



Máster en ingeniería de telecomunicación

Trabajo de fin de master

**Diseño, validación y desarrollo de un modelo de
negocio sobre drones salvavidas autónomos
basados en inteligencia artificial**

Autora:

Marina Alonso Parra

Supervisado por:

Javier Fuentes Ibáñez

Madrid

Junio 2022

Declaro, bajo mi responsabilidad, que el Proyecto presentado con el título **“Diseño, validación y desarrollo de un modelo de negocio sobre drones salvavidas autónomos basados en inteligencia artificial”** en la ETS de Ingeniería - ICAI de la Universidad Pontificia Comillas en el curso académico 2021-2022 es de mi autoría, original e inédito y no ha sido presentado con anterioridad a otros efectos. El Proyecto no es plagio de otro, ni total ni parcialmente y la información que ha sido tomada de otros documentos está debidamente referenciada.



Fdo.: Marina Alonso Parra

Fecha: 15/ 6/ 2022

Autorizada la entrega del proyecto

EL DIRECTOR DEL PROYECTO

Fdo.: Javier Fuentes Ibáñez

Fecha: 15/06/2022





Máster en ingeniería de telecomunicación

Trabajo de fin de master

**Diseño, validación y desarrollo de un modelo de
negocio sobre drones salvavidas autónomos
basados en inteligencia artificial**

Autora:

Marina Alonso Parra

Supervisado por:

Javier Fuentes Ibáñez

Madrid

Junio 2022

DISEÑO, VALIDACIÓN Y DESARROLLO DE UN MODELO DE NEGOCIO SOBRE DRONES SALVAVIDAS AUTÓNOMOS BASADOS EN INTELIGENCIA ARTIFICIAL

Autor: Alonso Parra, Marina.

Director: Fuentes Ibáñez, Javier

Entidad Colaboradora: ICAI-Universidad Pontificia Comillas

RESUMEN DEL PROYECTO

El objetivo de este proyecto fue diseñar y validar un modelo de negocio que consiste en un sistema de drones salvavidas autónomos basados en inteligencia artificial enfocados en reducir el número de ahogamientos en las playas sin vigilar. La validación se hizo a través del método *lean startup*, donde a través de tres iteraciones se analizó la idea desde el punto de vista del cliente, usuario y producto; y finalmente, se evaluó desde el punto de vista financiero.

Palabras clave: salvamento, playas, drones autónomos, visión artificial, aprendizaje profundo, *lean startup*, *design thinking*, emprendimiento.

1. Introducción

Según la OMS, al año mueren en el mundo alrededor de 235.000 personas ahogadas [1]. En España en 2020 esta cifra fue de 338 personas [2] y es la más baja obtenida en los últimos seis años, donde las cifras alcanzaron valores de hasta 481 personas. Además, el 85% de los casos se producen en lugares sin vigilar. Pese al esfuerzo de las autonomías para establecer equipos de socorrismo, resulta imposible asegurar el salvamento en todas las playas ya que obligaría a los ayuntamientos a incurrir en un gran gasto de personal. Además, resultaría muy poco eficiente cubrir playas las 24 horas del día los 365 días al año, cuando hay periodos donde no hay ningún bañista.




Figura 1. Cifras de ahogamientos

Este proyecto ofrece una alternativa de salvamento más viable económicamente. Consiste en el diseño y desarrollo de un modelo de negocio de drones salvavidas de bajo coste. El sistema automatizaría el proceso de salvamento por medio de

inteligencia artificial de tal manera que no sería necesario tener una persona física en la playa. De este modo se evitarían altos costes de personal de salvamento y reducirían los ahogamientos.

2. Desarrollo del proyecto y metodología

El proyecto se desarrolló en tres partes, en primer lugar, la generación y desarrollo de la idea, en segundo lugar, la validación de la idea y, por último, el desarrollo de proyecciones financieras.

En la fase de desarrollo de la idea, se identifica el problema de los ahogamientos y como afecta a las diferentes personas involucradas. También se define la idea original y se modifica a través de técnicas de *design thinking* [3], más concretamente con el método SCAMPER.

La validación de la idea se hace a través de la metodología *lean startup* [4]. Se realizan tres iteraciones, para validar el comportamiento de los usuarios, el de los clientes y la viabilidad del producto. En cada iteración se establecen las hipótesis necesarias para que el modelo de negocio funcione, los experimentos para comprobarlas y finalmente, se analizan los resultados y se modifica el modelo en función de ellos.

Durante los experimentos de usuario se realizan entrevistas y encuestas sobre comportamiento en la playa y confianza en la inteligencia artificial. Para el experimento de producto se realiza un MVP de un modelo de detección de bañistas en el mar a través de *deep learning*. Finalmente, para los experimentos de cliente, se realiza un análisis comparativo de costes entre situación actual y futura, se hacen entrevistas a socorristas para analizar su reacción ante el producto y finalmente, se realiza una presentación al cliente para validar el precio y su respuesta.

En la tercera parte, se desarrollan las proyecciones financieras del proyecto. Se define la inversión inicial, los costes tanto fijos como variables, los ingresos y se estima la evolución del mercado. Se evalúa la proyección de crecimiento de los ingresos netos y se calcula el valor actual neto del proyecto, para decidir si se lleva a cabo.

3. Resultados

3.1. Fase de desarrollo de la idea

Durante esta fase se definió un sistema basado en drones autónomos con visión artificial. Los drones estarían distribuidos de forma homogénea por la costa y descansarían en plataformas seguras y estancas. Ante una emergencia, por ejemplo, una llamada al 112; se activaría el dron más cercano a la playa, volaría de forma autónoma por ella, la escanearía a tiempo real con una cámara y buscaría a la persona que está ahogándose a través de visión artificial. Cuando se detectase a la persona, se le lanzaría un chaleco salvavidas encapsulado en una pastilla de sal que se

disolvería en el agua, hincharía el chaleco y permitiría a la víctima aguantar el tiempo suficiente hasta que los servicios de rescate apareciesen.

3.2. Fase de validación

En esta fase, primeramente, se definió el modelo de negocio inicial. El principal segmento de clientes son los ayuntamientos con zonas costeras. Las relaciones con el cliente se mantienen de forma presencial con planes personalizados. Económicamente, hay dos tipos de ingresos. En primer lugar, un ingreso por la compra y despliegue de las infraestructuras, y, en segundo lugar, una cuota anual, que incluye el plan de mantenimiento tanto del HW como del SW, las actualizaciones...

Después de definir el modelo de negocio inicial, se realizaron tres iteraciones que permitieron identificar los elementos clave y modificar o mantener el modelo de negocio en función de los resultados.

Durante la primera iteración, se demostró que los usuarios siempre llevan el móvil a la playa, por lo que resulta efectivo como método de aviso ante una emergencia. Además, se demostró que se tendría que publicitar el sistema de forma explícita en las playas para que los usuarios sean consciente de que lo pueden usar. Finalmente, el resultado más remarcable obtenido es que los usuarios no confían en los sistemas puramente autónomos, por lo que resulta fundamental pivotar el modelo de negocio para que tenga éxito. Para ello, se incluye la presencia de centros de control que supervisen a varios drones a la vez y puedan tomar el control en caso de necesidad., amentando así la confianza en el producto.




Figura 2. Respuestas de la encuesta respecto a sistemas autónomos

Durante la segunda iteración, se demostró que se puede construir un MVP del modelo de detección de objetos, que pueda servir como punto de inicio para seguir perfeccionándolo y como presentación a cliente. El MVP está basado en redes neuronales, más concretamente en la red YOLOv5. Para el entrenamiento se utilizan imágenes aéreas de playas obtenidas en internet y etiquetadas manualmente. Tras la

evaluación se puede comprobar que el modelo obtiene una precisión del 82% y una exhaustividad del 68% y las curvas de pérdida demuestran que no hay sobre aprendizaje. Además, se puede ver que la detección de objetos es casi total en la mayoría de imágenes de test, exceptuando aquellas que contienen objetos desconocidos para el algoritmo como rocas o tablas de surf. Por lo que se puede considerar un primer modelo bastante bueno.



Figura 3. Ejemplo de detección de bañistas

La detección se hace en menos de 1.2 ms por imagen, lo que permite aplicar el algoritmo en tiempo real sobre imágenes obtenidas de un vídeo.

Finalmente, también se pudo comprobar que, para crear modelos más precisos y complejos, se requiere utilizar un HW especializado como una TPU y entrenar el modelo con mayor número de imágenes y clases para evitar sesgos.

Finalmente, en la última iteración se vio que, si se implementase el sistema de drones, los ayuntamientos ahorrarían más del 90% de los gastos asociados al coste económico del fallecimiento de una persona, lo que se conoce como valor de una vida estadística (VVE). En 10 años, el sistema desplegado costaría 20 millones de euros, mientras que por el contrario el coste total por muertes sería de 3900 millones. Esto demuestra que el proyecto tiene atractivo económico para el cliente.

También se comprobó que los socorristas verían utilidad al sistema de drones, no solo para reducir ahogamientos en playas sin vigilar; sino para complementar su trabajo playas vigiladas y reducir los riesgos que sufren durante un salvamento. Esto permite desplegar el sistema en toda la costa, indiferentemente de si está vigilada o no; lo que aumenta el mercado potencial.

Por último, se realizó una presentación para cliente, sin embargo, no se pudo obtener ningún resultado concreto ya que, debido a la complejidad de acceso a la administración, no se pudo llegar a presentar. Quedaría pendiente como próximos pasos.



Figura 4. Tríptico de presentación a cliente

3.3. Fase de estimación financiera

Durante esta fase se establecen los costes del negocio y precio de venta del producto. Se define una inversión inicial de 22.000€ que incluye el material y trabajo necesario para desarrollar la primera versión del producto. También se ve que el coste variable por dron es de 1.925€. Los costes fijos dependen del número de drones desplegados y están definidos por el coste del salario de los ingenieros de software, representante de ventas, ingeniero de hardware, controlador...; y el coste de infraestructura que incluye el HW para producción de modelos, y del centro de control. Finalmente, el mantenimiento de drones de aproximadamente 100€ al año por dron. Por otro lado, el precio de los drones se fija a 4000€ iniciales y 600€ anuales por dron.

En base al crecimiento esperado del mercado y los costes e ingresos, se puede calcular el beneficio neto teórico que tendría la empresa. Se puede ver que durante el año 0 que es el piloto se pierden aproximadamente 11.000€ y a partir del año 1 el beneficio es positivo llegando a alcanzar más de 25 millones de euros en el año 10.




Figura 5. Evolución del beneficio neto

Finalmente, se calculó el VAN (valor actual neto) del proyecto en función de diferentes tasas de crecimiento perpetuo y WACCs, ya que resulta muy complejo calcular el valor exacto de estos parámetros en empresas recién creadas.

Crecimiento \ WACC	10%	15%	20%	25%	30%	35%
2%	151.397.692 €	66.864.887 €	35.420.771 €	20.747.173 €	12.996.737 €	8.558.053 €
3%	169.563.390 €	71.045.732 €	36.813.392 €	21.307.080 €	13.249.906 €	8.682.323 €
4%	193.784.321 €	75.986.729 €	38.380.092 €	21.920.312 €	13.522.551 €	8.814.610 €
5%	227.693.625 €	81.915.926 €	40.155.684 €	22.594.868 €	13.817.006 €	8.955.716 €
6%	278.557.580 €	89.162.723 €	42.184.932 €	23.340.429 €	14.136.000 €	9.106.554 €
7%	363.330.838 €	98.221.218 €	44.526.373 €	24.168.830 €	14.482.733 €	9.268.166 €
8%	532.877.355 €	109.867.855 €	47.258.053 €	25.094.690 €	14.860.986 €	9.441.749 €
9%	1.041.516.906 €	125.396.705 €	50.486.403 €	26.136.283 €	15.275.264 €	9.628.685 €
10%		147.137.094 €	54.360.423 €	27.316.755 €	15.730.969 €	9.830.575 €

Figura 6. Análisis de sensibilidad del Valor Actual Neto (VAN)

Se pudo ver que, en todos los casos, el VAN del proyecto es superior a 0, lo que indica que el proyecto genera valor y se debería llevar a cabo. Este valor varía entre 8.5 y 1000 millones de euros, pero, en cualquier caso, con las estimaciones realizadas, resulta rentable.

4. Conclusiones

En conclusión, se ha podido ver que, en este punto del desarrollo, el proyecto cumple los requisitos necesarios de viabilidad, tanto desde la perspectiva del cliente, como del usuario, del producto y proyecciones financieras. Se requiere seguir desarrollando la idea con el proceso *lean* y hacer más iteraciones para perfeccionar el producto y el modelo de negocio, y así adaptarse lo mejor posible a las necesidades del cliente. Si todo continuase de forma correcta, potencialmente podría convertirse en una *startup* con éxito.

5. Referencias

- [1] W. H. Organization, «Drowning,» [En línea]. Available: <https://www.who.int/news-room/fact-sheets/detail/drowning>.
- [2] R. F. E. d. s. y. socorrismo, «Informe nacional de ahogamientos,» 2020.
- [3] I. D. Foundation, «What is Design Thinking?,» [En línea]. Available: <https://www.interaction-design.org/literature/topics/design-thinking>.
- [4] Cowan, «Your lean startup,» [En línea]. Available: <https://www.alexandercowan.com/creating-a-lean-startup-style-assumption-set/>.
- [5] V. V. Moraleiz, «Valor actual neto,» [En línea]. Available: <https://economipedia.com/definiciones/valor-actual-neto.html>.

DESIGN, VALIDATION AND DEVELOPMENT OF A BUSINESS MODEL FOR AUTONOMOUS LIFE-SAVING DRONES BASED ON ARTIFICIAL INTELLIGENCE.

Author: Alonso Parra, Marina.

Director: Fuentes Ibáñez, Javier

Collaborating Entity: ICAI-Comillas Pontifical University

PROJECT SUMMARY

The objective of this project was to design and validate a business model consisting of a system made of autonomous lifeguard drones based on artificial intelligence focused on reducing the number of drownings on unguarded beaches. The validation was done following the lean startup method, where through three iterations, the idea was analyzed from the point of view of the customer, user and the product; and finally, it was evaluated from the financial point of view.

Keywords: lifeguarding, beaches, autonomous drones, computer vision, deep learning, lean startup, design thinking, entrepreneurship.

1. Introduction

According to the WHO, around 235,000 people die each year worldwide from drowning. [1]. In Spain in 2020 this figure was 338 people [2] and it is the lowest obtained in the last six years, where the figures reached values of up to 481 people. Moreover, 85% of the cases happened in unguarded places. Despite the efforts of the regions to set up lifeguard teams, it is impossible to ensure lifeguarding on all beaches, as this would oblige local councils to incur a high personnel cost. Furthermore, it would be very inefficient to cover beaches 24 hours a day, 365 days a year, when there are periods when there are no swimmers at all.



Figure 1. Drowning figures

This project offers a more economically viable lifesaving alternative. It consists of the design and development of a low-cost life-saving drone business

model. The system would automate the rescue process by means of artificial intelligence in such a way that it would not be necessary to have a physical person on the beach. This would avoid high lifeguard personnel costs and reduce drowning.

2. Project development and methodology

The project was developed in three parts, firstly the generation and development of the idea, secondly the validation of the idea and finally the development of financial projections.

In the idea development phase, the drowning problem is identified and how it affects the different people involved. The original idea is also defined and modified through design thinking techniques, [3] more specifically with the SCAMPER method.

The validation of the idea is done through the lean startup methodology. [4]. Three iterations are carried out to validate user behavior, customer behavior and product viability. In each iteration, the hypotheses necessary for the business model to work are established, also the experiments to test them and, finally, the results are analyzed and the model is modified accordingly.

During the user experiments, interviews and surveys on behavior on the beach and trust in artificial intelligence are carried out. For the product experiment, an MVP of a model for detecting swimmers in the sea using deep learning is carried out. Finally, for the customer experiments, a comparative cost analysis is carried out between the current and future situation, interviews are conducted with lifeguards to analyze their reaction to the product and finally, a presentation is made to the customer to validate the price and their response.

In the third part, the financial projections of the project are developed. The initial investment, fixed and variable costs, revenues and market development are defined. The net revenue growth projection is evaluated and the net present value of the project is calculated in order to decide whether to carry it out.

3. Results

3.1. Idea development phase

During this phase, a system based on autonomous drones with computer vision was defined. The drones would be distributed homogeneously along the coast and would rest on secure, watertight platforms. In the event of an emergency, e.g. a 112 call, the drone closest to the beach would be activated, fly autonomously over the beach, scan it in real time with a camera and search for the drowning person through computer vision. When the person is detected, a life jacket encapsulated in a salt tablet would be dropped onto the person, dissolving in the water, inflating the jacket and allowing the victim to hold on long enough for rescue services to show up.

3.2. Validation phase

In this phase, firstly, the initial business model was defined. The main customer segment are the municipalities with coastal areas. Customer relations are maintained on a face-to-face basis with personalized plans. Financially, there are two types of income. Firstly, an income for the purchase and deployment of the infrastructures, and secondly, an annual fee, which includes the maintenance plan for both the HW and SW, updates...

After defining the initial business model, three iterations were carried out to identify key elements and to modify or maintain the business model based on the results.

During the first iteration, it was shown that users always take their mobile phones to the beach, making it an effective emergency warning method. In addition, it was shown that the system would need to be explicitly advertised on beaches to make users aware that they can use it. Finally, the most remarkable result obtained is that users do not trust purely autonomous systems, so it is essential to pivot the business model in order for it to be successful. This includes the presence of control centers that monitor several drones at the same time and can take control in case of need. This will increase confidence in the product.




Figure 2. Survey responses regarding autonomous systems

During the second iteration, it was proved that an MVP of the object detection model can be built, which can serve as a starting point for further refinement and as a presentation to the client. The MVP is based on neural networks, more specifically on the YOLOv5 network. For training, aerial images of beaches obtained from the internet and manually labelled are used. After evaluation it can be seen that the model obtains an accuracy of 82% and a recall of 68%, and the loss curves show that there is no overfitting. Furthermore, it can be seen that the detection of objects is almost perfect in most of the test images, except for those containing objects unknown to the algorithm such as rocks or surfboards. So, it can be considered a fairly good first model.



Figure 3. Example of bather detection

Also, detection is done in less than 1.2 ms per image, which allows the algorithm to be applied in real time on images obtained from a video.

