

## RELATÓRIO FINAL

# PROJETO FISHVISION

*PO-AÇORES 2020 – AÇORES-01-0247-FEDER-00002 – FISHVISION*

*FISHMETRICS, LDA*

*Contacto: César Santos Silva, [cesar.silva@fishmetrics.pt](mailto:cesar.silva@fishmetrics.pt)*

*Horta, 25 de junho de 2020*

## Resumo

O esforço de monitorização do pescado tem vindo a aumentar nos últimos anos, devido a uma crescente preocupação na conservação e gestão dos recursos pesqueiros, que exigem dados de amostragem cada vez mais precisos. Este é um desafio importante, especialmente para locais remotos e dispersos onde a amostragem de peixes apresenta custos insuportáveis, levando a esquemas de amostragem espacial estatisticamente limitados, falta de informação sobre espécies desembarcadas raras e ocasionais, bem como algumas observações erróneas e tendenciosas. Neste projeto, a Fishmetrics propôs um novo sistema autónomo que pode ser instalado em locais de monitorização ou a bordo de navios de pesca, capaz de adquirir remotamente todos os peixes desembarcados ou capturados e medi-los automaticamente sem qualquer interação física. O sistema utiliza (1) uma câmara e um sensor 3D para ter uma leitura completa de XYZ do peixe, e (2) uma Rede Neuronal Convolutiva, treinada para um conjunto representativo de espécies para detetar e medir os peixes desembarcados. O sistema foi validado em condições reais, utilizando observações contínuas do peixe desembarcado em três ilhas dos Açores, Faial, Pico e Santa Maria. O projeto FISHVISION consistiu na investigação e desenvolvimento de uma solução integrada de classificação e medição de pescado. Neste relatório daremos uma visão detalhada das atividades realizadas, apresentando resultados do método proposto, tal como os principais entregáveis propostos em sede de candidatura.

## Introdução

O projeto desenvolveu-se entre 1 de julho de 2017 e 31 de março de 2020, totalizando 33 meses, centrando-se no âmbito da investigação e desenvolvimento de novas estratégias que permitem facilitar, automatizar e, conseqüentemente, agilizar o processo de medição de comprimentos do pescado. Em particular, incidiu sobre dois procedimentos específicos que têm vindo a comprometer a eficiência e fiabilidade do processo de medição, uma vez que estão dependentes do operador humano que os executa: a **identificação das espécies de pescado** e a **determinação do seu tamanho ou calibre**.

Para cumprir os objetivos definidos, definiram-se em sede de candidatura o seguinte conjunto de atividades:

Atividade 1: Atividade de gestão e divulgação;

Atividade 2: Análise de trabalho relacionado e levantamento de requisitos;

Atividade 3: Recolha de imagens de pescado e análise anatômica e morfológica de diferentes espécies de pescado;

Atividade 4: Arquitetura do sistema;

Atividade 5: Desenvolvimento de algoritmos de processamento de imagem e visão;

Atividade 6: Desenvolvimento de protótipo para teste;

Atividade 7: Testes e validação dos algoritmos desenvolvidos com novas imagens de pescado.

Neste Relatório iremos apresentar em detalhe as atividades propostas, apresentando objetivos, resultados e eventuais desvios realizados para cada uma dessas atividades.

Terminaremos o Relatório com uma breve conclusão do projeto e principais desvios observados.

## **Atividade 1: Gestão do projeto e divulgação**

Esta atividade, transversal ao projeto, decorreu ao longo de todo o período em que o projeto decorreu.

Para além de todas as tarefas relacionadas com a gestão do projeto de investigação, esta atividade teve uma importante componente de divulgação de resultados e de proteção da Propriedade Intelectual.

Esta atividade iniciou-se com o planeamento do projeto, que numa primeira fase incidiu na definição dos requisitos e objetivos a alcançar, e na definição de metas temporais para os mesmos. Estes requisitos, objetivos e metas foram claramente definidos, colocados acessíveis a todos os participantes no projeto.

A gestão das atividades de I&D ficou assente no princípio da colaboração e comunicação frequentes, sendo incentivada a colaboração e comunicação entre os vários elementos/equipas, principalmente nas tarefas que apresentavam interdependências e/ou que decorriam em paralelo.

A gestão das atividades de I&D foi também uma componente importante de monitorização dos resultados, baseada na realização de reuniões periódicas em que cada uma das equipas/elementos apresentou os resultados obtidos e enquadrou o estado e evolução das

suas tarefas face ao planeado. Em sequência das necessidades surgidas ao longo do projeto deram-se alguns reajustes em algumas etapas do projeto, de modo a não comprometer os objetivos e o plano financeiro do projeto, pelo que foram realizadas duas extensões ao projeto, a primeira de 6 meses e a segunda de 3 meses, totalizando uma extensão final de 9 meses ao tempo de projeto inicialmente previsto. As extensões centraram-se nas atividades 6 e 7, sendo detalhadas nas seções dedicadas a estas duas atividades (ver Atividades 6 e 7 deste Relatório). Remetemos para a última secção uma análise mais global às alterações e desvios ao projeto.

No contexto desta atividade foram ainda desenvolvidos todos os trabalhos escritos e de apresentação no âmbito dos entregáveis, da publicação e da divulgação de resultados do projeto. Foram sistematizados na forma de *Milestones* da seguinte forma:

M1.1 – Entrega de Relatório Final – consiste no presente relatório.

M1.2 – Página de Internet – descrição do projeto no sítio web da Fishmetrics, onde se descreve sucintamente o projeto, podendo ser consultado em [www.fishmetrics.pt/fishvision.html](http://www.fishmetrics.pt/fishvision.html).

M1.3 - Submissão de um artigo científico – o artigo foi escrito e submetido a uma publicação científica internacional, *ICES Journal of Marine Science*, encontrando-se ainda em fase de avaliação por parte do editor. Apresenta-se no **ANEXO C** a versão submetida para avaliação.

M1.4 – Pedido de patente – a submissão do primeiro registo de prioridade fez-se ainda em 2016 (antes de iniciar o projeto Fishvision). Durante o projeto FishVision foram realizadas todas as diligências quer de alteração quer de adição de reivindicações necessárias para habilitar o documento aos critérios de patenteabilidade, estando ainda a decorrer os processos de análise. O **ANEXO D** inclui o documento de prioridade para consulta.

M1.5 – Apresentação da Tecnologia em Conferência e Workshop Internacional – o trabalho desenvolvido foi submetido a dois eventos diferentes:

1. Poster (**ANEXO A**) submetido e aceite na nona conferência International Fisheries Observer and Monitoring Conference (IFOMC), em 2018, que decorreu em Vigo, tendo sido apresentado no local por César Silva. Incluído nos *Proceedings* da conferência.
2. Artigo (**ANEXO B**) submetido e aceite no Workshop on Science with Industry Initiatives (WKSCINDI), em 2019, realizado em Copenhaga e organizado pelo ICES. Apresentado no local por Ricardo Aires e incluído nos *Proceedings* do Workshop.

## **Atividade 2: Análise de trabalho relacionado e levantamento de requisitos**

Esta atividade decorreu entre os meses 1 e 3 do projeto, tal como previsto em sede de candidatura. Nesta atividade compilou-se, com detalhe, todo o trabalho relacionado produzido na área da deteção, identificação, e medição automática de espécimes de pescado, com enfoque a sistemas que se propunham resolver estes problemas recorrendo a tecnologias de processamento de imagem e visão por computador. Em seguida, iremos apresentar os trabalhos mais relevantes relacionados com o nosso projeto, resultantes da análise comparativa efetuada no contexto da atividade 2.

### **1. Trabalho relacionado**

Os métodos de medição de peixes mais comuns são tipicamente rudimentares. Baseiam-se na utilização de réguas e outros métodos semelhantes. As patentes [2] e [3] são exemplos desses métodos, que exigem o manuseamento do peixe. Alguns sistemas eletrónicos, como o proposto em [4], tentam minimizar o manuseamento do peixe, mas ainda assim exigem a intervenção do utilizador. Além disso, não guardam as medições e não é possível repeti-las mais tarde. Se, por alguma razão, existir algum erro sistemático no procedimento de medição, não poderá ser corrigido mais tarde. Sempre que possível um sistema de medição deve ser

capaz de guardar informações sobre os peixes de forma a que se possa confirmar as medições ou efetuar novas medições no futuro.

Outros sistemas, tais como [5] e [6], adicionam automaticamente as medições a uma base de dados e registam outras variáveis, como o peso dos peixes e a região piscatória. No entanto, são lentos e ainda requerem o manuseamento do peixe. Para além do referido sistema, também houve várias publicações, tais como [7], [8] e [9], que propõem novos métodos de medição de peixes utilizando técnicas de visão computacional. No entanto, estes sistemas são de alguma forma limitados, uma vez que não lidam com a ambiguidade típica da escala que caracteriza os sistemas de visão monocular, produzindo medições erróneas.

A patente em [10] propõe também uma abordagem baseada na visão computacional, onde os autores se livram da ambiguidade da escala utilizando fotogrametria estéreo. No entanto, este tipo de sistemas tem uma desvantagem importante, uma vez que não funcionam com oclusões e exigem a intervenção do utilizador na calibração e identificação do objeto a medir.

O problema geral do reconhecimento e identificação de objetos em imagens é extremamente complexo e tem sido abordado usando várias estratégias diferentes, tais como deteção de padrões, Histograma de Gradientes Orientados (HOGs), correlação ou redes neuronais. Em [15], por exemplo, os autores utilizam técnicas baseadas em SIFT (Transformação de características invariantes em escala) e PCA (Análise principal de componentes) para reconhecer peixes em imagens, no entanto, tais abordagens são muito sensíveis às variações da iluminação, que podem degradar o seu desempenho. Além disso, tais métodos pressupõem que os peixes estão isolados, o que não é o caso geral em imagens adquiridas

em lotas, onde as caixas de peixe geralmente incluem vários indivíduos (eventualmente empilhados) da mesma espécie. Das estratégias acima mencionadas, a abordagem utilizando HOGs é provavelmente a mais promissora, no entanto, tem dificuldades em distinguir espécies que são muito semelhantes e peixes que são curvados e/ou em posições estranhas dentro das caixas. As estratégias baseadas na correlação sofrem dos mesmos problemas.

No entanto, nos últimos anos, as redes neuronais evoluíram e levaram ao surgimento de estratégias de reconhecimento de imagem baseadas em aprendizagem profunda (*Deep learning*), que revolucionaram o campo do reconhecimento de padrões em processamento de imagem, à medida que os computadores se comparam agora aos humanos em tarefas de reconhecimento e identificação de objetos. Embora o uso de métodos tradicionais de aprendizagem automática em aplicações de visão computacional tenha sido uma abordagem comum para certas tarefas, o novo paradigma de recolha de dados associado às crescentes capacidades de processamento de computadores de GPUs (Unidades de Processamento de Gráficos) e TPUs (Unidades de Processamento de Tensor) levou a novas e mais complexas metodologias de resolução de problemas. Em particular, as *Convolutional Neural Networks* (CNN) recolheram muita atenção e utilização devido à melhoria de desempenho no reconhecimento, deteção e segmentação de objetos.

Um dos modelos precursores da CNN desenvolvidos por LeCun [16] remonta a 1989, consistindo numa rede de 5 camadas, na altura aplicada ao reconhecimento manuscrito de dígitos. Desde então, o número de CNNs aumentou, bem como a dimensão e complexidade das suas camadas. Um exemplo da mudança de paradigma foi quando o AlexNet, uma rede de 8 camadas desenvolvida em [17], ficou em primeiro lugar no desafio ImageNet de 2012,

batendo, nesse ano, outros algoritmos de aprendizagem não supervisionada na classificação de objetos numa extensa base de dados. Todos os vencedores do desafio anual subsequente apresentaram soluções de *Deep Learning* com um desempenho crescente, à custa de um número crescente de camadas de rede, parâmetros totais e consumo de memória. Exemplos incluem a rede VGG com versões de 16 e 19 camadas [18], a rede de inepção [19], e a ResNet [20] com versões até 150 camadas no total. Os constrangimentos colocados pelas capacidades limitadas de processamento dos dispositivos móveis levaram igualmente ao desenvolvimento de redes mais leves com um número reduzido de parâmetros treináveis, como o MobileNet [21].

O leque de aplicações destas redes começou a crescer a partir das tarefas simples de classificação de imagem, com exemplos como segmentação semântica, deteção de objetos e identificação e segmentação individual de objetos. Em particular, para a deteção de objetos, os métodos YOLO [22] e SSD [23] são o estado atual da arte, sendo muito rápidos a treinar e a realizar estimativas.

Em detalhe, o algoritmo YOLO divide cada imagem de treino numa grelha de regiões menores (células de grelha) e atribui o ponto médio de um objeto à célula correspondente. Além disso, um conjunto de caixas de âncora estão associadas a cada célula de grelha permitindo a deteção de múltiplos objetos de diferentes classes com o mesmo ponto médio. Uma estimativa inicial do número de caixas de âncora (e suas posições) pode ser determinada maximizando a IoU (intersecção sobre a união) no conjunto de formação. O treino é realizado utilizando uma rede neural convolucional, com as imagens e as posições da caixa de delimitação como características de entrada. Durante o tempo de previsão, a avaliação é

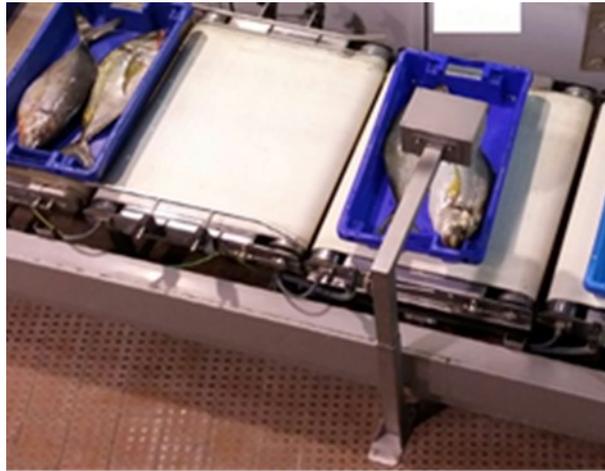
aplicada à imagem completa e, para cada região, produz uma probabilidade de existência de objeto (vulgarmente designada por pontuação) e coordenadas de caixa de delimitação. Utilizando a supressão não máxima, todas as caixas se fundem na melhor caixa de delimitação aproximada para o objeto estimado.

