



Su Ürünleri Yetiştiriciliği İçin Balık Davranışlarının Bilgisayarlı Görüntü İşleme Yöntemleriyle İzlenmesi

Güray TONGUÇ¹ Beytullah Ahmet BALCI^{2*} Muhammed Nurullah ARSLAN³

¹Akdeniz Üniversitesi, Uygulamalı Bilimler Fakültesi, Yönetim Bilişim Sistemleri Bölümü, Antalya, Türkiye

²Akdeniz Üniversitesi, Su Ürünleri Fakültesi, Su Ürünleri Yetiştiriciliği Bölümü, Antalya, Türkiye

³Recep Tayyip Erdoğan Üniversitesi, Su Ürünleri Fakültesi, Su Ürünleri Yetiştiriciliği Bölümü, Rize, Türkiye

Geliş Tarihi: 01.11.2022

Kabul Tarihi: 19.12.2022

Basım Tarihi: 31.12.2022

Atıf yapmak için: Tonguç, G., Balcı, B.A. & Arslan, M.N. (2022). Su Ürünleri Yetiştiriciliği İçin Balık Davranışlarının Bilgisayarlı Görüntü İşleme Yöntemleriyle İzlenmesi. *Anadolu Çev. ve Hay. Dergisi*, 7(4), 568-581.

How to cite: Tonguç, G., Balcı, B.A. & Arslan, M.N. (2022). Monitoring of Fish Behaviors with Computerized Image Processing Methods for the Aquaculture. *J. Anatolian Env. and Anim. Sciences*, 7(4), 568-581.

*ID: <https://orcid.org/0000-0002-6762-3259>

ID: <https://orcid.org/0000-0002-5476-7114>

ID: <https://orcid.org/0000-0002-9322-6804>

***Sorumlu yazarın:**

Beytullah Ahmet BALCI
Akdeniz Üniversitesi, Su Ürünleri Fakültesi, Su
Ürünleri Yetiştiriciliği Bölümü, Antalya,
Türkiye.

✉: abalci@akdeniz.edu.tr

Öz: Hayvan davranışlarının izlenip, yorumlanarak faydalı bilgiler haline getirilmesi son yıllarda önem kazanan konulardan birisi olmuştur. Makine öğrenmesi ve derin öğrenme algoritmaları gibi yazılımsal gelişmeler, görüntüleme cihazları ve elde edilen görüntülerin işlenmesine imkân tanıyan donanımsal gelişmeler, hayvan davranışlarının izlenmesine altyapı oluşturmaktadır. Özellikle insanlarla sesli veya fiziki etkileşim yeteneği bulunmayan balıkların yaşam alanlarında temassız ve tahribatsız izlenmesi, bu teknolojiler sayesinde mümkün olabilmektedir. Alternatif türlerin yoğun akuakültüre kazandırılmasında karşılaşılan problemlerin başında canlıların biyotik ve abiyotik gereksinimlerinin bilinmemesi gelmektedir. Bu çalışmada görüntü işleme yöntemleri ile balıkların günlük yaşamları, bakımları, beslenmeleri, bazı deneysel işlemlerin yapılması, bireysel veya sürü hareketleri, bu hareketlerin izlenmesi için oluşturulmuş donanımsal ve yazılımsal düzenekler ile ilgili yapılan çalışmalar hakkında bilgiler verilmiştir. Ayrıca, düzeneklerde kullanılan balıklar ve deney prosedürleri, elde edilen görüntülerin işleme yöntemleri, kullanılan istatistiksel yöntemler ve sonuçlarda ele alınmıştır. Bu makalede, su ürünleri yetiştiriciliği sektörü için kullanılabilecek görüntü işleme alanındaki çalışmalar incelenip sunulmuştur.

Anahtar kelimeler: Balık davranışları, görüntü işleme, invazif olmayan, su ürünleri yetiştiriciliği, tahribatsız teşhis.

Monitoring of Fish Behaviors with Computerized Image Processing Methods for the Aquaculture

Abstract: Observing and interpreting animal behaviors and turning them into useful information has become an issue that has gained importance in recent years. Software developments such as machine learning and deep learning algorithms, imaging devices, and hardware developments allow the processing of obtained images from the infrastructure for monitoring animal behavior. Thanks to these technologies, non-contact and non-destructive detection of fish, which cannot interact with people verbally or physically, in their habitats is possible. One of the problems encountered in introducing alternative species into intensive aquaculture is the lack of knowledge of the biotic and abiotic requirements of the living thing. This study gives information about the image processing methods, the daily life of fish, their care, feeding, some experimental procedures, individual or swarm movements, and the hardware and software mechanisms created to monitor these movements. In addition, the fish used in the setups and the experimental procedures, the processing methods of the images obtained, the statistical techniques used, and the results are discussed. This manuscript reviews and presents studies in the field of image processing that can be used for the aquaculture sector.

***Corresponding author's:**

Beytullah Ahmet BALCI
Akdeniz University, Faculty of Fisheries,
Department of Aquaculture, Antalya, Türkiye.

✉: abalci@akdeniz.edu.tr

Keywords: Aquaculture, fish behaviors, image processing, non-destructive detection, non-invasive.

GİRİŞ

Günümüzde ziraattan havacılık sanayisine kadar pek çok alanda her geçen gün daha fazla tahribatsız teşhis sistemi uygulamalarına geçilmektedir (Chen vd., 2013; Xia vd., 2019). Kullanılan ekipmana göre görsel, ultrasonik veya manyetik tabanlı olmak üzere çeşitli tahribatsız teşhis yöntemleri bulunmaktadır. Sadece Birleşik Krallık'ta yılda yarım milyondan fazla balık, bilimsel prosedürlere katılmaktadır (Anonim, 2022; Torjesen, 2014). Tahribatsız sistemlerin kullanılması ile özellikle canlı sistemlerde ölçüm yapılacak canlının ölçüm anında özelliklerinin değişmemesi, ölçüm sonrasında canlı veya cansız sistemde kalıcı hasar ya da ölçüm belirtileri kalmaması önemli bir avantajdır (Genç, 2011). Bu özelliğinden dolayı balıkların çeşitli durumlar karşısında izlenmesi ve anlamlı sonuçlar çıkarılması amacıyla kullanımı uygun olmaktadır. Bu çalışmada su ürünleri sektöründe kullanılan görüntü işleme uygulamaları, yazılımsal ve donanımsal yönleriyle ele alınmıştır.

Görüntü İşleme: Elektronik ortamda görüntüler piksel adı verilen noktacıklardan oluşmaktadır. Çözünürlük kavramı görüntüyü oluşturan piksellerin en ve boy olarak ölçüsünü belirtmektedir. Günlük hayatımızda görüntüleme cihazları ile ilgili sıklıkla duyduğumuz Full HD, 4K gibi tanımların temelinde çözünürlük kavramı yer almaktadır. Renkli resim dosyasında resmi oluşturan her bir pikselin yapısında kırmızı, yeşil ve mavi olmak üzere üç temel renk bazında değerleri kayıtlıdır. Bu değerler 0 ile 255 (2^8) arasında olabilir. Bir görüntü ekranda görüntülenirken bu üç rengin karışımı olan ara renk ekranda gösterilir. Görüntü işleme operasyonlarında belirli algoritmalar kullanılarak bu görüntüyü oluşturan piksellerin renk değerlerinin değişimi gerçekleştirilir. Videolar saniyede yaklaşık 24 sabit resim karesinden oluştuğu için videolarda görüntü işleme işlemleri videoyu oluşturan sabit karelerden birisinin ele alınarak üzerinde işlem yapılır, işlem tamamlandıca yeni bir sabit görüntü ile işlem sürekli olarak tekrarlanır.

Görüntü işleme işlemlerinde kullanılan algoritmalar üzerinde çalışılacak görüntünün ihtiyacı olan işleme göre değişiklik gösterir. Genel olarak görüntü aritmetiği, nokta işlemleri, geometrik işlemler, görüntü analizi, dijital filtreler, özellik çıkarma ve görüntü dönüşümü kategorilerinde algoritmalar (Safaei vd., 2022; Rao & Arora, 2004) ve bu algoritmaları bünyesinde hazır olarak bulunduran OpenCV gibi kütüphaneler mevcuttur (Bradski & Kaehler, 2008).

Görüntü işleme uygulamaları günümüzde sağlık, robotik, askeri, eğitim gibi pek çok alanlarda plaka okuma, yüz ifadelerinden duygu tespiti, uydur görüntülerinden zirai alan bilgilerinin çıkarılması, vücut görüntülerinden damar haritalarının çıkarılması (Koçer & Çevik, 2021), meyve

kalitesinin tespiti (Gao vd., 2010) gibi uygulamalarda yer bulmaktadır.

Avantajlar, Dezavantaj ve Kısıtlılıklar: Görüntü işleme yöntemlerinin su ürünleri yetiştiriciliğinde kullanımının çeşitli faydaları bulunmaktadır. Öncelikli olarak gözlemlenen balıklarda acı veren (invaziv) yöntemlerin kullanılmaması, balıkların doğal ortamlarında doğal halleri ile gözlemlenebilmesine imkân sağlamaktadır. Ayrıca görüntü işleme temelli sistemlerin ilk kurulum maliyetleri dışında işletme ve bakım maliyetleri oldukça düşüktür. Bu sistemler doğal ortamlarda veya özel düzeneklerde, akademik ya da endüstriyel çalışmalarda balıkların gözlemlenmesinde pek çok avantaj sağlayacaktır.

Avantajlarının yanı sıra görüntü işleme uygulamalarının ilk kurulum maliyetleri kurulacak düzeneğe bağlı ve göreceli olarak yüksek bulunabilir. Yapay zekâ algoritmalarına dayalı düzeneklerin ilk kurulum aşamasında eğitimi ve gerekli durumlarda güncellenmesi ek iş yükü gerektirebilir. Ayrıca sistemin doğruluğu ışık, bulanıklık, derinlik ve uzunluk gibi faktörlerden etkilenebilir. Pylatiuk vd., (2019), yaptığı çalışmada elde ettiği %2-4 arası hata oranı ile ilgili olarak kamera çözünürlüğü, kalibrasyon doğruluğu, balığın hızlı hareketi sırasında kırılma-düzeltilme hatası ve büyük derinlik mesafesinde görüntü bölümlenme ve morfolojik işlemlerle ilgili bozulma gibi unsurların sebep olabileceğini belirtmiştir.

Kullanım Amaçları: Su ürünlerinde görüntü işleme yöntemlerinin pek çok kullanımı bulunmakla birlikte (Niu vd., 2018) ilgili literatürde yer alan çalışmaların çoğunun tam olarak endüstriye uygulanmadığı veya deneysel düzeyde kaldığı görülmektedir.