Finally, it was also found that, in order to create more accurate and complex models, it is necessary to use a specialized HW such as a TPU and to train the model with a larger number of images and classes to avoid biases.

Finally, in the last iteration it was found that, if the drone system were deployed, municipalities would save more than 90% of the costs associated with the economic cost of a person's death, known as the value of a statistical life. Over 10 years, the deployed system would cost 20 million euros, while the total cost per death would be 3.900 million euros. This shows that the project is economically attractive to the customer.

It was also found that lifeguards would find the drone system useful, not only to reduce drownings on unguarded beaches, but also to complement their work on guarded beaches and to reduce the risks they face during a rescue. This allows the system to be deployed along the entire coastline, regardless of whether it is guarded or unguarded, which increases the potential market.

Finally, a customer presentation was made, however, no concrete results could be obtained as, due to the complexity of access to the administration, it could not be presented. It will have to be done in the next steps.



Figure 4. Brochure presentation to the client

3.3. Financial estimation phase

During this phase, the business costs and selling price of the product are defined. It is seen that the variable cost per drone is €1,925. The fixed costs depend on the number of drones deployed and are defined by the cost of the salary of the software engineers, sales representative, hardware engineer, controller...; and the infrastructure cost which includes the HW for model production, and the control center. Finally, drone maintenance is approximately €100 per year per drone. On the other hand, the price of the drones is set at €4000 upfront and €600 per year per drone.

Based on the expected growth of the market and the costs and revenues, the theoretical net profit of the company can be calculated. It can be seen that during year 0, which is the pilot year, approximately €11,000 is lost, and from year 1 onwards the profit is positive, reaching more than €25 million in year 10.




Figure 5. Evolution of net profit

Finally, the NPV (net present value) of the project was calculated based on different perpetual growth rates and WACCs, as it is very complex to calculate the exact value of these parameters in newly established companies.

Crecimiento \ WACC	10%	15%	20%	25%	30%	35%
2%	151.397.692 €	66.864.887 €	35.420.771 €	20.747.173 €	12.996.737 €	8.558.053 €
3%	169.563.390 €	71.045.732 €	36.813.392 €	21.307.080 €	13.249.906 €	8.682.323 €
4%	193.784.321 €	75.986.729 €	38.380.092 €	21.920.312 €	13.522.551 €	8.814.610 €
5%	227.693.625 €	81.915.926 €	40.155.684 €	22.594.868 €	13.817.006 €	8.955.716 €
6%	278.557.580 €	89.162.723 €	42.184.932 €	23.340.429 €	14.136.000 €	9.106.554 €
7%	363.330.838 €	98.221.218 €	44.526.373 €	24.168.830 €	14.482.733 €	9.268.166 €
8%	532.877.355 €	109.867.855 €	47.258.053 €	25.094.690 €	14.860.986 €	9.441.749 €
9%	1.041.516.906 €	125.396.705 €	50.486.403 €	26.136.283 €	15.275.264 €	9.628.685 €
10%		147.137.094 €	54.360.423 €	27.316.755 €	15.730.969 €	9.830.575 €

Figure 6. Sensitivity analysis of Net Present Value (NPV)

It could be seen that in all cases the NPV of the project is higher than 0, which indicates that the project generates value and should be carried out. This value

varies between 8.5 and 1000 million euros, but in any case, with the estimates made, it is profitable.

4. Conclusions

In conclusion, it has been seen that, at this point in the development, the project meets the necessary requirements, both from the perspective of the customer, the user, the product and financial projections. Further development of the idea with the lean process and further iterations are required to refine the product and business model so that it best suits the customer's needs. If everything continues in the right way, it could potentially become a successful *startup*.

5. References

- [1] W. H. Organization, "Drowning," [Online]. Available: <https://www.who.int/news-room/fact-sheets/detail/drowning>.
- [2] R. F. E. E. d. s. y. lifeguarding, "National Drowning Report," 2020.
- [3] I. D. Foundation, "What is Design Thinking?," [Online]. Available: <https://www.interaction-design.org/literature/topics/design-thinking>.
- [4] Cowan, "Your lean startup," [Online]. Available: <https://www.alexandercowan.com/creating-a-lean-startup-style-assumption-set/>.
- [5] V. V. Moralez, "Net Present Value," [Online]. Available: <https://economipedia.com/definiciones/valor-actual-neto.html>.

A mi familia, mis amigos y Jorge.

Índice general

1. Introducción	1
2. Estado del Arte	3
2.1. Soluciones de salvamento en playas tradicionales	3
2.2. Soluciones tecnológicas de salvamento en playas y piscinas	4
2.3. Soluciones de salvamento general con drones	7
2.4. Aplicaciones de la inteligencia artificial a los Drones	9
3. Definición del trabajo	13
3.1. Objetivos del proyecto	13
3.2. Metodología utilizada	14
4. Descripción de las tecnologías usadas para el MVP	16
4.1. Bibliotecas python para <i>computer vision</i>	16
4.1.1. OpenCV [33]	16
4.1.2. Scikit-learn [35]	17
4.1.3. Pytorch [36]	17
4.2. <i>Computer vision</i> y <i>machine learning</i>	18
4.2.1. Técnicas para <i>computer vision</i>	18

4.2.2.	Modelos para <i>computer vision</i>	21
4.3.	<i>Deep learning</i> en detalle	25
4.3.1.	Tipos de redes	26
4.3.2.	Hiperparámetros de redes	27
4.3.3.	Redes preentrenadas	28
4.3.4.	Métricas de modelos <i>machine learning</i>	30
5.	Generación de la idea	35
5.1.	Problemática	35
5.1.1.	Cuando hay un ahogamiento	35
5.1.2.	En una situación normal	36
5.2.	Presentación de la idea	36
5.3.	SCAMPER	37
6.	Validación de la idea	39
6.1.	Business model canvas inicial	39
6.2.	Primera iteración: Experimentos con usuarios	41
6.2.1.	Hipótesis	41
6.2.2.	Experimento 1 - Entrevistas	41
6.2.3.	Experimento 2 - Encuestas	44
6.2.4.	Conclusiones	49
6.2.5.	Modificación del producto y BMC	50
6.3.	Segunda iteración: MVP	52
6.3.1.	Hipótesis	52
6.3.2.	Experimento	52

6.3.3.	Conclusiones	70
6.3.4.	Modificación del modelo de negocio	71
6.4.	Tercera iteración: experimentos con cliente	73
6.4.1.	Hipótesis	73
6.4.2.	Experimento 1 - Cálculo de beneficios	73
6.4.3.	Experimento 2 - Entrevistas a socorristas	74
6.4.4.	Experimento 3 - Presentación a cliente	76
6.4.5.	Conclusiones	79
6.4.6.	Modificación del modelo de negocio	80
7.	Consideraciones financieras	82
7.1.	Inversión inicial	82
7.2.	Costes	83
7.2.1.	Costes variables	83
7.2.2.	Costes fijos	86
7.3.	Ingresos	88
7.4.	Proyecciones de crecimiento en mercado	88
7.5.	Proyecciones financieras	89
7.5.1.	Evolución anual de costes e ingresos	90
7.5.2.	Cuenta anual de resultados	91
7.5.3.	Análisis del valor actual neto del proyecto	92
7.6.	Conclusiones	93
8.	Conclusiones	94
8.1.	Conclusiones del proyecto	94

8.2. Próximos pasos	96
8.3. Comentario final	97
A. Anexo A: Cálculo del número de drones a desplegar por kilómetro	99
B. Anexo B: Objetivos de desarrollo sostenible	102
B.1. Introducción a los ODS	102
B.2. ODSs primarios	103
B.3. ODSs secundarios	104
Bibliografía	106

Índice de figuras

1.1. Cifras de ahogamiento [2]	1
2.1. Material de salvamento [8]	4
2.2. Visión cámara socorrista [11]	5
2.3. Robot socorrista [13]	6
2.4. AuxDron [14]	7
2.5. Dron para localizar personas [16]	8
2.6. Dron para transporte de material sanitario [17]	8
2.7. Dron de coordinación logística en incendio [19]	9
2.8. Plan iSAR de salvamento marítimo [20]	9
2.9. Dron para logística en DHL [23]	10
2.10. Aplicaciones de la visión artificial [25]	11
2.11. Visión térmica de paneles solares [29]	12
2.12. Visión artificial en ganadería	12
3.1. Metodología de innovación	14
3.2. Metodología lean detallada [32]	15
4.1. <i>Pipeline</i> de visión artificial [38]	18

4.2.	Diferencias de color en función del número de bits por píxel	19
4.3.	Separación de canales	19
4.4.	Aumento de datos [39]	20
4.5.	Extracción de características [40]	21
4.6.	Extracción de características en <i>machine learning</i> frente a <i>deep learning</i> [41]	22
4.7.	Árbol de decisión[43]	22
4.8.	Máquinas de vector de soporte	23
4.9.	K vecinos más cercanos	24
4.10.	Neurona artificial	25
4.11.	Perceptrón multicapa	26
4.12.	Extracción de características con CNN y clasificación con DNN [50]	27
4.13.	IoU	28
4.14.	Funcionamiento red YOLO	30
4.15.	Arquitectura de la red YOLO	30
4.16.	Curva precisión-exhaustividad.	32
4.17.	Sobre-aprendizaje [56]	33
4.18.	Signos de sobreaprendizaje [56]	34
6.1.	Respuestas encuesta sobre uso móvil	45
6.2.	Respuestas encuesta sobre atención a avisos de seguridad	46
6.3.	Respuestas encuesta sobre seguridad	47
6.4.	Respuestas encuesta sobre confianza en sistemas autónomos	47
6.5.	Respuestas encuesta sobre tratamiento de datos personales	48
6.6.	Diagrama de flujo del algoritmo de detección de imágenes [29]	53

6.7. Ejemplo de imágenes de la base de datos	54
6.8. LabelImg [29]	55
6.9. Ejemplo de dato etiquetado	55
6.10. Diferencia en características de las imágenes	56
6.11. Número de elementos [29]	56
6.12. Estructura de ficheros [29]	57
6.13. Versiones de YOLOv5 [59]	58
6.14. swimmers.yaml	58
6.15. Métricas modelo "desde cero"	59
6.16. Métricas modelo con red preentrenada y capas congeladas	60
6.17. Métricas modelo con red preentrenada y <i>fine tuning</i>	61
6.18. Métricas modelo con red pre-entrenada con <i>fine tuning</i> aumentando el tamaño de las imágenes	62
6.19. Ejemplo de aplicación de albumentations	62
6.20. Métricas modelo con red preentrenada y aumento de datos	63
6.21. Métricas modelo con red preentrenada y evolución de hiperparámetros	64
6.22. Resumen métricas de los modelos	64
6.23. Curvas de pérdida	65
6.24. Ejemplo de detección 1	66
6.25. Ejemplo de detección 2	66
6.26. Ejemplo de detección 3	67
6.27. Ejemplo de detección 4	67
6.28. Ejemplo de detección	68
6.29. Ejemplo de detección	68
6.30. Ejemplo de detección	69

6.31. Velocidad de detección	69
6.32. Costes actuales	74
6.33. Costes con proyecto ANGEL	74
6.34. Playa de Sa Canova	75
6.35. Marcos y Alexis, socorristas de la playa de Sa Canova	76
6.36. Estructura tríptico	79
7.1. Splash Drone 3+	84
7.2. Pastilla salvavidas	84
7.3. Beneficio neto	92
A.1. Superficie recogida en foto	100
A.2. Probabilidad de que haya una persona ahogándose	100
A.3. Cálculo tiempo medio en base a probabilidades	101
B.1. Objetivos de desarrollo sostenible[77]	103

Índice de tablas

7.1. Costes inversión inicial	83
7.2. Costes de producción del dron	85
7.3. Costes del emplazamiento del dron	85
7.4. Coste de personal	86
7.5. Coste de centros de control	87
7.6. Coste de recursos Cloud	87
7.7. Coste de mantenimiento	88
7.8. Precios	88
7.9. Crecimiento del mercado	89
7.10. Evolución de costes e ingresos	90
7.11. Cuenta de resultados	91
7.12. Flujos de caja	92
7.13. Análisis de sensibilidad	93

1. Introducción

Según la OMS, al año mueren en el mundo alrededor de 235.000 personas ahogadas. Esta cifra únicamente tiene en cuenta aquellas muertes producidas por ahogamientos en ríos, lagos y océanos y no considera las producidas en accidentes de transporte, ni desastres naturales. Supone aproximadamente el 0,4 % de las 70 millones de muertes que se producen en total al año y el 7 % de las muertes por traumatismo involuntario, lo que convierte el ahogamiento en un grave problema de salud mundial.[1] Además, es importante destacar que 90 % de los ahogamientos se producen en países del tercer mundo; por lo tanto, no solo es un problema de salud, sino que también se podría considerar un problema social.

Según el informe nacional de ahogamientos [2], en España en 2020 murieron 338 personas ahogadas. Esta es la cifra más baja obtenida en los últimos seis años, donde en años previos, las cifras alcanzaron valores de hasta 481 personas.




Figura 1.1: Cifras de ahogamiento [2]

Pese al esfuerzo de las autonomías para establecer equipos de socorrismo y reducir estas cifras, se puede ver que alrededor del 85 % de los casos se producen en lugares sin vigilar como pueden ser algunas playas, ríos y pantanos. Esto está directamente relacionado con el hecho de España tiene aproximadamente 3.500 playas [3] y que tan solo el 40 % están vigiladas[4]. Además, muchas están vigiladas únicamente durante la temporada alta del año.

Los motivos principales de esta falta de vigilancia son regulatorios y económicos. En primer lugar, no existe una regulación nacional que decida que playas tienen que estar vigiladas [5] y depende de cada municipio y de sus necesidades y presupuesto disponible. Por lo que en muchas ocasiones, playas con gran afluencia quedan sin vigilar, como es el ejemplo del Pantano de San Juan [6]. Asociado a este hecho está el problema económico, ya que un socorrista cobra de media al mes mil euros [7] y en la mayoría de situaciones los socorristas trabajan en parejas. El vigilar todas las playas, obligaría a los ayuntamientos a incurrir en un gran gasto de personal de salvamento, en lugares que igual son visitados por una persona en todo el día. Situación que desde el punto de vista económico no es viable.

Este proyecto se propone para tratar de dar una alternativa de seguridad más viable económicamente, ya que consiste en el diseño y desarrollo de un modelo de negocio de drones salvavidas de bajo coste. El objetivo es crear una flota lo suficientemente grande como para poder situar un dron en cada playa sin vigilar y cubrir todas las áreas, hasta ahora desprotegidas. La reducción de costes se hará por medio de materiales más baratos y drones más sencillos; pero sobre todo, automatizando el proceso por medio de inteligencia artificial de tal manera que no sea necesario tener una persona física vigilando la playa. El funcionamiento del sistema sería tal que, cuando se recibe una alerta de que hay una persona ahogándose, el dron da un aviso de forma automática a emergencias, emprende el vuelo y de forma auto-dirigida recorre la playa. A la vez, por medio de visión artificial, escanea el recorrido realizado y cuando detecta a la persona que se está ahogando, le lanza un chaleco salvavidas encapsulado en una pastilla de sal. Esta al caer al agua se deshace, hinchando el chaleco y permitiendo a la víctima aguantar el tiempo suficiente hasta que los servicios de rescate aparecen. Como se puede ver, no es un sistema para sustituir el salvamento actual, sino para cubrir un área hasta ahora desprotegida por medio de un sistema relativamente económico.

2. Estado del Arte

En esta sección hará una recopilación de las soluciones de rescate existentes, tanto las soluciones tradicionales como las más innovadoras; prestando especial atención a los denominados "drones en salvamento". Finalmente, se tratará el estado actual de la tecnología de los drones con inteligencia artificial.

2.1. Soluciones de salvamento en playas tradicionales

Medios humanos

El sistema de salvamento principal son los socorristas en posesión del título de "socorrista acuático". En playas vigiladas suelen trabajar como mínimo por parejas y se aumenta el número dependiendo de la extensión de la playa. En la actualidad no existe una regulación que indique el número de socorristas mínimo por playa, depende del ayuntamiento.

Material

Utilizado para facilitar el trabajo de los socorristas durante las tareas de vigilancia y salvamento.

- Tabla de salvamento
- Lata de rescate
- Tubo de rescate
- Prismáticos

- Walkie-talkie
- Tabla espinal
- Aletas de socorrismo
- Botiquín de urgencia
- Moto de agua
- Embarcación
- Quad



Figura 2.1: Material de salvamento [8]

2.2. Soluciones tecnológicas de salvamento en playas y piscinas

Gracias a las nuevas tecnologías como el Big Data, los drones, la inteligencia artificial, las aplicaciones móviles... se han podido diseñar nuevos sistemas de salvamento que refuerzan la capacidad de detección y prevención de peligros de los socorristas.

Big Data y análisis de datos para predecir riesgos en playas

En la mayoría de ocasiones, los socorristas esperan hasta el final del día para apuntar los incidentes ocurridos, las personas que había en la playa... lo que hace que en numerosas ocasiones se pierdan registros.

La iniciativa llamada *Smart Beaches* lanzada en New South Wales [9], equipa todos los dispositivos de rescate con GPS de tal manera que cuando se realiza un rescate, queda automáticamente registrado junto con la hora, temperatura del agua, estado de la marea, posición... Gracias a ellos, junto con las cámaras de detección de aforos en las playas, se pueden obtener correlaciones entre distintos fenómenos de la playa y la probabilidad de accidente. Por ejemplo, cuando la marea está baja hay mayor número de ahogamientos. Así los socorristas pueden estar más atentos o mejor posicionados de cara a hacer una vigilancia más eficiente. [10]

Cámaras de seguridad con inteligencia artificial

El sistema está compuesto por varios dispositivos estáticos instalados a lo largo de la playa. Mediante inteligencia artificial detectan a las personas, sus movimientos, sus interacciones con el medio... y con sistemas de aprendizaje profundo (*deep learning*) analizan las situaciones y las clasifican en función del riesgo, avisando a los socorristas para que actúen. [11]. Además permiten analizar otros parámetros costeros como puede ser la presencia de fuertes corrientes, de animales peligrosos, vehículos en el agua...