A YOLO mostra muitas vantagens em relação aos métodos populares baseados na R-CNN [24], uma vez que olha para toda a imagem e não apenas para as regiões propostas. Uma abordagem mais recente, Mask R-CNN [25] apareceu como uma extensão da R-CNN mais rápida, adicionando um ramo para prever máscaras de segmentação em paralelo com o ramo existente para o reconhecimento da caixa de delimitação. Tem sido geralmente considerado como um método muito robusto e rápido, mostrando resultados precisos para objetos parcialmente obstruídos, e já foi usado em [26] para a medição de peixes usando câmaras de leilão de CCTV. No entanto, isto não representa uma vantagem no nosso caso, uma vez que queremos medir a totalidade do peixe e com um objeto parcialmente obstruído não é possível obter uma boa estimativa das extremidades através dos dados fornecidos pelo sensor de infravermelhos. Além disso, utilizamos também uma configuração de aquisição mais abrangente e adequada a um ambiente real (com imagens obtidas diretamente das lotas). Os autores de [27] também usam a Máscara R-CNN para estimar o tamanho dos peixes, mas a experiência utiliza uma pequena quantidade de dados e as medições são retiradas de pares de imagens estéreo, que precisam de ser calibrados (um passo complexo e dispendioso), que tem de lidar com o problema da correspondência e fornece resultados não tão robustos.

O sucesso de estratégias baseadas em aprendizagem profunda em tarefas de reconhecimento de espécies de peixes foi confirmado pelos mais recentes desafios de detecção de peixes, nomeadamente a LifeCLEF 2015 Fish Task [28], onde os melhores resultados foram obtidos por esses métodos.

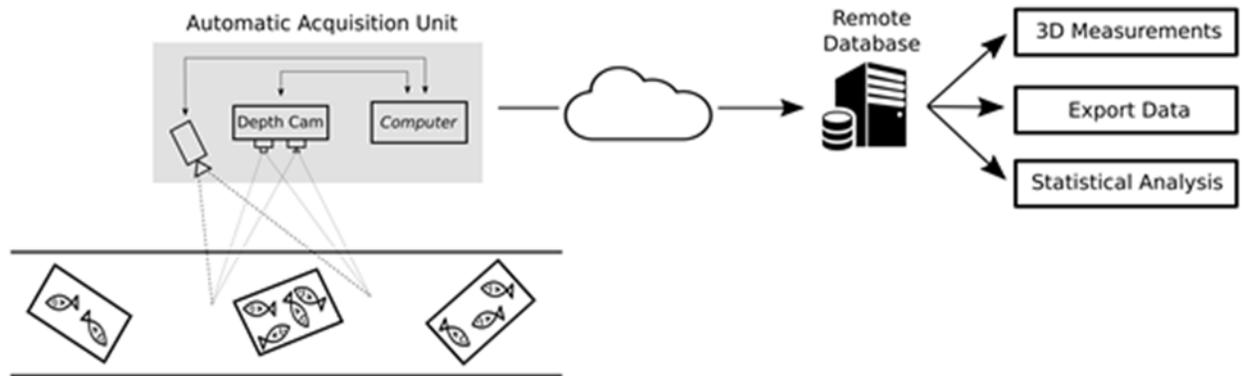
## 2. Requisitos do sistema

Foi feito um levantamento de todos os requisitos que o sistema devia cumprir, nomeadamente no que se refere ao número de espécies a identificar, à precisão das medidas a obter, ao modo de funcionamento do sistema e ao modo de utilização / integração com outros sistemas. Uma parte significativa da análise de requisitos incidiu sobre os dados de *input* que os algoritmos deveriam receber e que *outputs* concretos produziram. Assim, começámos por considerar que o sistema devia ser passível de ser aplicado a lotas onde se realize pesagem ou leilão de peixe, nas quais o peixe ou caixas de peixe são colocados em cima de uma superfície plana, onde ficam parados cerca de 1 ou 2 segundos. A Fig. 1 mostra várias caixas de peixe numa lota típica de peixe. Isto acontece normalmente durante o processo de pesagem de peixe e/ou de leilão, onde as caixas de peixe são geralmente colocadas numa escala industrial ou num tapete transportador.



**Fig. 1:** Caixas de peixe sobre um tapete transportador.

Tendo presente esta configuração, o nosso objetivo é detetar o momento em que as caixas estão paradas, e usar este instante para adquirir dados que podem ser usados mais tarde para recuperar informações 3D sobre os peixes. Estas informações devem ser processadas e depois enviadas para uma base de dados remota, como se mostra na Fig. 2. O sistema não precisa de estimar as medidas ou classificar a espécie em tempo real, contudo o tempo de cálculo deve ser minimizado, antevendo futuras aplicações em que o tempo real seja necessário.



**Fig 2.** – Arquitetura geral do sistema de aquisição.

Outros requisitos importantes têm a ver com o número de espécies a detetar. Estimou-se que cerca 30 espécies nas lotas dos Açores representam mais de 90% do total de capturas, pelo que se definiu como requisito que a rede de classificação deveria classificar 30 espécies. A precisão do sistema de deteção (que tipicamente deve ser inferior a 5mm) define o erro máximo dos comprimentos, o que é coerente com o erro máximo aceitável na medição de pescado (meio centímetro). Estes requisitos foram posteriormente aferidos nas atividades seguintes, porquanto estão criticamente dependentes da recolha de dados (Atividade 3) e da arquitetura proposta (Atividade 4).

## Atividade 3: Recolha de imagens de pescado e Análise Morfométrica do Pescado

Esta atividade consistiu na recolha de imagens de pescado em 3 lotas: na lota de Santa Cruz da Horta, na lota de Madalena do Pico e na lota de Vila do Porto em Santa Maria.

A atividade de recolha e análise dos dados realizou-se entre os meses 4 e 20, sendo que a atividade de recolha de dados nas lotas referidas teve a duração de 7 meses (conforme previsto), sendo recolhida a informação que serviu de ponto de partida ao desenvolvimento dos algoritmos de processamento de imagem e permitiu testar os mesmos. O número e variedade de imagens a adquirir permitiu construir um vasto conjunto de treino e de teste.

As imagens foram capturadas com o sistema Fishmetrics (inclui câmara RGB e scanner 3D), que permitiu obter imagens 2D e os correspondentes mapas tridimensionais calibrados, de caixas de pescado. Mais de 25.000 imagens foram adquiridas para as três lotas referidas neste período. As imagens RGB dos peixes desembarcados têm uma resolução de 1920x1080 pixels e o mapa de profundidade tem uma resolução de 640x480 pixels, que está registado nas imagens da webcam após a calibração estéreo dos dois dispositivos envolvidos, de forma que, para cada pixel da imagem RGB, as suas coordenadas 3D são conhecidas e é possível efetuar medições métricas entre dois pontos arbitrários com uma resolução de +/- 1mm.

A informação recolhida pode ser consultada sob pedido em [www.apps.reverse.com/fishmetrics/index.php](http://www.apps.reverse.com/fishmetrics/index.php). Para aceder, são necessárias credenciais (username: fishvision pw: fishmetrics). Um conjunto significativo das imagens adquiridas presentes neste sítio

foram rotuladas através da aplicação web, onde o utilizador pôde seleccionar dois ou mais pontos de interesse do corpo de peixe (ex: comprimento total, diâmetro do olho, tamanho da cabeça), resultando um conjunto de caixas de delimitação que foram usadas como dados de entrada para treinar e avaliar o modelo de rede neural convolucional a desenvolver nas Atividades seguintes. Neste processo foram estimadas equações morfométricas para diferentes medidas para diferentes espécies, de forma a aumentar significativamente a base de treino e teste disponível, porquanto muitos indivíduos não aparecem completos na imagem.

## Atividade 4: Arquitetura do sistema

Nesta atividade, que durou entre o Mês 4 e o Mês 7, definiu-se a estrutura geral do sistema, os componentes do sistema e a sua interação. Esta atividade foi essencial para garantir que as partes do sistema a desenvolver ficariam articuladas, e produziu um guia de desenvolvimento para todos os intervenientes no processo.

Na Fig. 2 propõe-se uma arquitetura geral do sistema, aplicada a lotas de peixe, com acesso remoto a dados de amostragem.

O sistema que propusemos é composto por dois módulos principais: uma unidade local e uma unidade remota, aqui também designada por unidade de aquisição automática e base de dados remota, respetivamente, como ilustrado na Fig. 2.

A unidade local (ver sistema colocado sobre o tapete na Fig. 1) é composta por uma câmara RGB, uma câmara de profundidade e um computador. A câmara de profundidade é um scanner 3D de luz estruturada que trabalha no espectro de infravermelhos, ou seja, inclui um projetor de infravermelhos e uma câmara de infravermelhos que fornecem um mapa 3D da cena. As duas câmaras estão ligadas a um computador, que as controla e é responsável por desencadear aquisições de imagem, processar os dados e comunicar com a base de dados remota.

A unidade remota é uma base de dados centralizada que recolhe dados de várias unidades locais diferentes, localizadas em diferentes leilões de peixe. É uma aplicação baseada na web que organiza todos os dados e os apresenta ao utilizador. Pode ser usado para extrair informações 3D sobre os peixes, medir distâncias sobre o corpo (como o comprimento total, comprimento da barbatana peitoral ou largura), e obter uma análise estatística em larga escala. É possível exportar todos os dados para os principais formatos conhecidos.

A instalação do sistema de aquisição, como se referiu na Atividade 3, foi feita em três lotas do Arquipélago dos Açores: Horta (Faial), Madalena (Pico) e Vila do Porto (Santa Maria). Na primeira lota, o sistema foi instalado sobre um tapete transportador como representado na Fig 1, com a aquisição a decorrer quando uma caixa de peixe (80x40 cm) estava parada no procedimento de leilão. Nos outros dois casos, os dados foram adquiridos quando um funcionário colocou a caixa manualmente sobre uma balança de pesagem. A configuração inclui uma webcam Logitech C920 RGB; um sensor estruturado de estrutura de luz infravermelha para os dados 3D da Structure-Occipital; e um computador para o processamento e upload dos dados para a base de dados remota. A arquitetura definida para software permitiu adquirir dados continuamente, adquirindo uma foto apenas quando é detetada a presença de uma nova caixa de peixe.

## Atividade 5: Desenvolvimento de algoritmos de processamento de imagem e visão

Esta atividade teve a sua duração entre os Meses 11 e 20, e consistiu em projetar e desenvolver todos os algoritmos de processamento de imagem responsáveis pela identificação e medição de pescado usando a informação adquirida nas lotas referidas. Os algoritmos desenvolvidos, inicialmente projetados para estarem divididos em dois módulos (um responsável pela determinação da espécie do pescado, e outro responsável pela obtenção de medidas), acabaram por ser projetados na mesma rede neuronal, possuindo esta as duas funcionalidades propostas.

Numa primeira fase do trabalho, a determinação da posição de cada indivíduo na imagem e a determinação da sua espécie foram estudados de modo independente. A abordagem baseou-se na análise dos mapas tridimensionais para determinar a posição de cada um dos indivíduos visíveis em cada imagem, seguida da utilização de estratégias de reconhecimento de objectos, como por exemplo *HOGs* (*histogram of oriented gradients*) ou métodos de *deep learning*. Numa segunda fase, combinou-se os métodos de reconhecimento de objectos acima referidos com técnicas de *sliding window*, que consistem em aplicar estes métodos a várias regiões da imagem.

O estudo de algoritmos de visão computacional para efetuar medições tridimensionais nos indivíduos visíveis nas imagens 2D requereu a utilização de técnicas de fusão sensorial. Em particular, foi necessário calibrar o sensor que adquire o mapa tridimensional da cena relativamente à câmara RGB, e desenvolver um método que permitiu obter as coordenadas 3D de cada *pixel* das imagens 2D.

Os algoritmos foram simulados e implementados em *software* próprio para simulações e testes em processamento de imagem, como por exemplo MATLAB e OpenCV.

O algoritmo final utilizou uma abordagem de dados estruturados de aprendizagem profunda (*Deep Learning*) utilizando a estrutura YOLO com o backend MobileNetV2 [21] para deteção de peixes. A medição do peixe é derivada da estimativa da caixa de delimitação de peixes, pelo que a deteção da espécie e a medida são produzidos em simultâneo na mesma rede.

Como qualquer rede neuronal típica, a rede teve de ser sujeita a uma fase de treino e validação. Os dados rotulados foram inicialmente separados por espécies e posteriormente divididos em conjuntos de treino, validação cruzada e ensaio numa proporção de 80/10/10 para o modelo de rede neuronal. Cada conjunto de espécies treinou um modelo YOLO de backend MobileNetV2 implementado em Keras/Tensorflow, utilizando um GeForce GTX 1080 Ti. Esta rede é um modelo mais leve do que outros, como os modelos ResNet [20] ou Inception [19] que demonstraram bons níveis de desempenho, no entanto têm um maior número de parâmetros treináveis e, conseqüentemente, requerem uma maior quantidade de recursos de memória. O MobileNet [21] representa uma alternativa sólida, embora com uma pequena diminuição de desempenho, pode executar estimativas em dispositivos com

menos recursos, como dispositivos móveis. A escolha desta rede foi feita com o objetivo de colocar um sistema automatizado de detecção e medição num local remoto que tenha recursos limitados.