Eldrogi vd., (2019) ve Barreiros vd., (2021) çalışmalarında bireysel veya sürü hareketlerinde balıkları, Liu vd., (2017), zebra balıklarının (*Danio rerio*) ve larvalarının çevre aydınlatmasında büyük değişikliklere tepkilerini (görsel motor tepkisi), AlZu'bi vd., (2015), zebra balığının bir dizi yaygın invaziv prosedüre karşı davranışsal tepkilerini, balığın 3 boyutlu yörüngesini, acı veren prosedürün uygulanmasından önce ve sonra gerçek zamanlı olarak izlemiştir. Papadakis vd., (2012) yaşam alanındaki balık yoğunluğunun balıklarda strese sebep olup olmadığı, Ditria vd., (2021) balık besleme davranışlarının otomatik analizi, Pylatiuk vd., (2019) balıkların lokomotor aktivitesini izleme ve otomatik beslenmesini sağlama konularında çalışmışlardır.

Chuang vd., (2016) sualtı görüntülerde görüntü işleme yöntemini kullanmıştır. Cui vd., (2020) bulanık Meksika Körfezi sularında balık görüntülerini incelemiştir. Knausgård vd., (2022) ılıman sularda balık türlerini tespit etmeye çalışmıştır. Labao ve Naval, (2019) ise bentik sualtı

videolarında balıkların tespiti üzerine çalışmalar yapmışlardır. Bazı çalışmalarda sualtı nesnelerinin üç boyutlu taranması için (Anwer vd., 2017), deniz içinden ve drone ile deniz üzerinden alınan görüntülerle deniz canlıları tespit edilmeye çalışılmıştır (Levy vd., 2018).

Balık boy ölçümü veya tahmini ile ilgili çalışmalar incelendiğinde, Man vd., (2016), resimden balık boy ölçümü için en uygun kameranın seçimi, Labao ve Naval, (2019) balık resimlerinden balığın boy tahminini, Petrellis, (2021) görüntülerde yer alan balıkların uzunluk, yükseklik ve görüntüde kapladığı alanları belirleme, Pérez vd., (2018), Al-Jubouri vd., (2017) boyutlu sanal simülatör ve emülatör ortamında, gerçek akvaryum ortamını oluşturma, balık boyutlarını tahmin etme ve ucuz web kameraları kullanarak küçük balıkların boy tahminini yapmışlardır.

Görüntü işleme yöntemleri kullanılarak balıkların herhangi bir insan gücü olmaksızın ayrıştırılmasına yönelik çalışmalarda (Kitasato vd., 2018) ve iki farklı balık türünün [Balon Balığı ve Japon Balığı] otomatik olarak ayrıştırılması üzerine çalışmalar yürütmüştür (Zhang vd., 2021).


Literatürde amonyağın balıklar üzerindeki etkisini tespit etme (Xu vd., 2020) ve koku uyarımına tepki olarak balık davranışının analizi üzerine çalışmalar da bulunmaktadır (Banerjee vd., 2021).

Donanımsal Ön İşlemler: İncelenen literatürdeki çalışmalardan bazılarında kurulan düzenekler doğrudan sualtında çalışır halde tasarlanırken bazıları akvaryum veya tanklardan alınan görüntülerden inceleme yapılmakta, bazıları ise sualtından veya akvaryum/tankları içerisinden çekilen videolar üzerinden işlem yapılmaktadır.

Barreiros vd., (2021) tarafından 55×25×20 cm ölçülerinde, su derinliği 10 cm, izleme algoritmasının hata yapmasını engellemek için dış duvarları kumlanmış cam bir tank kullanılmıştır. Papadakis vd., (2012), içerisinde 100 L tuzlu su (tuzluluk 38ppt) bulunan, iç yüzeyleri beyaza boyanmış dokuz adet paralel kenar tank 115×34×40 cm kullanmıştır. Banerjee vd., (2021), balığı görsel olarak korkutmak için cam bir tankın dışına dönen başka bir tank ve onun iç yüzeyinde bir noktaya siyah bir kâğıt yapıştırmış, tank dönüp siyah kâğıt balığın olduğu yere gelince balığın korkutulması amaçlamıştır.

Al-Jubouri vd., (2017), balık gövdesinin konturu ve konumu, incelenen balık popülasyonunun ön ve yan görüntülerini sürekli olarak yakalayarak belirlemişlerdir (Şekil 1). Düzenek bir akvaryum, iki kalibrasyon nesnesi, iki web kamerası ve bir bilgisayardan oluşmaktadır. Veri toplama, işleme ve izleme amaçları için genel bir dizüstü bilgisayar kullanılır (Intel R Core i5–3320M CPU 2,6 GHz, 8,0 GB RAM, MATLAB 2013b ve 64-bit Windows 7). Tankın üstü açıktır ve altı açıkken ortam ışığına maruz

kalmıştır. İki kalibrasyon nesnesi (2,03 cm çapında madeni paralar) tankın iki bitişik tarafına sabitlenmiştir. Çalışmada kullanılan web kameralar (TRIXES) 640×480 piksel (yani 300k piksel) görüntü boyutu, 29 kare/saniye hız ve 3,85 mm odak uzaklığına sahiptir.



Şekil 1. Akvaryuma kurulmuş bir görüntü alma düzeneği (Al-Jubouri vd., 2017).

Figure 1. An image-taking device installed in the aquarium (Al-Jubouri vd., 2017).


Papadakis vd., (2012) tanktan aldığı görüntüleri iki adet FireWire kartı ile (5+4) birleştirerek tek bir görüntü haline getirmiş ve web arayüzü ile izlenmesine imkân sağlamıştır. Üç farklı tankın içine yerleştirilmiş ağ ile (kesilmemiş, az kesilmiş, kesilmiş) balıkların bu bölmelerde yer değiştirmelerini izlemiştir. Balıklar, 5 mm kalınlığında camdan yapılmış tankın en uzun tarafından gözlemlenmiştir. Her tank, 17 mm altıgen gözlü, 31×28 cm boyutlarında beyaz bir su ürünleri ağından yapılmış bir ağ kullanılarak hacimce 60:40 olmak üzere iki bölgeye ayrılmıştır. Düzenekten her saniye 3 adet fotoğraf çekilmiştir.

Barreiros vd., (2021), kamera olarak Full HD (1920×1080) kamera kullanarak saniyede 30 kare hızında görüntü kaydetmiştir. Kamera akvaryumun yaklaşık 50 cm yukarısına monte edilmiştir. AlZu'bi vd., (2015), balıkların çeşitli invaziv işlemler sonrası davranışlarını ölçmek için iki özdeş akvaryum düzeneği kurmuş, kurduğu düzeneklerde yan ve üst taraflara kamera yerleştirilmiştir. Ditria vd., (2021), çalışmasında kullandığı verileri Tweed Nehri ağzında su altı aksiyon kameraları (Haldex Sports Action Cam HD 1080p) kullanılarak kaydetmiş, çeşitli arka planların ve balık açılarının yakalanmasını sağlamak için değişen açı ve kamera yerleşimi ile çeşitli deniz çayırı parçalarına 1 saat boyunca altı kamera yerleştirmiştir. Anwer vd., (2017) sualtı nesnelerinin üç boyutlu taranması için Kinect V2 kamerası kullanmış, kameranın sudan yalıtımı için tasarladıkları, çeşitli önlemlerin yer aldığı muhafazanın tasarımını paylaşmıştır.

Kullanılan donanımlar incelendiğinde; (Rico-Díaz, vd., 2020), iki tane su muhafazalı aksiyon kamerası

ve sistem olarak Intel Core i7-3770 CPU / NVIDIA GT 640 ekran kartı / 16 GB 1600 MHz DDR3 RAM sistem kullanmıştır. Görüntü elde etme ve işlemi için Barreiros vd., (2021), Intel Core i7 7700HQ CPU at 2800 8 GB RAM, Geforce GTX 1050 4 GB off-board ekran kartı, Petrellis, (2021), Intel Core i5-9500 CPU 3.00 GHz 6 core 16 GB RAM sistemini kullanmıştır.

Düzenek içi aydınlatma işlemi için Barreiros vd., (2021), akvaryumun altına 60×30 cm boyutlarında düz beyaz led ışık kaynağı yerleştirmiştir. Xu vd., (2020), oluşturduğu düzenekte yansımanın fotoğraf üzerindeki etkisini azaltmak için akvaryumun dibine siyah bir bez tabakası yerleştirmiş, 40×40×40 cm boyutunda akvaryum kullanmış, akvaryumun 67 cm yukarısına da renkli bir kamera yerleştirmiş ve onu tripod ile sabitlemiştir (Şekil 2). Balıkların davranışlarını rahat bir şekilde gözlemleyebilmek için tanka 5,6 L su ilave edildiği zaman su seviyesi yaklaşık 5 cm'dir ve kamera mesafesi su yüzeyinden 102 cm uzaklıktadır. Su seviyesi, balığın yüzme menziline iki boyutlu düzlemde kalmasını sağlamıştır.



Şekil 2. Akvaryuma kurulmuş bir görüntü alma düzeni (Xu vd., 2020).
Figure 2. An image-taking device installed in the aquarium (Xu vd., 2020).

Diğer çalışmalardan farklı olarak Pylatiuk vd., (2019), 26 °C'de 10 L (25×12×33 cm) hacimli tanklarda balık aktivitelerini izlemek için her tankın ön panelinin ortasına ve balıkların beslenme alanına giden bölüm üzerine birer adet uzun menzilli hassasiyete sahip bir IR fotosel sensörü yerleştirmiştir. İlk sensör balıkların lokomotor aktivitelerini izlemek için, ikincisi beslenme davranışlarını izlemek için kullanılmıştır. İkinci sensör,

önüne gelen bir balığı algılayınca otomatik yemleme sistemi çalışır. IR sensörlerden veri alma işlemi USB-1024HLS (Measurement Computing Corporation, Norton, MA) veri toplama cihazı ile gerçekleştirilir. Alınan veriler Labview yazılımı ile kaydedilmiş ve yemleme düzeneği çalıştırmıştır.