Figura 2.2: Visión cámara socorrista [11]

El principal impulsor de esta tecnología es la empresa israelí, SightBit [11]. Según ellos al permitir mejorar en gran medida la eficiencia de los salvavidas, no solo se rescatan a más personas; sino que permite reducir hasta un 40 % en costes operativos. [12]

Robot socorrista

Es un sistema de salvamento especialmente diseñado para piscinas desarrollado por el Instituto Fraunhofer de Optrónica. El robot se encuentra anclado al fondo de la piscina esperando a recibir una alarma. En el exterior de la piscina hay cámaras que en función del movimiento de la persona y pueden detectar si se está ahogando. En ese momento lanzan una señal al robot que se enciende y de forma autónoma detecta a la víctima y se desplaza hasta ella para salvarla. [13]

Los robots están equipados con motores, sensores y cámaras; y según las últimas pruebas pueden realizar un rescate en 2 minutos. Este sistema se podría implementar en lagos y playas si existiese un sistema, por ejemplo, drones; para procesar las imágenes de las personas y detectar a la víctima.



Figura 2.3: Robot socorrista [13]

Drones para salvamento en playas

Son drones diseñados para complementar el sistema de socorrismo tradicional y ayudar al control y vigilancia de las playas. Están dirigidos por un piloto y permiten recorrer la longitud de la playa y mediante una cámara detectar si hay alguien en peligro. Asisten en funciones de control de aforos y de auxilio en caso de emergencia. Cuentan con un megáfono para tranquilizar a la víctima y un chaleco salvavidas. Un ejemplo son los drones AuxDron [14], diseñados por General Drones y puestos en marcha en las playas de Mallorca. [15]



Figura 2.4: AuxDron [14]

2.3. Soluciones de salvamento general con drones

Como se ha visto en el apartado anterior, los drones son una de las soluciones para mejorar el servicio de salvamento en playas. Además actualmente se han desarrollado otros muchos casos de uso que aprovechan su velocidad y agilidad para efectuar maniobras de rescate y salvamento. Estos drones están dirigidos por personal especializado y controlados por medio de GPS y 4G.

Drones para localizar personas

Este tipo de sistemas están especializados en localización de personas en situaciones de emergencia como pueden ser unos montañeros perdidos en la montaña. Son drones equipados con cámaras normales, térmicas y nocturnas. Tienen capacidad de recorrer grandes terrenos y tienen gran eficiencia energética lo que les permite volar hasta 7 horas. Un ejemplo de esta tecnología es el dron híbrido AeroHyb [16]

Drones para transportar material de emergencia

Son drones diseñados para poder cargar con hasta 5 kilogramos de material de emergencias y volar hasta 2 horas para alcanzar el objetivo de rescate. En situaciones hostiles permiten la llegada de forma rápida a las zonas más inaccesibles, como por ejemplo, una cueva en una montaña. También son de gran utilidad para transporte urgente en ciudad, evitando los retrasos creados por el tráfico. Este último caso es el del dron diseñado por la Universidad Politécnica de Valencia



Figura 2.5: Dron para localizar personas [16]

durante la pandemia del COVID 19, que consiguió transportar material sanitario urgente en ciudad en menos de 3 minutos alcanzando una velocidad de 15 m/s.



Figura 2.6: Dron para transporte de material sanitario [17]

Drones para coordinación logística

Drones especialmente diseñados para moverse en ambientes hostiles y coordinar operaciones de rescate complejas. Se caracterizan por su rapidez y ligereza. Permiten localizar caminos bloqueados, zonas peligrosas, establecer las rutas más óptimas para el acceso de servicios de rescate. Además se reduce el riesgo al que se exponen a los rescatadores ya que permiten detectar rápidamente desprendimientos, fuegos... [18] Un ejemplo puede ser los drones que se usan para controlar incendios.

Drones para salvamento marítimo

Son sistemas que permiten hacer una gestión más eficiente de la vigilancia del mar, de las maniobras de emergencia y de rescate de embarcaciones y personas y del control de contaminación. Están equipados con sensores inteligentes y pueden trabajar tanto de día como de noche, aterrizar en plataformas marítimas...

En la actualidad, este tipo de sistemas se utilizan principalmente como parte



Figura 2.7: Dron de coordinación logística en incendio [19]

del plan iSAR de salvamento marítimo.[20]




Figura 2.8: Plan iSAR de salvamento marítimo [20]

2.4. Aplicaciones de la inteligencia artificial a los Drones

Desplazamientos autónomos

Es el campo de la inteligencia artificial que permite a los drones moverse de un

punto a otro sin necesidad de un piloto que lo controle. Dentro de los desplazamientos autónomos existen dos tipos de sistemas. [21]

- **Drones auto-conducidos:** son aquellos sistemas que están programados para desplazarse hacia un conjunto de coordenadas que se le indica o para seguir un objeto concreto. En este caso las instrucciones de cuando salir y a donde ir vienen proporcionadas por un humano.
- **Drones totalmente autónomos:** son aquellos sistemas que cuentan con una inteligencia que les permite decidir por donde ir, a donde ir, evitar obstáculos, establecer medidas de contingencia en caso de accidentes... Este tipo de sistemas requieren estar equipados con una gran cantidad de sensores, potentes algoritmos de decisión y conexión 5G.

A nivel de negocio, las empresas que más están desarrollando la tecnología de drones autónomos son las de logística como DHL.[22] Su objetivo es poder utilizarlos para el transporte de paquetes en ciudad o para la comunicación, inventario y transporte de mercancías dentro de almacenes y fábricas. De este modo se aumenta la seguridad de los operarios ya que no tienen que subir a grandes alturas para hacer el inventario; y a la vez se multiplica por seis el número de productos escaneados por hora. [23]



Figura 2.9: Dron para logística en DHL [23]

Visión artificial (*Computer vision*)

La visión artificial es el campo de la inteligencia artificial que permite a los ordenadores distinguir objetos y entender imágenes como si fuesen seres humanos [24]. En general existen distintas aplicaciones de la visión artificial:

- **Clasificación de imágenes:** con este método se decide si una imagen pertenece a un grupo u a otro. Este método se utiliza, por ejemplo, en medicina para distinguir órganos sanos de órganos enfermos.
- **Localización de objetos:** con este método se detecta un objeto en concreto dentro de una imagen. Este procedimiento se utiliza para seguimiento de caras en sistemas de videovigilancia.
- **Detección de objetos:** en imágenes con distintos objetos, se localizan y distinguen. Este es el caso de uso de los coches autónomos, donde resulta fundamental detectar y diferenciar los coches de los peatones.
- **Segmentación de instancias:** consiste en la clasificación de cada píxel de una imagen de tal manera que se puedan agrupar por objetos creando siluetas. Este método se utiliza para la elaboración de modelos 3D de ciudades basados en imágenes.




Figura 2.10: Aplicaciones de la visión artificial [25]

En el caso de los drones, la visión artificial tiene múltiples aplicaciones en diferentes industrias entre las que destacan: [26]

- **Seguridad:** los drones son de gran utilidad para el control de aforos, seguimiento de manifestaciones, detección de acceso a áreas restringidas, seguridad de edificios... [27] Un buen ejemplo es la empresa Indoor Robotics, que recientemente ha logrado la creación de flotas de drones autónomos que patrullan los edificios eliminando la necesidad de más de 1000 cámaras y altos presupuestos de seguridad. [28]

- **Aplicaciones industriales:** para la detección de fallos en infraestructuras, sobrecalentamientos, monitorización de variables concretas. Un ejemplo concreto, son los drones con cámaras térmicas para control de granjas de paneles solares. Los paneles solares tienden a estar más calientes cuando están dañados, permitiendo a los drones identificar y etiquetar los paneles defectuosos. [29]




Figura 2.11: Visión térmica de paneles solares [29]

- **Agricultura y ganadería:** los drones se pueden utilizar para monitorizar el estado de las cosechas, recoger los productos que estén listos, detectar plagas, inundaciones o incendios. También permiten el seguimiento y recuento de los animales en cuestión de pocos minutos en largas extensiones. Tevel es una de las empresas líderes en el desarrollo de drones autónomos para agricultura. [30]




Figura 2.12: Visión artificial en ganadería

3. Definición del trabajo

En esta sección se especificará el objetivo principal del proyecto, y los objetivos secundarios y la metodología utilizada.

3.1. Objetivos del proyecto

Como se ha definido previamente, el objetivo de este proyecto es el diseño, validación y desarrollo de un modelo de negocio sobre drones salvavidas autónomos basados en inteligencia artificial.

Para conseguir el objetivo principal, se definen los siguientes subobjetivos:

1. **Desarrollo de la idea:** Primeramente, se definirá la idea inicial para solucionar el problema de los ahogamientos en playas sin vigilar, y por medio de técnicas de *design thinking* se trabajará en profundidad.
2. **Validación de la idea:** En segundo lugar, se creará un plan de negocio inicial y se iterará sobre él siguiendo el método *Lean Startup*. Dentro de este plan se incluyen los siguientes objetivos:
 - a) **Desarrollo de un business model canvas:** que se irá modificando en cada iteración si se considera necesario.
 - b) **Planteamiento de hipótesis:** se definirán las hipótesis que se consideran necesarias para validar el plan de negocio.
 - c) **Elaboración de experimentos:** se desarrollarán experimentos que validen las hipótesis. Estos experimentos serán encuestas al usuario, desarrollo de un MVP y elaboración de entregables para el cliente final.

3. **Desarrollo de un prototipo:** como parte de los experimentos desarrollará un algoritmo de detección de personas en el agua a través de redes neuronales. Para ello, los objetivos que se definen son:
 - a) **Búsqueda y etiquetado de datos**
 - b) **Entrenamiento, testeo y modificación de distintas redes neuronales de forma iterativa**
 - c) **Selección del mejor modelo de detección**
4. **Elaboración de proyecciones financieras:** Finalmente, se analizarán los flujos de caja necesarios para el desarrollo, venta e implementación del producto, su escalabilidad y viabilidad económica.

3.2. Metodología utilizada

Para el diseño, desarrollo y validación del modelo de negocio se utilizará una combinación de dos metodologías de innovación como son *Design Thinking* y *Lean Startup*.




Figura 3.1: Metodología de innovación

Design Thinking

Es un proceso iterativo que se utiliza para resolver problemas complejos con una visión centrada en la persona. De este modo se enfoca en la perspectiva del usuario para entender y responder de forma eficiente a entornos que cambian de forma rápida. Está compuesto por 5 pasos: [31]

- Empatizar con el usuario para entender sus problemas
- Definir los problemas localizados
- Desafiar las diferentes soluciones a los problemas
- Crear las soluciones
- Probar las soluciones

Lean Startup

Es una metodología para el desarrollo de startups, que permite optimizar los recursos para los ciclos de desarrollo, medir el progreso y obtener las opiniones de los clientes. Mediante el proceso iterativo se descubren las necesidades del público objetivo. Se basa en el uso del método científico, donde se plantean una serie de hipótesis necesarias para que el proyecto tenga éxito, se diseñan experimentos, se analizan los resultados y en base a ellos se modifica la idea y reitera el ciclo o se continúa. [32]




Figura 3.2: Metodología lean detallada [32]

4. Descripción de las tecnologías usadas para el MVP

En esta sección se hablará de la tecnología de *computer vision* utilizada para desarrollar el prototipo de detección de personas en el agua. En primer lugar se hablará de las bibliotecas utilizadas, de la forma de representar imágenes, de la visión artificial con *machine learning* y *deep learning*.

4.1. Bibliotecas python para *computer vision*

4.1.1. OpenCV [33]

Es una librería multi-plataforma para aplicaciones de visión artificial. Originalmente fue lanzada por Intel en 1999 y en 2012 fue adquirida por una organización sin ánimo de lucro. OpenCV se centra en manipulación de imágenes y creación de herramientas para reconocimiento de patrones y clasificación. [34] Los módulos principales son:

- **Image processing:** permite el filtrado de imágenes, transformaciones geométricas, histogramas...
- **Video:** permite el análisis de vídeo, eliminación de fondo y seguimiento de objetos a tiempo real.
- **Highgui:** ofrece interfaces de uso sencillo con capacidades UI.
- **Objdetect:** ofrece los módulos para detección de objetos predefinidos como caras, ojos, coches...

- **Calib3d:** Ofrece algoritmos para multi-visión geométrica, calibración de cámaras y reconstrucción de elementos 3D.

4.1.2. Scikit-learn [35]

Es una librería de python para el desarrollo de aplicaciones *machine learning*. Fue desarrollada inicialmente por David Cournapeau en 2007 como parte de un proyecto para el *Gooogle Summer of Code*. En 2010, Fabian Pedregosa, Gael Varoquaux, Alexandre Gramfort y Vincent Michel se hicieron con el liderazgo y publicaron por primera vez la biblioteca.

Dentro de las funcionalidades que ofrece esta librería, se encuentran principalmente las siguientes:

- **Aprendizaje sin supervisar:** clusterización, estimación de covarianzas, redes neuronales...
- **Aprendizaje supervisado:** Modelos lineales, Naive Bayes, árboles de decisión, k vecinos más cercanos, SVM, árboles de decisión...
- **Selección y evaluación de modelos:** validación cruzada, modificación de hiperparámetros, representación de métricas y curvas.
- **Inspección y visualización**
- **Transformaciones de datos:** preprocesamiento de datos, selección de características (*feature selection*), reducción de dimensionalidad...

4.1.3. Pytorch [36]

Es una biblioteca de código abierto desarrollada por el laboratorio de inteligencia artificial de Facebook en 2016. Está basada en Torch y se utiliza principalmente para desarrollo de aplicaciones basadas en *deep learning* como son el procesamiento del lenguaje natural y visión artificial.

Los módulos principales son:

- **Autograd:** es un módulo que permite calcular los gradientes de los parámetros ahorrando tiempo en el entrenamiento de las redes neuronales.

- **Optim**: implementa los algoritmos de optimización que son usados para la construcción de redes neuronales.
- **NN**: permite definir redes neuronales complejas.

4.2. Computer vision y machine learning

La inteligencia artificial son el conjunto de técnicas que permiten a una máquina tener comportamientos “inteligentes” similares a los humanos. Dentro de la inteligencia artificial, existe un subconjunto denominado aprendizaje automático o *machine learning* que permite a las máquinas solucionar problemas de forma automática basándose en modelos que identifican patrones, en vez de estar explícitamente programados para resolverlos. Finalmente, la visión artificial o *computer vision*, es el subconjunto de la inteligencia artificial que permite distinguir objetos y entender imágenes. [37]

4.2.1. Técnicas para *computer vision*

En una *pipeline* de *computer vision* las imágenes de entrada sufren una serie de transformaciones antes de introducirse en los modelos de ML, por ejemplo, de clasificación.




Figura 4.1: *Pipeline* de visión artificial [38]

4.2.1.1. Representación de imágenes

Es la transformación de una imagen analógica en una representación que pueda ser comprendida por un ordenador. Las imágenes están representadas en forma de matrices de píxeles de diferentes tamaños. Cada píxel está definido por una cantidad determinada de bits, que indicará el rango de colores que se puede cubrir.



Figura 4.2: Diferencias de color en función del número de bits por píxel

Además, en función del número de canales que tenga la imagen, la matriz tendrá una o más dimensiones. Por ejemplo, una foto en escala de grises estará representada por una matriz en 2D. Sin embargo, una imagen en formato RGB tendrá tres dimensiones, donde la tercera dimensión corresponde a la superposición de las distintas capas de distintos colores que forman la imagen.




Figura 4.3: Separación de canales

En función del tamaño de las imágenes, del número de bits por píxel y del número de canales, se obtendrán imágenes con más o menos calidad lo que influirá por un lado en la calidad del algoritmo, pero también en la complejidad de su entrenamiento.

4.2.1.2. Preprocesamiento y *data augmentation*

Normalmente, las imágenes vienen de una serie de fuentes diferentes, lo que hace que a menudo tengan características muy diversas que pueden crear problemas en los algoritmos. Algunas de las técnicas que se pueden aplicar son eliminación del ruido de fondo, normalización de los rangos de color, conversión de imágenes de color a escala de grises para reducir la complejidad... Además, cuando se trabaja

con determinados modelos como son las redes neuronales es fundamental que las imágenes tengan el mismo tamaño al entrar en la red, por lo que también se hace escalado. [39]

Data augmentation es una técnica de preprocesamiento que resulta de especial importancia en el caso del *deep learning* donde es crítico tener una gran cantidad de datos. Es un proceso que consiste en aplicar una serie de transformaciones a una imagen para crear variaciones de ella que puedan ser utilizadas como datos nuevos. Algunas de las transformaciones que se pueden realizar son el rotado de la imagen, el emborronamiento, añadir ruido, cambiar los tonos...




Figura 4.4: Aumento de datos [39]

4.2.1.3. Extracción de características

Esta técnica, más conocida por su término en inglés *feature extraction*. Es el proceso por el cual se identifican los patrones de una imagen que ayudan a identificarla. Entre las características se incluyen esquinas, bordes, puntos de interés... [40] Además, es una técnica fundamental para reducir la dimensionalidad de las imágenes, ya que en vez de considerar todos los píxeles, se trabajan solo con aquellos identificados como importantes.

Algunas de las características que tiene que tener una buena *feature* son: ser fácilmente identificables, que se repita en varias imágenes con el mismo objeto, que sean pequeñas y que sean eficientes (cuantas menos mejor).



Figura 4.5: Extracción de características [40]

En el aprendizaje automático tradicional era necesario hacer la extracción de características de forma manual para luego introducir estas características en los modelos de clasificación. Algunas de las técnicas que se utilizaban eran:

- Histogram of Oriented Gradients (HOG)
- Haar Cascades
- Scale-Invariant Feature Transform (SIFT)
- Speeded Up Robust Feature (SURF)

En los modelos de aprendizaje profundo, la extracción de características no se realiza de forma manual, sino que la propia red asigna unos pesos a las conexiones y aprende la importancia de las características de forma automática. Es una de las principales ventajas del aprendizaje profundo frente al aprendizaje automático, ya que se obtiene más exactitud [41].

4.2.2. Modelos para *computer vision*

Como se ha dicho en la sección 2.4 existen diversas problemáticas que la CV trata de resolver, las dos principales son la clasificación de imágenes y detección de objetos, que es una combinación de búsqueda y clasificación. La primera problemática puede ser resuelta con modelos de aprendizaje automático clásicos, tanto supervisados como sin supervisar. Por el contrario, para la segunda se requieren modelos de aprendizaje profundo de alta complejidad.