As imagens para o treino foram dimensionadas para uma resolução de entrada de 416x416 pixels. Para garantir que o peixe está numa posição horizontal, giramos as imagens em conformidade e espelhamos a imagem resultante horizontal e verticalmente para aumento de dados. Isto facilita o posicionamento da caixa de delimitação em torno do peixe, garantindo que os limites horizontais da caixa se encaixam perfeitamente com a amostra. Escolhemos o otimizador Adam [29]. Nenhum número predefinido de épocas foi definido no início do treino, e o modelo treinou até não ser registada nenhuma alteração significativa dos pesos da rede. O número máximo de deteções de caixas por imagem foi definido como sendo 10 e os pesos iniciais foram pré-treinados no conjunto de dados de imagem COCO [30].

## **Atividade 6: Desenvolvimento de protótipo**

O desenvolvimento de um protótipo envolveu um período mais longo que o inicialmente previsto, entre os meses 16 e 33. Na realidade, esta atividade incluiu toda a fase de treino das várias redes definidas na atividade anterior e respetivo teste com a informação adquirida nas lotas.

Durante a fase de testes, constatou-se ser necessário um aumento substancial do número de amostras de imagens de pescado, de forma a melhorar a aprendizagem das redes desenvolvidos. Esta necessidade é mais relevante em algumas espécies que, devido à escassez de capturas ou à sazonalidade, estão menos representadas no conjunto de treino do sistema, pelo que foi necessário proceder a uma aquisição mais rica de imagens e a um treino estendido com as mesmas. Para proceder à aquisição, marcação, treino, validação e aprendizagem do sistema de inteligência artificial, pediu-se uma extensão de 9 meses quer para esta Atividade 6 - Desenvolvimento do Protótipo, quer para a atividade seguinte, Atividade 7 - Testes e validação do sistema. Em conformidade, a Atividade 1 de gestão do projeto foi estendida o mesmo tempo.

Como se referiu anteriormente, para testar o sistema proposto em condições reais, foi instalado nas três lotas referidas o sistema de aquisição. Adquiriu-se remotamente todos os peixes desembarcados ou capturados, classificaram-se de acordo com a espécie e tamanho,

e mediram-se. Este sistema automático capturou remotamente todos os dados dos peixes, armazenando a informação numa base de dados em nuvem para futura inspeção e análise estatística. Esta informação inclui as imagens de peixes, o mapa tridimensional que permite a medição, e todos os metadados relevantes (localização de captura, artes de pesca, momento de captura).

A CNN proposta foi aplicada às imagens para prever o tamanho dos peixes. As figuras 3, 4, 5 e 6 mostram exemplos de estimação para as espécies selecionadas, para imagens selecionadas a partir dos conjuntos de teste. Apenas uma caixa de delimitação é representada para cada imagem, uma vez que a pontuação máxima é obtida para uma posição horizontal de cada espécime, após rodar a imagem  $180^\circ$  com uma discretização de  $5^\circ$ .



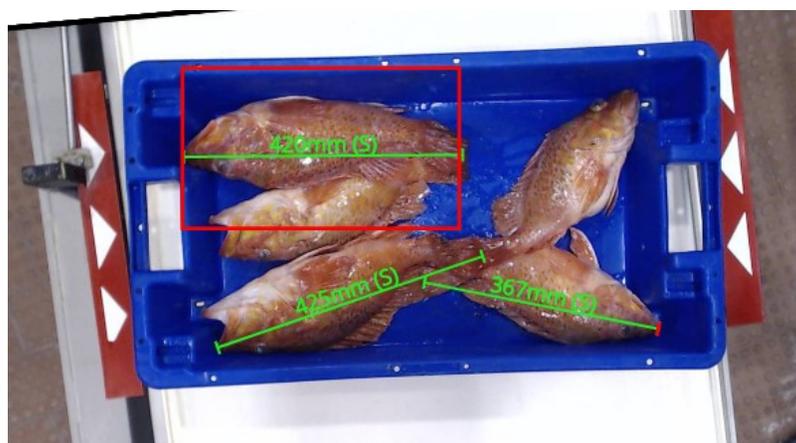
**Figura 3** - Amostra de uma caixa de peixe de *Polyprion americanus*. A vermelho, a caixa de delimitação prevista pela CNN proposta. A verde, a medida verdadeira. Note como os limites laterais da caixa de delimitação prevista estão perfeitamente alinhados com a boca e a cauda.



**Figura 4** - Amostra de uma caixa de *pagrus Pagrus*. A vermelho, a caixa de delimitação prevista pela CNN. A verde, a medida verdadeira. A CNN prevê uma ou mais caixas de delimitação por direção. Como os peixes têm direções diferentes, a CNN deteta-os em instantes diferentes.



**Figura 5** - Amostra de uma caixa de *Pagellus bogaraveo*. A vermelho, a caixa de delimitação prevista pela CNN. A verde, a medida verdadeira.



**Figura 6** - Amostra de uma caixa de *Pontinus kuhlii*. A vermelho, a caixa de delimitação prevista pela CNN. A verde, a medida verdadeira. Note que o peixe detetado é medido corretamente, embora esteja parcialmente escondido.

## Atividade 7: Testes e validação dos algoritmos desenvolvidos com novas imagens de pescado

Esta atividade correspondeu à validação de todos os métodos desenvolvidos e implementados, decorrendo entre os meses 21 e 33. Durante esta atividade testaram-se e validaram-se:

- o método de deteção da presença de pescado;
- o método de determinação da posição do pescado identificado;
- o método de identificação da espécie dos indivíduos visíveis na imagem;
- a exatidão das medidas do pescado;
- as funcionalidades e opções do programa;
- a robustez dos algoritmos propostos a variações de iluminação.

Nesta atividade desenvolveu a análise de erro por comparação dos dados estimados com as medidas obtidas manualmente. Para fins exemplificativos no contexto do presente relatório, foram selecionadas quatro das espécies de peixes mais representativas dos Açores: *Pontinus kuhlii*, *Polyprion americanus*, *Pagellus bogaraveo* e *Pagrus pagrus*. Para cada espécie, 400 indivíduos foram selecionados aleatoriamente do universo de peixes capturados na experiência. Estas amostras não foram usadas no treino ou validação da CNN, para evitar a contaminação dos resultados.

Species	RMSE	RMedSE	RMSE (removing 10% outliers)	RMedSE (removing 10% outliers)	Normalized Error by Size (%)	95% Confidence Interval
<i>Polyprion americanus</i>	42.31	23.56	27.39	19.91	3.97	14.32 - 25.71
<i>Pagrus pagrus</i>	23.34	13.49	16.65	11.95	4.39	5.45 -10.10
<i>Pagellus bogaraveo</i>	24.51	15.67	18.58	14.12	5.28	8.69 - 12.88
<i>Pontinus kuhlii</i>	28.70	20.00	21.65	18.00	6.94	15.86 - 21.20

**Tabela 1** – Análise do erro das medidas obtidas pela CNN, em milímetros.

Para cada amostra, foi calculada a diferença entre a medição manual do tamanho do peixe e a medição fornecida pelo método proposto, em milímetros (mm). A Tabela 1 mostra o Quadrado Médio raiz do erro (RMSE) para o conjunto de todas as amostras selecionadas (100%) e para o conjunto de todas as amostras após a remoção de 10% dos erros mais elevados (outliers). Para estudar o efeito dos outliers na estimativa do tamanho dos peixes, é também apresentado o Root Median Square of the Error (RMedSE) para 100% e 90% das observações. O RMSE relativo, ponderado pelo tamanho do peixe, também é calculado. A última coluna do Quadro mostra o intervalo de confiança de 95% (para um valor  $p < 0,05$ ), representando o intervalo em que se prevê que a média das estimativas do método proposto

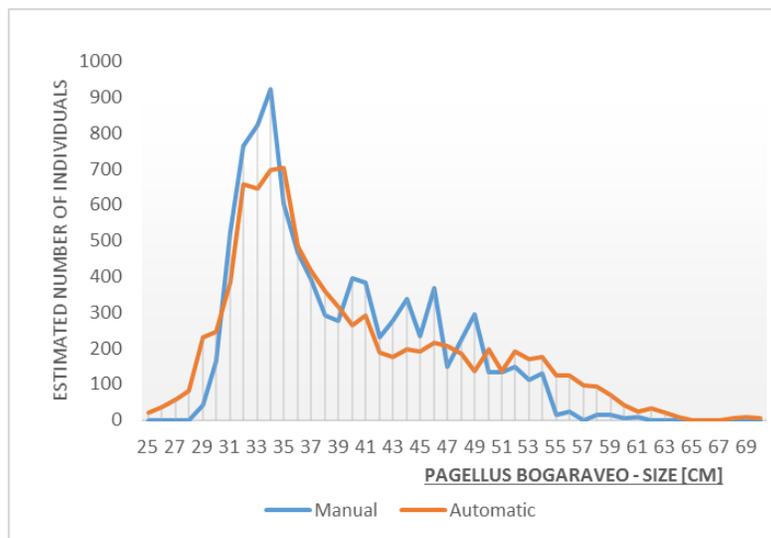
se encontra em relação à realidade. Isto permite-nos determinar um desvio sistemático do método de medição proposto, que pode ser considerado e descontado para novas medições.

Com base nestes resultados, podemos concluir o seguinte: (1) após a remoção de outliers, o RMSE (ou RMedSE) é inferior a 2,1 cm para todas as espécies, excluindo o *Polyprion americanus* (2,7cm); (2) o sistema produz poucos outliers, uma vez que a presença de outliers aumenta o RMSE em apenas 0,6cm (excluindo novamente o *Polyprion americanus* para o qual a RMSE aumenta quase 2cm); (3) Quando ponderado pelo tamanho dos peixes, o RMSE relativo encontra-se entre 0 e 7% para todas as espécies, o que significa que o erro da estimativa do tamanho é de aproximadamente 0-7% do tamanho; (4) Espera-se que a média das estimativas do método proposto tenha um desvio entre 1 cm e 2 cm em relação à verdade terrestre (dependendo da espécie), o que sugere que o método automático tem um enviesamento que pode ser integrado em estimativas adicionais. Note que os erros de medição são geralmente mais elevados para o *Polyprion americanus* devido ao tamanho da espécie, atingindo 120 cm de comprimento. Isto aumenta naturalmente a presença de outliers para esta espécie, embora não afete o RMSE relativo.

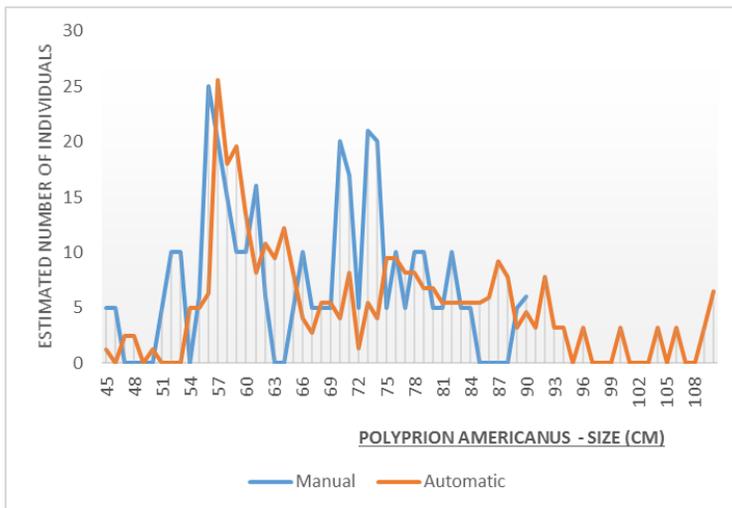
Em seguida, comparamos os histogramas obtidos utilizando o sistema proposto com os histogramas fornecidos pela metodologia de amostragem tradicional. Ao fazer esta comparação, esperamos identificar desvantagens e vantagens do sistema de medição proposto em relação à recolha tradicional de dados.

Para fins ilustrativos no contexto do presente relatório, restringimos o nosso exemplo às observações feitas na ilha do Faial. Estes dados foram comparados com as informações fornecidas pelo Programa de Recolha de Dados das Pescas (FDCP) para o mesmo período. A FDCP exigia a presença de amostradores em terra que recolhessem manualmente dados de comprimentos de peixe diariamente na lota do Faial. Os desembarques açorianos são geralmente multiespécies, e muitos são classificados em diferentes tamanhos comerciais. Por essa razão, a abordagem do regime de amostragem é estratificada (sempre que necessário) de acordo com as categorias de métiers e tamanhos comerciais disponíveis em cada dia e barco, respetivamente. Os dados são então normalizados (ampliados) dado o peso total dos desembarques para cada categoria. Note-se que as categorias para as quais não houve nenhuma ou muito poucas observações devido ao processo de amostragem, a referida normalização produz um resultado sem sentido.

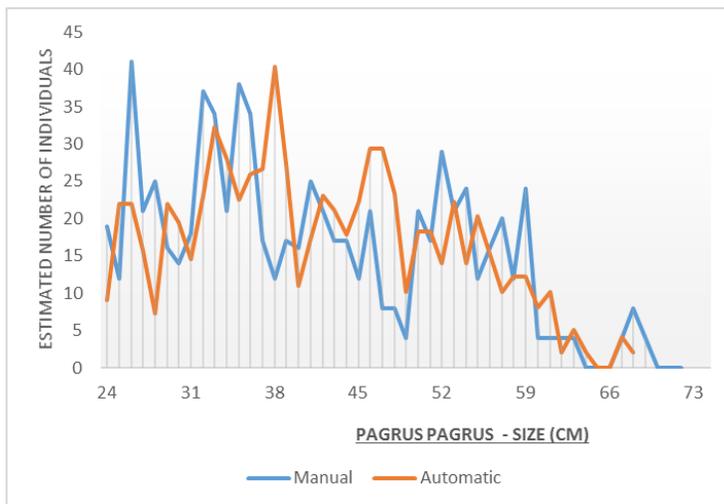
Na Figura 7, apresentamos resultados para as espécies previamente selecionadas. Para cada espécie, ambos os histogramas são normalizados usando o peso total dos peixes desembarcados durante o período de tempo selecionado, de modo que o número total de indivíduos em ambas as abordagens seja aproximadamente o mesmo.



