



XVII Simposio CEA de Control Inteligente

27-29 de junio de 2022, León



Detección y clasificación de animales subacuáticos en observatorios cableados

Lopez-Vazquez, V.^{a, b, *}, Lopez-Guede, J.M.^c

^a Universidad del País Vasco (UPV/EHU), Nieves Cano, 12, 01006, Vitoria-Gasteiz, España.

^b Deusto Seidor S.A., 01015, Vitoria-Gasteiz, España.

^c Departamento de Ingeniería de Sistemas y Automática, Universidad del País Vasco (UPV/EHU), Nieves Cano, 12, 01006, Vitoria-Gasteiz, España.

To cite this article: Lopez-Vazquez, V., Lopez-Guede, J.M. 2022. Detection and classification of underwater animals at cabled observatories. XVII Simposio CEA de Control Inteligente.

Resumen

Los océanos son ecosistemas sensibles y de gran importancia debido a la biodiversidad y recursos que ofrecen. A pesar de que el fondo marino es prácticamente inaccesible para el ser humano, es posible explorarlo gracias a vehículos de guiado automático (AGVs) o mediante cámaras fijas provistas por observatorios cableados. Estos dispositivos pueden obtener imágenes sobre la fauna y flora en entornos donde la luz natural escasea y la presión es mayor, con el fin de realizar un seguimiento del entorno y de las especies que habitan en él. Sin embargo, analizar y clasificar manualmente grandes cantidades de imágenes de manera rápida es una tarea imposible. Por ello, proponemos un proceso para el análisis de datos visuales que integra técnicas de detección y clasificación de animales subacuáticos y de mejora de imágenes y/o vídeos del fondo marino para desarrollar un proceso de detección y clasificación automática de especies marinas.

Palabras clave: Aprendizaje automático, Procesamiento de imágenes, Redes neuronales, Técnicas de inteligencia artificial, Algoritmos en tiempo real.

Detection and classification of underwater animals at cabled observatories

Abstract

The oceans are sensitive ecosystems of great importance due to the biodiversity and resources they offer. Although the seabed is virtually inaccessible to humans, it can be explored using automated guided vehicles (AGVs) or fixed cameras provided by wired observatories. These devices can obtain images of fauna and flora in environments where natural light is scarce and pressure is higher, in order to monitor the environment and the species that inhabit it. However, manually analyzing and classifying large amounts of images quickly is an impossible task. Therefore, we propose a process for the analysis of visual data that integrates techniques for the detection and classification of underwater animals and the enhancement of images and/or videos of the seabed to develop a process of automatic detection and classification of marine species.

Keywords: Machine Learning, Image processing, Neural networks, Artificial intelligence techniques, Real-time algorithms.

1. Introducción

En las últimas dos décadas, la vigilancia y monitorización de los océanos, así como la obtención de imágenes subacuáticas (Bicknell et al. 2016) y el desarrollo de plataformas robóticas cubiertas de sensores ambientales para la obtención de datos, han adquirido una gran importancia (Danovaro et al. 2017). Los observatorios cableados son plataformas multiparamétricas conectadas a la costa mediante

cables de fibra óptica (Favali et al. 2015), siendo una de sus funciones adquirir material de imagen para posteriormente analizarlo e identificar y contar animales de diferentes especies durante largos periodos de tiempo (De Leo et al. 2018).

Sin embargo, en muchos casos, el procesamiento de imágenes sigue siendo manual y las plataformas de observatorios cableados aún no están equipadas con las herramientas adecuadas para el reconocimiento y clasificación de imágenes.

1.1 Objetivo

El objetivo de este artículo es presentar una línea de trabajo para la detección y clasificación de animales submarinos, que incluye la mejora de la imagen, la anotación manual (para definir los conjuntos de datos de entrenamiento y validación), y los pasos automatizados de reconocimiento de contenido y posterior clasificación en la imagen.

Para ello, se hizo uso del material visual proporcionado por la red de observatorios cableados Lofoten-Vesterålen (LoVe) (Godø et al. 2014), situada a 260 m de profundidad, en Noruega. Aún no se ha llevado a cabo el seguimiento de su población local y de otras especies de la comunidad circundante, algo que podría ser de gran relevancia para producir algunos datos auxiliares para los modelos de gestión independientes de la pesca y basados en el ecosistema.