Kullanılan Balık Türleri: İncelenen çalışmalarda genellikle zebra balığı kullanıldığı dikkat çekmektedir. Zebra balığı, davranışsal sinirbilim, nöropsikofarmakoloji ve nörotoksikoloji alanında canlı modeli olarak kullanımı giderek yaygınlaşmaktadır (Lawrence, 2007; Maximino vd., 2010; Stewart vd., 2012; Di Paolo vd., 2015). Bir model organizma olarak, zebra balığı, nörofarmakolojik mekanizmaları anlamak için yararlı bir kaynak olduğunu kanıtlayan yüksek verimli ve düşük maliyetli test konusu sağlar. Zebra balığının ayrıca ilaç keşfini kolaylaştırmak için harika bir kaynak olduğu kanıtlanmıştır (Linney vd., 2004). Birçok çalışma, zebra balıklarının dış uyaranlara bir yanıt olarak kaygıyla ilgili davranış sergilediğini kanıtlamıştır (Egan vd., 2009; Stewart vd., 2011; Maximino vd., 2014). Levin vd., (2007), zebra balıklarında kaygıyla ilgili davranış tankın kenarı boyunca yüzmekle ilişkilendirmiştir. Balıkların kaygı davranışlarını uyararak için farklı dozlarda nikotin kullanılmış, zebra balığının, deney boyunca yüzme aktivitelerinde önemli bir değişiklik gösterdiği, dış uyaranlara maruz kaldıktan sonra tankın dibinde durmaya meyilli olduğu görülmüştür. Liu vd., (2017) bildirdiğine göre zebra balığı, nörodavranışsal araştırmalarda yaygın olarak kullanılmaktadır, çünkü bu model birkaç benzersiz avantaj sağlar. Bunlardan birisi zebra balığının yüksek doğurganlığa sahip olması ve çiftleştiğinde rutin olarak yüzlerce embriyo bırakmasıdır. Bu embriyolar da küçüktür ve üç ila dört gün içinde yüzen larvalara dönüşürler, bu da farklı deneysel koşullar altında lokomotor davranışlarının eşzamanlı takibini kolaylaştırır. Bu sebeplerden dolayı nörobiyoloji (Prober vd., 2006; Gao vd., 2014), farmakoloji (Baxendale vd., 2012; Bruni vd., 2016; Kokel vd., 2013; Nath vd., 2013; Rihel vd., 2010; Zhang vd., 2016) ve toksikoloji (Akhtar vd., 2013; MacPhail vd., 2009) alanlarında önemi gün geçtikçe artmaktadır.

Barreiros vd., (2021) ve Liu vd., (2017) çalışmalarında zebra balığı kullanmışlardır. (Barreiros vd., 2021), her iki cinsiyetten 13'er zebra balığı kullanmış ve görüntülerde aynı anda 3 ila 100 arasında değişen balık görüntüsü yer almıştır. AlZu'bi vd., (2015), 40 adet zebra balığı kullandığını bildirmiştir. Al-Jubouri vd., (2017), farklı uzunluklarda iki zebra balığı (42 ve 45 mm) ile çalışmalarını yapmışlardır. Pylatiuk vd., (2019), her balık tankında 7-14 balık olacak şekilde yetişkin medaka balığı (*Oryzias latipes*) ve zebra balığı kullanmışlardır. Papadakis vd., (2012), gerçekleştirdiği her bir test için 135, toplam 405 çipura (*Sparus aurata*) kullanırken, Petrellis, (2021),

levrek (*Dicentrarchus labrax*), sivriburun karagöz (*Diplodus puntazzo*), berlam (*Merluccius merluccius*) ve çipura (*Sparus aurata*) türü balıklar kullanılmıştır. Kitasato vd., (2018), kolyoz (*Scomber japonicus*) ve mavi uskumru (*Scomber australasicus*), Zhang vd., (2021), türlerini otomatik ayırt etmeye çalıştığı [Balon Balığı (Pufferfish) ve Japon Balığı (Goldfish)], (Xu vd., 2020) benzer büyüklükte, gövde uzunluğu yaklaşık 6 cm, gövde yüksekliği ise yaklaşık 2 cm olan üç adet Japon balığı ile çalışmışlardır.

Ditria vd., (2021), çalışmasında kullandığı Parore balığının (*Girella tricuspidata*) yaklaşık 30-40 cm boyutu ile kolayca gözlemlenebilir olduğunu, kıyı habitatlarında yaygın olduğunu ve beslenirken bariz bir vücut hareketi sergilediğini bunun da onları bu yöntemi test etmek için iyi bir model tür haline getirdiğini bildirmiştir. Rico-Díaz vd., (2020), iki farklı test düzeneğinin birisinde 9 cm'lik parlak renkli bir tek balık, ikincisinde 1 m uzunluğunda iki balık kullanmıştır.

Kullanılan Veri Setleri: Literatürde incelenen çalışmaların bazılarında yapay zekâ modellerini eğitmek için oluşturulan deney düzeneklerinden veya çeşitli denizlerden görüntü alınmakla birlikte bazı çalışmalarda hazır balık görüntüsü veri setleri kullanıldığı belirlenmiştir.

Ditria vd., (2021), Avustralya, Queensland, Tweed Nehri ağzında, Cui vd., (2020), Meksika körfezindeki bulanık su ortamlarından, Zhang vd., (2021), Çin'de bulunan bir göletten video çekmiş ve bunları gerekli ön işleme tabi tutmuşlardır. Labao & Naval, (2019), Filipinler'in 10 farklı bölgesinden bentik su altı videolarını çekmiştir. Yapay zekâ modellerinde eğitim ve test amaçlı kullanılacak görüntülerin araştırmacılar tarafından oluşturulması genellikle videoların ilgili ortamdan çekilmesi, videolarda uygun olan karelerin elde edilmesi, görüntülerde eğitimi yapılacak nesnelere işaretlenerek etiketlenmesi adımlarını içermektedir. Araştırmacının gerekli görmesi halinde görüntülerin modele verilmeden önce bazı görüntü işleme yöntemleri ile iyileştirmelere tabi tutulması gerekebilir. Bu işlemler genellikle zahmetlidir ve uzun zaman almaktadır. Bunun yerine çeşitli balık türlerine ait resimlerin bulunduğu ve etiketlendiği hazır veri setleri de çalışmalarda kullanılmıştır (Chuang vd., 2016; Knausgård vd., 2022; Monkman vd., 2019; Petrellis, 2021). İnternet taraması ile daha fazla örnekleri bulunabilecek bu veri setlerine bazı örnekler aşağıda verilmiştir.

- Labeled Fishes in the Wild (Vahşi Doğada Etiketli Balıklar): Test Videoları+1328 Pozitif+149 Negatif görüntü (433MB) (Anonim, 2014).
- Aquarium Dataset (Akvaryum Veri Kümesi): 638 görüntü (Anonim, 2020b).
- Brackish Underwater Dataset (Acısu Sualtı Veri Kümesi): 14.674 görüntü (Anonim, 2020c).

- A Large Scale Fish Dataset (Büyük Ölçekli Balık Veri Kümesi): 9 farklı deniz türü ve her tür için 1.000 artırılmış görüntü ve bunların ikili olarak artırılmış temel gerçekleri (3GB) (Anonim, 2020a).
- RoboFlow Fish Dataset (RoboFlow Balık Veri Kümesi): 680 görüntü (Anonim, 2020d).
- Shellfish-OpenImages Dataset (Kabuklu deniz ürünleri-OpenImages Veri Kümesi): İçerik: 581 görüntü (Anonim, 2020e).

Deney Prosedürleri: İncelenen çalışmalarda her bir deney kendine has özellikler içerdiği için farklı deney prosedürleri ve işlem adımlarına sahiptir bu nedenle aşağıdaki gibi ayrı ayrı bahsedilmiştir. Eldrogi vd., (2019) yaptıkları çalışmada balıklar izlenmeye başlamadan önce işaretlenmiş sonra deney ortamına bırakılmıştır. Barreiros vd., (2021) yaptıkları çalışmada balıklar işleme alınmadan önce iki hafta boyunca kapalı devre sistemde tutulmuştur. Su kalitesi, mekanik, biyolojik ve kimyasal filtrasyon ile sıcaklık 26 ± 1 °C'de ve pH yaklaşık 7,2'de tutularak haftalık olarak izlenmiş, balıklar günde dört kez ticari gıdalarla beslenmiştir (%38 protein, %4 yağ). Aydınlatma, 12 saat aydınlık, 12 saat karanlık döngüsünde ayarlanmıştır. Pérez vd., (2018), doğal koşulları daha doğru bir şekilde yeniden oluşturmak için akvaryumda sıcaklık, pH, çözülmüş oksijen, iletkenlik ve bulanıklık sensörleri monte etmiştir.

Xu vd., (2020), amonyağın balıklar üzerine etkisini tespit etmek için yaptığı deneyi üç kez tekrarlamış ve her bir deney iki gün sürmüştür. İlk gün normal ortamı korumak için suya amonyum klorür eklenmemiştir. İkinci gün, farklı amonyum klorür konsantrasyonlarının değiştirilmesi dışında her balık için deney koşulları ilk günkü ile aynı bırakılmıştır. Deneylerin her iki gününde de çekim yapılmıştır. Her yemlemeden önce ve sonra, akvaryumda saat 8:25 ve 18:35'te suyun pH değeri ve amonyak, nitrojen içeriği tespit edilmiştir. Ortama amonyum eklenmesinin ardından balık yörüngelerinin daha net görülebilmesi için, her deney için yalnızca yarım saatlik izleme yapılmıştır.

Papadakis vd., (2012), yaptıkları deneme sırasında balıklar tankın %60'lık bölümünde (bekleme alanı olarak adlandırılır) tutulmuş ve her gün bir kez saat 14:00'te yemlenmiştir. Her tankta sağlanan yem miktarı, tanktaki ilk balık popülasyonunun biyokütlesinin %2'sine eşdeğer tutulmuş ve su akıntıları nedeniyle ağın diğer tarafına olası yem akışını önlemek için, yem her zaman tutma alanının bir köşesinden verilmiştir. Deneylerde günlük 24 saat kamera kaydı devam etmiş fakat analiz işlemi sadece aşağıdaki süreci içeren kayıtlar için gerçekleştirmişlerdir. Her bir deneyde önce dört gün balıklara iklimlendirme süreci uygulanmış, sonraki 24 saatte kayıt alıp incelenmiş, bu 24 saat içinde de sadece günün başında (8:30), sabah ortasında (11:00), besleme

saatinden önce (13:00), sonrası besleme saati (15:30) ve günün sonunda (19:30), 15 er dakikalık videolarda ağa yakınlık ve ağı ısırma durumları incelenmiştir.

Al-Jubouri vd., (2017), balık boy tahmini yaptıkları çalışmalarında balıkları oda sıcaklığında (25 °C) ve filtrelenmiş su ile doldurulmuş, daha önce belirtilen boyutları olan iki tanka yerleştirmiş, balığın gerçek uzunluğunu 30×11×17 cm'lik ek küçük cam tank kullanılarak ölçülmüştür. Her balığın uzunluğunu tahmin etmek için iki ayrı yetişkin zebra balığı ile yapılan deney 10 kez tekrarlanmıştır. Test edilen balıklar için uygun refah durumunu korumak için, bu deneyleri günde iki deney sıklığında gerçekleştirmişler, her deneyde balık, alışma için yaklaşık bir saat boyunca test tankına alınmışlar ve çalışmanın amacı için yeterli olduğu düşünülen 3000 kare yakalanana kadar görüntü yakalama işlemini başlatmışlardır. Bu işlem test edilen balığın yüzme davranışına bağlı olarak bir saat kadar sürmektedir.