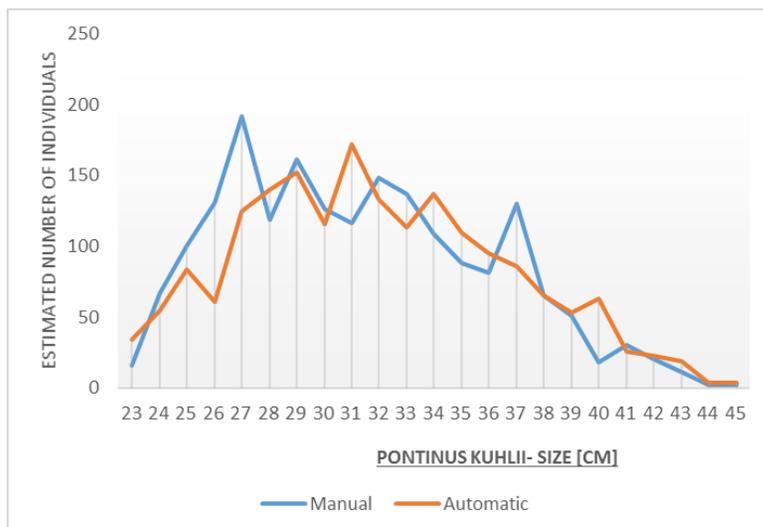
(a) *Pagellus bogaraveo*



(b) *Polyprion americanus*



(c) *Pagrus pagrus*



(d) *Pontinus kuhlii*

**Figura 7** - Histogramas para peixes capturados durante 1 mês na ilha do Faial, para a espécie indicada. Em azul: Histograma estimado pelo Programa de Recolha de Dados das Pescas. A vermelho: Histograma estimado pelo sistema proposto.

O primeiro resultado observado na Figura 7 é que os histogramas são geralmente próximos um do outro. Isto significa que ambos os métodos produzem aproximadamente os mesmos resultados. No entanto, notamos que a quantidade de dados recolhidos para o local monitorizado é mais suave do que os dados recolhidos pelos amostradores em terra, especialmente para populações mais numerosas. Isto acontece porque há muito mais

amostras disponíveis no método proposto para essas espécies, donde as dimensões contíguas se tornam estatisticamente relacionadas, como é expectável.

Também notamos que o nosso método fornece informações mais ricas para alguns tamanhos de peixe, que parece ser omitida pela abordagem manual, especialmente para categorias de maior tamanho. Por exemplo, as categorias de maior tamanho de *Pagellus bogaraveo* e *Polyprion americanus* parecem estatisticamente mais relevantes após a utilização do nosso método, em comparação com o método manual que os negligenciou, como se observa nas figuras 7 (a) e (b). Isto acontece porque a natureza da amostragem do método manual tende a ignorar categorias com poucas ou nenhuma amostras.

## Conclusões

**Principais desvios** – na generalidade foram atingidos os objetivos propostos, quer técnico-científicos quer nos entregáveis ao longo do projeto (patente, conferências, artigo científico, etc), como se apresenta no presente relatório. O principal desvio incidiu sobre o tempo total do projeto, que teve uma extensão de 9 meses relativamente ao inicialmente previsto, devido à necessidade de dilatar os tempos de execução das atividades 6 e 7 para melhor caracterização de algumas espécies e treino do protótipo. Não se observaram desvios financeiros, atingindo-se praticamente a totalidade da execução financeira prevista.

**Síntese final** - Neste trabalho, é apresentada uma configuração completa de um sistema para identificação e medição de pescado, utilizando uma Rede Neuronal Convolutiva treinada (CNN), uma câmara e um sensor 3D baseado na luz infravermelha estruturada. O sistema proposto foi instalado em três ilhas do Arquipélago dos Açores: Faial, Pico e Santa Maria. O sistema recolheu imagens das caixas de peixe desembarcadas nas lotas das ilhas mencionadas, durante um longo período de tempo, de forma exaustiva.

**Contribuições** - Tanto quanto sabemos, esta é a experiência de longo prazo mais vasta utilizando um sistema de medição automática aplicado a condições reais em lota [31]. Os peixes foram medidos de forma automática e exaustiva durante o período mencionado. Neste relatório são apresentados alguns exemplos obtidos pelo sistema, acompanhados por uma análise da robustez e fiabilidade do processo. A análise comparativa desenvolvida neste projeto revelou que o sistema de medição proposto tem várias vantagens, a começar pela (1) dispensa parcial ou total de amostradores nas lotas; (2) a quantidade de dados recolhidos para o local monitorizado é consideravelmente maior do que os dados recolhidos pelos amostradores em terra, com os dados recolhidos a fornecerem mais informações sobre as unidades populacionais de peixes do Arquipélago dos Açores; (3) a natureza autónoma do sistema conduz a uma recolha exaustiva de dados, gerando uma amostra mais representativa e robusta dos peixes capturado, sendo particularmente válido para espécies (ou tamanhos) que são frequentemente sub-amostradas devido ao número limitado de desembarques ocasionais e, conseqüentemente, têm mais dados sobre espécies (ou tamanhos) mais regulares e abundantes em desembarques. Além disso, ao contrário das metodologias tradicionais de amostragem, (4) este sistema fornece a capacidade para os amostradores acederem a todos os dados após a medida do peixe (para memória futura), oferecendo mais uso ou validação dos dados disponíveis. Uma Rede Neuronal Convolucional (CNN) foi treinada

para medir automaticamente um conjunto de espécies. Os resultados obtidos são robustos e fiáveis, trabalhando em ambientes desordenados, mesmo com peixes empilhados e na presença de oclusões.

**Agradecimentos**

Agradecemos ao Centro de Ciências do Mar e do Ambiente do MARE e ao IMAR Institute of Marine Research da Universidade dos Açores, Portugal, por fornecerem os dados recolhidos pelo Programa de Recolha de Dados das Pescas e participarem na elaboração de um artigo para conferência (Anexo A). Agradecemos ainda à LOTAÇOR – Serviços de Lotas dos Açores, SA, por nos permitir e ajudar na instalação dos sistemas nas suas lotas.

## Referências bibliográficas

- [1] Ernesto Jardim, Manuela Azevedo and Nuno Brites, “Harvest control rules for data limited stocks using length-based reference points and survey biomass indices,” *Fisheries Research*, 171: 12-19, 2015.
- [2] John G. O'Keefe, inventor; Keefe John G O, assignee. “Fish length measuring device,” United States patent US5339532 A, 23 Aug 1994.
- [3] Kevin Wakeman, inventor; Kevin Wakeman, assignee. “Fish measurement device,” United States patent US20120324751 A1, 27 Dez 2012.
- [4] Gregory E. Lentine, inventor; Lentine Gregory E, assignee. “Fish scale and length measuring sensor,” United States patent US7408125 B2, 5 Aug 2008.
- [5] Robert Castaneda and Basil E. Battah, inventors; Spfm, L.P., assignee. “Systems and methods for electronically obtaining a fish length,” United States patent US20150316367 A1, 5 Nov 2015.
- [6] J.T. Øvredal and B. Totland, “The scantrol FishMeter for recording fish length, weight and biological data,” *Fisheries Research*, 55, pp. 325-328, 2002.
- [7] M. Rahim, et al, N. Abdullah and T. Saba, “FiLeDI framework for measuring fish length from digital images,” *International Journal of Physical Sciences*, 7.4:607-618, 2012

- [8] D. J. White, C. Svellingen, and N. J. C. Strachan. "Automated measurement of species and length of fish by computer vision," *Fisheries Research*, 80.2: 203-210, 2006.
- [9] Ching-Lu Hsieh, Hsiang-Yun Chang, Fei-Hung Chen, Jhao-Huei Liou, Shui-Kai Chang, and Ta-Te Lin, "A simple and effective digital imaging approach for tuna fish length measurement compatible with fishing operations," *Computers and Electronics in Agriculture*, 75.1: 44-51, 2011.
- [10] G. Chamberlain and B. J. Rothschild, inventors; G. Chamberlain and B. J. Rothschild, assignee; "Methods and systems for determining fish catches," United States patent US20130223693 A1, 29 Aug 2013.
- [11] FAO, "The State of Worlds Fisheries and Aquaculture, Part 1 Worlds review of fisheries and aquaculture," Food and Agriculture organization of the United Nations, Rome, 3:96, 2014.
- [12] EU, "Regulation (EU) No 1380/2013 of the European Parliament and of the Council of 11 December 2013 on the Common Fisheries Policy," *Official Journal of the European Union*, 28/12/2013.
- [13] EU, "Council Regulation (EC) No 1224/2009 of 20 November 2009 establishing a Community control system for ensuring compliance with the rules of the common fisheries policy," *Official Journal of the European Union*, 20/11/2009, 2009.

- [14] EU, "Directive 2008/56/EC of the European Parliament and of the Council of 17 June 2008 establishing a framework for community action in the field of marine environmental policy (Marine Strategy Framework Directive)", Official Journal of the European Union, L 164/19, 25/06/2008, 2008.
- [15] Rodrigues, Marco, et al. "Automatic fish species classification based on robust feature extraction techniques and artificial immune systems." Bio-Inspired Computing: Theories and Applications (BIC-TA), 2010 IEEE Fifth International Conference on. IEEE, 2010.
- [16] Yann LeCun et al. "Gradient-based learning applied to document recognition" Proceedings of the IEEE 86, 11 pp. 2278-2324 (1998).
- [17] Alex Krizhevsky et al. "ImageNet Classification with Deep Convolutional Neural Networks", Advances in Neural Information Processing Systems 25 pp. 1097-1105 (2012).
- [18] Karen Simonyan and Andrew Zisserman "Very Deep Convolutional Networks for Large-Scale Image Recognition", arXiv 1409.1556 (2014).
- [19] Christian Szegedy et al. "Going Deeper with Convolutions", arXiv 1409.4842 (2014).
- [20] Kaiming He et al. "Deep Residual Learning for Image Recognition", arXiv 1512.03385 (2015).
- [21] Mark Sandler et al. "MobileNetV2: Inverted Residuals and Linear Bottlenecks", arXiv 1801.04381 (2018).

- [22] Joseph Redmon et al. "You Only Look Once: Unified, Real-Time Object Detection", arXiv 1506.02640 (2015).
- [23] Liu, Wei et al. "SSD: Single Shot MultiBox Detector", Lecture Notes in Computer Science pp. 21–37 (2016).
- [24] Ross Girshick et al. "Rich feature hierarchies for accurate object detection and semantic segmentation", arXiv 1311.2524 (2013).
- [25] Kaiming He et al. "Mask R-CNN", arXiv 1703.06870 (2017).
- [26] Amaya Álvarez-Ellacuría et al. "Image-based, unsupervised estimation of fish size from commercial landings using deep learning", ICES Journal of Marine Science (2019).
- [27] Rafael Garcia et al. "Automatic segmentation of fish using deep learning with application to fish size measurement", ICES Journal of Marine Science (2019).
- [28] Joly, Alexis, et al. "LifeCLEF 2015: multimedia life species identification challenges." International Conference of the Cross-Language Evaluation Forum for European Languages. Springer International Publishing (2015).
- [29] Diederik P. Kingma and Jimmy Ba "Adam: A Method for Stochastic Optimization", arXiv 1412.6980 (2014).
- [30] Tsung-Yi Lin et al. "Microsoft COCO: Common Objects in Context" arXiv 1405.0312 (2014).

[31] César Santos Silva, et al, “An exhaustive sampling approach for fish data collection, using an automatic measuring system”, Kennelly, S.J. & Borges, L. (eds.) (2018). Proceedings of the 9th International Fisheries Observer and Monitoring Conference, Vigo, Spain. ISBN: 978-0-9924930-7-3, 395 pages.

## **ANEXO A**

Artigo aceite e apresentado na Fisheries Observers and Monitoring Conference (2018), realizada em Vigo. Apresenta-se uma fotografia do poster apresentado, tal como excertos dos Proceedings (pags. 1 e 324).

81

# An exhaustive sampling approach for Fish Data Collection, using an Automatic Measuring System

Tiago Gaspar, Ricardo Aires, Maria Luisa Ramalho and César Santos Silva

FishMetrics, Lda, Horta, Portugal  
cesar.silva@fishmetrics.pt  
www.fishmetrics.pt

Dália Reis, Hugo Diogo, Ângela Canha, João Gil Pereira

MARE Marine and Environmental Sciences Centre and IMAR Institute of Marine Research, University of the Azores, Horta, Portugal

### FishMetrics Automatic Measuring System

FishMetrics is an integrated system that automates fish data collection in fishing vessels and fish auctions. It simplifies the fish measurement procedure by uploading the data to a remote database, where measurements can be taken at a later stage. Does not require physical access to the fish. FishMetrics system is currently installed in three islands in the Azores.



Automatic FishMetrics System

Vs.



Manual FishMetrics System

### Manual size sampling

Complex at main ports or onboard fishing vessels, integrated in the Fisheries Data Collection Programme (FDCCP). Manual measurements with rulers, paper forms, voice recorders, etc. Only the main ports are covered (due to costs) and/or statistical representativeness. Not all species are sampled.

### FishMetrics architecture

FishMetrics consists of two main modules: Local unit, responsible for the acquisition of the data (2D and 3D images of the fish) - it is composed of an RGB camera, a depth camera, and a computer.