2. Materiales y métodos

2.1. Datos

Las imágenes proporcionadas por el observatorio LoVe fueron adquiridas en un entorno no controlado, caracterizado por un fondo heterogéneo, donde la turbidez y los cambios de iluminación artificial dificultan la detección de elementos. La Figura 1 muestra las diferentes especies detectadas en el conjunto de imágenes.

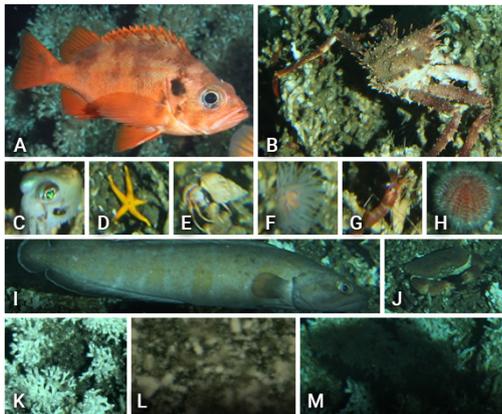


Figura 1: Un ejemplo de las especies detectadas y utilizadas para construir el conjunto de datos de entrenamiento. A., Pez Roca (*Sebastes* sp.); B., Cangrejo real (*Lithodes maja*); C., Calamar (*Sepiolidae*); D., Estrella de mar; E., Cangrejo ermitaño; F., Anémona (*Bolocera tuediae*); G., Camarón (*Pandalus* sp.); H., Erizo de mar (*Echinus esculentus*); I., Pez anguila (*Brosme brosme*); J., Cangrejo (*Cancer pagurus*); K., Coral (*Desmophyllum pertusum*); y finalmente, L. Turbidez y M., Sombra.

Las imágenes utilizadas fueron obtenidas por una cámara fija en dos ventanas temporales, la primera del 04/10/2017 al 27/06/2018 y la segunda del 10/12/2018 al 29/06/2019. En consecuencia, se dispuso de un total de 8818 imágenes de forma continua en el periodo de 24 horas (obteniendo una imagen cada 60 minutos).

2.2. Procesamiento de imágenes

Se diseñó y desarrolló un proceso para el tratamiento de imágenes basado en herramientas de visión por ordenador para mejorar el contraste de la imagen y para segmentar las subregiones relevantes de la imagen, cuyo esquema puede verse en la Figura 2.

En primer lugar, se generan imágenes de fondo que después se utilizarán para realizar la sustracción de fondo tras aplicar diferentes técnicas a las imágenes. Para mejorar el contraste fondo y primer plano de la imagen se aplicó la técnica de Ecuilización Adaptativa de Histograma con Contraste Limitado (CLAHE) (Reza 2004). Después de esta ecualización, se aplica un filtrado bilateral (Tomasi and Manduchi 1998) para descartar la información no relevante de la imagen y preservar los bordes de los objetos que se van a extraer. En este momento se realiza la sustracción de fondo. De este modo, se obtiene un fotograma con sólo los elementos detectados en la imagen original. Finalmente, se detectan los contornos de la imagen a la que se le aplicó el método del valor umbral para extraer las características globales (como las de textura o color) para su posterior clasificación.

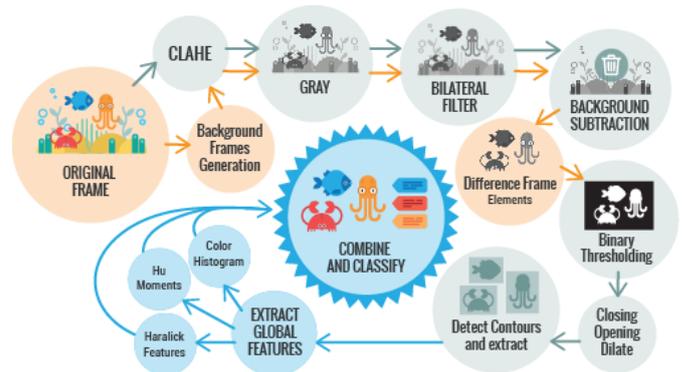


Figura 2: Proceso para el tratamiento de imágenes.