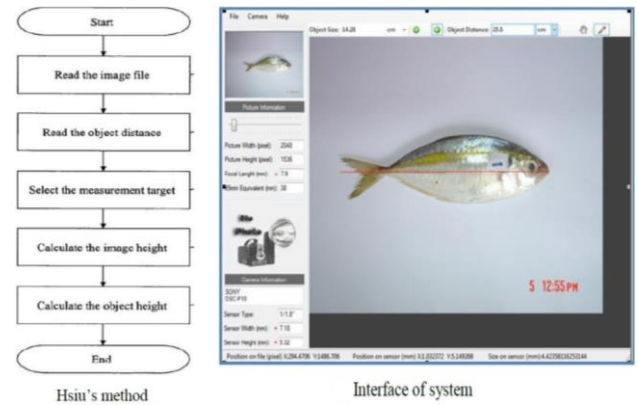
Pylatiuk vd., (2019), balıkları 14 saat aydınlık-karanlık döngüsüne sahip devir daim suyu sistemlerinde standart koşullar altında 10 saat tutmuştur. Deneysel işlemleri Avrupa Birliği hayvan refahı standartlarına uygun olarak gerçekleştirmişlerdir (Anonim, 2010).

Balıkların koku uyarımına tepkisini ölçmek üzere hazırladığı deneyinde Banerjee vd., (2021), şu adımları izlemiştir; Balıklar, her akvaryumda bir balık olacak şekilde deney yapılacak akvaryuma konulmuştur, balıklar, 30 dakika boyunca tamamen karanlıkta bırakılarak ortama adapte olmuştur. Balıklar, dönen bölümün yaklaşımına davranışsal tepkiler için test edilmiştir. Başlangıçta, dönen segmenti aydınlatan ışığın yoğunluğu, neredeyse tamamen karanlık bir seviyeye ayarlanmıştır. Ardından balık dönen segmente kaçış tepkileri gösterene kadar 0,5 log birim kademeli olarak artırılmıştır. Kaçış tepkilerini ortaya çıkarmak için gereken minimum ışık, eşik ışık hassasiyeti (mutlak görsel hassasiyet seviyesi) olarak not edilmiştir, ışık eşiği belirlendikten sonra, bir pipet aracılığıyla akvaryuma koku uyarımı (1 µL metionin stok solüsyonu, 3 mM suda çözülmüş) uygulanmıştır ve hemen sonra balığın görsel duyarlılığı tekrar ölçülmüştür.

Pérez vd., (2018), 3 boyutlu sanal simülator ve emülatör ortamında, gerçek akvaryum ortamını oluşturmaya ve balık boyutlarını tahmin etmeye çalıştığı projesinde üç aşama tanımlamıştır bunlar, 3B sanal simülator, test akvaryumu ve gerçek doğal ortamdır. Hem simülator hem de test akvaryumunda su altında meydana gelen doğal koşullar kontrollü bir şekilde yeniden oluşturulmaya çalışılmışlardır. İlk aşamada sadece test ortamlarında elde edilen sonuçlar toplanmış, karşılaştırılmış ve bununla ölçüm yazılımının geliştirilmesi ve iyileştirilmesi sağlanmıştır. İkinci aşamada ise gerçek ortam üzerinde çalışmaya başlanmış ve elde edilen

bilgilere göre hem test ortamlarının hem de ölçüm yazılımının iyileştirildiği bir süreç başlatmışlardır.

Görüntülerin İşlenme Yöntemleri: Görüntü işleme uygulamalarında temel işlemlerden birisi olarak elde edilen görüntülerden arka plan görüntüsü çıkarılmaktadır. Eldrogi vd., (2019) ve Rico-Díaz vd., (2020) balıkların takibi için ağırlık merkezlerinin tespitinde Kalman filtresi, Eldrogi vd., (2019) ve Barreiros vd., (2021), balık hareket yörüngelerinin tespiti için de en yakın komşuluk yöntemi ve kendi geliştirdikleri matematiksel yöntemler kullanmıştır. Liu vd., (2017), bu işlemi her karede larvanın hareketi bir önceki karedekinden belirli bir eşik miktarınca hareket ettiğinde balığın hareketini kayıt altına alarak yapmıştır. Man vd., (2016), resimden balık boy ölçümü yapmak üzere en uygun kamera tespiti üzerine yaptığı çalışmada Şekil 3'te görülen HSIU modelini ve ilgili yazılımı kullanmıştır.




Şekil 3. Örnek bir görüntü işleme algoritması ve yazılımı (Man vd., 2016).
Figure 3. An example image processing algorithm and software (Man vd., 2016).

Papadakis vd., (2012), resimlerin işlenmesi için Labview yazılımında arka plan çıkarma ve nesne algılama (object detection) yöntemlerini kullanmıştır. Görüntülerde bir noktayı referans noktası olarak kullanmışlar ve her bir görüntüdeki balığın orta noktasını tespit edip referans noktasına uzaklığını hesaplamışlardır. Başka bir algoritma, balık popülasyonunun ortalama pozisyonunun referans noktasına uzaklığını hesaplamış görüntüdeki balık sayısı, referans noktasına yatay dikey uzaklığı ve ortalama hızları kayıt altına alınmıştır.

AlZu'bi vd., (2015), balıkların davranış analizini yapmak için kameralardan aldığı görüntülerde arka plan çıkarma ve "Blob Analizi" işlemlerini yapmışlardır. Araştırmacılar kendi geliştirdikleri davranış analizi yazılımı ile hız, ivme (hızlanma/yavaşlama), aktif zaman, keskin manevra, işgal hacmi, mekânsal aktivite dağılımı gibi özelliklerin çıkarılmasını yapmaktadırlar. Bunun yanı sıra dinlenme durumundan çıkarılan özellik vektörü, geri kalan durumları normalleştirmek için bir temel olarak kullanılır ve SVM (Support vector machine) sınıflandırıcısı, balık aktivite durumunu, yani normal ve

anormal durumunu tanımak için kullanılmaktadır. Ayrıca düzenekten elde edilen veriler ikinci dereceden diskriminant analizi (QDA) sınıflandırıcısını eğitmek için kullanılmaktadır.

Kitasato vd., (2018) çalışmalarında Şekil 4'te görüldüğü gibi *Scomber japonicus* (kolyoz) ve *Scomber australasicus* (mavi uskumru) balık türlerinin otomatik olarak ayrımı için kenar algılama (sobel), genişleme (dilation), aşınma (erosion) gibi görüntü işleme yöntemlerini içeren algoritma oluşturulmuş ve bu iki balık türünün kendine has özellikleri kullanılarak balıklar görsel olarak ayrt edilmiştir.

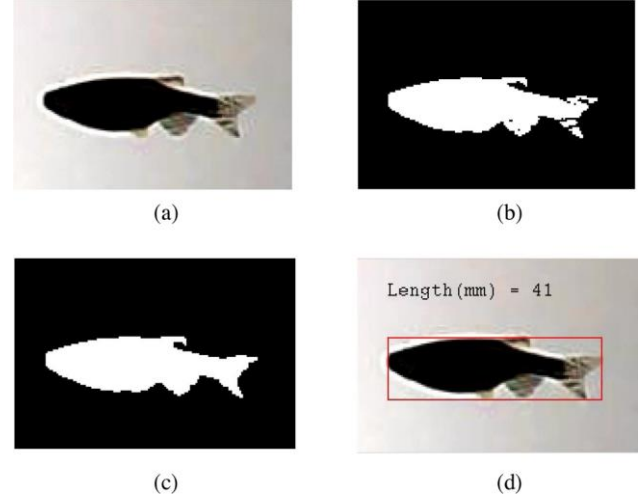


Şekil 4. Ölçüm noktaları tespit edilmiş balık görüntüsü (Kitasato vd., 2018).

Figure 4. Fish image with measuring points detected (Kitasato vd., 2018).

Rico-Díaz vd., (2020), çalışmasında balıkların tespiti için iki farklı yöntem kullanmış, birincisinde arka plan çıkarma, RGB->Gri Skala dönüşümü, Gaussian Blur, Hough algoritması, Mean Shift, Canny, bulanıklaştırma, netleştirme gibi pek çok görüntü işleme yönteminden oluşan algoritma oluşturularak, akvaryumda balığın kabaca görüntüsü tespit edildikten sonra belirlenen nesnenin gerçekten balık olup olmadığını anlamak için balık gözü, göz bebeği ve göz akı araması yapılmış. İkinci yöntemde Yapay Sinir Ağı (YSA) temelli algoritmada gizli katmanda 2000 nöron ve 7500 periyod ile örnekler gösterilerek YSA'nı eğitmişlerdir.

Al-Jubouri vd., (2017), yaptığı çalışmada kameradan gelen derinlik ve ışığın kırılmasından kaynaklanan projeksiyon hatasını açıklayan matematiksel bir model türetmiş ve uygulamıştır (Şekil 5). Balık boyu ölçümleri sırasında ışık kırılmasını hesaba katmak için otomatik bir kalibrasyon prosedürü de önerilmiştir. Benzer şekilde, bir kamera mesafesi kalibrasyonu deneysel olarak yapılır ve balık boyunun tahmin süreci boyunca dikkate alınmıştır. Kamera-akvaryum arası mesafe hesabının ardından kalibrasyon ve arka plan algılama işlemleri yapılır, arka plan algılama işleminin ardından %50 eşik değeri uygulanarak görüntü ikili formata (binary) çevrilmiştir. Bu işlem sırasında balığın şeffaf olan kısımlarındaki görüntü kayıplarını gidermek için morfolojik görüntü işleme algoritmaları kullanılmıştır. Mikrometre başına düşen piksel sayısı (457 ve 253 px/ μm) her iki kamera için ayrı ayrı hesaplanmıştır.




Şekil 5. İlgili işlemler sonucu ölçüleri elde edilmiş balık görüntüsü (Al-Jubouri vd., 2017).

Figure 5. Fish image whose measurements have been obtained as a result of the related processes (Al-Jubouri vd., 2017).

Ditria vd., (2021), kayıt altına aldığı videoları, balık görüntülerini içerecek şekilde eğitim için 25 kare/sn'ye bölmüş ve etiketleme işlemi yapmıştır. Etiketleme işleminde balık görüntüleri görüntünün alındığı anda besin alan veya besin almayan olarak belirtilmiştir. Eğitim veri seti, belirli bir davranış için orantısız eğitim verilerine sahip olmaktan tahmin yanlılığını önlemek için yaklaşık olarak eşit sayıda her iki davranışı içerecek şekilde dengelenmiştir. Bu, yalnızca tek bir davranış üzerine eğitim verilmesi, o davranışın algoritma tarafından tahmin edilme olasılığını artıracak ve daha fazla sayıda yanlış pozitif sonuç vereceği için önemlidir. Beslenme, bir balığın ağzını deniz çayırına dokundurduğu andan başlayıp onu koparıp ayrılmasına kadarki süreci kapsamaktadır. Sınıflandırma işlemi için ResNet50 modeli Microsoft Azure Veri Bilimi Sanal Makinesi üzerinde 40.000 yineleme ile gerçekleştirilmiştir. Veri büyütme tekniği olarak verilerin rastgele %50'si seçilerek ters çevrilmiştir.