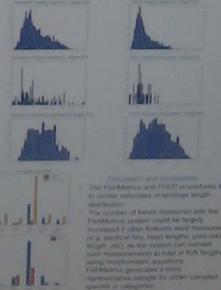
Remote unit: centralized database that collects data from several different local units, and makes them available to users, who can take remote measurements of the fishes and perform statistical analysis.

Table with columns: Species, Date, Length, Weight, etc. showing fish measurement data.

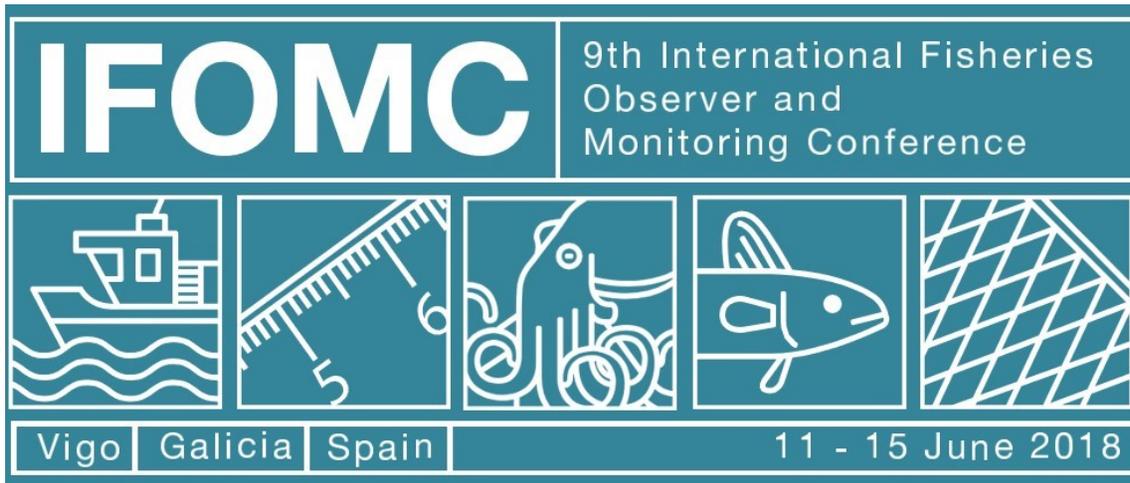


### Experimental Results

To validate the FishMetrics system, the sampled data using the FishMetrics system and the FDCCP were compared, focused on Faial Island for August of 2018. FDCCP requires the presence of onshore samplers who collect fish lengths data on a daily basis at Faial's fish auction market. The sampling scheme approach is stratified (reference needed) according to the available meters and commercial size categories of each day and landing, respectively. The comparative analysis reveals that the FishMetrics system generates a more representative and robust sample of the captured fish and this is particularly relevant for species or sizes that were often under-sampled due to a limited number of occasional landings or available resources.



Statistical test conclusions: The FishMetrics and FDCCP procedures led to similar estimates of average length distribution. The number of fishes measured with the FishMetrics system could be largely increased if other fisheries were measured (e.g. different fish, head lengths, and vertical height, etc.) as the system can capture such measurements in 2D or 3D images using morphometric algorithms. FishMetrics generates a more representative sample for under-sampled species or categories.



# Proceedings of the 9th International Fisheries Observer and Monitoring Conference

Edited by

**Prof Steve Kennelly**

IC Independent Consulting ([www.icic.net.au](http://www.icic.net.au))

and

**Lisa Borges**

FishFix ([www.fishfix.eu](http://www.fishfix.eu))

ISBN: 978-0-9924930-7-3

**Preferred citation:** Kennelly, S.J. & Borges, L. (eds.) (2018). Proceedings of the 9th International Fisheries Observer and Monitoring Conference, Vigo, Spain. ISBN: 978-09924930-7-3, 395 pages.

[...]

### **An exhaustive sampling approach for fish data collection, using an automatic measuring system**

**César Santos Silva<sup>1</sup>, Tiago Gaspar<sup>1</sup>, Ricardo Aires<sup>1</sup>, Maria Luísa Ramalho<sup>1</sup>, Dália Reis<sup>2</sup>, Hugo Diogo<sup>2</sup>, Ângela Canha<sup>2</sup>, João Gil Pereira<sup>2</sup>**

<sup>1</sup> **Fishmetrics, Lda, Portugal,**

<sup>2</sup> **MARE Marine and Environmental Sciences Centre and IMAR Institute of Marine Research, University of the Azores, Portugal**

Fish monitoring effort has been increasing over the past years, due to conservation and management requests demanding more and accurate data and consequently with raising costs. This is an important challenge especially for remote and disperse locations where fish sampling poses unbearable costs, leading to limited spatial sampling schemes, limited data on rare and occasionally landed species, as well as some erroneous and biased observations cases.



Figure 1. On the left: Scanner mounted above a scale; on the right: image acquired by the scanner, with some measures between 3D points.

Fishmetrics has developed a new autonomous system that can be installed on monitoring spots or on board fishing vessels, which is able to acquire remotely all the landed or captured fish, classify it, according to species and size, and measure it automatically without any physical interaction. The system uses a tridimensional infrared light system that is contactless, hence non-damaging for the fish. The

identification and classification algorithm is based on Machine Learning. This system can capture all the fish data remotely, storing the information in a cloud database for future inspection and statistical analysis. This information includes not only fish images and a tridimensional map that enables the measuring, but also all relevant metadata (fish species, vessel identification, capture location, fishing gear and more).

ID	ADDED	CAPT.	BOX #	WEIGHT (KG)	SEAPORT	SIZE	GEAR	BOAT	AREA	STATE	SPECIES	SPEC. CORNL.	IMAGE
8440	2016-02-24 12:45:45	2016-02-03 09:26	28	6579.6	Peniche	TSA	M	Antonio Ramos	Auto-Test Only	Not Assigned	Carapau	98	
8439	2016-02-24 12:45:40	2016-02-03 09:12	23	6578.5	Peniche	Unknown	M	Antonio Ramos	Auto-Test Only	Not Assigned	Polvo Cabeçuda	97	
8438	2016-02-24 12:45:35	2016-02-03 09:06	23	6577.1	Peniche	TSA	M	Antonio Ramos	Auto-Test Only	Not Assigned	Chouco	81	
8437	2016-02-24 12:45:30	2016-02-03 08:59	23	6576.9	Peniche	TSA	M	Antonio Ramos	Auto-Test Only	Not Assigned	Chouco	81	
8436	2016-02-24 12:45:25	2016-02-03 08:53	23	6575.7	Peniche	Unknown	M	Antonio Ramos	Auto-Test Only	Not Assigned	Polvo	82	

Figure 2. Screen of the Fishmetrics System Cloud browser application where the fish measurements are performed.

The aim of this work is to provide an overview of the system, its architecture and an analysis of the sampled data, by comparing the results of the Fishmetrics system with a traditional sampling methodology, in order to identify potential advantages of the system in relation to traditional data collection. Fishmetrics installed its system in Faial fish auction market working uninterruptedly for 18 months. However, the period of analysis was framed between July and August of 2016. The Fishmetrics system data was compared with Fisheries Data Collection Programme (FDPC) for the same period. FDPC requires the presence of onshore samplers which collect fish lengths data daily at Faial fish auction market. The Azorean landings are generally multispecies, and many are classified within different commercial sizes. For that reason, the sampling scheme approach is stratified (whenever needed) according to the available métiers and commercial sizes categories at each day and landing, respectively.

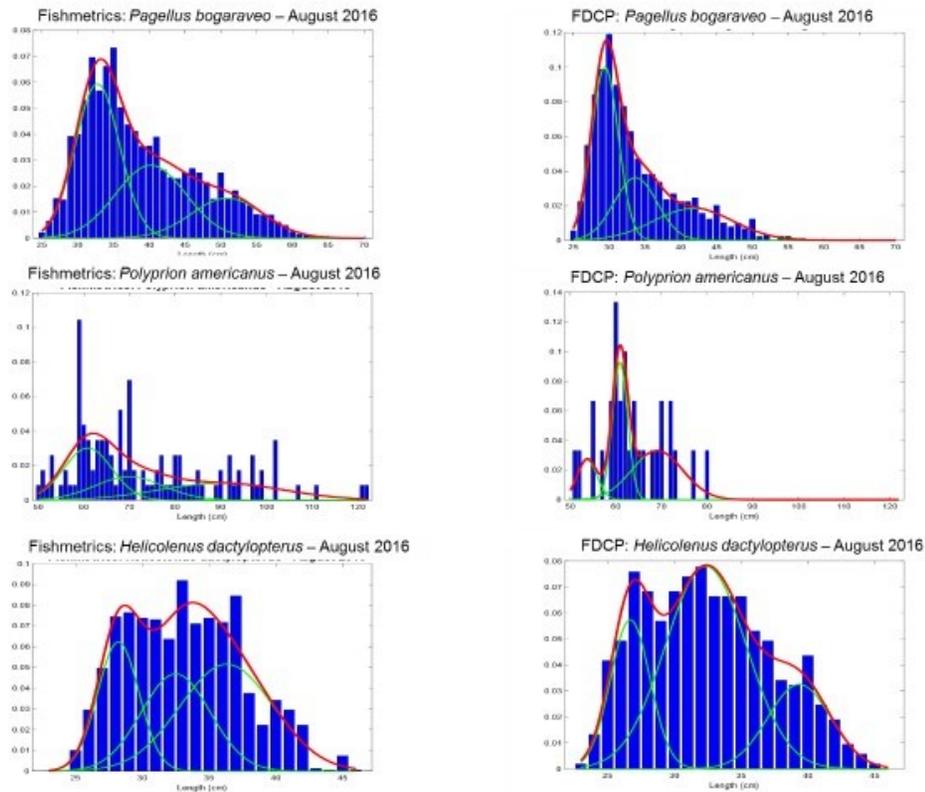


Figure 3 – Length histograms for the fish captured in August 2016, for three species. On the left: Based on Fishmetrics data; On the right: Based on FDCP data.

The comparative analysis reveals that the Fishmetrics system generates a more representative and robust sample of the captured fish and this is particularly relevant for species or sizes that were often under-sampled due to a limited number of occasional landings or available resources. The Fishmetrics system has three additional major advantages: it does not require the presence of samplers at the fish auction markets (useful for remote monitoring spots); the autonomous nature of the system leads to an exhaustive data collection; the data stored in the cloud database allows to re-measure any samples and to validate morphometric relations.

## **ANEXO B**

Artigo aceite para apresentação oral na Workshop on Science with Industry Initiatives, cuja síntese foi incluída no respetivo Report (WKSCINDI Report, página 44) e do qual apresentamos de seguida excertos.



## WORKSHOP ON SCIENCE WITH INDUSTRY INITIATIVES (WKSCINDI)

VOLUME 1 | ISSUE 68

ICES SCIENTIFIC REPORTS

RAPPORTS  
SCIENTIFIQUES DU CIEM



**ICES** INTERNATIONAL COUNCIL FOR THE EXPLORATION OF THE  
**SEA CIEM** CONSEIL INTERNATIONAL POUR L'EXPLORATION DE LA  
**MER**

## International Council for the Exploration of the Sea Conseil International pour l'Exploration de la Mer

H.C. Andersens Boulevard 44-46  
DK-1553 Copenhagen V  
Denmark  
Telephone (+45) 33 38 67 00  
Telefax (+45) 33 93 42 15  
[www.ices.dk](http://www.ices.dk)  
[info@ices.dk](mailto:info@ices.dk)

The material in this report may be reused for non-commercial purposes using the recommended citation. ICES may only grant usage rights of information, data, images, graphs, etc. of which it has ownership. For other third-party material cited in this report, you must contact the original copyright holder for permission. For citation of datasets or use of data to be included in other databases, please refer to the latest ICES data policy on ICES website. All extracts must be acknowledged. For other reproduction requests please contact the General Secretary.

This document is the product of an expert group under the auspices of the International Council for the Exploration of the Sea and does not necessarily represent the view of the Council.

ISSN number: 2618-1371 | © 2019 International Council for the Exploration of the Sea

[...]

### **Fishmetrics**

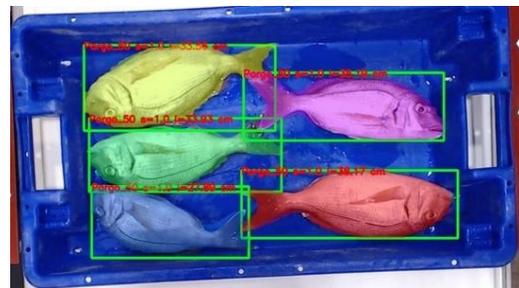
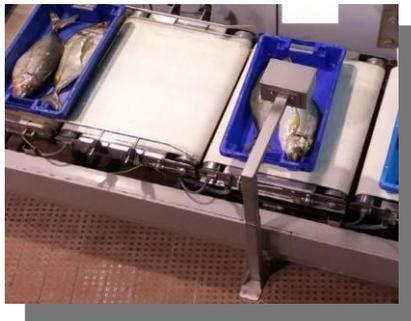
*Ricardo Aires*

Our technological solution for fish sampling and stock assessment consists of a system that can be installed in a fish auction, typically over a conveyor belt or weighing scale that takes color and depth (3D) pictures with metric information of the landed fish, typically placed inside boxes. These images, alongside with the relevant metadata, are uploaded to a remote server, which users can access via a web browser to perform the measurements. The images are acquired automatically on the passage of a new box and the depth images possess a very high degree of accuracy (less than 1 mm). Users can access the web application to take the measures, generate statistical reports, associate morphometric equations to estimate fish weights among many other features.