2.3. Diseño experimental

En cuanto a los algoritmos de clasificación utilizados, se seleccionaron un total de 16 algoritmos, teniendo en cuenta sus resultados en este campo (Fang et al. 2018; Rimavicius and Gelzinis 2017; Saberioon et al. 2018; Spampinato et al. 2016). Se escogieron 8 algoritmos clásicos: dos versiones de Support Vector Machine (LSVM y SVM+SGD), dos K-Nearest Neighbors (K-NN1 y K-NN2), dos Decision Trees (DT1 y DT2) y dos Random Forests (RF1 y RF2).

Por otra parte, 8 redes neuronales: cuatro redes convolucionales (denominadas CNN1, CNN2, CNN3 y CNN4) y cuatro redes neuronales profundas (DNN1, DNN2, DNN3 y DNN4). Se eligieron diferentes parámetros de configuración, optimizadores y estructuras, para realizar una comparación entre las redes.

3. Resultados

Los valores medios de exactitud (*accuracy*) y AROC; el área bajo la curva ROC (acrónimo de *Receiver Operating Characteristic*, o Característica Operativa del Receptor) obtenidos para todas las clases y para cada clasificador que se obtuvieron realizando una validación cruzada, pueden verse en la Tabla 1.

En cuanto a los clasificadores tradicionales, el peor resultado lo obtuvo el K-NN2, ya que apenas alcanzó un valor de AUROC de 0.6390. El RF2 obtuvo el valor AUROC más alto, siendo 0.8210. Los valores de exactitud son bastante

inferiores para cada clasificador en comparación con los valores de AUROC.

Los enfoques DL obtuvieron mejores resultados que casi todos los clasificadores tradicionales. Todas las redes obtuvieron valores AROUC de más del 80%. Las CNN obtuvieron valores de AROUC entre 0.7983 y 0.8180, mientras que las DNN obtuvieron valores más altos, entre 0.8361 y 0.8759 respectivamente.

Tabla 1: Valores de exactitud y AUROC alcanzados con el conjunto de datos de prueba obtenidos por diferentes modelos.

Enfoque	Clasificador	Exactitud	AUROC
Clasificadores tradicionales	Linear SVM	0.5137	0.7392
	LSVM+SGD	0.4196	0.6887
	K-NN1	0.4463	0.7140
	K-NN2	0.3111	0.6390
	DT1	0.4310	0.6975
	DT2	0.4331	0.6985
	RF1	0.4326	0.6987
	RF2	0.6527	0.8210
Técnicas de DL	CNN1	0.6191	0.7983
	CNN2	0.6563	0.8180
	CNN3	0.6346	0.8067
	CNN4	0.6421	0.8107
	DNN1	0.7618	0.8759
	DNN2	0.7576	0.8730
	DNN3	0.6904	0.8361
	DNN4	0.7140	0.8503

La figura 3 muestra la matriz de confusión de los resultados de clasificación obtenidos por la DNN1, que obtuvo buenos resultados para casi todas las clases.

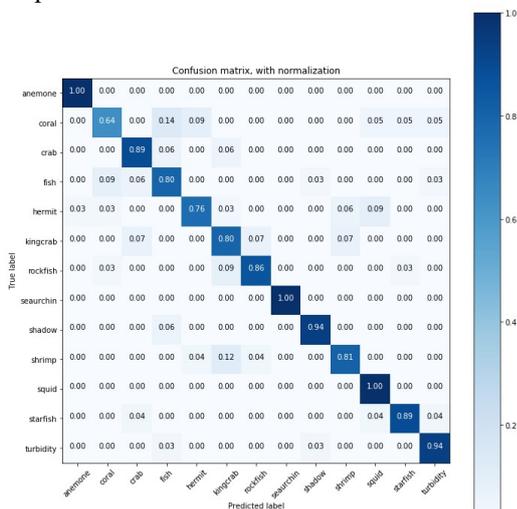


Figura 3: Matriz de confusión para los resultados de clasificación (precisión) obtenidos por la DNN1.