Pérez vd., (2018), sualtında balığın görüntüsünü tespit etmek ve boyutunu hesaplamak için öncelikle arka plan çıkarma işlemi için Zivkovic ve Van Der Heijden, (2006) ve Zivkovic, (2004)'ün kullandığı gibi "Gaussian Mixture-based Background / Foreground Segmentation Algorithm" kullanmıştır. İki farklı kameradan alınan görüntüler üzerinde Gaussian bulanıklaştırma filtresi çalıştırılmış (Şekil 6A), ardından kenar belirleme (canny), aşındırma, genişletme filtreleri kullanılarak balığın şekli belirlenmiştir (Şekil 6B-F).

Monkman vd., (2019), NASNet, RESNet, MobileNet ve R-CNN metodları ile oluşturduğu algoritmayı eğitmek için 918 (734 eğitim, 184 doğrulama) adet resim kullanmıştır. Bu işlemler sırasında balıkların gövdesine balığın boyutu ile ilgili bilgi içeren karekod da yerleştirilmiştir.



Sekil 6. Doğal ortamında resmedilen ve ölçüleri çıkarılan balığın işlem adımları (Pérez vd., 2018).

Figure 6. Processing steps of the fish pictured and measured in its natural environment (Pérez vd., 2018).

Barreiros vd., (2021) balık kafa bölgelerini belirlemek için evrişimli bir nesne tanıma ağı olan YOLOv2 yi balık baş bölgesi resimleri ile eğitip kafa bölgesinden yola çıkarak balığın ağırlık merkezi tahmini yapılırken, (Feijó vd., 2018; Qian, vd., 2014; Wang vd., 2016; Zhao vd., 2019) balığın vücudunu tespit ve tanımlamanın bir tamamlayıcısı olarak kullanmıştır.

Barreiros vd., (2021), test işlemini tamamı 30 fps ile kaydedilmiş 1920×1080 çözünürlükte toplam 8427 kareden oluşan video ve 3712×3712 çözünürlükte 6820 kareden oluşan video verileri ile yapmışlardır. Yüksek çözünürlüklü resimleri YoloV2 ağına uyumlu hale getirmek için resimler üzerinde inceleme öncesi ve sonrası bir dizi işlem yapılmıştır. Elde edilen görüntülerin işlenmesinde Matlab R2019b yazılımından faydalanmışlardır. Petrellis, (2021), görüntü işleme ve makine öğrenimi tekniklerine dayalı iki farklı yöntemi balıkların göreceli uzunluğu, yüksekliği ve görüntüde kapladığı alanı tespit etmek için kullanmıştır. Görüntü işleme için sobel, canny gibi kenar belirleme algoritmaları denenmiş fakat daha etkin sonuç veren imgradient ile

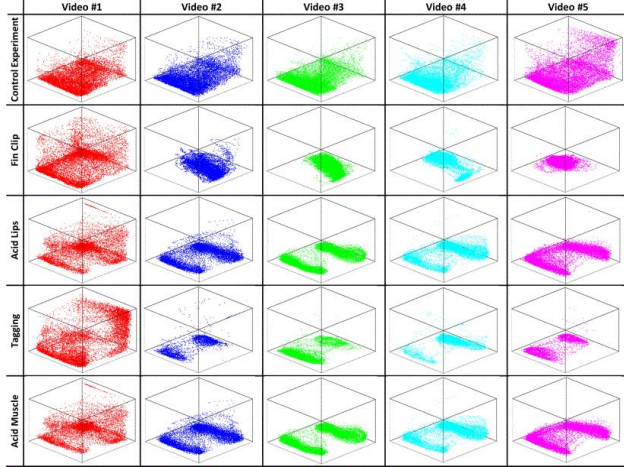
balıkların kenar bilgilerini elde etmeye çalışmıştır. İkinci yöntemde ise karmaşık arka plan görüntülerine sahip balık görüntüsünü içeren resimlerin işlenmesi için VGG16 CNN algoritmasını ImageNet veri seti ile eğitmişlerdir.

Knausgård vd., (2022) ise tanıma işlemi için YoloV3 modelini ve Squeeze-and-Excitation (SE) mimarisine sahip CNN (Evrişimsel Sinir Ağı) kullanmışlardır. Labao ve Naval, (2019) bu işlem için “ResNet v2 Architecture” kullanmıştır. Levy vd., (2018) bu işlemi YOLO ve ResNet kombinasyonu ile yapmışlardır. Xu vd., (2020), balık takibi sırasında balıkların tespiti için Faster R-CNN ve YOLO-V3 modellerini kullanmışlar. Bu modellerin eğitimi için akvaryumdan kaydettikleri 10 saatlik videoları her saniyeye bir görüntü gelecek şekilde Matlab yazılımı ile Jpeg formatında parçalamışlardır. Oluşan 36000 adet görüntüden 21600 tanesi normal ortamda, kalanı amonyak eklenmiş su ortamındadır. Bunlardan rastgele 1700 tanesi alınmış, 1190 eğitim, 510 test (7:3) amaçlı olarak kullanılmıştır. Görüntüler LabelImg yazılımı ile etiketlendikten sonra modeller eğitime tabi tutulmuştur. YZ modeli oluşturmak ve eğitmek için Python, elde edilen balık konum sonuçlarından balık yörünge haritası çıkarmak için Matlab kullanmışlardır. İşlemler Windows 10 altında MATLAB 2018a ve Python 3.5 tarafından işlenir ve süreç GPU tarafından hızlandırılır.

Banerjee vd., (2021), balığın yer aldığı tanka koku maddesi vermeden önce ve sonra takip etmek için tankı yukarıdan gören tek bir kameradan aldıkları görüntüleri YoloV3 ile değerlendirmişler ve sonuçta balığın işlem öncesi ve sonrası gezindiği konumları tespit etmişlerdir. Zhang vd., (2021), Çin’de yer alan bir göletten çektikleri videodan 1500 adet görüntü elde etmişlerdir. Ön işlemlerden geçirilen görüntülerde 700 balon balığı, 600 Japon balığı resmi etiketlendikten sonra YOLO V4 ile YoloV4+CBAM (Convolutional Block Attention Module) modellerini eğitmek için kullanılmıştır. Elde edilen verilerin değerlendirilmesi için Papadakis vd., (2012) ve Liu vd., (2017), balıkların hareketlerini incelerken t-testi, Anova ve Manova testi kullanmış, normallik testi verilerin normal dağılmadığını gösterdiğinde Kruskal-Wallis testi ve Wilcoxon işaretli sıra testi gibi parametrik olmayan testler kullanmışlardır.

Elde Edilen Sonuçlar: AlZu’bi vd., (2015), balıkların acı verici (invaziv) prosedürlerden geçtikten sonra belirli aktivite kalıpları geliştirdiğini belirtmişlerdir. Dinlenme durumunda, balık belirli bir hareket modeli olmaksızın tankın etrafında hareket etme eğilimindedirler. Yaygın prosedürlerden birini uyguladıktan hemen sonra, balık yörüngesi, dinlenme durumundaki yörüngeden önemli ölçüde farklı hale gelir, örneğin balıklar, tüm tankı işgal etmek yerine zamanın çoğunu tankın altında geçirme eğilimindedir. Balıklar genellikle prosedürler

uygulandıktan sonra Şekil 7’de görüldüğü gibi daha az aktiftir; balıklar aynı zamanda tank içindeki lokalize alanlara yoğunlaşmaktadırlar. Balık yörüngelerinden çıkarılan bir dizi özellik, acı belirtisi olarak yorumlanmıştır. Çalışma sonunda ikinci dereceden diskriminant analizi (QDA) sınıflandırıcısı anormallik aktivitelerini ortalama %95 doğrulukla tespit edilebilmiştir.



Şekil 7. İnvaziv işlem sonucu balık yörüngeleri (AlZu’bi vd., 2015).

Figure 7. Fish trajectories as a result of invasive procedure (AlZu’bi vd., 2015).

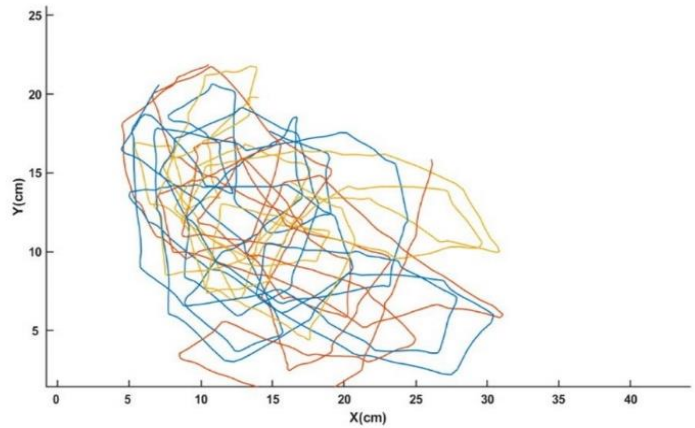
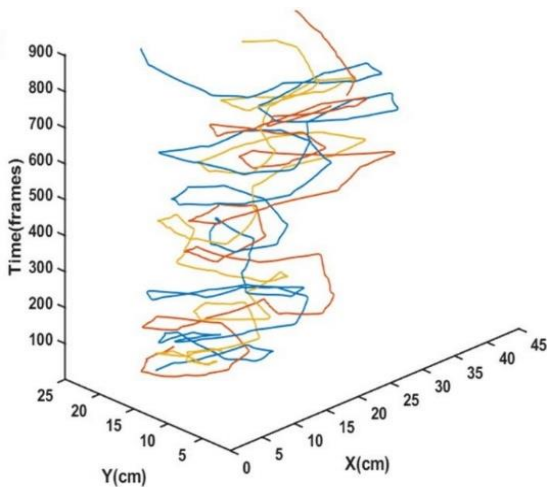
Pylatiuk vd., (2019), IR sensörler ile balık lokomotor davranışlarını izlediği ve yemleme sistemini aktive ettiği çalışmasında Medaka balığının lokomotor ve beslenme aktivitelerinin temsili aktogramları üretmiştir. Bu aktogramlarda medaka balığının aktivitesinin ağırlıklı olarak gündüz ile sınırlı olduğu, gece boyunca küçük aktivite nöbetleri, yetersiz yüzme aktivitesi ile karakterize edilen uyku evrelerini kesintiye uğratan kısa yüzme dönemleri, ışık evresinin başlangıcından başlayan ve daha sonra ışık döneminin geri kalanında azalan ve günlük

beslenme evreleri görülmektedir. Ayrıca kayıtlar medaka balığının besleme sistemini nasıl etkinleştireceğini hızla öğrendiğini gösteren sabit bir günlük besleme düzenini göstermiştir.

Papadakis vd., (2012), balık yoğunluğunun balıklarda strese sebep olup olmadığını belirlemeye çalıştığı düzenekte dominant balıkların yemleri kontrol ettiğini dolayısı ile balık yoğunluğu ile balık davranışları ve beslenme arasında bağlantı bulunduğunu gözlemlemiştir.

Ditria vd., (2021), Parore balıkları için ResNet50 algoritması ile %92 doğru tespit işlemi yapıldığını, yöntemin daha küçük veya şifreli türler veya ince davranışlar sergileyenler için daha az uygun olabileceğini bildirmişlerdir.