This system was initially deployed in three fish auctions in the Azores region and acquired more than 120.000 images for nearly three years, corresponding to an estimative of 2 million fish individuals. We compared the results obtained by our system with the results obtain by manual sampling and realised that for the amount of relevant data is much higher. As an example, for certain species, we have sampled more than 75% of the entire fish landed every month, which generates a sample much more representative of the fish population under study, hence improving the stock assessment. This is relevant for species with a low capture rate, which may go unsampled in a manual sampling scheme. The amount of measures obtained with our system can also increase if length-length morphometric relations are used for the semi-obstructed fish in the bottom of the boxes.

On top of this, we decided to use this vast database to train neural networks with deep learning algorithms to automatically identify the species inside the box and automatically measure the fish. We achieved an acceptable identification rate of 90% and obtained a measurement average error of 0.8 cm using the AI methods.

In summary, our system can greatly increase the amount of data sampled, improving the confidence of the statistical distributions leading to better assessments without even touching the fish. The sampling is performed remotely, which can greatly reduce the associated costs and the measuring can be automatized, which is important for remote auctions, but also for fishing vessels, where an automated system can detect, categorize and measure the fish, leading to real time accurate results.



## **ANEXO C**

Artigo submetido ao jornal ICES Journal of Marine Science. Aguarda decisão para publicação.  
Anexamos versão para revisão.

# Automatic fish measurement using a camera and a 3D sensor applied to a long-term experiment

*César Santos Silva\**, *Ricardo Aires*, *Flávio Rodrigues*

Fishmetrics, Lda, Horta, Portugal

\*Corresponding author: tel: +351 934477988; e-mail: [cesar.silva@fishmetrics.pt](mailto:cesar.silva@fishmetrics.pt)

## Abstract

Fish monitoring effort has been increasing over the past years, due to conservation and management requests demanding more accurate data and, consequently, with raising costs. This is an important challenge especially for remote and disperse locations where fish sampling poses unbearable costs, leading to limited spatial sampling schemes, limited data on rare and occasional landed species, as well as some erroneous and biased observations cases. In this paper, we propose a new autonomous system that can be installed on monitoring spots or on board fishing vessels, which is able to acquire remotely all the landed or captured fish and measure it automatically without any physical interaction. The system uses (1) a camera and a 3D sensor to have a complete XYZ reading of the fish, and (2) a Convolutional Neural Network, trained for a representative set of species to detect and measure the individuals visible in a box. The system was validated in real conditions, using continuous observations of the landed fish in three islands of the Azores Archipelago, for two years. The aim of this paper is to provide an overview of the measuring system and an analysis of the sampled data, by comparing the results of the proposed method with the traditional sampling methodology for a given period.

**Keywords:** convolutional neural networks, deep learning, fish size estimation, landings

## 1. Introduction

Fish stock assessment and management has received a lot of attention in recent years, mostly due to ecological and sustainability reasons. Unrestricted fishing of certain species has led to a significant reduction in their stocks, which is a threat to their sustainability [11]. Additionally, there is also an economic side to this issue, related with sea economy, as it includes shipowners, fish auctions, fish markets, and intermediaries. Given the importance of the problem, several European legislation and norms set rules for managing European fishing fleets and for conserving fish stocks (e.g. Common Fisheries Policy, [12]), to regulate fishing activity (e.g. Fishing Control Regulation, [13]) and to protect more effectively the marine environment across Europe (e.g. Marine Strategy Framework Directive, [14]). Since fisheries management is based on data and scientific advice, fisheries and biological data is collected for all stocks commercially exploited by European fleets under the European Data Collection Framework, DCF (Council Regulation (EC) No 199/2008, [13]), mainly carried out by National Research Institutes.

One of the most important biological data for fish stock assessment and management is the fish catch and landings length composition [1]. An accurate, fast, and versatile method of fish measurement would largely increase the data available for scientific morphometric analysis, as well as fish size control in aquaculture and fishery inspection services.

One of the biggest challenges in collecting fish size data is the limited amount of information that is available for many species due to the high cost of their acquisition (substantial increase in the number of sampling events). Nowadays, fish sampling is mostly carried out in fishing vessels and in fish auctions. However, having observers in every fishing vessel or fish auction is expensive and not feasible. On the other hand, statistical sampling assumptions are frequently difficult to be accomplished by observers (e.g. random sampling, stratified sampling) and affect the representativeness of the samples, resulting in biased length compositions. Sampling in fish auctions may also be slow (e.g. fish measurements recorded using rulers) and may alter the fish market quality due to manual fish handling. This latter aspect is particularly important since it often leads to fishermen reluctance in allowing fish sampling. Moreover, although market sampling is carried out in most representative fishing ports, low sampling of some species may result in unrepresentative or biased length compositions of stock catch or landings.

In this paper, a complete measuring set-up is presented, using a trained Convolutional Neural Network (CNN), a camera and a 3D sensor based on structured infrared light. The proposed system was installed in three Islands of the Azores Archipelago: Faial, Pico and Santa Maria. The system gathered images of the landed fish boxes in the fish auctions of the mentioned islands, for two years. To the best of our knowledge, this is the vastest long-term experiment using an automatic measuring system, applied to real conditions [31]. The fish were measured automatically and exhaustively for the mentioned period. Some results are presented, showing the robustness and reliability of the process.

## 2. Background

The most common fish measurement methods are typically rudimentary. They are based on the use of rulers and other similar methods. The patents [2] and [3] are examples of such methods, requiring handling the fish manually. Some electronic systems, such as the one proposed in [4], try to minimize the manual handling of the fish, but they are not completely successful in achieving this goal. Moreover, they do not save the measurements and it is not possible to repeat them later. If, for some reason, some systematic error in the measurement procedure exists, it cannot be corrected later. If possible, the measurement system should be able to save information about the fish that can be used to confirm the measurements or to take new measurements in the future.

Other systems, such as [5] and [6], automatically add the measurements to a database and register other variables, such as the fish weight and fishing region. However, they are slow and still require manual handling of the fish. In addition to the aforementioned system, there have also been several works, see [7], [8] and [9], that propose new methods for fish measurement using computer vision techniques. However, these systems are somehow limited, as they must deal with the typical ambiguity in scale that characterizes monocular vision systems, producing erroneous measurements.

The patent in [10] also proposes a computer vision-based approach, where the authors get rid of the ambiguity in scale by using stereo-photogrammetry. However, this type of systems has an important disadvantage, as they require dealing with occlusions and with the image-to-image matching problem.

The general problem of object recognition in images is extremely complex and has been tackled using several different strategies, such as feature detection and matching, Histogram of Oriented Gradients (HOGs), correlation, or neural networks. In [15], for instance, the authors use SIFT (Scale-invariant feature transform) and PCA (Principal Component Analysis) based techniques to recognize fishes in images, however, such approaches are very sensitive to variations in illumination, which can degrade its performance. Moreover, such methods assume that fishes are isolated, which is not the general case in images acquired in fish auctions, where fish boxes usually include several (eventually stacked) individuals of the same species. From the strategies mentioned above, the approach using HOGs is probably the most promising, however, it struggles to distinguish species that are similar and fishes that are curved and/or in strange positions inside the boxes. Correlation-based strategies suffer from the same problems.

However, in recent years, neural networks have evolved and led to the emergence of deep learning-based image recognition strategies, which revolutionized the field, as computers now compare to humans in object recognition and identification tasks. Even though the usage of traditional machine learning methods in computer vision applications has been a common approach for certain tasks, the new paradigm of data gathering coupled with the increasing computer processing capabilities of GPUs

(Graphics Processing Units) and TPUs (Tensor Processing Units) has led to new and more complex problem-solving methodologies. In particular, Convolutional Neural Networks (CNN) gathered a lot of attention and usage due to their performance increase in image recognition, object detection and segmentation.

One of the precursor CNN models developed by LeCun [16] dates back to 1989, consisting of a 5-layer network with backpropagation, at the time applied to handwritten digit recognition. Since then, the number of CNNs has increased as well as the dimension and complexity of their layers. One example of the paradigm shift was when the influential AlexNet, a 8-layer network developed by [17], ranked first in the 2012 ImageNet challenge beating non-supervised learning algorithms in image classification. All the subsequent yearly challenge winners featured deep learning solutions with increasing performance, at the cost of a growing number of network layers, total parameters and memory consumption. Examples include the VGG network with 16- and 19-layer versions [18], the Inception network [19], and the ResNet [20] with versions up to 150 layers in total. The constraints posed by the limited processing capabilities of mobile devices also led to the development of lighter networks with a reduced number of trainable parameters, such as MobileNet [21].

The range of applications of these networks started to grow from the simple image classification tasks, with examples such as semantic segmentation, object detection and individual object identification and segmentation. In particular, for object detection, the YOLO [22] and SSD [23] methods are the current state of the art, being very fast to train and to perform predictions.

In detail, the YOLO algorithm divides each training image in a grid of smaller regions (grid cells) and assigns the midpoint of an object to the corresponding cell. Furthermore, a set of anchor boxes are associated with each grid cell allowing the detection of multiple objects of different classes with the same midpoint. An initial estimation of the number of anchor boxes (and their positions) can be determined by maximizing the IoU (intersect over union) in the training set. The training is accomplished using a convolutional neural network, with the images and the bounding box positions as input features. During prediction time, the evaluation is applied to the full image and, for each region, it outputs an object probability of existence (commonly referred to as *score*) and bounding box coordinates. Using non-maximum suppression, all the boxes coalesce into the best approximated bounding box for the estimated object.

YOLO shows many advantages over popular R-CNN based methods [24], since it looks at the entire image and not only at proposed regions. In some implementations, it even runs faster than the upgraded versions of these region proposal networks (Fast and Faster R-CNN). A more recent approach, Mask R-CNN [25] appeared as an extension to Faster R-CNN, by adding a branch for predicting segmentation masks in parallel with the existing branch for bounding box recognition. It has been generally regarded as a very robust and fast method, showing accurate results for occluded objects, and was already used in [26] for fish measurement using CCTV auction cameras. However, this does not represent a good advantage in our case, since we want to

take the total measurement of the fish and with a partially occluded object it is not possible to get a depth estimate of the extremities through the data provided by the infrared sensor. Furthermore, we also use a more comprehensive and adequate acquisition setup. The authors in [27] also use Mask R-CNN for estimating the fish size, but the experiment uses a small amount of data and the measurements are taken from stereo image pairs, which needs to be calibrated (a complex and costly step), has to deal with the matching problem and provides results not so accurate.

The success of deep learning-based strategies in fish species recognition tasks has been confirmed by the most recent fish detection challenges, namely the LifeCLEF 2015 Fish Task [28], where the best results were obtained by such methods.

### 3. Proposed Method

#### 3.1. System setup

In this section, we propose the general architecture of the system, applied to fish auctions, with remote access to sampling data.

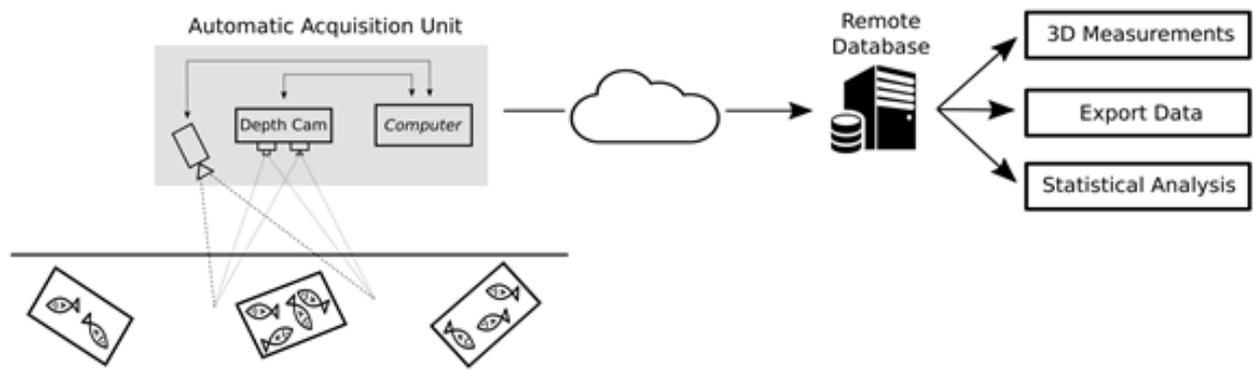


Figure 1- System Architecture.

Before getting into details about the architecture, let us start by describing the problem at hand. Consider a fish auction where fish, or fish boxes, are put on top of a planar surface, where they stand still for about 1 or 2 seconds. Fig. 2 shows several fish boxes in a fish auction. This typically happens during the fish-weighing process, where fish boxes are usually put on an industrial scale or on a weighing conveyor belt. Given this setup, our goal is to detect the moment in which the boxes/fishes are standing still and use this instant to acquire data that can later be used to retrieve 3D information about the fishes. This information must be processed and then uploaded to a remote database.

The system we propose consists of two main modules: a local unit and a remote unit, here also referred to as automatic acquisition unit and remote database, respectively, as illustrated in Fig. 1.

The local unit, see Fig. 2, is composed of an RGB camera, a depth camera, and a computer. The depth camera is a structured-light 3D scanner working on the infrared spectrum, i.e., it includes an infrared projector and an infrared camera that provide a 3D map of the scene. The two cameras are connected to a computer, which controls them and is responsible for triggering image acquisitions, processing the data, and communicating with the remote database.



Figure 2- Automatic acquisition unit integrated on a weighing conveyor belt.

The remote unit is a centralized database that collects data from several different local units, located in different fish auctions. It is a web-based application that organizes all the data and presents them to the user. It can be used to extract 3D information about the fishes, measure distances on their surfaces (such as their total length, pectoral fin length, or width), and get full-scale statistical analysis. It is possible to export all the data.

The acquisition setup was installed in three fish auctions of the Azores Archipelago: Horta (Faial), Madalena (Pico) and Vila do Porto (Santa Maria). In the first auction, the system was installed over a conveyor belt, with the acquisition taking place when a fish box (80x40 cm) was still for the auction procedure. In the two other cases, the data was acquired when an employee placed the box manually over a weighing scale. The setup includes a Logitech C920 RGB webcam; a structured infrared light Structure Sensor for the 3D data; and a computer for processing and uploading the data to the remote database. The software acquired data continuously, but only took a picture when the presence of a new fish box was detected.