Figura 4.6: Extracción de características en *machine learning* frente a *deep learning* [41]

4.2.2.1. Modelos de aprendizaje supervisado

En aprendizaje supervisado, los datos que entran a los modelos están etiquetados con la categoría a la que pertenecen, es decir, la salida que se desea que el algoritmo devuelva. De este modo el modelo aprende los resultados deseados y crea estrategias para alcanzarlos de la forma más adecuada. [42]

Existen numerosos modelos de aprendizaje supervisado, algunos de los más importantes son los siguientes:

Árboles de decisión

Es un algoritmo basado en una serie de reglas de decisión. Convierte información continua proveniente de una imagen, en información discreta. Su funcionamiento es tal que cuando una imagen entra en el algoritmo, en función de los valores de sus *features* se recorren las ramas para acabar en la hoja que indica la clase. [43]




Figura 4.7: Árbol de decisión[43]

Naive Bayes

Es un algoritmo de clasificación probabilístico basado en el teorema de Bayes. Utiliza probabilidades condicionadas, es decir, dado una serie de *features* calcula la probabilidad la imagen pertenezca a la clase x . Este procedimiento se realiza para todas las clases y finalmente se selecciona la que tenga la probabilidad más alta. [44]

Este algoritmo es sencillo, rápido y puede funcionar con pequeñas cantidades de datos; sin embargo, es demasiado simple ya que considera que las *features* son independientes que es algo que raramente ocurre.

Support vector machines

Es un tipo de algoritmo que se puede utilizar tanto en clasificación como en regresión; por lo que permite usar variables categóricas o continuas. El objetivo del modelo es definir el hiperplano que mejor separa dos clases en el espacio. Se hace de forma iterativa minimizando el error y se busca el hiperplano que más margen (distancia) entre clases tenga. Cuando existe riesgo de *overfitting* en vez de SVM se utilizan clasificadores de vector de soporte, que no dividen las clases perfectamente por lo que reducen el sobre aprendizaje. El problema es que esto solo vale para problemas lineares, en el resto de casos se necesitan SVM.[45]




Figura 4.8: Máquinas de vector de soporte

K vecinos más cercanos

Es un algoritmo que se basa en la teoría de que los elementos similares están juntos. La similaridad se entiende como la menor distancia euclídea entre las distintas *features* que representan las imágenes. Cuando los elementos están agrupados

por clases, a ese grupo se le asigna la etiqueta mayoritaria. Finalmente, a la hora de clasificar un elemento nuevo, se calcula su distancia con las clases definidas y se le asigna aquella que esté más próxima. [46]




Figura 4.9: K vecinos más cercanos

4.2.2.2. Modelos con aprendizaje sin supervisar

En estos modelos los datos no tienen la etiqueta que indica la clase deseada, sino que es el propio algoritmo el que extrae patrones y los asocia de la forma que obtenga el mejor resultado. El objetivo general de estos algoritmos es encontrar la estructura básica de los datos para hacer agrupamientos o reducir su dimensionalidad. El algoritmo más utilizado en aprendizaje sin supervisar es, k-means.

K-means

Es un algoritmo que resulta especialmente útil en el pre-procesamiento de datos para identificar la similitud entre ellos. El objetivo del algoritmo es de forma iterativa ir definiendo subgrupos donde cada dato pertenece a un grupo y solo a uno. En cada iteración, el algoritmo trata de minimizar la distancia entre los elementos del *cluster* y maximizar la distancia entre los *clusters*. Además, se considera que cuanto menos variación haya entre los elementos de un *cluster*, más homogéneos son los datos. [47]

4.2.2.3. Modelos con aprendizaje profundo (*deep learning*)

El aprendizaje profundo consiste en un conjunto de técnicas desarrolladas en los últimos años que utiliza estructuras lógicas similares al sistema neurológico

humano. La unidad fundamental es la neurona que está formada por una serie de conexiones con pesos sinápticos, una función de suma y una función de activación. De tal manera que los datos de entrada se multiplican por los pesos, se suman y tras la función de activación se obtiene la salida. [48]




Figura 4.10: Neurona artificial

Las neuronas se agrupan por capas, donde cada capa es capaz de detectar una serie de características, primeramente las más generales y en las últimas capas las más específicas. Un conjunto de varias capas interconectadas forma lo que se conoce como una red neuronal.

Durante el entrenamiento de las redes se introduce un dato etiquetado y se pasa a través de toda la red, es lo que se conoce como *forward-propagation*. Cuando se obtiene la salida, se compara con lo deseado y se calcula el error (la diferencia). Este error es mandado de vuelta a la red y se van modificando los diferentes pesos para intentar eliminarlo, es lo que se conoce como *back-propagation*. De este modo se entrenan las redes neuronales.

4.3. *Deep learning en detalle*

Como se ha dicho previamente, el *deep learning* es fundamental para resolver problemas complejos que el ML es incapaz de solucionar. Una de las principales aplicaciones del DL es *computer vision*, más concretamente aplicaciones como detección de objetos serían irresolubles sin estos modelos.

4.3.1. Tipos de redes

Existen numerosos tipos de redes neuronales que, dependiendo de su funcionamiento y arquitectura, sirven para resolver distintos problemas de aprendizaje profundo. Las principales redes son: [49]

- Perceptrón
- Red *feed forward*
- Perceptrón multicapa
- Red convolutional
- Red recurrente
- LSTM – *Long Short-Term Memory*
- Modelos *sequence to sequence*
- Redes modulares

Las más utilizadas para visión artificial son:

Perceptrón multicapa

Es una red formada por varias capas de neuronas, todas conectadas entre sí; por lo que también recibe el nombre de red densa. Es una red especialmente diseñada para la clasificación de objetos como imágenes. Está formada por una capa de entrada, donde a cada píxel se le asigna una neurona; varias capas intermedias ocultas y finalmente, una capa de salida con tantas neuronas como clases haya. Se entrena por *back and forward propagation* modificando los pesos en función del error obtenido para conseguir un clasificador exacto.




Figura 4.11: Perceptrón multicapa

Red neuronal convolucional

Es un tipo de red especialmente diseñada para la extracción de características. En ella, existen dos tipos de capas, las de convolución y las de pooling. En las capas de convolución las neuronas se llaman filtros, son matrices que se solapan creando una matriz 3D. Cada filtro recorre paso a paso pequeñas partes de la imagen para obtener las características más importantes. Las salidas de los filtros se combinan para dar la salida final de la capa. Las primeras capas obtienen las características más generales como la forma, color... y las capas más profundas las más específicas como la forma de los ojos, de la nariz... Finalmente, las capas de pooling sirven para reducir la dimensionalidad de la salida de la capa convolucional y hacer que el proceso sea menos complejo. [50]

Es importante destacar que el objetivo de las redes convolucionales es exclusivamente extraer características, por lo tanto tienen que ser complementadas con una red densa que permita la clasificación. Entre ambas redes se añade una capa de aplanamiento que convierta las salidas 3D de la CNN en entradas 2D para la DNN.




Figura 4.12: Extracción de características con CNN y clasificación con DNN [50]

4.3.2. Hiperparámetros de redes

Los hiperparámetros son valores que se especifican antes de la creación de la red y definen su estructura o cómo se entrena. En función de estos hiperparámetros, la red conseguirá unos resultados más o menos exactos y tendrá más o menos complejidad, por lo que resulta imprescindible elegirlos correctamente. [51]

Algunos de los hiperparámetros más importantes en una red de detección de objetos son:

- **Número de iteraciones:** corresponde con el número de veces que un mismo

conjunto de datos es visto por el algoritmo. Normalmente, mientras siga aprendiendo se seguirá iterando; sin embargo, en un punto el algoritmo deja de aprender cosas nuevas y entra en *overfitting*.

- **Tasa de aprendizaje:** define cómo de rápido se modifican los parámetros de la red. Una tasa alta reduce el tiempo de aprendizaje, pero puede provocar que el algoritmo nunca converja en un mínimo.
- **Optimizador:** durante el proceso de *back propagation*, define el tipo de algoritmo que se utiliza para modificar de la forma más óptima los pesos de la red en función del error cometido.
- **IoU:** cuyas siglas significan *intersection over union* es un parámetro utilizado únicamente en *object detection*. Permite definir la exactitud con la que se ha detectado un objeto basándose en su posición real y la posición estimada por el algoritmo. Se define como en la imagen 4.18. Gracias a este parámetro, se puede especificar cómo de preciso se quiere ser. Lo normal es definir un límite de IoU de 0.5, es decir, la mitad del objeto se ha detectado. [52]

$$\text{Intersection over Union (IoU)} = \frac{\text{Area of Overlap}}{\text{Area of Union}}$$

Figura 4.13: IoU

4.3.3. Redes preentrenadas

Como se ha dicho previamente, las redes se entrenan modificando sus pesos en función de los datos de entrada y los errores generados. Esto en la mayoría de ocasiones es un proceso largo que requiere una gran capacidad de cómputo y gran cantidad de datos. Por ello existen las redes preentrenadas, que son modelos entrenados previamente con miles de datos y cuyas características se asemejan al problema que se trata de resolver. De este modo en vez de inicializar los pesos aleatoriamente, se inicializan con los del modelo preentrenado, mejorando en gran medida el rendimiento del algoritmo. Es lo que se conoce como *transfer learning* [53].

4.3.3.1. Fine tuning

Las redes preentrenadas solucionan un problema similar al planteado; sin embargo, en muchas ocasiones se requiere modificar en cierta medida la red para adaptarla más precisamente a los datos. Existen diferentes formas de hacer *fine tuning* [53]:

- **Usar CNN y cambiar DNN:** este planteamiento se utiliza en casos en los que el conjunto de datos de la red preentrenada es muy similar al deseado, pero cambia el tipo de clasificación que se hace. En estos casos se mantiene la red convolucional para hacer la extracción de características, y se crea una nueva red densa que permita clasificar acorde al problema.
- **Modificar CNN congelando primeras capas:** este planteamiento se utiliza cuando el conjunto de datos es diferente al deseado y no se tienen demasiados datos. En estos casos, se mantienen los pesos de las primeras capas que son las que guardan los rasgos más generales y se modifican los de las últimas para adaptarse a las características específicas del nuevo conjunto.
- **Modificar CNN completa:** por último, este planteamiento se aplica cuando se tienen una gran cantidad de datos o se quiere obtener mayor precisión. En este caso se inicializan los pesos de la CNN con los de la red preentrenada, pero se modifican todas las capas para adaptarse a los nuevos datos.

4.3.3.2. Red YOLO

YOLO es la red preentrenada más efectiva para detección de objetos a tiempo real. Se basa el enfoque de *you only look once*, donde en vez de detectar las áreas de interés de una imagen y luego reconocer objetos, como haría Fast CNN; se hace todo a la vez con una sola red. De este modo se evita mirar de forma repetida el mismo área de una imagen, reduciendo el tiempo de entrenamiento y detección.

Funcionamiento

El algoritmo funciona dividiendo la imagen en una red con diferentes regiones del mismo tamaño. Las regiones calculan por un lado B cajas de diferentes tamaños y les asocian la probabilidad de que haya un objeto en ellas; y por otro lado, calculan la probabilidad de que en esa caja haya una clase determinada. Estas probabilidades se combinan y se eliminan aquellas cajas para las que la probabilidad sea menor del umbral.




Figura 4.14: Funcionamiento red YOLO

Arquitectura

La red YOLO está formada por 24 capas convolucionales, seguidas de 2 capas densas. Para reducir la dimensionalidad se utilizan capas convolucionales de 1x1 seguidas de capas de 3x3 y capas de pooling.




Figura 4.15: Arquitectura de la red YOLO

4.3.4. Métricas de modelos *machine learning*

Las métricas de los modelos permiten definir qué modelos son mejores en función del número de objetos que detecten y cómo los detecten. Se utilizan tanto para entrenar el algoritmo, enfocándolo hacia las mejores métricas; como para seleccionar un modelo final. [54]

4.3.4.1. Definición de términos

Hay algunos términos que es necesario definir para poder entender las métricas.

- **Positivo real:** son aquellos elementos que existen y se detectan correctamente. Es el caso en el que el IoU es superior al límite establecido.
- **Falso positivo:** son aquellos elementos que se detectan, pero no existen. Es el caso en el que el IoU es inferior al límite establecido.
- **Falso negativo:** es cuando un elemento existe y no es detectado.
- **Negativo real:** no se aplica a detección de objetos ya que hay muchas partes de una imagen en las que no hay objetos.
- **Confianza:** es un valor que va del 0 al 1 y define el nivel de seguridad en la detección de ese objeto. Está asociado al límite del IoU, si se aumenta la confianza se obtienen menos TP.

4.3.4.2. Precisión

Es una métrica que representa el grado de exactitud que tiene el modelo para detectar los objetos relevantes. Está definido como:

$$Precisión = \frac{VP}{VP + FP} = \frac{VP}{todas\ detecciones} \quad (4.1)$$

Una alta exactitud implica que los objetos detectados, con mucha probabilidad se encuentran de verdad ahí.

4.3.4.3. Exhaustividad

Es una métrica que define la capacidad que tiene un modelo para detectar todos los objetos que se encuentran en una imagen. Se define:

$$Exhaustividad = \frac{VP}{VP + FN} = \frac{VP}{elementos\ reales} \quad (4.2)$$

Una alta exhaustividad implica que un modelo no está dejando objetos sin detectar.

4.3.4.4. Precisión promedia

Como se ha dicho previamente, la precisión y exhaustividad de un modelo dependerán de la confianza asociada. Estos dos valores son los que ayudan a identificar cómo de bueno es un modelo, por lo que se define una nueva métrica que los relaciona: la precisión promedia. Es la integral de la curva que relaciona la precisión y la exhaustividad.

$$AP@{\alpha} = \int_0^1 p(r) \cdot dr \quad (4.3)$$

Siendo $p(r)$:




Figura 4.16: Curva precisión-exhaustividad.

4.3.4.5. mAP

En detección de objetos, normalmente no se detecta una única clase sino que hay que obtener una métrica que calida media sobre todas las clases. Este valor se llama media de las precisiones promedias, y se define como mAP (*mean average precision*). Siendo mAP:

$$mAP@{\alpha} = \frac{1}{n} \sum_{i=1}^n AP@{\alpha}_i \text{ para } n \text{ en clases} \quad (4.4)$$

Además, resulta interesante conocer el valor del mAP no solo para un límite, sino para varios a la vez. De este modo se puede saber la calidad final de un modelo sin tener que elegir previamente el límite de confianza. Se define este valor como

mAP $\alpha : \beta$, donde α normalmente se define como 0.5 y β como 0.95 con saltos de 0.05. Por lo que mAP 0.5:0.95 es la media de las mAPs para cada valor en el intervalo.

4.3.4.6. Curvas de pérdida

Las curvas de pérdida relacionan el número de iteraciones hechas por el algoritmo con un valor de pérdida. Este valor está asociado a la ineficiencia del modelo y se trata de minimizar. Existen distintos tipos de pérdida: [55]

- **Pérdida de caja:** representa cómo de bien un algoritmo detecta el centro de un objeto y en que medida la caja de predicción cubre la superficie real del objeto.
- **Pérdida de objetividad:** representa la probabilidad de que un objeto exista en una región de interés.
- **Pérdida de clasificación:** representa cómo de bien se predice la clase correcta.

4.3.4.7. Sobre-aprendizaje

El sobre-aprendizaje o *overfitting* es un fenómeno que ocurre en *deep learning* cuando un algoritmo trata de entrenarse de forma completa con los datos de entrada. En estos casos la función de predicción se sobre ajusta, lo que resulta en unos resultados muy buenos para los datos de entrenamiento, y sin embargo, muy malos para los de validación. El algoritmo es incapaz de generalizar. [56]




Figura 4.17: Sobre-aprendizaje [56]

Es un fenómeno que se suele dar cuando un modelo se entrena con pocos datos, con datos sin preprocesar que generan desviaciones, o cuando se realizan demasiadas iteraciones. Uno de los signos más claros de *overfitting* es cuando curvas de pérdida y de precisión de los datos de entrenamiento y validación divergen.




Figura 4.18: Signos de sobreaprendizaje [56]

5. Generación de la idea

En esta sección se presentará la problemática que trata de solucionar el proyecto, tanto para los usuarios como para el cliente. Se explicará la idea que se propone para solucionarla y finalmente, se usarán técnicas de la metodología *Design Thinking* como el método SCAMPER para “estresar” la idea.

5.1. Problemática

Como se ha dicho en la introducción, el problema principal reside en que al año hay más de 400 ahogamientos en superficies acuáticas en España. De los cuales el 85 % se producen en lugares sin vigilar. Desde el punto de vista de las personas esto supone una serie de problemas; tanto cuando ocurre un accidente, como de forma general.

5.1.1. Cuando hay un ahogamiento

Primero se enfoca desde el punto de vista de las consecuencias cuando hay un accidente que resulta en ahogamiento.

Para los usuarios de las playas

1. Pérdida de la propia vida o de la vida de un conocido.
2. Cuando eres testigo de un ahogamiento, pero no puedes hacer nada (el mar está mal, estás muy lejos...) la angustia de sentirte impotente.

Para los ayuntamientos o responsables de la zona

1. Impacto personal y social de la muerte de una persona.
2. Gastos económicos asociados a la muerte de un ciudadano en un lugar público.
3. Mala imagen, tanto en términos de gestión, como de seguridad de las playas, lo que puede desembocar en reducción del turismo, quejas, necesidad de aumentar seguridad y gasto...

5.1.2. En una situación normal

También es importante remarcar que no solo hay problemas cuando se produce el accidente; sino que el hecho de que haya tantos ahogamientos en playas sin vigilar tiene un impacto en las personas de manera habitual.

Para los usuarios de las playas

1. Limitación en la elección de playas si hay preocupación de seguridad.
2. En la playa, necesidad de preocupación por personas vulnerables, como ancianos o niños.
3. En la playa, modificación de conductas como tipo de baño, de deporte a practicar... por seguridad.

Para los ayuntamientos o responsables de la zona

1. Pérdida de turismo.
2. Necesidad de inversión en servicio de socorristas.

5.2. Presentación de la idea

La idea pretende dar una solución al problema de la falta de socorrismo en playas que actualmente se encuentran sin vigilar, no se trata de sustituir el sistema de socorrismo actual de playas vigiladas.

El producto es un dron conducido autónomamente, es decir, sin un piloto. Cuenta con una cámara y un controlador que por medio de inteligencia artificial

permite detectar a una persona ahogándose y salvarla por medio de un flotador embebido en una pastilla de sal. Los drones están desplegados a lo largo de la costa, separados aproximadamente 2 kilómetros los unos de los otros y situados en postes seguros.