Rico-Díaz vd., (2020) küçük balıkların akvaryumun camlarına yaklaştığı anlarda balığın tespitinin zorlaştığını bildirmiştir. Yalnız görüntü işleme yöntemleri ile oluşturduğu algoritma ile 90 cm’lik balıklarda %50, 100 cm’lik balıklarda %60, YSA temelli model ile %80 doğruluk elde etmiştir. Knausgård vd., (2022), ılıman sulardaki balık türlerini %86 doğruluk oranı ile tespit etmişlerdir. Labao & Naval, (2019), ResNet v2, Multi-task CNN ve Dense CRF mimarisini kullandığı çalışmasında bentik sualtı videolarında balık görüntülerini %93,77 doğrulukta bulmuştur. Monkman vd., (2019) balık boyut tahminini %95 oranında doğrulukla gerçekleştirmiştir. Petrellis, (2021) balığın üzerindeki karmaşık desenlerin tespit doğruluğunu azaltabileceğini bildirmiştir. Petrellis, (2021), göreceli balık uzunluğu, yüksekliği ve alanı, %4,93’lük bir ortalama uzunluk hatası ile tahmin ettirmiştir. Al-Jubouri vd., (2017) bu işlemi ortalama yaklaşık %1 hata ile gerçekleştirmiştir. Barreiros vd., (2021), YoloV2 ağını Matlab ile 0,001 öğrenme oranını hedefleyerek 300 periyot boyunca eğitmiştir (Şekil 8).



Şekil 8. Üç balıktan oluşan deney düzeneğinde balıkların yemleme öncesi hareketleri (Barreiros vd., 2021).

Figure 8. Movements of fish before feeding in the experimental setup consisting of three fish (Barreiros vd., 2021).

Xu vd., (2020) Faster R-CNN ve YOLO-V3 modellerini balık görüntüleri ile eğitmiş, bu modellerin balık tespitindeki doğruluklarını karşılaştırmış ve amonyak eklenen ortamda balık yörüngelerini çıkarmışlardır (Şekil 9).



Şekil 9. Amonyak eklenen ortamda balıkların izlediği yollar (Xu vd., 2020).

Figure 9. Fish trajectories in ammonia added environment (Xu vd., 2020).

Buna göre ortalama başarı oranı, Faster R-CNN'ye göre %98,13'tür ve YOLO-V3'e göre %2,47 daha fazladır. Yeşil eğri, balığın normal ortamdaki davranış yörüngesini temsil etmektedir. Kırmızı eğri ise, balığın amonyak ortamındaki davranış yörüngesini temsil etmektedir. Görüldüğü gibi normal ortama kıyasla amonyak içeren ortamda balığın hareketi önemli ölçüde azalmıştır. İlk on dakikadaki yörünge, balığın suda temelde sabit olduğunu göstermektedir ve balık tüm zaman boyunca neredeyse hareketsiz kalmıştır. 600 mg/L amonyum klorür koşulları altında, balık 9 saat içinde ölmüştür. Bu nedenle, davranış yörüngesine göre balık aktif olmadığında gerçek yetiştiricilik ortamıyla ilgili sorunların olabileceği sonucuna varılmıştır. Zhang vd., (2021), balon balığı ve japon balıklarını ayırt etmek için eğittiği YoloV4 ve YoloV4+CBAM (Convolutional Block Attention Module) modellerini doğruluk (mAP) ve hız (FPS) açısından karşılaştırmıştır. Sonuçlarda hız açısından iki model yakın sonuçlar verirken (32,3/32,8), doğruluk açısından YoloV4+CBAM daha yüksek doğrulukla çalıştığını tespit etmişlerdir (89,06 / 96,18).

SONUÇ VE ÖNERİLER

AlZu'bi vd., (2015)'nin bildirdiğine göre yüzgeç kesme, etiketleme ve düşük pH'lı kimyasallara maruz kalma gibi acı verici bir dizi prosedür balıklarda davranış değişikliği ile ilişkilendirilmiştir. Su ürünleri ile ilgili yapılacak araştırmalarda bu tür işlemlerin uygulanması balıklarda belirli aktivite kalıpları gelişimine yol açarak deney çıktısını etkileyebilir ve karıştırabilir.

Elde edilen deneysel bulgular ve gözlemler, düşük maliyetle sağlam ve tahribatsız bir balık boyu tahmin sistemi geliştirmek için önerilen matematiksel modeli kullanmanın fizibilitesini göstermektedir (Al-Jubouri vd., 2017).

Resimlerin işlenmesinde kullanılan temel algoritmalar genel kabul görmüş ve yaygın kullanım gören işlemlerdir. Bu algoritmalarla elde edilen verilerin yapay zekâ algoritmaları ile işleme alınmasının daha anlamlı sonuçlar elde edildiğini göstermektedir. Mevcut algoritmalara yenilerinin eklenmesi, mevcut görüntüleme cihazlarına derinlik algılaması veya termal görüntü algılaması yapan cihazların da eklenmesi ile bu alan daha verimli çalışmalara kavuşabilecektir. Otomasyon tekniklerini kullanarak, balık davranışlarını ölçmek mümkün olsa da artan su bulanıklığı veya azalan ışık gibi çevresel koşullarda kamera sınırlamaları nedeniyle, canlıların davranışları bilgisayarla görme teknikleri ile etkin bir şekilde yakalanamayabilir (Gray vd., 2011; Gray vd., 2014; Van der Sluijs vd., 2011).

Rico-Díaz vd., (2020) bu duruma yönelik olarak yalnızca görüntü işleme yöntemleri üzerine kurulmuş bir algoritma ve YSA destekli ikinci bir algoritma kullanmışlardır. Bu yöntemi takip etmesinin nedeni, YSA temelli algoritmanın işlem süresinin uzun olmasıdır (10 saniyeden fazla). Çalışmada öncelikle birinci algoritma işleme alınmakta, yeterli doğruluk elde edilemediği durumda ikinci algoritma işleme alınmaktadır.

González-Rivero vd., (2020) derin öğrenme kullanılarak mercan kayalığı görüntülerinin otomatik olarak işlenmesinin, maliyetlerde %99 azalma ile sonuçlandığını ve manuel yöntemlerden 200 kat daha hızlı olduğunu göstermiştir. Bununla birlikte, Liu vd., (2017)'ye göre elde edilen veriler yüksek boyutlu ve karmaşıktır. Altta yatan nöro davranış hakkında kritik bilgileri ortaya çıkarmak için yeni istatistiksel analiz yöntemleri gerektirmektedir.

Görüntü işleme uygulamaları aracılığıyla balıkların yemleme öncesi ve sonrasındaki davranışlarının izlenmesi, efektif yemleme için doğru zamanı belirlemeyi sağlayacaktır. Bu durumda doğru zamanda doğru miktarda yemleme yapılarak balıkların optimum büyümeleri sağlanarak üretim maliyetlerini azaltacaktır. Bununla birlikte hastalık öncesi ve sonrasında izlenen balık davranışları, balıkların hastalık ihtimallerini önceden tespit edebilmeye yardımcı olacaktır. Bu şekilde proaktif yaklaşım ile hastalıklar meydana gelmeden önlemler alınarak büyük kayıpların önüne geçilebilmesi imkanı olacak ve üretim maliyetleri azalacaktır. Ayrıca balıkların suda kat ettikleri mesafe, hızları ve su kolonu kullanımı gibi değerleri elde edip, bu değerlerin su kalite parametreleriyle birlikte yorumlanabilmesi için fırsat verecektir. Bu elde edilen veriler ile yetiştiriciliği yapılan türlerin, yetiştiricilik sistemlerinde ihtiyaç duyduğu optimum koşullarının oluşturulması sağlanacaktır.

Bu alanda daha çeşitli ve kapsamlı çalışmaların yapılması, yetiştiricilik sistemlerindeki optimum koşulların tespit edilmesiyle balık refahını arttırmaya,

üretim ve işletme maliyetlerini azaltmaya katkı sağlayacaktır. Bu durum su ürünleri yetiştiriciliği sektörünün gelişmesine de olumlu etki edecektir.

