Vol. 223, p. 165499, 2020.
  38. Amanullah Baloch, D., Ali, M., Gül, F., Basir, S., and Afzal, I., “Fish Image Segmentation Algorithm (FISA) for Improving the Performance of Image Retrieval System”, *International Journal of Advanced Computer Science and Applications*, Vol. 8, No. 12, Pages 396-403, 2017.
  39. Qiu, C., Zhang, S., Wang, C., Yu, Z., Zheng, H., and Zheng, B., “Improving transfer learning and squeeze-and-excitation networks for small-scale fine-grained fish image classification”, *IEEE Access*, Vol. 6, Pages 78503–78512, 2018.
  40. Mathur, M. and Goel, N., “FishResNet: Automatic Fish Classification Approach in Underwater Scenario”, *SN Comput. Sci.*, Vol. 2, No. 4, Pages 1–12, 2021.
  41. Adiwinata, Y., Sasaoka, A., Bayupati, I. P. A., and Sudana, O., “Fish Species Recognition with Faster R-CNN Inception-v2 using QUT FISH Dataset”, *Lontar Komput. J. Ilm. Teknologi Inf.*, Vol. 11, No. 3, Pages 144-160, 2020.
  42. Guo, Z., “Few-shot Fish Image Generation and Classification”, in *Global Oceans 2020: Singapore–US Gulf Coast*, Pages 1–6, 2020.
  43. Sarıgül, M., and Avcı, M., “Comparison of different deep structures for fish classification”, *Int. J. Comput. Theory Eng.*, Vol. 9, No. 5, Pages 362–366, 2017.