El sistema funciona de tal manera que cuando alguien detecta a una persona ahogándose o en riesgo, llama al número de emergencias, se localiza automáticamente su posición, se llama a socorrismo y se despliega el dron más cercano. El dron de manera autónoma, en pocos minutos, recorre la playa, y cuando detecta a la víctima le lanza la pastilla con el salvavidas, que se disuelve en el agua. De este modo la víctima es capaz de aguantar a flote con el salvavidas el tiempo necesario hasta que los servicios de emergencia llegan; evitando así el periodo crítico entre que se hace la llamada y se recibe la ayuda muchos minutos más tarde.

5.3. SCAMPER

Esta herramienta permite “estresar” la idea aplicándole una serie de transformaciones.

- **Sustituir:** En vez de usar drones, se propone usar boyas salvavidas distribuidas en zonas de grandes corrientes. Permitirían a las personas aferrarse a ellas y avisar a emergencias cuando fuese necesario.
- **Combinar:** Se propone el despliegue de la flota de drones autónomos con visión artificial, pero controlados remotamente desde una centralita de salvamento.
- **Adaptar:** La idea puede ser establecer cámaras como las de control de aforos en playas, de gran calidad para detectar a personas ahogándose y llamar al dron, evitando que sea necesario que una persona avise.
- **Magnificar:** En vez de mantener el dron parado hasta que haya una emergencia, se puede crear una flota de drones en cada playa que estén continuamente sobrevolándola.
- **Poner para otro uso:** Además de para salvamento en playas, los drones se podrían utilizar para vigilar otro tipo de situaciones como deportes extremos, montañismo...

- **Eliminar:** Se puede eliminar la conducción autónoma y que sean dirigidos por socorristas que se encuentren presencialmente en la playa. La visión artificial serviría únicamente de apoyo a la decisión.
- **Reordenar:** En lugar de que una persona externa tenga que avisar al dron, se puede hacer el sistema de tal manera que las propias personas diesen el aviso por medio de un grito o una señal.

6. Validación de la idea

En esta sección se expondrá el proceso seguido para validar el modelo de negocio siguiendo la metodología *lean startup*. Primero se expondrá el modelo de negocio original, después se harán tres iteraciones. Para cada iteración se definirán las hipótesis que se quieren demostrar, los experimentos que se desarrollan, los resultados que se consiguen y cómo se modifica el producto o el modelo de negocio.

6.1. Business model canvas inicial

En esta sección se propone un modelo de negocio inicial. El principal segmento de clientes al que está enfocada la idea son los ayuntamientos o comunidades con zonas costeras. Es por lo tanto un proyecto enfocado en la administración pública. Las relaciones con el cliente se mantendrán de forma presencial con planes personalizados para cada cliente. Se garantizará la gestión, seguimiento y se ofrecerán informes mensuales personalizados para cada cliente.

Económicamente, el modelo está basado en dos tipos de ingresos. En primer lugar un ingreso por la compra y despliegue de las infraestructuras, entre lo que se incluyen los drones totalmente equipados y los postes donde se mantienen, que están diseñados de tal modo que quedan protegidos de las inclemencias del tiempo y del acceso de las personas. En segundo lugar, se pagará una cuota anual, que dependerá del número de drones desplegados. Esta cuota incluirá el plan de mantenimiento tanto del HW como del SW, las actualizaciones, los informes de situaciones ocurridas, el reemplazamiento de piezas (como el flotador tras un evento)...

El resto del BMC se puede consultar en más detalle en la siguiente imagen:

The Business Model Canvas

Designed for:

Designed by:

Date:

Version:

Key Partners - Productor de drones - Productor de cámaras - Productor de raspberry pi - Empresas de testado de drones - Instituciones públicas	Key Activities - Diseño, ensamblaje y testado del HW - Diseño, planificación y despliegue de la infraestructura - Desarrollo y mejora del SW - Creación y venta de propuestas al cliente	Value Propositions - Salvar vidas: lo que proporciona mejor calidad de vida y ahorra gastos - Evitar excesivo gasto en personal de socorrismo - Mejorar la imagen para sectores públicos - Aumento del turismo en playas	Customer Relationships - Creación de propuesta personalizada para el cliente y venta en persona - Periodos de prueba - Instalación - Gestión del producto por subscripción: - Mantenimiento y reparaciones - Mejora y actualización del SW v HW Channels - Representantes de ventas en persona - Página web	Customer Segments - Ayuntamientos o comunidades de zonas costeras - Ayuntamientos de zonas de ríos y pantanos - Urbanizaciones privadas en zonas de pantanos
Cost Structure - Costes fijos: personal (desarrollador del SW, diseñador del HW, ventas...), marketing, infraestructura (alquiler oficina, servidores y página web), mantenimiento de drones. - Costes variables: HW (cada uno de los drones) e instalación en emplazamientos seguros.	Revenue Streams - Compra inicial del producto: HW+SW+Instalación - Pagos recurrentes por subscripción - Renovación del HW (después de 10 años) - Patrocinadores			

6.2. Primera iteración: Experimentos con usuarios

En esta sección el objetivo es ver como se comportarían los usuarios ante el producto. Se entienden por usuarios aquellas personas que van a la playa y que pueden sufrir o presenciar un ahogamiento.

6.2.1. Hipótesis

1. Los usuarios llevan el móvil a la playa.
2. Los usuarios leen los carteles de advertencia antes de entrar en las playas.
3. Aumentaría el número de usuarios que van a una playa si fuese más segura.
4. Los usuarios confían en productos controlados puramente por inteligencia artificial.
5. Los usuarios confían en una empresa tecnológica privada asociada al gobierno para gestionar el tratamiento de sus datos personales.

6.2.2. Experimento 1 - Entrevistas

En esta primera sección se hacen 5 entrevistas a personas de diferentes rangos de edad. Las preguntas están relacionadas con la importancia que dan a la seguridad en la playa, su confianza en la tecnología autónoma, su preocupación por el tratamiento de los datos...

Daniel, 20 años

Va a la playa aproximadamente 20 veces al año ya que veranea en un pueblo con mar. A priori, la seguridad en la playa no es un factor que defina su elección, pero si dos playas fuesen iguales iría a la más segura. Siempre lleva el móvil a la playa y suele leer los carteles de aviso.

Dice que confía en los sistemas totalmente autónomos. Que en términos de seguridad no sustituiría el salvamento actual, pero que le parece una buena solución cuando no lo hay. Cuando se le propuso la opción de que una persona estuviese

detrás vigilando por si acaso, dijo que no le parecía que cambiase mucho con respecto a que fuese totalmente solo.

Opina que la mejor forma de gestionar los datos personales es a través de una empresa privada asociada a un ayuntamiento. Además, no tendría problema con compartir sus datos ya que dice que a día de hoy toda nuestra información está controlada por empresas y que “por lo menos” que sea para aumentar la seguridad en las playas. Finalmente, considera que además de avisar del nuevo mecanismo de seguridad en carteles, habría que hacer publicidad en la televisión, marquesinas de autobuses... De este modo es más probable que la gente lo conozca y lo utilice, opina que si solo hubiese carteles en la playa mucha gente no se daría cuenta.

Mario, 55 años

Va a la playa aproximadamente 10 días al año. La seguridad le parecía un elemento fundamental cuando sus hijos eran pequeños; pero que en el resto de los casos prioriza una playa bonita y tranquila. Siempre lleva el móvil a la playa. Suele hacer caso a las banderas de salvamento y a la megafonía de la playa, pero no suele leer carteles.

Confía totalmente en un sistema autónomo, aunque prefiere que esté supervisado por una persona. Además, en términos de confianza considera que si una tecnología se despliega en un lugar público es porque ha sido completamente probada, entonces no duda de su funcionamiento.

También opina que en temas de seguridad es fundamental informar a la gente de las nuevas medidas implementadas a través de todos los niveles de comunicación pública, ya sea prensa, carteles, megafonía de la playa... Además, piensa que las nuevas tecnologías en gran medida se comparten de boca a boca, y que si se va a implementar un sistema nuevo de seguridad en una playa debería haber algún rasgo distintivo para identificarla y saber que se puede hacer uso de ella.

En términos de protección de datos no aceptaría que se pusiesen cámaras de seguridad a grabar en una playa; sin embargo, opina que si es para salvamento y de forma puntual, prevalece el salvamento a la intimidad. De todos modos considera que habría que tener en cuenta el enfoque, la calidad, la distancia a la persona... Afirmo que estos datos tendrían que estar regulados por alguna institución privada sometida a una regulación clara sobre derechos de protección de imagen; como las ambulancias.

Silvia, 54 años

Va a la playa aproximadamente 30 días al año, el 50 % de las veces va a playas que ya conoce y el otro 50 % intenta descubrir playas nuevas. Actualmente no le da mucha importancia a la seguridad, pero cuando tenía hijos sí, ya que le preocupaba que se perdiesen y ahogasen.

Siempre lleva el móvil a la playa. No se fija en los carteles, considera que en general están sobrecargados de información y que si se trata de medidas de seguridad la información importante tiene que estar a golpe de vista. Por el contrario, sí mira las banderas de marea y considera que si viese una bandera nueva que pensase que está relacionada con algo de peligro, se molestaría en buscar su significado para mantenerse informada.

Acerca de las tecnologías autónomas, dice que no confiaría su seguridad en un sistema sin supervisión; que necesitaría que estuviese supervisado aunque fuese desde la distancia. También considera que confiaría más si le explicasen el funcionamiento; y si el sistema ya llevase un tiempo implementado y se hubiese demostrado que funciona. Dice que para ella, cualquier tecnología de seguridad tiene que ser muy fácil de usar y evidente, por ejemplo: un cartel grande con “ en caso de ahogamiento, llamad a este número”. Y con una leyenda para continuar leyendo si te interesa más.

Finalmente, con respecto al tratamiento de datos, se considera muy poco tecnológica y tiende a desconfiar de cualquier organización que maneje sus datos. Al mismo tiempo sabe que hay empresas que los necesitan para cumplir sus funciones, como por ejemplo las empresas de seguridad. Dice que para ella la playa tiene más problemas que cuando te graban entrando en un comercio; sin embargo, si la grabación se hace en un momento puntual para un rescate y por el beneficio común no le molestaría. En cualquier caso, considera que las medidas tienen que ser de actuación, no de prevención; no le gustaría que hubiese de forma continua cámaras grabando en la playa, solo en casos puntuales y justificados con una emergencia.

Pablo, 24 años

Va a la playa aproximadamente 10 días al año, suele cambiar de zona y buscar playas nuevas, siempre lleva el móvil a la playa. No le preocupa la seguridad, aunque alguna vez de pequeño ha tenido problemas en mares muy agitados. En general opina que las personas no leen los carteles, que si se quiere transmitir información importante tiene que mostrarse de forma llamativa.

No confiaría en un sistema 100 % autónomo. Solo confiaría en un sistema remotamente controlado cuando entendiese el proceso que hay detrás. Considera que

cualquier nuevo desarrollo que se haga con tecnología tiene que estar bien explicado a los usuarios.

Finalmente, no confía en ninguna entidad que procese sus datos, aunque no los almacene, por miedo a ciber-ataques. Sin embargo, no dejaría de ir a una playa que le gustase por que hubiese cámaras.

Ignacio, 90 años

Ignacio va una media de 5 días a la playa, aunque cuando era joven iba más. Considera que sus prioridades también han cambiado con el tiempo, hace años era más atrevido e imprudente. Ahora trata de buscar playas seguras (preferiblemente con socorristas) y cómodas y no se mete en peligros innecesarios. Además, siempre lee carteles, banderas y atiende a todos los avisos de seguridad que se dan.

Respecto a la tecnología, siempre va a la playa con el móvil por si ocurriese algo. Confía plenamente en los ordenadores, dice que aunque él no es muy hábil con ellos, cuando los maneja alguien que sabe siempre funcionan. Por lo que confiaría en un sistema de seguridad controlado por un ordenador.

Respecto al tratamiento de datos, dice que no le importaría que hubiese cámaras en las playas si son de salvamento. Que los datos tendrían que estar controlados por organizaciones de carácter público como los ayuntamientos de las playas; y no privado ya que se presta a malos usos e intereses personales.

6.2.3. Experimento 2 - Encuestas

En esta sección se hace una encuesta a más de 100 personas de distintos grupos de edad para evaluar, en primer lugar su comportamiento en la playa y en segundo lugar su predisposición hacia el producto. Las encuestas son similares a las entrevistas, pero en vez de recoger opiniones de forma concreta, sirven para comprobar el comportamiento de la mayoría.

6.2.3.1. Planteamiento

La encuesta está formada por 10 preguntas:

1. Número días de playa al año
2. Criterios para elegir una playa

3. Prioridades cuando se va con la familia
4. Visitas a otro tipo de superficies acuáticas
5. Práctica de deportes
6. Situaciones pasadas de peligro
7. Móvil en la playa
8. Atención a elementos de seguridad en la playa
9. Confianza en organizaciones para el tratamiento de datos personales
10. Confianza en tecnologías controladas por inteligencia artificial

6.2.3.2. Resultados

A continuación, se presentan únicamente los resultados más importantes para la validación de las hipótesis presentadas inicialmente.

Uso de móvil en la playa




Figura 6.1: Respuestas encuesta sobre uso móvil

Se puede ver que casi el 95 % de las personas llevan el móvil a la playa. Esto demuestra que un sistema de avisos de emergencia por medio de llamadas telefónicas

es el método más efectivo. Para evitar los problemas de cobertura, se puede hacer que las llamadas pasen como números de emergencia de tal manera que aunque el usuario no tenga servicio en la playa, se pueda realizar la llamada.

Atención a avisos de seguridad en las playas




Figura 6.2: Respuestas encuesta sobre atención a avisos de seguridad

En este caso se puede ver, que no tendría mucho efecto la idea inicial de indicar el nuevo procedimiento de salvamento en carteles a la entrada de las playas; ya que tan solo el 15 % de personas los leen. Resultaría más efectivo indicarlo a través de banderas o megafonía.

Importancia de la seguridad en una playa

Se puede ver que el 16 % de las personas consideran la seguridad como el factor número 1 para elegir una playa. Esto lleva a pensar que en muchas ocasiones, añadiendo un sistema de seguridad, se podría obtener un aumento del turismo en playas no vigiladas. Además, resulta interesante que de las personas que lo han seleccionado como segunda prioridad consideran que la primera es que se puedan hacer deportes de agua. Por lo que existe un nicho de turismo deportivo como surf, windsurf... que puede explotarse aumentando la seguridad en ciertas playas.




Figura 6.3: Respuestas encuesta sobre seguridad

Confianza en sistemas autónomos




Figura 6.4: Respuestas encuesta sobre confianza en sistemas autónomos

En la gráfica se puede comprobar que todavía hay bastantes dudas con respecto a los sistemas totalmente autónomos. Esto hace que el modelo presentado inicialmente tanto autónomo en movimiento como en detección, pueda generar inseguridades en la población. Sin embargo, se puede ver que en cuanto se introduce el control de un humano, aunque sea solo de supervisión, la aceptación aumenta al 87 %. Lo que sugiere que el producto tendría que contar con este factor.

Confianza en tratamiento de datos personales




Figura 6.5: Respuestas encuesta sobre tratamiento de datos personales

En la imagen anterior se puede ver que hay una gran proporción de la población que no confía en que sus datos sean tratados por ninguna organización. Esto es un dato importante en un tema sensible como pueden ser imágenes personales en la playa. Sin embargo, al igual que pasa en muchos casos en la calle, se podría establecer este sistema e indicarlo de cara a que sea de libre elección si ir o no. En el resto de los casos, se ve que la mayor confianza está en las empresas tecnológicas como sería el caso de la empresa que se trata de desarrollar, por lo que se puede considerar que los usuarios confiarían el tratamiento de sus datos.

6.2.4. Conclusiones

Hipótesis 1: Los usuarios llevan el móvil a la playa. Validada al 100 %

Tanto en la encuesta como en las entrevistas, se puede ver que casi el 100 % de las personas llevan el móvil a la playa. Por lo tanto, se puede afirmar que a día de hoy es el mejor sistema para dar un aviso de emergencia.

Hipótesis 2: Los usuarios leen los carteles de advertencia antes de entrar en las playas. Validada al 15 %

Se ha podido ver que la mayoría de usuarios no leen los carteles en las playas, únicamente si la advertencia es muy grande y explícita. Por ello, se considera que hay modos mejores de advertir a la población de que en esa playa se puede utilizar determinada tecnología como los drones autónomos. Por ejemplo, como se sugirió en la entrevista con Mario, una idea podría ser establecer un código de banderas que la identificase, como las banderas azules en las playas limpias. De esta manera, una vez todo el mundo conociese el código, la gente vería inmediatamente el aviso.

Hipótesis 3: Aumentaría el número de usuarios que irían a una playa si fuese más segura. Validada al 75 %

Se puede ver que el 30 % de las personas han elegido la seguridad como su prioridad 1 o 2; por lo que se puede llegar a pensar, que si playas sin salvamento fuesen más seguras, irían más personas. Además, entre las personas que no valoran tanto la seguridad, dicen que a igualdad de condiciones, por supuesto prefieren una playa con algo de seguridad, que siempre lo van a considerar un aliciente.

Hipótesis 4: Los usuarios confían en productos controlados por puramente por inteligencia artificial. Validada al 10 %

Claramente se puede ver que las personas todavía tienen muchas dudas con respecto a las tecnologías totalmente autónomas, y más en lo que respecta a su seguridad. Sin embargo, en cuanto una tecnología está supervisada por un humano que puede tomar control, la confianza aumenta en gran medida. Este hecho resulta de gran importancia a la hora de plantear el funcionamiento del producto y debe hacer pivotar la idea.

Hipótesis 5: Los usuarios confían en el tratamiento de sus datos por una organización asociada al gobierno. Validada al 90 %

En general se ha visto, que aunque los usuarios no se sienten totalmente cómodos con el hecho de que haya cámaras en un lugar como la playa, si están de

acuerdo si se utilizan en momentos puntuales y para salvamento. Además, se ha podido ver que las empresas en las que más confían son empresas tecnológicas y si encima están reguladas por un acuerdo con gobiernos, mejor.