KAYNAKLAR

- Akhtar, M.T., Ali, S., Rashidi, H., Van Der Kooy, F., Verpoorte, R. & Richardson, M.K. (2013).** Developmental effects of cannabinoids on zebrafish larvae. *Zebrafish*, *10*(3), 283-293. DOI: [10.1089/zeb.2012.0785](https://doi.org/10.1089/zeb.2012.0785)
- Al-Jubouri, Q., Al-Nuaimy, W., Al-Tae, M. & Young, I. (2017).** An automated vision system for measurement of zebrafish length using low-cost orthogonal web cameras. *Aquacultural Engineering*, *78*(B), 155-162. DOI: [10.1016/j.aquaeng.2017.07.003](https://doi.org/10.1016/j.aquaeng.2017.07.003)
- AlZu'bi, H., Al-Nuaimy, W., Buckley, J., Sneddon, L., & Young, I. (2015).** Real-time 3D fish tracking and behaviour analysis. *IEEE Jordan Conference on Applied Electrical Engineering and Computing Technologies, AEECT 2015*. DOI: [10.1109/AEECT.2015.7360567](https://doi.org/10.1109/AEECT.2015.7360567)
- Anonim. (2010).** Directive 2010/63/Eu of the European Parliament and of the Council of 22 September 2010 on the protection of animals used for scientific purposes (Text with EEA relevance). Official Journal of the European Union, 10-20.
- Anonim. (2014).** <https://swfscdata.nmfs.noaa.gov/labeled-fishes-in-the-wild>
- Anonim. (2020a).** <https://www.kaggle.com/datasets/crowww/a-large-scale-fish-dataset>
- Anonim. (2020b).** <https://public.roboflow.com/object-detection/aquarium>
- Anonim. (2020c).** <https://public.roboflow.com/object-detection/brackish-underwater>
- Anonim. (2020d).** <https://public.roboflow.com/object-detection/fish>
- Anonim. (2020e).** <https://public.roboflow.com/object-detection/shellfish-openimages>
- Anonim. (2022).** Statistics of scientific procedures on living animals-GOV.UK. Retrieved October 21, 2022. <https://www.gov.uk/government/collections/statistics-of-scientific-procedures-on-living-animals>
- Anwer, A., Ali, S.S.A., Khan, A. & Mériaudeau, F. (2017).** Underwater 3D scanning using Kinect v2 time of flight camera. *Thirteenth International Conference on Quality Control by Artificial Vision*, *10338*, 103380C. DOI: [10.1117/12.2266834](https://doi.org/10.1117/12.2266834)
- Banerjee, S., Alvey, L., Brown, P., Yue, S., Li, L. & Scheirer, W.J. (2021).** An assistive computer vision tool to automatically detect changes in fish behavior in response to ambient odor. *Scientific Reports* *11*, 1002. DOI: [10.1038/s41598-020-79772-3](https://doi.org/10.1038/s41598-020-79772-3)
- Barreiros, M.de O., Dantas, D.de O., Silva, L.C. de O., Ribeiro, S. & Barros, A.K. (2021).** Zebrafish tracking using YOLOv2 and Kalman filter. *Scientific Reports* *11*, 3219. DOI: [10.1038/s41598-021-81997-9](https://doi.org/10.1038/s41598-021-81997-9)
- Baxendale, S., Holdsworth, C.J., Meza Santoscoy, P.L., Harrison, M.R.M., Fox, J., Parkin, C.A., Ingham, P.W. & Cunliffe, V.T. (2012).** Identification of compounds with anti-convulsant properties in a zebrafish model of epileptic seizures. *Disease Models & Mechanisms*, *5*(6), 773-784. DOI: [10.1242/dmm.010090](https://doi.org/10.1242/dmm.010090)
- Bradski, G. & Kaehler, A. (2008).** *Learning OpenCV: Computer Vision with the OpenCV Library*. https://books.google.com.tr/books/about/Learning_OpenCV.html?id=seAgiOfu2EIC&redir_esc=y
- Bruni, G., Rennekamp, A.J., Velenich, A., McCarroll, M., Gendele, L., Fertsch, E., Taylor, J., Lakhani, P., Lensen, D., Evron, T., Lorello, P.J., Huang, X-P., Kolczewski, S., Carey, G., Caldarone, B.J., Prinssen, E., Roth, B.L., Keiser, M.J., Peterson, R.T. & Kokel, D. (2016).** Zebrafish behavioral profiling identifies multitarget antipsychotic-like compounds. *Nature Chemical Biology*, *12*, 559-566. DOI: [10.1038/nchembio.2097](https://doi.org/10.1038/nchembio.2097)
- Chen, Q., Zhang, C., Zhao, J. & Ouyang, Q. (2013).** Recent advances in emerging imaging techniques for non-destructive detection of food quality and safety. *TrAC Trends in Analytical Chemistry*, *52*, 261-274. DOI: [10.1016/j.trac.2013.09.007](https://doi.org/10.1016/j.trac.2013.09.007)
- Chuang, M-C., Hwang, J-N. & Williams, K. (2016).** A feature learning and object recognition framework for underwater fish images. *IEEE Transactions on Image Processing*, *25*(4), 1862-1872. DOI: [10.1109/TIP.2016.2535342](https://doi.org/10.1109/TIP.2016.2535342)
- Cui, S., Zhou, Y., Wang, Y. & Zhai, L. (2020).** Fish detection using deep learning. *Applied Computational Intelligence and Soft Computing*. DOI: [10.1155/2020/3738108](https://doi.org/10.1155/2020/3738108)
- Di Paolo, C., Seiler, T.B., Keiter, S., Hu, M., Muz, M., Brack, W. & Hollert, H. (2015).** The value of zebrafish as an integrative model in effect-directed analysis-A review. *Environmental Sciences Europe*, *27*, 1-11. DOI: [10.1186/s12302-015-0040-y](https://doi.org/10.1186/s12302-015-0040-y)

- Ditria, E.M., Jinks, E.L. & Connolly, R.M. (2021).** Automating the analysis of fish grazing behaviour from videos using image classification and optical flow. *Animal Behaviour*, *177*, 31-37. DOI: [10.1016/j.anbehav.2021.04.018](https://doi.org/10.1016/j.anbehav.2021.04.018)
- Egan, R.J., Bergner, C.L., Hart, P.C., Cachat, J.M., Canavello, P.R., Elegante, M.F., Elkhayat, S.I., Bartels, B.K., Tien, A.K., Tien, D.H., Mohnot, S., Beeson, E., Glasgow, E., Amri, H., Zukowska, Z. & Kalueff, A.V. (2009).** Understanding behavioral and physiological phenotypes of stress and anxiety in zebrafish. *Behavioural Brain Research*, *205*(1), 38-44. DOI: [10.1016/j.bbr.2009.06.022](https://doi.org/10.1016/j.bbr.2009.06.022)
- Eldrogi, N., Altherany, I. & Alqaddafi, S. (2019).** Automatic fish tracking by kalman filter. *Journal of Pure & Applied Sciences*, *18*(4), 20-23. DOI: [10.51984/jopas.v18i4.377](https://doi.org/10.51984/jopas.v18i4.377)
- Feijó, G.de O., Sangalli, V.A., da Silva, I.N.L. & Pinho, M.S. (2018).** An algorithm to track laboratory zebrafish shoals. *Computers in Biology and Medicine*, *96*, 79-90. DOI: [10.1016/j.combiomed.2018.01.011](https://doi.org/10.1016/j.combiomed.2018.01.011)
- Gao, H., Zhu, F., & Cai, J. (2010).** A review of non-destructive detection for fruit quality. *International Conference on Computer and Computing Technologies in Agriculture CCTA 2009: Computer and Computing Technologies in Agriculture III, IFIP Advances in Information and Communication Technology (IFIPACT)*, *317*, 133-140. DOI: [10.1007/978-3-642-12220-0_21](https://doi.org/10.1007/978-3-642-12220-0_21)
- Gao, Y., Chan, R.H.M., Chow, T.W.S., Zhang, L., Bonilla, S., Pang, C-P., Zhang, M. & Leung, Y.F. (2014).** A high-throughput zebrafish screening method for visual mutants by light-induced locomotor response. *IEEE/ACM Transactions on Computational Biology and Bioinformatics*, *11*(4), 693-701. DOI: [10.1109/TCBB.2014.2306829](https://doi.org/10.1109/TCBB.2014.2306829)
- Genç, M. (2011).** Dikili durumdaki ağaçların iç kısımlarında oluşan ve belirgin bir emare göstermeyen çürük ve boşlukların tahribatsız belirlenmesi. *I. Ulusal Akdeniz Orman ve Çevre Sempozyumu*, 26-28 Ekim 2011, Kahramanmaraş, *Bildiriler Kitabı*, 306-314. https://www.academia.edu/6001195/Dikili_Durumdaki_Ağaçların_İç_Kısımlarında_Oluşan_ve_Belirgin_Bir_Emare_Göstermeyen_Çürük_ve_Boşlukların_Tahribatsız_Belirlenmesi
- González-Rivero, M., Beijbom, O., Rodriguez-Ramirez, A., Bryant, D.E.P., Ganase, A., Gonzalez-Marrero, Y., Herrera-Reveles, A., Kennedy, E.V., Kim, C.J.S., Lopez-Marcano, S., Markey, K., Neal, B.P., Osborne, K., Reyes-Nivia, C., Sampayo, E.M., Stolberg, K., Taylor, A., Vercelloni, J., Wyatt, M., & Hoegh-Guldberg, O. (2020).** Monitoring of coral reefs using artificial intelligence: A feasible and cost-effective approach. *Remote Sensing*, *12*(3), 489. DOI: [10.3390/rs12030489](https://doi.org/10.3390/rs12030489)
- Gray, S.M., Bieber, F.M.E., McDonnell, I.H., Chapman, I.J. & Mandrak, N.E. (2014).** Experimental evidence for species-specific response to turbidity in imperilled fishes. *Aquatic Conservation: Marine and Freshwater Ecosystems*, *24*(4), 546-560. DOI: [10.1002/aqc.2436](https://doi.org/10.1002/aqc.2436)
- Gray, S.M., Sabbah, S. & Hawryshyn, C.W. (2011).** Experimentally increased turbidity causes behavioural shifts in Lake Malawi cichlids. *Ecology of Freshwater Fish*, *20*(4), 529-536. DOI: [10.1111/j.1600-0633.2011.00501.x](https://doi.org/10.1111/j.1600-0633.2011.00501.x)
- Kitasato, A., Miyazaki, T., Sugaya, Y. & Omachi, S. (2018).** Automatic discrimination between *Scomber japonicus* and *Scomber australasicus* by geometric and texture features. *Fishes*, *3*(3), 26. DOI: [10.3390/fishes3030026](https://doi.org/10.3390/fishes3030026)
- Knausgård, K.M., Wiklund, A., Sordalen, T.K., Halvorsen, K.T., Kleiven, A.R., Jiao, L. & Goodwin, M. (2022).** Temperate fish detection and classification: a deep learning based approach. *Applied Intelligence*, *52*(6), 6988-7001. DOI: [10.1007/s10489-020-02154-9](https://doi.org/10.1007/s10489-020-02154-9)
- Koçer, H.E. & Çevik, K.K. (2021).** Deep neural networks based wrist print region segmentation and classification. *MANAS Journal of Engineering*, *9*(1), 30-36. DOI: [10.51354/mjen.853971](https://doi.org/10.51354/mjen.853971)
- Kokel, D., Cheung, C.Y.J., Mills, R., Coutinho-Budd, J., Huang, L., Setola, V., Sprague, J., Jin, S., Jin, Y.N., Huang, X-P., Bruni, G., Woolf, C.J., Roth, B.L., Hamblin, M.R., Zylka, M.J., Milan, D.J. & Peterson, R. T. (2013).** Photochemical activation of TRPA1 channels in neurons and animals. *Nature Chemical Biology*, *9*, 257-263. DOI: [10.1038/nchembio.1183](https://doi.org/10.1038/nchembio.1183)
- Labao, A.B. & Naval Jr., P.C. (2019).** Simultaneous localization and segmentation of fish objects using multi-task CNN and dense CRF. *Asian Conference on Intelligent Information and Database Systems ACIIDS 2019: Intelligent Information and Database Systems, Lecture Notes in Computer Science*, *11431*, 600-612. DOI: [10.1007/978-3-030-14799-0_52](https://doi.org/10.1007/978-3-030-14799-0_52)
- Lawrence, C. (2007).** The husbandry of zebrafish (*Danio rerio*): A review. *Aquaculture*, *269*(1-4), 1-20. DOI: [10.1016/j.aquaculture.2007.04.077](https://doi.org/10.1016/j.aquaculture.2007.04.077)