In the next sections, we propose a Convolutional Neural Network based model to accomplish the measuring task, using the data stored in the database.

Species	pictures	Training objects	Measure Type
<i>Pagellus bogaraveo</i>	1,200	1,826	Fork length
<i>Pagrus pagrus</i>	1,200	1,674	Fork length
<i>Polyprion americanus</i>	1,200	1,322	Total length

Table 1- Image sets used to train CNN's.

### **3.2. Data acquisition**

More than 75,000 images were acquired for 26 months for the three fish auctions. The RGB images of the landed fish have a resolution of 1920x1080 pixels and the depth map has a resolution of 640x480 pixels, which is registered to the webcam pictures after stereo calibration of the two input devices, hence for each pixel of the RGB image, its 3D coordinates are known and it is possible to take metric measurements between any two points of that frame, with a resolution of +/- 1 mm.

Notice that our main goal in this work is not to classify the fish according to its species, but rather to measure it. Typically, for each box, we already know the fish species, which is obtained from the auction database. All the acquired images were labelled through the web application, where the user can select two or more points alongside the fish body, resulting in a set of bounding boxes that will be used as input data to train and evaluate a convolutional neural network model. This process will also output a measurement of the fish, a distance that is regarded as a ground-truth value to evaluate the deep learning model performance.

Depending on the species, the default measure can be a total length or a fork length. Table 1 shows four species for which 1,200 images were selected for training and evaluating the model (see Section 3.3). These images were randomly selected from the entire dataset of pictures acquired throughout all the experiment. Since there are several individuals per image (per box), the training objects can vary, as shown in the table.

### **3.3. Deep Learning Model and Training**

In this work, we use a deep learning structured data approach using the YOLO framework with the MobileNetV2 backend [21] for fish detection. The fish measurement is derived from the fish bounding box estimation.

The labelled data was initially separated by species and subsequently split into training, cross validation and test sets in an 80/10/10 proportion for the neural network model fit. Each set of species trained a MobileNetV2 backend YOLO model implemented in Keras/Tensorflow, using a GeForce GTX 1080 Ti. This network is a lighter model than other ones such as ResNet [20] or Inception models [19] which demonstrated good levels of performance, however they have a higher number of trainable parameters, and consequently require a greater amount of memory and training resources. MobileNet [21] represents a solid alternative, albeit having a small performance decrease, it can perform predictions on less resource consuming devices such as mobile devices. The choice of this network was made with the goal of placing an automated detection and measurement system on a remote location that has limited resources.

The images for the training were scaled to an input resolution of 416x416 pixels. To ensure that the fish is in a horizontal position, we rotated the images accordingly and mirrored the resulting image horizontally and vertically for data augmentation.

This facilitates the positioning of the bounding box around the fish, guaranteeing that the horizontal boundaries of the box fit perfectly with the endpoints of the specimen. Less care was given to the box vertical boundaries as they are not relevant for the accuracy of the measurement. We chose the Adam optimizer [29] with  $\beta_1= 0.99$  and  $\beta_2= 0.9999$  and a learning rate of 0.0001 without decay. The score and IoU thresholds were 0.3. No predefined number of epochs were set at the beginning of the training, and the model trained until no significant weight change was recorded. The maximum number of box detections per image was 10 and the initial weights were pretrained in the COCO image dataset [30].

### **3.4. Evaluation**

The data evaluations on the test set, for each species, were performed by comparing the measurement taken by manually selecting the fish endpoints and the measurement given by selecting the coordinates of the mid-points of the horizontal boundaries of the predicted box. For each fish, we selected the bounding box with the highest score given by the prediction, after rotating the test image 180° with a discretization of 5°.

## **4. Results**

As mentioned before, to test the proposed system in real conditions it was installed on three monitoring spots, so that we are able to acquire remotely all the landed or captured fish, classify it, according to species and size, and measure it automatically without any physical interaction. This automatic system captured all the fish data remotely, storing the information in a cloud database for future inspection and statistical analysis. This information includes not only the fish pictures and a tridimensional map that enables the measuring, but also all relevant metadata (fish species, vessel identification, capture location, fishing gear and more).

The proposed CNN was applied to the images to predict the fish size. Figures 3, 4, 5 and 6 show prediction examples for the selected species for images on the test sets. Only one bounding box is represented for each image, since the maximum score is obtained for a horizontal position of every specimen, after rotating the image 180° with a discretization of 5°.

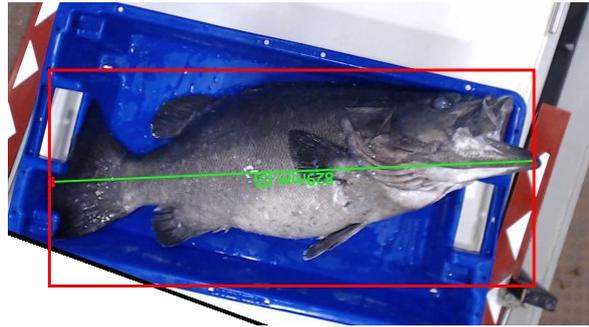


Figure 3- Sample of a fish box of *Polyprion americanus*. In red, the bounding box predicted by the proposed CNN. In green, the ground-truth. Notice how the lateral boundaries of the predicted bounding box are perfectly aligned with the mouth and the tail...



Figure 4- Sample of a box of *Pagrus pagrus*. In red, the bounding box predicted by the CNN. In green, the ground-truth. CNN predicts one or more bounding boxes per direction. Since fish have different directions, CNN detects them in different instants.



Figure 5- Sample of a box of *Pagellus bogaraveo*. In red, the bounding box predicted by the CNN. In green, the ground-truth.

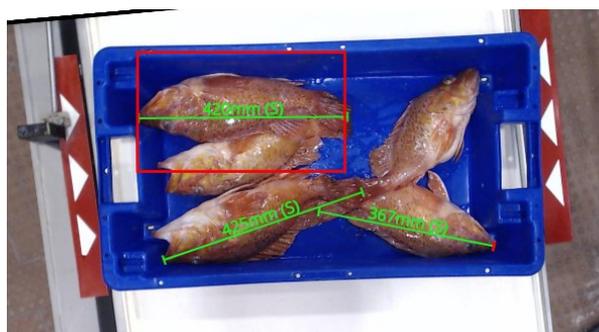


Figure 6- Sample of a box of *Pontinus kuhlii*. In red, the bounding box predicted by the CNN. In green, the ground-truth. Notice that the detected fish is measured correctly, although it is partially hidden.

Next, we present an error analysis by comparing the estimated data to the ground-truth. Four of the most representative fish species in the Azores were selected: *Pontinus kuhlii*, *Polyprion americanus*, *Pagellus bogaraveo* and *Pagrus pagrus*. For each species, 400 individuals were randomly selected from the universe of fish caught in the experiment. These samples weren't used in the training or validation of the CNN, to avoid the contamination of the results.

Species	RMSE	RMedSE	RMSE (removing 10% outliers)	RMedSE (removing 10% outliers)	Normalized Error by Size (%)	95% Confidence Interval
<i>Polyprion americanus</i>	42.31	23.56	27.39	19.91	3.97	14.32 - 25.71
<i>Pagrus pagrus</i>	23.34	13.49	16.65	11.95	4.39	5.45 - 10.10
<i>Pagellus bogaraveo</i>	24.51	15.67	18.58	14.12	5.28	8.69 - 12.88
<i>Pontinus kuhlii</i>	28.70	20.00	21.65	18.00	6.94	15.86 - 21.20

Table 2-Error analysis of the measurements taken by CNN, in millimeters.

For each specimen, it was computed the difference between the ground-truth fish size measurement and the measurement provided by the proposed method, in millimeters (mm). Table 2 shows the Root Mean Square of the Error (RMSE) for the set of all selected samples (100%) and for the set of all samples after removing 10% of the highest errors (outliers). To study the effect of the outliers on the fish size estimation, the Root Median Square of the Error (RMedSE) is also presented, for 100% and 90% of observations. The relative RMSE, weighted by the fish size, is also computed. The last column of the Table shows the 95% confidence interval (for a p value < 0.05), representing the interval where the mean of the estimates of the proposed method is expected to be in relation to the ground-truth. This allows us to determine a systematic deviation of the proposed measuring method, which can be considered and discounted for further measurements.

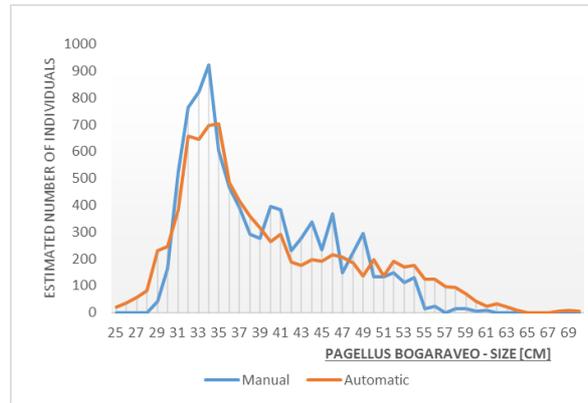
Based on these results, we can conclude the following: (1) after removing outliers, the RMSE (or RMedSE) is below 2.1 cm for all species, excluding *Polyprion americanus* (2.7cm); (2) the system produces few outliers, since the presence of outliers

increases the RMSE by only 0.6cm (excluding again *Polyprion americanus* for which RMSE increases almost 2cm); (3) when weighted by the fish size, the relative RMSE is in the range 0-7% for all species, which means that the error of the size estimation is approximately 0-7% of the size; (4) the mean of the estimates of the proposed method is expected to have a deviation between 1cm and 2cm in relation to the ground-truth (depending on the species), which suggests that the automatic method has a bias that can be integrated on further estimations. Notice that the measuring errors are generally higher for the *Polyprion americanus* because of the species size, reaching 120 cm in length. This naturally increases the presence of outliers for this species, although it does not affect the relative RMSE.

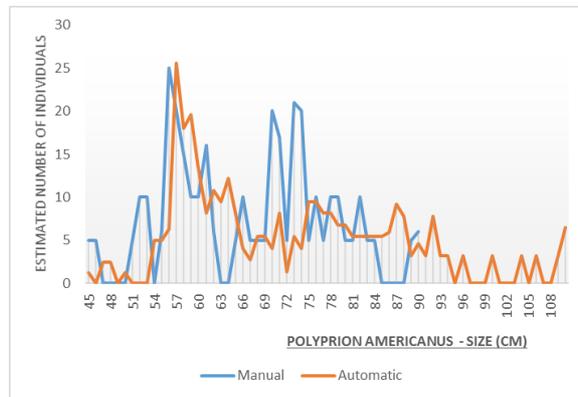
Next, we compare the size histograms obtained by using the proposed system with the histograms provided by the traditional sampling methodology. Doing this comparison, we expect to identify disadvantages and advantages of the proposed measuring system in relation to traditional data collection.

In this section, we restrict our study to the observations taken in Faial Island for a given period: July, 2016. This data was compared to the information provided by the Fisheries Data Collection Programme (FDCP) for the same month. FDCP required the presence of on-shore samplers who manually collected fish lengths data on a daily basis at Faial fish auction market. The Azorean landings are generally multispecies, and many are classified within different commercial sizes. For that reason, the sampling scheme approach is stratified (whenever needed) according to the available métiers and commercial sizes categories at each day and landing, respectively. The data is then normalized (amplified) given the total weight of the landings for each category. Notice that categories for which there were none or very few observations due to the sampling process, the mentioned normalization produces a meaningless result.

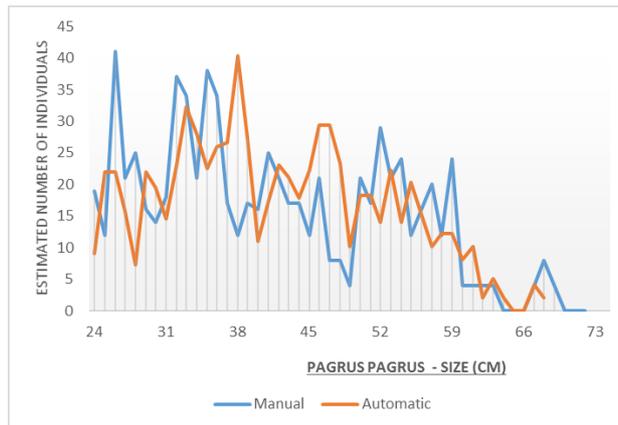
In Figure 7, we present results for the previously selected species. For every species, both histograms are normalized using the total weight of fish landed for the mentioned period, so that the total number of individuals in both approaches is approximately the same.



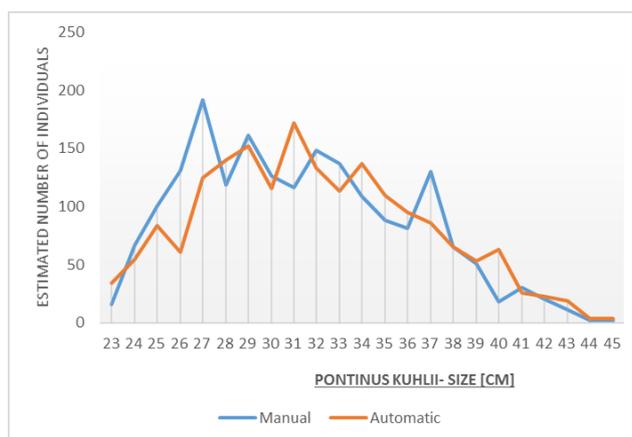
(e) *Pagellus bogaraveo*



(f) *Polyprion americanus*



(g) *Pagrus pagrus*



(h) *Pontinus kuhlii*

**Figure 7** – Histograms for fish caught for 1 month in Faial Island, for the species indicated. In blue: Histogram estimated by Fisheries Data Collection Programme. In red: Histogram estimated by the proposed system.