6.2.5. Modificación del producto y BMC

En base a las conclusiones obtenidas en esta primera iteración, se decide modificar el funcionamiento del producto.

En primer lugar, el aviso de que en una playa se utiliza tecnología de seguridad por drones, tendrá que hacerse de alguna otra forma que no sea por medio de carteles. Se propone el uso de una bandera especial que lo indique. Además, se tendrá que hacer publicidad exterior para dar a conocer ese nuevo sistema y que los usuarios sepan que pueden utilizarlo.

En segundo lugar, para aumentar la confianza de la gente en el sistema de salvamento y además reducir la posibilidad de fallos críticos, se propone un sistema de control. La idea sería crear un centro de control único para toda una región, desde donde un operario pudiese controlar todos los drones. De esta manera, cuando se lanzase una alarma en uno de los drones, le saldría al operario en una pantalla y ayudado del sistema autónomo de conducción y detección, podría seguir el recorrido del dron y asistirlo si fuese necesario.

Estas modificaciones tienen impacto en el *business model canvas* ya que por un lado, hay que tener en cuenta costes extra de alquiler, HW y gestión del centro de control (se necesita personal para controlar). Y por otro lado, se modifican las relaciones con el cliente: en el modelo de suscripción se incluye el control y mantenimiento de los centros de supervisión.

A continuación, se muestra el BMC modificado donde se incluyen en rojo las modificaciones hechas tras la última iteración.

The Business Model Canvas

Designed for:

Designed by:

Date:

Version:

Key Partners - Productor de drones - Productor de cámaras - Productor de raspberry pi - Empresas de testado de drones - Instituciones públicas	Key Activities - Diseño, ensamblaje y testado del HW - Diseño, planificación y despliegue de la infraestructura - Desarrollo y mejora del SW - Creación y venta de propuestas al cliente - Control de drones desde los centros de supervisión	Value Propositions - Salvar vidas: lo que proporciona mejor calidad de vida y ahorra gastos - Evitar excesivo gasto en personal de socorrismo - Mejorar la imagen para sectores públicos - Aumento del turismo en playas	Customer Relationships - Creación de propuesta personalizada para el cliente y venta en persona - Periodos de prueba - Instalación - Gestión del producto por suscripción: - Mantenimiento y reparaciones - Mejora y actualización del SW y HW - Supervisión en los centros de control Channels - Representantes de ventas en persona - Página web	Customer Segments - Ayuntamientos o comunidades de zonas costeras - Ayuntamientos de zonas de ríos y pantanos - Urbanizaciones privadas en zonas de pantanos
Cost Structure - Costes fijos: personal (desarrollador del SW, diseñador del HW, ventas, controladores...), marketing, infraestructura (alquiler espacio para centros de control, HW de control, servidores y página web,), mantenimiento de drones. - Costes variables: HW (cada uno de los drones) e instalación en emplazamientos seguros.	Revenue Streams - Compra inicial del producto: HW+SW+Instalación - Pagos recurrentes por subscripción - Renovación del HW - Publicidad/patrocinadores			

6.3. Segunda iteración: MVP

En esta sección se decide crear un prototipo funcional del algoritmo de detección de personas ahogándose en el agua. Este algoritmo permitirá comprobar si realmente es posible la detección de personas en el agua y permitirá exponer el funcionamiento al cliente. Además, supone un primer paso para determinar cómo seguir trabajando sobre el producto final.

6.3.1. Hipótesis

1. El modelo es capaz de detectar personas en el agua con los datos existentes.
2. La precisión y exhaustividad son mayores del 70 %.
3. El tiempo de detección es menor a 30ms por fotografía lo que permite la detección a tiempo real.
4. El entrenamiento de los modelos se puede realizar sin un HW específico.

6.3.2. Experimento

Como se ha dicho previamente el experimento es el desarrollo de un modelo de inteligencia artificial para la detección de personas en el agua. Al ser un primer MVP, estará centrado únicamente en detectar personas, en futuras iteraciones se perfeccionaría para añadir la lógica que permita diferenciar una persona bañándose de una persona ahogándose.

El algoritmo está basado en redes neuronales, más concretamente sigue la estructura de YOLO v5, definida en el apartado 4.3.3.2. En esta sección se irá aumentando progresivamente la complejidad de las redes para obtener mejores métricas, con la contrapartida de que el entrenamiento de esas redes requerirá más tiempo y recursos.

6.3.2.1. Diagrama de flujo del algoritmo

A continuación, se puede ver el diagrama de flujo que se seguirá para el desarrollo del algoritmo. Las diferentes etapas se encuentran detalladas más adelante.





Figura 6.6: Diagrama de flujo del algoritmo de detección de imágenes [29]

6.3.2.2. Obtención de los datos para el entrenamiento

En general, los modelos de *deep learning* requieren una gran cantidad de datos para poder ser entrenados. En muchas ocasiones existen bases de datos con miles de imágenes etiquetadas con el propósito de desarrollar estos modelos. En este caso, al ser un problema novedoso, no existe esta base de datos. Las imágenes se obtienen de buscadores como Google y de redes sociales como Instagram o Youtube, por lo que el número de imágenes no es muy grande. Las imágenes seleccionadas son fotografías aéreas tomadas por drones a distintas distancias y sobre distintos fondos, entre los que se incluyen tormentas, olas, mares tranquilos y de color turquesa o mares de color más oscuro. Además las fotografías también

tienen variedad en cuanto al número de bañistas que hay: pueden no tener ninguno, uno o muchos. Todas estas variaciones del mismo problema permiten que la red aprenda múltiples casuísticas, mejorando la generalización y evitando el sobre-aprendizaje.

En total se obtuvieron unas 165 imágenes. A continuación, se muestra un ejemplo de los datos:



(a) Ejemplo 1

(b) Ejemplo 2

Figura 6.7: Ejemplo de imágenes de la base de datos

6.3.2.3. Etiquetado de datos

Como se ha dicho previamente, las redes neuronales son algoritmos de aprendizaje supervisado. Eso quiere decir que para que el entrenamiento se haga de forma correcta, los datos de entrada tienen que estar etiquetados.

Para poder etiquetar los datos en formato YOLO, se utiliza la herramienta LabelImg [57]. Que permite por medio de una interfaz gráfica seleccionar la posición de los objetos. Los objetos de las imágenes están definidos en una línea que contiene 5 elementos:

- Id de la clase del objeto
- Posición normalizada del centro del objeto en x

- Posición normalizada del centro del objeto en x y y
- Anchura del objeto, en relación a la anchura total de la imagen
- Altura del objeto, en relación a la altura total de la imagen




Figura 6.8: LabelImg [29]

Tras pasar por todas las imágenes, los datos terminan etiquetados de la siguiente forma:



(a) Imagen

photo_118.txt

0	0.447630	0.546575	0.045107	0.093151
0	0.514908	0.497260	0.051223	0.082192
0	0.537080	0.645890	0.049694	0.113699

(b) Etiqueta

Figura 6.9: Ejemplo de dato etiquetado

6.3.2.4. Análisis exploratorio

Antes de introducir los datos en las redes neuronales, es importante saber como están distribuidos los objetos en las imágenes, cuántos objetos hay de cada clase, el tamaño y resolución de las imágenes... ya que si existiesen datos de muy mala calidad, o muy sesgados; se podría influir negativamente en el modelo.

Primeramente se miden los parámetros de las fotos, como son el tamaño, la cantidad de píxeles, el rango, el valor medio de los píxeles (color).

shape	(4833, 4833, 3)	shape	(147, 343, 3)
pixels	70073667	pixels	150696
range	[82, 234]	range	[0, 211]
avg_pixel	197.768831	avg_pixel	58.07214
dtype: object		dtype: object	

(a) Detalles de la imagen más grande

(b) Detalles de la imagen más pequeña

Figura 6.10: Diferencia en características de las imágenes

Como se puede ver, entre fotos hay una gran diferencia de tamaño, del rango de píxeles, del número de píxeles... Teóricamente, si estos datos se introdujesen tal cual en la red harían que los datos de mayor calidad y con colores más brillantes (píxeles más altos) sesgasen los resultados ya que se considerarían más importantes para el algoritmo. Para evitar esto más adelante se hará el preprocesado de los datos.

Otro elemento interesante a ver en el análisis exploratorio, es el número de elementos que hay en total.

```

swimmer    764
surfer      67
shark       32
person     28
float       20
ray         5
boat        2
rock        1
dtype: int64

```

Figura 6.11: Número de elementos [29]

Se puede ver que hay numerosos elementos etiquetados a parte de los “swimmers”, esto se debe a que originalmente se valoró la idea de diferenciar los distintos tipos de objetos. Sin embargo, al ver la gran diferencia en número entre unos y otros, se llegó a la conclusión de que harían falta más fotos para que estuviesen más o menos equilibrados. Sino, con mucha probabilidad habría problemas de sesgo. Por lo tanto se decidió tener en cuenta solo los elementos etiquetados como bañistas.

6.3.2.5. Pre-procesamiento de imágenes

Como se ha dicho previamente, el objetivo de esta sección es evitar los sesgos que imágenes de diferentes calidades puedan crear en la red. Este preprocesado se realiza directamente en la función de entrenamiento de YOLOv5, facilitando al programador la obtención de modelos más precisos. Algunos de los mecanismos que se utilizan son: la normalización de las imágenes en el mismo rango, conversión de imágenes rectangulares en cuadradas añadiendo *padding* y escalado de todas las imágenes al mismo tamaño.

Por otro lado, cuando se trabaja con redes prediseñadas, como YOLOv5, es necesario organizar los ficheros de tal forma que el algoritmo sea capaz de localizarlos. En esta sección también se aprovechó para distribuir los ficheros con estructura de datos necesaria[58]:




Figura 6.12: Estructura de ficheros [29]

6.3.2.6. Entrenamiento de la red

Para la creación y desarrollo del modelo de detección, se utiliza la red YOLO v5. Más concretamente la versión 5s (*small*) que, aunque tiene menos precisión media que las otras redes, es más rápida a la hora de inferir información, lo que resulta fundamental para detectar a personas a tiempo real y reduce las posibilidades de tener *overfitting*.




Figura 6.13: Versiones de YOLOv5 [59]

El código utilizado para entrenar, validar e inferir métricas; así como los ficheros de configuración y todos los ficheros auxiliares se encuentran en el siguiente GitHub [59] desarrollado por la empresa de inteligencia artificial Ultralytics [60]. Algunos de los elementos principales que se pueden encontrar dentro de este proyecto son:

- **train.py**: fichero para entrenamiento de la red.
- **data/swimmers.yaml**: es un fichero personalizado para cada problema e indica al algoritmo donde se pueden encontrar los archivos para el entrenamiento y el número de categorías que se espera tener. En este caso es un fichero así:

```
train: /Users/mac/Desktop/Master2/TFM/MVP/Images_Labels/swimmer_label/images/train/
val: /Users/mac/Desktop/Master2/TFM/MVP/Images_Labels/swimmer_label/images/val/
test: /Users/mac/Desktop/Master2/TFM/MVP/Images_Labels/swimmer_label/images/test/

# number of classes
nc: 9

# class names
names: ["swimmer", "surfer", "shark", "w", "person", "float", "ray", "boat", "rock"]
```

Figura 6.14: swimmers.yaml

Cabe destacar que en este fichero se indican 9 clases (las definidas originalmente) en vez de 1 debido a que probando se descubrió que daba más precisión.

- **models/yolov5s.yaml**: es el archivo en el que se define la arquitectura de la red tal y como se definió en la sección 4.3.3.2.

- **runs/train:** cada vez que se entrena una red, se guardan los mejores modelos en este directorio y se muestran las métricas que permiten interpretarlos.

Red entrenada desde 0

En primer lugar, se empieza entrenando la red “desde 0”, es decir, los pesos de las conexiones se inicializan de forma aleatoria y van modificándose en cada iteración. Algunos elementos a resaltar es que se empieza con un tamaño de imagen de 80x80 para evitar generar muchos parámetros (cuantos más píxeles más precisión, pero también más esfuerzo de cómputo). Se hacen 1000 iteraciones (*epochs*), pero si después de 100 el resultado no ha mejorado se para (*patience*). Y finalmente, el fichero de pesos (*weights*) está vacío; esto es para indicar que los pesos se inicializan aleatoriamente.

```
python train.py --img 80 --cfg yolov5s.yaml --batch 32 --patience 100 \
--epochs 1000 --data swimmers_v3.yaml --weights '' --workers 24 \
--name yolo_fromScratch_det
```

Tras entrenar el modelo, se obtienen las métricas con las imágenes de validación:

Class	Images	Labels	P	R	mAP@.5	mAP@.5:.95:
all	16	40	0.555	0.25	0.238	0.0754
swimmer	16	40	0.555	0.25	0.238	0.0754

Figura 6.15: Métricas modelo “desde cero”

Se puede ver que no son unas métricas muy buenas, de precisión tiene un 55 %, es decir, solo clasifica bien el 55 % de las imágenes. De *recall* (exhaustividad) solo tiene un 25 %, por lo tanto, solo encuentra el 25 % de las personas del agua.

Estas métricas son insuficientes como para poder validar este modelo como apto para ser un primer MVP, por ello se decide ir aumentando la complejidad a ver si se obtienen modelos mejores.

Red preentrenada con capas congeladas

Lo primero que se hace para intentar mejorar las métricas es entrenar la misma red, pero en vez de inicializar los pesos de forma aleatoria, se inicializan con los de una red preentrenada. Como se ha definido en la sección 4.3.3, estas redes están optimizadas para detectar determinadas clases ya que han sido entrenadas con una base de datos con miles de imágenes. En este caso se ha usado la red preentrenada

con COCO (*common objects in context*) [61], conjunto de datos que cuenta con más de 200 mil imágenes etiquetadas para detección de objetos.

Además de utilizar los pesos de esta red, se congelan todas las capas para que la red no modifique sus pesos, sino que simplemente infiera las características necesarias para detectar los nadadores.

Para ello, se lanza el mismo comando que antes pero con el fichero de pesos en el parámetro *weight* y se le añade la opción de *freeze*.

```
python train.py --img 80 --cfg yolov5s.yaml --batch 32 --patience 100 \
--epochs 1000 --data swimmers_v3.yaml --weights yolov5s.pt --freeze 24 \
--workers 24 --name yolo_frozen_det
```

Nuevamente se obtienen las métricas sobre el conjunto de validación, para comprobar lo efectivo que es el algoritmo detectando.

Class	Images	Labels	P	R	mAP@.5	mAP@.5:.95:
all	16	40	1	0.025	0.026	0.0104
swimmer	16	40	1	0.025	0.026	0.0104

Figura 6.16: Métricas modelo con red preentrenada y capas congeladas

En este caso se puede ver algo muy interesante, la precisión es del 100 %, es decir, el algoritmo es perfectamente capaz de clasificar un objeto. Sin embargo, la exhaustividad es de tan solo el 2.5 % por lo que la mayoría de personas no son detectadas. Estas métricas tan extremas se deben a que, al no modificarse los pesos de la red, el algoritmo detecta perfectamente a los bañistas que se ve muy claramente que son personas (objeto conocido por COCO). Sin embargo, los bañistas que no parecen tanto personas son indetectables para esta red.

Red pre-entrenada con *fine tuning*

La solución para la problemática anterior es descongelar las capas de la red para permitir al algoritmo generalizar los nuevos objetos introducidos.

Se empieza a entrenar con los pesos de la red COCO, pero se van modificando a medida que pasan las iteraciones. Esto aumenta en gran medida el tiempo y recursos de entrenamiento, pero debería ofrecer mejores métricas. Para ello simplemente se elimina el parámetro *freeze*.

```
python train.py --img 80 --cfg yolov5s.yaml --batch 32 --patience 300 \
```

```
--epochs 1000 --data swimmers_v3.yaml --weights yolov5s.pt \
--workers 24 --name yolo_swimmers2_det
```

Nuevamente se obtienen las métricas sobre el conjunto de validación, para comprobar lo efectivo que es el algoritmo detectando.

Class	Images	Labels	P	R	mAP@.5	mAP@.5:.95:
all	16	40	0.571	0.5	0.433	0.114
swimmer	16	40	0.571	0.5	0.433	0.114

Figura 6.17: Métricas modelo con red preentrenada y *fine tuning*

Como se puede ver en la imagen 6.17 tanto la precisión como la exhaustividad han aumentado con respecto al primer modelo. Se puede ver que, aunque la precisión solo es ligeramente superior, la exhaustividad es el doble. Esto es muy importante ya que indica que el algoritmo detecta al 50 % de personas en el agua. Todavía es una métrica que habría que perfeccionar, pero supone una gran mejora.

Red pre-entrenada con *fine tuning* aumentando el tamaño de las imágenes

A continuación, se pudo identificar que en algunas imágenes con objetos pequeños, al estar reducidas a 80x80 los objetos ocupaban tan solo un píxel. Esto hace que prácticamente ese objeto no aporte información ya que el algoritmo no lo puede utilizar. Por ello, se decidió aumentar el tamaño de las imágenes que entran a la red a 300x300 y aprovechar mejor esa información.

Por otro lado, al estar trabajando con modelos tan complejos, en muchas ocasiones tras horas de procesamiento el ordenador se quedaba sin memoria y el proceso se cortaba. Para evitar perder el trabajo realizado, se le añadió una opción que fuese guardando progresos y no tener que empezar desde cero, es el *save period*.

```
python train.py --img 300 --cfg yolov5s.yaml --batch 32 --patience 300 \
--epochs 1000 --data swimmers_v3.yaml --weights yolov5s.pt \
--workers 24 --name yolo_swimmers3_det --save-period 50
```

Las métricas que se obtienen son las siguientes:

Class	Images	Labels	P	R	mAP@.5	mAP@.5:.95:
all	16	40	0.722	0.65	0.677	0.308
swimmer	16	40	0.722	0.65	0.677	0.308

Figura 6.18: Métricas modelo con red pre-entrenada con *fine tuning* aumentando el tamaño de las imágenes

Se puede ver que, como se esperaba, han aumentado tanto la precisión como la exhaustividad.