- Levin, E.D., Bencan, Z. & Cerutti, D.T. (2007). Anxiolytic effects of nicotine in zebrafish. *Physiology & Behavior*, **90**(1), 54-58. DOI: [10.1016/j.physbeh.2006.08.026](https://doi.org/10.1016/j.physbeh.2006.08.026)
- Levy, D., Belfer, Y., Osherov, E., Bigal, E., Scheinin, A.P., Nativ, H., Tchernov, D. & Treibitz, T. (2018). Automated analysis of marine video with limited data. *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, 1466-1474. DOI: [10.1109/CVPRW.2018.00187](https://doi.org/10.1109/CVPRW.2018.00187)
- Linney, E., Upchurch, L. & Donerly, S. (2004). Zebrafish as a neurotoxicological model. *Neurotoxicology and Teratology*, **26**(6), 709-718. DOI: [10.1016/j.ntt.2004.06.015](https://doi.org/10.1016/j.ntt.2004.06.015)
- Liu, Y., Ma, P., Cassidy, P.A., Carmer, R., Zhang, G., Venkatraman, P., Brown, S.A., Pang, C.P., Zhong, W., Zhang, M. & Leung, Y. F. (2017). Statistical analysis of zebrafish locomotor behaviour by generalized linear mixed models. *Scientific Reports*, **7**, 2937. DOI: [10.1038/s41598-017-02822-w](https://doi.org/10.1038/s41598-017-02822-w)
- MacPhail, R.C., Brooks, J., Hunter, D.L., Padnos, B., Irons, T.D. & Padilla, S. (2009). Locomotion in larval zebrafish: Influence of time of day, lighting and ethanol. *Neurotoxicology*, **30**(1), 52-58. DOI: [10.1016/j.neuro.2008.09.011](https://doi.org/10.1016/j.neuro.2008.09.011)
- Man, M., Abdullah, N., Rahim, M.S.M. & Amin, I.M. (2016). Fish length measurement: The results from different types of digital camera. *Journal of Advanced Agricultural Technologies*, **3**(1), 67-71. DOI: [10.18178/joaat.3.1.67-71](https://doi.org/10.18178/joaat.3.1.67-71)
- Maximino, C., Da Silva, A.W.B., Araújo, J., Lima, M.G., Miranda, V., Puty, B., Benzecry, R., Picanço-Diniz, D.L.W., Gouveia Jr., A.G., Oliviera, K.R.M. & Herculano, A.M. (2014). Fingerprinting of psychoactive drugs in zebrafish anxiety-like behaviors. *PLOS ONE*, **9**(7), e103943. DOI: [10.1371/journal.pone.0103943](https://doi.org/10.1371/journal.pone.0103943)
- Maximino, C., de Brito, T.M., da Silva Batista, A.W., Herculano, A.M., Morato, S. & Gouveia, A. (2010). Measuring anxiety in zebrafish: A critical review. *Behavioural Brain Research*, **214**(2), 157-171. DOI: [10.1016/j.bbr.2010.05.031](https://doi.org/10.1016/j.bbr.2010.05.031)
- Monkman, G.G., Hyder, K., Kaiser, M.J. & Vidal, F.P. (2019). Using machine vision to estimate fish length from images using regional convolutional neural networks. *Methods in Ecology and Evolution*, **10**(12), 2045-2056. DOI: [10.1111/2041-210X.13282](https://doi.org/10.1111/2041-210X.13282)
- Nath, A.K., Roberts, L.D., Liu, Y., Mahon, S.B., Kim, S., Ryu, J.H., Werdich, A., Januzzi, J.L., Boss, G.R., Rockwood, G.A., MacRae, C.A., Brenner, M., Gerszten, R.E. & Peterson, R.T. (2013). Chemical and metabolomic screens identify novel biomarkers and antidotes for cyanide exposure. *The FASEB Journal*, **27**(5), 1928-1938. DOI: [10.1096/fj.12-225037](https://doi.org/10.1096/fj.12-225037)
- Niu, B., Li, G., Peng, F., Wu, J., Zhang, L. & Li, Z. (2018). Survey of Fish Behavior Analysis by Computer Vision. *Journal of Aquaculture Research & Development*, **9**(5). DOI: [10.4172/2155-9546.1000534](https://doi.org/10.4172/2155-9546.1000534)
- Papadakis, V.M., Papadakis, I.E., Lamprianidou, F., Glaropoulos, A. & Kentouri, M. (2012). A computer-vision system and methodology for the analysis of fish behavior. *Aquacultural Engineering*, **46**, 53-59. DOI: [10.1016/j.aquaeng.2011.11.002](https://doi.org/10.1016/j.aquaeng.2011.11.002)
- Pérez, D., Ferrero, F.J., Alvarez, I., Valledor, M. & Campo, J.C. (2018). Automatic measurement of fish size using stereo vision. *2018 IEEE International Instrumentation and Measurement Technology Conference (I2MTC)*, 1-6. DOI: [10.1109/I2MTC.2018.8409687](https://doi.org/10.1109/I2MTC.2018.8409687)
- Petrellis, N. (2021). Measurement of fish morphological features through image processing and deep learning techniques. *Applied Sciences*, **11**(10), 4416. DOI: [10.3390/app11104416](https://doi.org/10.3390/app11104416)
- Prober, D.A., Rihel, J., Onah, A.A., Sung, R.J. & Schier, A.F. (2006). Hypocretin/orexin overexpression induces an insomnia-like phenotype in zebrafish. *The Journal of Neuroscience*, **26**(51), 13400-13410. DOI: [10.1523/JNEUROSCI.4332-06.2006](https://doi.org/10.1523/JNEUROSCI.4332-06.2006)
- Pylatiuk, C., Zhao, H., Gursky, E., Reischl, M., Peravali, R., Foulkes, N. & Loosli, F. (2019). DIY automated feeding and motion recording system for the analysis of fish behavior. *Technology Briefs*, **24**(4), 394-398. DOI: [10.1177/2472630319841412](https://doi.org/10.1177/2472630319841412)
- Qian, Z-M., Cheng, X.E. & Chen, Y.Q. (2014). Automatically detect and track multiple fish swimming in shallow water with frequent occlusion. *PLOS ONE*, **9**(9), e106506. DOI: [10.1371/journal.pone.0106506](https://doi.org/10.1371/journal.pone.0106506)
- Rao, R.M. & Arora, M.K. (2004). Overview of image processing. *Advanced Image Processing Techniques for Remotely Sensed Hyperspectral Data*, 51-85. DOI: [10.1007/978-3-662-05605-9_3](https://doi.org/10.1007/978-3-662-05605-9_3)
- Rico-Díaz, Á.J., Rabuñal, J.R., Gestal, M., Mures, O.A. & Puertas, J. (2020). An application of fish detection based on eye search with artificial vision and artificial neural networks. *Water*, **12**(11), 3013. DOI: [10.3390/w12113013](https://doi.org/10.3390/w12113013)

- Rihel, J., Prober, D.A., Arvanites, A., Lam, K., Zimmerman, S., Jang, S., Haggarty, S.J., Kokel, D., Rubin, L.L., Peterson, R.T. & Schier, A.F. (2010).** Zebrafish behavioral profiling links drugs to biological targets and rest/wake regulation. *Science*, *327*(5963), 348-351. DOI: [10.1126/science.1183090](https://doi.org/10.1126/science.1183090)
- Safaei, N., Smadi, O., Masoud, A. & Safaei, B. (2022).** An automatic image processing algorithm based on crack pixel density for pavement crack detection and classification. *International Journal of Pavement Research and Technology*, *15*, 159-172. DOI: [10.1007/s42947-021-00006-4](https://doi.org/10.1007/s42947-021-00006-4)
- Stewart, A., Gaikwad, S., Kyzar, E., Green, J., Roth, A. & Kalueff, A.V. (2012).** Modeling anxiety using adult zebrafish: A conceptual review. *Neuropharmacology*, *62*(1), 135-143. DOI: [10.1016/j.neuropharm.2011.07.037](https://doi.org/10.1016/j.neuropharm.2011.07.037)
- Stewart, A., Maximino, C., De Brito, T.M., Herculano, A.M., Gouveia Jr., A., Morato, S., Cachat, J.M., Gaikwad, S., Elegante, M.F., Hart, P.C. & Kalueff, A.V. (2011).** Neurophenotyping of adult zebrafish using the light/dark box paradigm. *Neuromethods*, *51*, 157-167. DOI: [10.1007/978-1-60761-953-6_13](https://doi.org/10.1007/978-1-60761-953-6_13)
- Torjesen, I. (2014).** Number of animals used in science increased slightly in 2013, Home Office reports. *BMJ*, *349*, g4586. DOI: [10.1136/bmj.g4586](https://doi.org/10.1136/bmj.g4586)
- van der Sluijs, I., Gray, S.M., Amorim, M.C.P., Barber, I., Candolin, U., Hendry, A.P., Krahe, R., Maan, M.E., Utne-Palm, A.C., Wagner H.J. & Wong, B.B.M. (2011).** Communication in troubled waters: Responses of fish communication systems to changing environments. *Evolutionary Ecology*, *25*, 623-640. DOI: [10.1007/s10682-010-9450-x](https://doi.org/10.1007/s10682-010-9450-x)
- Wang, S.H., Cheng, X.E., Qian, Z-M., Liu, Y. & Chen, Y.Q. (2016).** Automated planar tracking the waving bodies of multiple zebrafish swimming in shallow water. *PLOS ONE*, *11*(4): e0154714. DOI: [10.1371/journal.pone.0154714](https://doi.org/10.1371/journal.pone.0154714)
- Xia, Y., Xu, Y., Li, J., Zhang, C. & Fan, S. (2019).** Recent advances in emerging techniques for nondestructive detection of seed viability: A review. *Artificial Intelligence in Agriculture*, *1*, 35-47. DOI: [10.1016/j.aiia.2019.05.001](https://doi.org/10.1016/j.aiia.2019.05.001)
- Xu, W., Zhu, Z., Ge, F., Han, Z., & Li, J. (2020).** Analysis of behavior trajectory based on deep learning in ammonia environment for fish. *Sensors*, *20*(16), 4425. DOI: [10.3390/s20164425](https://doi.org/10.3390/s20164425)
- Zhang, H., Wu, J., Yu, H., Wang, W., Zhang, Y. & Zhou, Y. (2021).** An underwater fish individual recognition method based on improved YoloV4 and FaceNet. *20th International Conference on Ubiquitous Computing and Communications (IUCC/CIT/DSCI/SmartCNS)*, 196-200. DOI: [10.1109/IUCC-CIT-DSCI-SMARTCNS55181.2021.00042](https://doi.org/10.1109/IUCC-CIT-DSCI-SMARTCNS55181.2021.00042)
- Zhang, L., Xiang, L., Liu, Y., Venkatraman, P., Chong, L., Cho, J., Bonilla, S., Jin, Z-B., Pang, C.P., Ko, K.M., Ma, P., Zhang, M. & Leung, Y.F. (2016).** A naturally derived compound schisandrin B enhanced light sensation in the pde6c zebrafish model of retinal degeneration. *PLOS ONE*, *11*(3), e0149663. DOI: [10.1371/journal.pone.0149663](https://doi.org/10.1371/journal.pone.0149663)
- Zhao, X., Yan, S. & Gao, Q. (2019).** An algorithm for tracking multiple fish based on biological water quality monitoring. *IEEE Access*, *7*, 15018-15026. DOI: [10.1109/ACCESS.2019.2895072](https://doi.org/10.1109/ACCESS.2019.2895072)
- Zivkovic, Z. (2004).** Improved adaptive Gaussian mixture model for background subtraction. *Proceedings-International Conference on Pattern Recognition*, *2*, 28-31. DOI: [10.1109/ICPR.2004.1333992](https://doi.org/10.1109/ICPR.2004.1333992)
- Zivkovic, Z. & Van Der Heijden, F. (2006).** Efficient adaptive density estimation per image pixel for the task of background subtraction. *Pattern Recognition Letters*, *27*(7), 773-780. DOI: [10.1016/j.patrec.2005.11.005](https://doi.org/10.1016/j.patrec.2005.11.005)