The first result observed in the Figure 7 is that the histograms are generally close to each other. This means that both methods produce approximately the same results. However, we notice that the amount of collected data for the monitored spot is smoother than the data sampled by the on-shore samplers, especially for more numerous populations. This happens because there are much more samples available in the proposed method for those species, resulting that the contiguous sizes become statistically related, as expected.

We also notice that our method provides richer information for some fish sizes, that seems to be omitted by the manual approach, especially for higher sizes. For example, the categories of higher size of *Pagellus bogaraveo* and *Polyprion americanus* seem statistically more relevant after using our method, compared to the manual method which neglected them, as is observed in Figures 7 (a) and (b). This happens because the sampling nature of the manual method tends to disregard categories with few or no samples.

## 5. Conclusions

The comparative analysis revealed that the proposed measuring system has several advantages, starting from not requiring the presence of samplers at the fish auction markets; the amount of collected data for the monitored spot is considerably larger than the data sampled by the on-shore samplers, with the sampled data providing more information about the Archipelago's fish stocks. The autonomous nature of the system leads to an exhaustive data collection, generating a more representative and robust sample of the captured fish. This is particularly valid for species (or sizes) that are often under-sampled due to limited number of occasional landings and consequently have more data on species (or sizes) more regular and abundant at landings. Also, unlike traditional sampling methodologies, this system provides the ability for the samplers to access all the data after the fish

is measured, offering further use or data validation. A Convolutional Neural Network was trained to measure automatically a set of species. The results obtained are robust and reliable, working in cluttered environments, even with stacked fish and in the presence of occlusions.

In synthesis, the major contributions of this work are:

1. To the best of our knowledge, this is the vastest long-term experiment using a totally automatic reading system for capturing and measuring fish, in an exhaustive way. This allows us to compare long-term statistics between the automatic method and the traditional ones.
2. We use a 3d scanner combined with a camera to have a dense 3D reading of the fish surface, so that each measurement used corresponds to an Euclidean distance between two 3D point measured in the space (and not measured in a photo).
3. We applied a neural network to measure several species. In this paper, we propose a convolutional neural network which can take measures of four different species, but the method we propose can be generalized to a variety of species. Other advantage of this neural network consists in being much faster than the generality of the neural networks, which means can run in smartphones.
4. We propose an integrated and complete system, from the acquisition to the measuring process.

***Note 1: The data underlying this article will be shared on reasonable request to the corresponding author.***

***Note 2: The system proposed is not a commercial product, but intellectual rights may be reserved. For more information, contact the corresponding author.***

### **Acknowledgements**

We thank the MARE Marine and Environmental Sciences Centre and IMAR Institute of Marine Research, University of the Azores, Portugal, for providing the data collected by the Fisheries Data Collection Programme. We thank LOTAÇOR – Serviços de Lotas dos Acores, SA, for allowing us and helping us on installation the systems at their Fish Auctions. The authors work for Research Department of Fishmetrics, and their work was developed in the context of the project FISHVISION (AÇORES-01-0247-FEDER-000002), partially funded by the Research Program ACORES2020, with participation of Azorean Funds, Portuguese Funds and European Funds.

### **References**

- [1] Ernesto Jardim, Manuela Azevedo and Nuno Brites, “Harvest control rules for data limited stocks using length-based reference points and survey biomass indices,” *Fisheries Research*, 171: 12-19, 2015.
- [2] John G. O’Keefe, inventor; Keefe John G O, assignee. “Fish length measuring device,” United States patent US5339532 A, 23 Aug 1994.

- [3] Kevin Wakeman, inventor; Kevin Wakeman, assignee. "Fish measurement device," United States patent US20120324751 A1, 27 Dez 2012.
- [4] Gregory E. Lentine, inventor; Lentine Gregory E, assignee. "Fish scale and length measuring sensor," United States patent US7408125 B2, 5 Aug 2008.
- [5] Robert Castaneda and Basil E. Battah, inventors; Spfm, L.P., assignee. "Systems and methods for electronically obtaining a fish length," United States patent US20150316367 A1, 5 Nov 2015.
- [6] J.T. Øvredal and B. Totland, "The scantrol FishMeter for recording fish length, weight and biological data," *Fisheries Research*, 55, pp. 325-328, 2002.
- [7] M. Rahim, et al, N. Abdullah and T. Saba, "FiLeDI framework for measuring fish length from digital images," *International Journal of Physical Sciences*, 7.4:607-618, 2012
- [8] D. J. White, C. Svellingen, and N. J. C. Strachan. "Automated measurement of species and length of fish by computer vision," *Fisheries Research*, 80.2: 203-210, 2006.
- [9] Ching-Lu Hsieh, Hsiang-Yun Chang, Fei-Hung Chen, Jhao-Huei Liou, Shui-Kai Chang, and Ta-Te Lin, "A simple and effective digital imaging approach for tuna fish length measurement compatible with fishing operations," *Computers and Electronics in Agriculture*, 75.1: 44-51, 2011.
- [10] G. Chamberlain and B. J. Rothschild, inventors; G. Chamberlain and B. J. Rothschild, assignee; "Methods and systems for determining fish catches," United States patent US20130223693 A1, 29 Aug 2013.
- [11] FAO, "The State of Worlds Fisheries and Aquaculture, Part 1 Worlds review of fisheries and aquaculture," Food and Agriculture organization of the United Nations, Rome, 3:96, 2014.
- [12] EU, "Regulation (EU) No 1380/2013 of the European Parliament and of the Council of 11 December 2013 on the Common Fisheries Policy," *Official Journal of the European Union*, 28/12/2013.
- [13] EU, "Council Regulation (EC) No 1224/2009 of 20 November 2009 establishing a Community control system for ensuring compliance with the rules of the common fisheries policy," *Official Journal of the European Union*, 20/11/2009, 2009.
- [14] EU, "Directive 2008/56/EC of the European Parliament and of the Council of 17 June 2008 establishing a framework for community action in the field of marine environmental policy (Marine Strategy Framework Directive)", *Official Journal of the European Union*, L 164/19, 25/06/2008, 2008.
- [15] Rodrigues, Marco, et al. "Automatic fish species classification based on robust feature extraction techniques and artificial immune systems." *Bio-Inspired Computing: Theories and Applications (BIC-TA)*, 2010 IEEE Fifth International Conference on. IEEE, 2010.
- [16] Yann LeCun et al. "Gradient-based learning applied to document recognition" *Proceedings of the IEEE* 86, 11 pp. 2278-2324 (1998).
- [17] Alex Krizhevsky et al. "ImageNet Classification with Deep Convolutional Neural Networks", *Advances in Neural Information Processing Systems* 25 pp. 1097-1105 (2012).

- [18] Karen Simonyan and Andrew Zisserman "Very Deep Convolutional Networks for Large-Scale Image Recognition", arXiv 1409.1556 (2014).
- [19] Christian Szegedy et al. "Going Deeper with Convolutions", arXiv 1409.4842 (2014).
- [20] Kaiming He et al. "Deep Residual Learning for Image Recognition", arXiv 1512.03385 (2015).
- [21] Mark Sandler et al. "MobileNetV2: Inverted Residuals and Linear Bottlenecks", arXiv 1801.04381 (2018).
- [22] Joseph Redmon et al. "You Only Look Once: Unified, Real-Time Object Detection", arXiv 1506.02640 (2015).
- [23] Liu, Wei et al. "SSD: Single Shot MultiBox Detector", Lecture Notes in Computer Science pp. 21–37 (2016).
- [24] Ross Girshick et al. "Rich feature hierarchies for accurate object detection and semantic segmentation", arXiv 1311.2524 (2013).
- [25] Kaiming He et al. "Mask R-CNN", arXiv 1703.06870 (2017).
- [26] Amaya Álvarez-Ellacuría et al. "Image-based, unsupervised estimation of fish size from commercial landings using deep learning", ICES Journal of Marine Science (2019).
- [27] Rafael Garcia et al. "Automatic segmentation of fish using deep learning with application to fish size measurement", ICES Journal of Marine Science (2019).
- [28] Joly, Alexis, et al. "LifeCLEF 2015: multimedia life species identification challenges." International Conference of the Cross-Language Evaluation Forum for European Languages. Springer International Publishing (2015).
- [29] Diederik P. Kingma and Jimmy Ba "Adam: A Method for Stochastic Optimization", arXiv 1412.6980 (2014).
- [30] Tsung-Yi Lin et al. "Microsoft COCO: Common Objects in Context" arXiv 1405.0312 (2014).
- [31] César Santos Silva, et al, "An exhaustive sampling approach for fish data collection, using an automatic measuring system", Kennelly, S.J. & Borges, L. (eds.) (2018). Proceedings of the 9th International Fisheries Observer and Monitoring Conference, Vigo, Spain. ISBN: 978-0-9924930-7-3, 395 pages.

## **ANEXO D**

A submissão do primeiro registo de prioridade realizou-se em 2016 (antes de iniciar o projeto Fishvision). Durante o projeto FishVision foram realizadas todas as diligências quer de alteração quer de adição de reivindicações necessárias para habilitar o documento aos critérios de patenteabilidade. Encontra-se ainda a decorrer os processos de análise. Anexamos excerto do documento de prioridade entregue à World Intellectual Property Organization (WIPO).

# WIPO

WORLD  
INTELLECTUAL PROPERTY  
ORGANIZATION

---

## DOCUMENT MADE AVAILABLE UNDER THE PATENT COOPERATION TREATY (PCT)

International application number:	PCT/PT2017/050012
International filing date:	13 April 2017 (13.04.2017)
Document type:	Certified copy of priority document
Document details: Country/Office:	<b>PT</b>
Number:	109333
Filing date:	16 April 2016 (16.04.2016)
Date of receipt at the International Bureau.	22 May 2017 (22.05.2017)

Remark: Priority document submitted or transmitted to the International Bureau in compliance with Rule 17. I(a), (b) or (b-bis)

(M , (los  
Colombollos .1 2 1 1  
Gencva 20,  
Switzcflancl

[www.wipo.int](http://www.wipo.int)

CERTIFICADO DE PEDIDO DE PATENTE DE INVENÇÃO  
NACIONAL

(li) 109333

Certifica-se que os elementos em anexo estão conforme o original do  
pedido de PATENTE DE  
INVENÇÃO NACIONAL n. ° 109333, apresentado em 16 de abril de 2016:

---

(22) Data de pedido: 16/04/2016

(71) Requerentes: CÉSAR AUGUSTO DOS SANTOS SILVA, AVENIDA GUERRA  
JUNQUEIRO, 95 ° DTO, 1000-166 LISBOA, PORTUGAL  
GUI MANUEL MACHADO MENEZES, RUA DR. ALBERTO CAMPOS DE  
MEDEIROS, 15, ILHA DO FAIAL, AÇORES, 9900-146 HORTA, PORTUGAL

(72) Inventores: CÉSAR AUGUSTO DOS SANTOS SILVA, PT  
GUI MANUEL MACHADO MENEZES, PT  
TIAGO FILIPE PIRES GASPAS, PT  
RICARDO RUBEN DOS SANTOS AIRES, PT

---

Estado do processo: Aguarda publicação

---

(51) Classificação: GOIG 1 9/60

(54) Epígrafe: SISTEMA PARA MEDIÇÃO DE PESCADO USANDO UMA  
CÂMARA E UM PROJECTOR DE LUZ ESTRUTURADA

(57) Resumo: ESTE INVENTO PROPÕE NUM SISTEMA PARA TIRAR  
MEDIDAS DE PESCADO, QUE COMPREENDE TRÊS ELEMENTOS  
CENTRAIS: UM PROJETO DE LUZ ESTRUTURADA, UMA CÂMARA E UMA  
SUPERFÍCIE ONDE O PESCADO ESTÁ POSICIONADO. POR VIA DA  
TRIANGULAÇÃO DOS RAIOS DE LUZ PROJETADOS E OBSERVADOS PELA  
CÂMARA, O SISTEMA PRODUZ SUCESSIVOS MAPAS TRIDIMENSIONAIS  
DO QUE OBSERVA. CONTUDO, O SISTEMA APENAS SELECIONA E  
GUARDA UMA MALHA TRIDIMENSIONAL POR CADA NOVA AMOSTRA DE  
INTERESSE. Isso É ESSENCIAL PARA SE TER UM E UM SÓ MAPA  
TRIDIMENSIONAL POR CADA AMOSTRA DE PESCADO, E NÃO UM  
CONJUNTO MASSIVO DE MAPAS TRIDIMENSIONAIS, DESNECESSÁRIO PARA O

PROCESSO DE MEDIÇÃO. ESTE INVENTO PROPÕE SABER, DE FORMA AUTOMÁTICA, A CADA INSTANTE, SE EXISTE PESCADO SOBRE A SUPERFÍCIE VISUALIZADA PELA CÂMARA E GUARDAR APENAS UMA VEZ A MALHA TRIDIMENSIONAL DO PESCADO. A INFORMAÇÃO DISPONIBILIZADA NA MALHA TRIDIMENSIONAL PERMITE A DETERMINAÇÃO DE DISTÂNCIAS RIGOROSAS ENTRE QUAISQUER DOIS PONTOS SOBRE A SUPERFÍCIE DO PESCADO.

---

Instituto Nacional da Propriedade Industrial, 15 de maio de 2017

Pelo Chefe de Departamento,  
André Robalo

O Responsável,  
Angela Canada

M0682.01 Campo das Cebolas - 1 149-035 LISBOA - PORTUGAL  
Telfs. (351-21) 881 81 00 Linha  
Azul: (351) 808 200 689 Fax. (351-  
21) 888 37 20 Internet:[www.mci.pt](http://www.mci.pt)