Red pre-entrenada con *fine tuning* y aumento de datos

Como se ha dicho previamente, uno de los retos que presenta el *deep learning* es la necesidad de tener grandes cantidades de datos que permitan a los modelos entrenarse de forma correcta. En el caso actual, la falta de datos (apenas 150 fotos) condiciona en gran medida el rendimiento del algoritmo. Para reducir este problema, se utiliza en muchas ocasiones la técnica llamada *data augmentation* definida en el apartado 4.2.1.2. YOLOv5 tiene la ventaja de que está integrado con la herramienta Albumentations [62] que permite aplicar *data augmentation* a las imágenes que entran en la red, de manera que por cada imagen se generan tres. Esto se hace aplicando técnicas como difuminado de la imagen, creación de mosaicos con las imágenes, cambio de colores... Haciendo que se consideren imágenes diferentes. Por ejemplo, a continuación se muestra como el algoritmo combina las imágenes creando mosaicos (la etiqueta 0 corresponde con “bañista”).



Figura 6.19: Ejemplo de aplicación de albumentations

El algoritmo se entrena de la misma forma que el anterior, pero habiendo instalado el paquete albumentations.

```
pip install -U albumentations
```

```
python train.py --img 300 --cfg yolov5s.yaml --batch 32 --patience 300 \
--epochs 1000 --data swimmers_v3.yaml --weights yolov5s.pt \
--workers 24 --name yolo_swimmers_augm_det --save-period 50
```

Las métricas que se obtienen son las siguientes:

Class	Images	Labels	P	R	mAP@.5	mAP@.5:.95:
all	16	40	0.818	0.675	0.689	0.29
swimmer	16	40	0.818	0.675	0.689	0.29

Figura 6.20: Métricas modelo con red preentrenada y aumento de datos

Con esta técnica el algoritmo ha mejorado en gran medida, se obtiene más de un 80 % de precisión y casi un 70 % de exhaustividad. Como se puede ver la técnica de *data augmentation* resulta efectiva. Sin embargo, es importante remarcar que no se puede abusar en la generación de imágenes, ya que se puede llegar a introducir *overfitting* en el modelo.

Red pre-entrenada con *fine tuning* y evolución de hiperparámetros

Finalmente, la última modificación que se hace del algoritmo es la evolución de hiperparámetros. Como se ha definido en la sección 4.3.2, los hiperparámetros son elementos que utiliza la red para definir cómo se hace el aprendizaje. Hasta ahora se han estado utilizando los hiperparámetros por defecto; sin embargo, modificar estos hiperparámetros, en muchas ocasiones permite obtener mejores métricas. Para elegir los mejores hiperparámetros se utilizó la funcionalidad *evolve* de YOLO. Al igual que ocurría durante el entrenamiento de la red con los pesos, los hiperparámetros se modifican hacia aquellos valores que maximizan las métricas. Sin embargo, en este caso en vez de entrenar una red una única vez (con 1000 iteraciones) se entrena la red hasta 50 veces con 100 iteraciones (1000 llevaría demasiado tiempo).

```
python train.py --img 300 --cfg yolov5s.yaml --batch 32 \
--patience 100 --epochs 100 --data swimmers_v3.yaml \
--weights best_model.pt --workers 24 --cache --name yolo_swimmers_evolve_det \
--evolve 50
```

En este caso, fue imposible conseguir un modelo final ya que el ordenador carece de capacidad de cómputo y después de 24h se paró el algoritmo. Sin embargo, se

Class	Images	Labels	P	R	mAP@.5	mAP@.5:.95:
all	16	40	0.846	0.55	0.629	0.284
swimmer	16	40	0.846	0.55	0.629	0.284

Figura 6.21: Métricas modelo con red preentrenada y evolución de hiperparámetros

tomó el mejor modelo calculado hasta el momento y se probaron las métricas a ver si había tenido éxito.

Se puede ver que la precisión ha mejorado; sin embargo, la exhaustividad, que resulta de gran importancia en la problemática definida, ha empeorado. Existen dos factores que hacen que esta técnica no haya tenido el efecto deseado, por un lado se ha hecho la evolución para 100 iteraciones cuando las previas eran con 1000 (teóricamente no se pueden comparar) y por otro lado, no se ha dejado que el proceso terminase debido a falta de tiempo y capacidad de computo.

Resulta evidente que si se tuviese capacidad y tiempo para terminar este proceso, se podrían obtener métricas mucho más altas. En estos casos habría que buscar el equilibrio entre buenas métricas y recursos de procesamiento.

6.3.2.7. Análisis del mejor modelo

Análisis de las métricas

A continuación se recoge un resumen con las métricas obtenidas para cada modelo presentado anteriormente:

Modelo	Precisión	Exhaustividad	mAP 0.5	mAP 0.5:0.95
From scratch	55%	25%	24%	7,5%
Capas congeladas	100%	3%	3%	1%
Fine tuning -todas las clases	57%	50%	43%	11%
Fine tuning-imagen aumentada	72%	65%	78%	30%
Fine tuning-data augmentation	82%	68%	69%	29%
Fine tuning-optimización hiperparámetros	85%	55%	63%	28%

Figura 6.22: Resumen métricas de los modelos

Se puede ver, que con los recursos actuales, el mejor modelo obtenido es el de “red preentrenada con aumento de datos”.

Análisis del *overfitting*

Cuando se obtiene un modelo de aprendizaje profundo, es importante asegu-

rarse de que no tenga *overfitting*. Como se ha dicho en el apartado 4.3.4.7, eso implicaría que el algoritmo tiene buenas métricas para los casos de *train*, pero no es capaz de generalizar. Para comprobarlo se observan las funciones de pérdida para los casos de entrenamiento y validación. Si las curvas están muy separadas es que hay *overfitting*.




Figura 6.23: Curvas de pérdida

Se puede ver que en este caso ninguna de las curvas está separada por más de 2 % lo que implica que no hay *overfitting*. Es un hecho muy beneficioso ya que, aunque el modelo no tenga una precisión del 100 %, se puede garantizar que va a ser capaz de generalizar en casos con imágenes nuevas.

Ejemplos de detección

Para comprobar de forma más visual como se detectan los objetos, se decide hacer una simulación con las imágenes almacenadas en la carpeta *test*, es decir, imágenes que no ha visto el algoritmo ni en entrenamiento ni en validación. Para ello se ejecuta el comando que teóricamente ejecutaría el dron para cada imagen cuando sobrevolase la playa.

```
python detect.py\
--weights runs/train/yolo_swimmers_augmentation_det/weights/best.pt \
--data data/swimmers_v3.yaml --img 300 \
--source /Images_Labels/swimmer_label/images/test
```

Primeramente, se prueba con una imagen clara a baja altura:



Figura 6.24: Ejemplo de detección 1

Se puede ver que en este caso el algoritmo detecta muy bien al bañista y tiene alta confianza en que lo es.

En segundo lugar, se prueba con una imagen más borrosa a baja altura:



Figura 6.25: Ejemplo de detección 2

Se puede ver que sigue detectando bien a los bañistas pero al ser una imagen menos clara, tiene menos confianza. Esto no es un problema ya que se le podría indicar al algoritmo que cualquier elemento con más del 40 % de confianza sea considerado como persona. Además, se puede ver que hay un falso positivo pero con menos confianza que los verdaderos, por lo que en un caso real quedaría excluido.

A continuación, se prueban imágenes a más altura y con múltiples personas:




Figura 6.26: Ejemplo de detección 3




Figura 6.27: Ejemplo de detección 4

En estos casos se puede ver como, a pesar de la distancia y de que las imágenes no son muy nítidas, los bañistas también son detectados con bastante precisión.

Finalmente, se muestra un caso extremo, a gran altura:



Figura 6.28: Ejemplo de detección

Se puede ver que incluso en este caso el modelo es capaz de detectar a casi todas las personas. Es importante remarcar que normalmente el dron no volaría a tanta altura, pero es bueno saber que si se hiciese seguiría manteniendo su capacidad de detección.

Por último, se analiza una foto que resulta más complicada para el algoritmo debido al entorno.



Figura 6.29: Ejemplo de detección

Como se puede ver, las rocas se confunden como si fuesen personas vistas desde lejos y por el contrario la verdadera persona no es detectada. Esto es un problema derivado de que el modelo no se ha entrenado con otros objetos a parte de “bañistas”. Si se obtuviesen más fotos con otras categorías, el modelo sería capaz de diferenciar una roca de una persona en el agua. Lo mismo ocurre con otros objetos como tablas de surf:




Figura 6.30: Ejemplo de detección

En resumen, se puede ver que con mayor o menor confianza el modelo es capaz de detectar a la mayoría de personas en el agua. Existen algunos casos donde para perfeccionarlo habría que introducir datos con otros objetos que se pueden encontrar en el entorno.

Análisis del tiempo de detección

Por otro lado, es muy importante el tiempo que tarda en procesar el algoritmo las imágenes, ya que si es excesivo puede ser incapaz de hacerlo en tiempo real. Al ejecutar el comando de detección, se muestra el tiempo que se tarda para las 18 imágenes que hay en la carpeta de test.

```
Speed: 0.6ms pre-process, 75.5ms inference, 1.2ms NMS per image at shape (1, 3, 320, 320)
```

Figura 6.31: Velocidad de detección

En la imagen 6.31 se puede ver que se tarda 1.2 ms por imagen. Teniendo en cuenta que un vídeo normal toma 24 fotogramas por segundo, el tiempo de procesamiento sería muy inferior al margen necesario ya que teóricamente podría

tardar hasta 24 segundos en detectar. Esto implica que si se consiguiese entrenar las redes con un HW más potente para crear modelos más complejos, se podrían desplegar sobre la raspberry pi para hacer la detección sin problema.

6.3.3. Conclusiones

Gracias a este experimento se ha podido obtener información de gran utilidad. En primer lugar, se ha obtenido un MVP sobre el que seguir trabajando y que se puede presentar al cliente para demostrar el funcionamiento del producto. En segundo lugar, se ha conseguido una serie de información sobre cuestiones a mejorar en el futuro y también validación para las hipótesis planteadas.

Hipótesis 1: El modelo es capaz de detectar personas en el agua con los datos existentes. Validada al 80 %

Se puede ver que con las imágenes obtenidas a día de hoy, se pueden elaborar unos modelos con unas métricas bastante buenas. Sin embargo, también se ha comprobado que un aumento en el número de datos aumenta en gran medida la eficiencia; por lo que más fotos podrían beneficiar al algoritmo. Por otro lado, se ha visto que el modelo tenía carencias con respecto a algunos elementos desconocidos en las imágenes, esto también se podría solucionar introduciendo fotos nuevas y etiquetando el resto de elementos que puedan formar parte del contexto. En cualquier caso se tendría que obtener un número equilibrado de cada elemento etiquetado para no crear desviaciones.

Hipótesis 2: La precisión y exhaustividad son mayores del 70 %. Validada al 100 %

Se puede ver que esta hipótesis es validada ya que el mejor modelo tiene un 82 % de precisión y 68 % de exhaustividad. Estas métricas aunque no son suficientemente altas para un despliegue real, permiten ver las grandes posibilidades que tendría el algoritmo si se introdujese más complejidad o más datos.

Hipótesis 3: El tiempo de detección es menor a 30ms por fotografía lo que permite la detección a tiempo real. Validada al 100 %

Se puede ver que la detección de imágenes con el modelo actual se hace en aproximadamente 1.2 ms. Esto implica que quedaría bastante margen para hacer los modelos más complejos y aún así entrar dentro del tiempo establecido. Sin embargo, en cualquier caso habría que comprobarlo cuando se realizasen esos modelos.

Hipótesis 4: El entrenamiento de los modelos se puede realizar sin un HW específico. Validada al 20 %

Se ha podido ver que, aunque es posible entrenar en cierta medida los modelos con el HW actual, hay un punto en el que la complejidad se ve limitada por su capacidad. Para poder aumentar más la complejidad de las redes, y aumentar el número de imágenes para el entrenamiento, es necesario comprar HW específico para alto procesamiento como pueden ser ordenadores físicos con grandes GPUs, alquilar máquinas virtuales que puedan escalar en función de nuestras necesidades, o incluso utilizar herramientas de DL como pueden ser las TPUs desarrolladas específicamente para el procesamiento de modelos con Tensorflow [63].

6.3.4. Modificación del modelo de negocio

Tras esta iteración, se ha comprobado que el producto planteado es viable desde un punto de vista tecnológico. Sin embargo, habría que introducir algunas modificaciones para que cumpliera las métricas necesarias para desplegarse.

Esto se materializa en cambios en el modelo de negocio. En primer lugar, habría que hacer una inversión inicial mayor en la recolección y etiquetado de datos. En segundo lugar, sería necesario aumentar los costes en infraestructura alquilando máquinas virtuales como TPUs para realizar el procesamiento.

Finalmente, como en toda empresa basada en algoritmos, hay que dar la importancia necesaria a los datos como un recurso clave. Los datos recogidos tanto al inicio del proyecto para crear el primer algoritmo, como los recogidos con el paso del tiempo cuando se despliegue la solución. La posesión de estos datos, es lo que puede diferenciarnos de un competidor nuevo que trate de entrar en el mercado; creando así una fuerte barrera de entrada.

A continuación, se muestra el BMC con las modificaciones hechas en esta iteración:

The Business Model Canvas

Designed for:

Designed by:

Date:

Version:

Key Partners - Productor de drones - Productor de cámaras - Productor de raspberry pi - Empresas de testado de drones - Instituciones públicas - Proveedores de infraestructuras Cloud como Google o AWS.	Key Activities - Diseño, ensamblaje y testado del HW - Diseño, planificación y despliegue de la infraestructura - Desarrollo y mejora del SW - Creación y venta de propuestas al cliente - Control de drones desde los centros de supervisión Key Resources - Flota de drones - SW de detección de personas en el agua y de desplazamiento autónomo - Relación de confianza con instituciones públicas - Centros de supervisión - Datos (imágenes recogidas y etiquetadas con distintas clases)	Value Propositions - Salvar vidas: lo que proporciona mejor calidad de vida y ahorra gastos - Evitar excesivo gasto en personal de socorrismo - Mejorar la imagen para sectores públicos - Aumento del turismo en playas	Customer Relationships - Creación de propuesta personalizada para el cliente y venta en persona - Periodos de prueba - Instalación - Gestión del producto por suscripción: - Mantenimiento y reparaciones - Mejora y actualización del SW y HW - Supervisión en los centros de control Channels - Representantes de ventas en persona - Página web	Customer Segments - Ayuntamientos o comunidades de zonas costeras - Ayuntamientos de zonas de ríos y pantanos - Urbanizaciones privadas en zonas de pantanos
Cost Structure - Costes fijos: personal (desarrollador del SW, diseñador del HW, ventas, controladores...), marketing, infraestructura (alquiler espacio para centros de control, HW de control, servidores y página web, bases de datos y TPUs), mantenimiento de drones. - Costes variables: HW (cada uno de los drones) e instalación en emplazamientos seguros.	Revenue Streams - Compra inicial del producto: HW+SW+Instalación - Pagos recurrentes por suscripción - Renovación del HW - Publicidad/patrocinadores			

6.4. Tercera iteración: experimentos con cliente

El objetivo de la tercera iteración es ver como respondería el cliente ante el proyecto y las características concretas del producto como precio y tiempo hasta rescate. Como se ha dicho previamente, se consideran clientes a los ayuntamientos y autonomías al cargo de costas y otros espacios acuáticos.

6.4.1. Hipótesis

1. El cliente reduce en más de 50 % sus gastos actuales con la implementación del producto.
2. Los socorristas tienen necesidad de refuerzo en la seguridad de las costas.
3. El cliente está dispuesto a pagar 4.000€ por dron inicialmente y 600€ de forma recurrente al año.
4. El cliente opina que es adecuado tener 1 dron cada 2 kilómetros y que tiempo medio hasta salvamento sea de 1.9 minutos.

6.4.2. Experimento 1 - Cálculo de beneficios

El primer experimento tiene como fin demostrar que la implementación del producto tendría un coste inferior al coste actual. Este coste se entiende no solo en términos de impacto social; sino también del impacto económico causado por un accidente mortal.

Según un estudio hecho por la DGT, cuando hay una víctima mortal, se incurre en tres tipos de costes:

1. Costes administrativos
2. Costes materiales
3. Costes asociados a las víctimas

Esto genera un coste para el estado de aproximadamente 1.3 millones de euros por cada víctima mortal, es lo que se conoce como *valor de una vida estadística (VVE)*. [64]

Para hacer la comparación, en primer lugar se tiene en cuenta que en España al año hay mínimo 300 víctimas mortales en entornos sin vigilar. Esto supone un gasto total de 390 millones de euros al año en España, es decir, 3.900 millones de euros cada 10 años.

Coste por muerte 1 persona	1.300.000 €
Media de personas	300
Coste total (año)	390.000.000 €
Número de años	10
Coste total 10 años	3.900.000.000 €

Figura 6.32: Costes actuales

Por el contrario, si se implementase la solución de drones en toda España, se necesitarían aproximadamente 2.000 drones como se explica en la sección 7.4. Definiendo un coste inicial por dron de 4.000€y un coste anual de 600€, el proyecto total tendría un coste de 20 millones de euros cada 10 años.

Numero de drones	2000
Coste inicial por dron	4.000 €
Coste inicial total	8.000.000 €
Costes recurrentes por dron	600 €
Costes recurrentes por año	1.200.000 €
Número de años	10
Coste recurrente total en 10 años	12.000.000 €
Coste total en 10 años	20.000.000 €

Figura 6.33: Costes con proyecto ANGEL

Por tanto, se puede ver que con este proyecto los costes quedan reducidos a un 0.5 % del coste actual.

6.4.3. Experimento 2 - Entrevistas a socorristas

En esta sección se hizo una entrevista a socorristas en una playa de Mallorca con el objetivo de comprobar sus necesidades actuales y su reacción al producto. Concretamente es la playa de Sa Canova, que tiene casi dos kilómetros de longitud y se considera una de las playas más peligrosas de Mallorca debido a su oleaje y corrientes.



Figura 6.34: Playa de Sa Canova

Según Marcos y Alexis, a día de hoy falta un gran número de socorristas en playas, sobre todo en lugares como las islas. Ponen el ejemplo, de que ellos son los únicos encargados de controlar y hacer rescates en Sa Canova, a pesar de su longitud y peligrosidad. Además, enfatizan que el servicio de socorrismo se encuentra activo solo hasta las 5 de la tarde, que es la hora punta a la que llega la gente. Todo ello hace que pierdan capacidad de reacción y de salvamento; lo que en los últimos años ha generado problemas, por ejemplo, el año pasado murieron dos personas. Dicen que por muy atentos que están, tardan aproximadamente 10 minutos en responder a una emergencia, así que en general aunque vayan a hacer prevención acaban haciendo rescate.