4. Conclusiones

El objetivo de este trabajo fue diseñar un proceso automático para la detección y clasificación de animales subacuáticos, realizando técnicas de filtrado y mejora y utilizando técnicas de aprendizaje automático. Se obtuvieron

resultados altos con valores de exactitud del 76.18% y AUROC del 87.59%.

La mejora de las imágenes subacuáticas también desempeñó un papel importante en la detección de elementos. Sería interesante profundizar en estos métodos, ya que una clara mejora de las imágenes podría reducir el trabajo posterior de detección de características y obtener mejores tasas de clasificación.

La utilización de clasificadores tradicionales y técnicas de DL orientadas a la detección de especies marinas y los resultados obtenidos, demuestran que la utilización de estos métodos puede ser un avance importante en este campo.

Agradecimientos

La investigación y desarrollo de este trabajo ha sido realizado en la empresa Deusto SEIDOR, junto con varias empresas colaboradoras. Se desarrolló en el marco de la Tecnoterra (ICM-CSIC/UPC), la Cofundación MarTERA ERA-Net y fue financiado por el Centro para el Desarrollo Tecnológico Industrial (CDTI) y RESBIO (TEC2017-87861-R; Ministerio de Ciencia, Innovación y Universidades).

Referencias

Bicknell, A. W., B. J. Godley, E. V. Sheehan, S. C. Votier, and M. J. Witt. 2016. "Camera technology for monitoring marine biodiversity and human impact." *Frontiers in Ecology and the Environment*, 14 (8): 424–432.

Danovaro, R., J. Aguzzi, E. Fanelli, D. Billett, K. Gjerde, A. Jamieson, E. Ramirez-Llodra, C. Smith, P. Snelgrove, L. Thomsen, and C. Dover. 2017. "An ecosystem-based deep-ocean strategy." *Science*, Vol. 355: 452–454. <https://doi.org/10.1126/science.aah7178>.

De Leo, F. C., B. Ogata, A. R. Sastri, M. Heesemann, S. Mihály, M. Galbraith, and M. G. Morley. 2018. "High-frequency observations from a deep-sea cabled observatory reveal seasonal overwintering of *Neocalanus* spp. in Barkley Canyon, NE Pacific: Insights into particulate organic carbon flux." *Progress in Oceanography*, 169: 120–137.

Fang, Z., J. Fan, X. Chen, and Y. Chen. 2018. "Beak identification of four dominant octopus species in the East China Sea based on traditional measurements and geometric morphometrics." *Fisheries Science*, 84 (6): 975–985.

Favali, P., L. Beranzoli, and A. De Santis. 2015. *SEAFLOOR OBSERVATORIES: A New Vision of the Earth from the Abyss*. Springer Science & Business Media.

Godø, O. R., S. Johnsen, and T. Torkelsen. 2014. "The LoVe Ocean Observatory is in Operation." *Marine Technology Society Journal*, 48 (2): 24–30.

Reza, A. M. 2004. "Realization of the contrast limited adaptive histogram equalization (CLAHE) for real-time image enhancement." *Journal of VLSI signal processing systems for signal, image and video technology*, 38 (1): 35–44.

Rimavicius, T., and A. Gelzinis. 2017. "A Comparison of the Deep Learning Methods for Solving Seafloor Image Classification Task." *International Conference on Information and Software Technologies*, 442–453. Springer.

Saberioon, M., C. Petr, L. Laurent, P. Sou, P. Pelissier, and T. Kerneis. 2018. "Comparative Performance Analysis of Support Vector Machine, Random Forest, Logistic Regression and k-Nearest Neighbours in Rainbow Trout (*Oncorhynchus Mykiss*) Classification Using Image-Based Features." *Sensors*, 18: 1027.

Spampinato, C., S. Palazzo, P.-H. Joalland, S. Paris, H. Glotin, K. Blanc, D. Lingrand, and F. Precioso. 2016. "Fine-grained object recognition in underwater visual data." *Multimedia Tools and Applications*, 75 (3): 1701–1720.

Tomasi, C., and R. Manduchi. 1998. "Bilateral filtering for gray and color images." *Iccv*, 2. Iccv.