Sobre la forma de gestión de las playas cuentan que ellos están contratados por empresas privadas que contratan los ayuntamientos. Es cada ayuntamiento el que elige los recursos mínimos que quiere tener, lo que causa problemas en playas controladas por varios ayuntamientos. Por ejemplo, ellos solo tienen control de tres cuartos de la playa y en el otro cuarto no tiene socorristas, entonces si hubiese un problema teóricamente no podrían intervenir. Dicen que lo que priorizan los ayuntamientos es reducir costes, sobre todo en zonas con pocos hoteles y resorts, que consideran menos turísticas.

A continuación, se les planteó la idea de los drones para playas sin vigilar. Consideraron que es una gran idea, no solo para playas sin vigilar donde les parece una forma fácil y práctica de reducir ahogamientos; sino también en playas vigiladas como complemento para ellos. Dicen que les ayudaría a reducir el estrés de las personas durante un rescate proporcionándoles un salvavidas al que aferrarse hasta que ellos lleguen. Además, dicen que en muchas ocasiones aunque ellos vayan con un salvavidas, la persona desesperada se agarra antes a ellos, lo que pone en peligro sus vidas. Con este sistema minimizarían estos casos.

Finalmente, enfatizan que una parte muy importante de su trabajo es tranquilizar a las personas durante un rescate. Por ello, consideran que el dron debería llevar algún tipo de altavoz que permitiese reproducir la voz del controlador o una grabación, de manera que se informase a la víctima de que está siendo rescatada, de que su posición está controlada y de que los servicios de emergencias están a 5 minutos. De esta forma se reduciría el impacto psicológico en la persona.



Figura 6.35: Marcos y Alexis, socorristas de la playa de Sa Canova

6.4.4. Experimento 3 - Presentación a cliente

En este experimento se decide crear un tríptico con la información que se presentaría a un cliente sobre el producto. Se incluye la imagen de marca, el contacto, la descripción técnica del producto, posibles beneficios para el cliente, precios, y un ejemplo de despliegue en su localidad concreta. En este caso el ayuntamiento que se elige es el de Tapia de Casariego debido a que es una zona conocida y donde se puede acceder con más facilidad a los clientes.

El tríptico presentado a continuación, está diseñado para ir doblado por las líneas rayadas (que no existirían en la realidad). La primera página corresponde a la cara exterior del tríptico con la portada, contra-portada y doblez interior; y la segunda página a la cara interior.

¿Quiénes somos?

// ANGEL surge de la necesidad de poner la innovación tecnológica al servicio de la sociedad.

Anualmente mueren ahogadas en España una media de 400 personas al año, la mayoría en zonas de costa no vigiladas.

Nuestra misión es ofrecer un sistema de salvamento a través de drones autónomos que garantice la seguridad de todas las costas y reduzca el número de ahogamientos. //



Marina Alonso Parra
Fundadora

¿Quieres saber más?



proyectoangel@gmail.com




www.proyectoangel.com



+34 91 356 87 62



Calle Alberto Aguilera 31.
28015, Madrid, España



Sistema de salvamento
en playas a través de
drones autónomos

¿Cuál es nuestro producto?

El sistema está formado por una flota de drones autónomos con inteligencia artificial. Cada dron tiene acoplado un chaleco salvavidas autohinchable y está conectado por 4G a un Centro de Control que supervisa todas las operaciones de rescate.

Los drones están desplegados a lo largo de la costa sobre estaciones base, cada una equipada con un solo dron y situada a aproximadamente dos kilómetros de distancia de la siguiente. De esta manera que todo el territorio quede bajo la supervisión de un dron.

Mediante una llamada al 112 el operador libera el dron más cercano que inmediatamente se dirige hacia el mar y usando un sistema de detección de objetos basado en aprendizaje profundo, localiza a la persona en peligro.



Una vez localizada, el dron se acerca y se libera el chaleco salvavidas que al contacto con el agua se hincha, proporcionado un soporte el tiempo suficiente para que los socorristas puedan proceder al rescate.

¿Qué ofrecemos?

Resulta imposible para los ayuntamientos costeros garantizar la vigilancia de toda su costa las 24h, limitándose por ello a las playas más transitadas en horarios de 9h a 19h y en temporada alta. Por este motivo, todavía se producen una gran cantidad de ahogamientos todos los años, la mayoría de ellos en zonas no vigiladas.

ANGEL ofrece una capa adicional de protección a los bañistas y un apoyo al sistema de salvamento actual, ofreciendo la posibilidad de evitar decenas de ahogamientos al año tan solo en España.

De este modo no solo se consigue evitar la tragedia humana asociada a la muerte de un familiar o amigo; sino también el enorme coste económico que supone al ayuntamiento.


Gracias el relativamente bajo coste de implementación del sistema ANGEL estamos seguros de que contaremos con la colaboración de las instituciones responsables a los que ofrecemos una solución "llave en mano" que incluye no solo la implementación del sistema, si no también el mantenimiento y control operativo.

¿Cómo se desplegaría en Tapia de Casariego?

Sabemos que cada costa tiene una longitud y relieve diferente a las demás, y por tanto unas necesidades concretas. Por ello desde ANGEL, nos comprometemos a hacerle una propuesta detallada del despliegue necesario para cubrir su ayuntamiento.

La costa del ayuntamiento de Casariego tiene 18 kilómetros. Por ello, resulta necesario desplegar 9 drones más o menos equidistantes, para garantizar el que el tiempo medio hasta salvamento sea de 2 minutos.

Un posible despliegue sería el siguiente:



Los drones estarán controlados por el centro de control del área norte de España, y no se superará nunca un número máximo de 300 drones por controlador.

El **precio del sistema** será:

- Pago inicial: 4000€ por dron
- Pago anual: 600€ por dron

Donde el pago anual incluye el mantenimiento del SW y HW, gestión de centros de control y mejora continua del SW.




Figura 6.36: Estructura tríptico

6.4.5. Conclusiones

Gracias a esta iteración, se ha podido obtener una idea más precisa sobre las necesidades del cliente.

Hipótesis 1: El cliente reduce en más de 50 % sus gastos actuales con la implementación del producto. Validada al 100 %

Comparando el coste de despliegue de la solución y el *valor de una vida estadística*, se ha podido ver que gracias al proyecto se reduce el coste al 0.5 % del actual. Este dato refuerza la propuesta de valor para el cliente, y se puede usar como argumento durante la presentación del producto para conseguir venderlo.

Hipótesis 2: Los socorristas tienen necesidad de refuerzo en la seguridad de las costas. Validada al 70 %

Como se pudo ver en la entrevista con Marcos y Alexis, actualmente los socorristas carecen de suficientes efectivos y necesitan refuerzos en playas. Consideran que el despliegue de drones sería de gran ayuda para reducir los accidentes, y para auxiliarles en su trabajo. La hipótesis está validada solo al 70 % ya que sería necesario hacer más entrevistas a otros socorristas para conseguir una visión más generalizada.

Hipótesis 3: El cliente está dispuesto a pagar 4.000€ por dron inicialmente y 600€ de forma recurrente al año.

Hipótesis 4: El cliente opina que es adecuado tener 1 dron cada 2 kilómetros y que tiempo medio hasta salvamento sea de 1.9 minutos.

Finalmente, para validar las hipótesis 3 y 4, se ha desarrollado el tríptico de presentación del producto para el cliente. Sin embargo, no se ha podido poner en

práctica el experimento, ya que no ha sido posible contactar con los ayuntamientos por a la imposibilidad de ir de forma presencial y los largos tiempos de espera para ser recibido. Por ello, quedaría como próximos pasos del proyecto.

6.4.6. Modificación del modelo de negocio

Tras esta iteración se ha modificado ligeramente el producto, añadiéndole un altavoz al dron. De esta forma se puede tranquilizar a una persona hasta que lleguen los servicios de rescate y transmitirle instrucciones en caso de ser necesario.

Por otro lado, se ha visto la posibilidad de implementarlo también en playas vigiladas. Puede servir como herramienta de soporte al socorrismo actual; y también para cubrir las playas cuando se termina el servicio de salvamento o en temporadas en las que no hay.

Todo esto se materializa como modificaciones en el BMC. En primer lugar, el uso de un altavoz aumenta los costes variables. En segundo lugar, aumentan los ingresos al ampliar el alcance de los drones a playas vigiladas. Por último, se añade un elemento a la propuesta de valor, que es ayudar a los socorristas actuales en las playas, garantizando su seguridad y efectividad.

Finalmente, es fundamental recoger las opiniones del cliente tras mostrarle el panfleto informativo, para saber si existe la necesidad de cambiar la proposición de valor, el precio o las relaciones con el cliente.

A continuación, se muestra el BMC con las modificaciones hechas:

The Business Model Canvas

Designed for:

Designed by:

Date:

Version:

Key Partners - Productor de drones - Productor de cámaras - Productor de raspberry pi - Empresas de testado de drones - Instituciones públicas - Proveedores de infraestructuras Cloud como Google o AWS.	Key Activities - Diseño, ensamblaje y testado del HW - Diseño, planificación y despliegue de la infraestructura - Desarrollo y mejora del SW - Creación y venta de propuestas al cliente - Control de drones desde los centros de supervisión	Value Propositions - Salvar vidas: lo que proporciona mejor calidad de vida y ahorra gastos - Evitar excesivo gasto en personal de socorrismo - Mejorar la imagen para sectores públicos - Aumento del turismo en playas - Apoyar a los sistemas de socorrismo actuales y aumentar su seguridad y efectividad	Customer Relationships - Creación de propuesta personalizada para el cliente y venta en persona - Períodos de prueba - Instalación - Gestión del producto por suscripción: - Mantenimiento y reparaciones - Mejora y actualización del SW y HW - Supervisión en los centros de control Channels - Representantes de ventas en persona - Página web	Customer Segments - Ayuntamientos o comunidades de zonas costeras - Ayuntamientos de zonas de ríos y pantanos - Urbanizaciones privadas en zonas de pantanos
Cost Structure - Costes fijos: personal (desarrollador del SW, diseñador del HW, ventas, controladores...), marketing, infraestructura (alquiler espacio para centros de control, HW de control, servidores y página web, bases de datos y TPUs), mantenimiento de drones. - Costes variables: HW (cada uno de los drones) e instalación en emplazamientos seguros.	Revenue Streams - Compra inicial del producto: HW+SW+Instalación - Pagos recurrentes por suscripción - Renovación del HW - Publicidad/patrocinadores			

7. Consideraciones financieras

En esta sección se definirá el coste de la inversión inicial y los costes e ingresos generales. Además, hará un cálculo de las proyecciones de ventas de los próximos años y asociado a ello las proyecciones de ingresos y beneficios. Finalmente, se hará un análisis del VAN (valor actual neto) para analizar el valor del proyecto.

7.1. Inversión inicial

En primer lugar, se requiere una inversión inicial que corresponde a los gastos para el lanzamiento del proyecto. Se considera que la primera fase de desarrollo dura 6 meses antes de lanzar el piloto. En estos seis meses se crea la página web [65], imagen corporativa [66] y se trata la constitución legal de la empresa [67]. También, se desarrolla el algoritmo de detección y conducción autónoma y se diseña el HW óptimo. Finalmente, se despliega sobre drones para comprobar el funcionamiento real.

Los costes de diseño del HW y desarrollo del algoritmo, corresponden al trabajo a tiempo completo durante 3 meses de un ingeniero de SW y otro de HW, con el sueldo definido en el apartado 7.2.2.1. El alquiler de equipos está incluido dentro de los gastos del año 0, como se define en 7.2.2.2 y la compra de un dron para pruebas tiene el coste definido en 7.2.1.

Inversión inicial	
Diseño web	1.000 €
Diseño logo e imagen corporativa	400 €
Asesoría legal	700 €
Algoritmo	
Recogida y etiquetado de datos	1.400 €
Desarrollo y entrenamiento algoritmo	9.500 €
Diseño HW	7.250 €
Alquiler equipos para desarrollo	- €
Compra dron para pruebas	1.925 €
Total	22.175 €

Tabla 7.1: Costes inversión inicial

Finalmente, se obtiene una inversión inicial de 22.175€.

7.2. Costes

En esta sección se definen dos tipos de costes: los fijos y los variables. Primeramente, en este apartado se tendrán en cuenta los costes unitarios, y más adelante en el 7.5.1 se considerará como evoluciona la demanda y proporcionalmente los costes.

7.2.1. Costes variables

Los costes variables incluyen, por un lado el coste del dron y por otro lado, el coste del emplazamiento donde se sitúa una vez desplegado en tierra.

7.2.1.1. Coste del dron

En primer lugar, se definen los componentes que forman el sistema del dron. Está compuesto por:

- **Splash Drone 3+:** Cuenta con una autonomía de 22 minutos y una velocidad de vuelo de hasta 60 km/h. Está especialmente diseñado para volar

en condiciones hostiles de viento y lluvia, y poder aterrizar en agua si fuese necesario [68].



Figura 7.1: Splash Drone 3+

- **Raspberry pi 4:** utilizada como controlador de dirección del vuelo del dron y para procesamiento del algoritmo de detección de objetos. [69]
- **Cámara óptica:** utilizada para la detección lejana de ahogamientos. [70]
- **Cámara infrarrojos:** utilizada para aumentar la precisión en detección cercana. [71]
- **Salvavidas:** embedido en una pastilla de sal para ser fácilmente portable por un dron. [72]



Figura 7.2: Pastilla salvavidas

- **Electro imán:** para soltar el salvavidas cuando sea necesario. [73]
- **Altavoz:** para tranquilizar a las personas durante un rescate. [74]

Además, se considera un coste de montaje que corresponde al sueldo de un técnico durante 4 horas.

Los costes se definen a continuación:

Dron	
Dron	1.500 €
Rasperry pi	50 €
Cámara óptica	30 €
Cámara infrarrojos	30 €
Salvavidas	10 €
Electroiman	7 €
Altavoz	17 €
Montaje	56 €
Total	1.700 €

Tabla 7.2: Costes de producción del dron

7.2.1.2. Coste del emplazamiento del dron

En segundo lugar, de cara a la conservación del dron una vez desplegado sobre la costa, se necesita un emplazamiento estanco y a gran altura para evitar vandalismo. Debe incluir un cerrojo remoto que permita al dron salir en caso de emergencia y un panel solar que permita que esté siempre cargado. Finalmente, para la instalación se considera el trabajo de dos técnicos durante 4 horas.

Instalación	
Poste aluminio	40 €
Caja estanca	50 €
Cerrojo remoto	35 €
Panel solar	20 €
Instalación	80 €
Total	225 €

Tabla 7.3: Costes del emplazamiento del dron

Teniendo en cuenta ambos costes, se considera que cada dron tiene un coste de 1.925 €.

7.2.2. Costes fijos

En esta sección se tienen en cuenta los tres costes fijos principales: el coste de personal, el coste de infraestructuras y el coste de mantenimiento de los drones.

7.2.2.1. Coste de personal

Se consideran dos tipos de personal, los que se incluyen en plantilla y los que están contratados por horas. Los sueldos del personal en plantilla, se basan en el sueldo medio en España como se define en plataformas como Jobted, incrementado en 5.000 €. El sueldo variable del representante de ventas, es proporcional a los ingresos por venta de drones.

Contratados por horas (€/h)	
Técnico montaje dron	14 €
Técnico instalación	10 €

Contratados al año (€/año)	
Ingeniero de software	38.000 €
Científico de datos	39.000 €
Representante de ventas [fijo]	21.000 €
Representante de ventas [variable]	1%
Ingeniero de hardware	29.000 €
Planificador del despliegue técnico	25.000 €
CEO	20.000 €
Controlador	24.000 €

Tabla 7.4: Coste de personal

7.2.2.2. Coste de infraestructura

Dentro del coste de infraestructura se consideran en primer lugar los costes de los recursos HW necesarios para el desarrollo del SW. Estos incluyen una TPU para el desarrollo del algoritmo de aprendizaje automático[75], bases de datos [76], servidores para los clientes conectarse y para la propia gestión interna; y finalmente, el coste de la web. Todo ello se aloja en *Cloud*, lo que permite pagar por años de forma elástica en función de la necesidad detectada.

HW para producción del SW (€/año)	
TPU	12.000 €
Bases de datos	5.000 €
Servidor	2.000 €
Web	100 €

Tabla 7.5: Coste de centros de control

En segundo lugar, como se comentó previamente, se desarrollarán unos centros de control que permitirán a un controlador supervisar hasta 300 drones, como medida preventiva en caso de que sea necesario tomar el control. Para ello se consideran dos costes: el de una oficina a 28 €/m y asumiendo que se necesitan 10 metros por controlador; y el del HW de control.

Infraestructura para centro de control (x controlador)	
Alquiler	3.360 €
HW de control	6.000 €
Amortización del HW (5 años)	1.200 €

Tabla 7.6: Coste de recursos Cloud

7.2.2.3. Coste de mantenimiento

Como se ha dicho previamente, dentro de la subscripción anual se incluye el mantenimiento de los drones desplegados. Es un coste dentro del cual se incluye: devolver el dron a su lugar tras un despliegue, reponer el flotador y renovar un dron o alguna parte del mismo en caso de rotura.

Para el cálculo, se desarrollan una serie de probabilidades que están estimadas en función del número de kilómetros de costa en España y el número de ahogamientos al año. Se considera que para cubrir España habría que desplegar 2.000 drones como se define en 7.4 y hay aproximadamente 400 ahogamientos al año. Lo que supone que hay una probabilidad del 20 % de que un dron tenga que actuar en un ahogamiento efectivo. Teniendo en cuenta falsas alarmas y demás condiciones, se define la siguiente probabilidad.

	Coste	Probabilidad	Coste estimado
Devolución dron a posición	10 €	46%	5 €
Flotador	10 €	31%	3 €
Dron roto	1.700 €	3%	52 €
Parte rota	510 €	8%	39 €
Mantenimiento por dron al año			99 €

Tabla 7.7: Coste de mantenimiento

Es decir, un coste de mantenimiento de aproximadamente 100 euros por dron al año.

7.3. Ingresos

En esta sección se define el precio que se cobraría a un cliente por dron, tanto el precio de compra e instalación, como el precio recurrente de mantenimiento.

El precio de compra e instalación se fija a aproximadamente dos veces el coste de producción e instalación, definido en la sección 7.2.1. Del cual se cobrará la mitad antes del proyecto para cubrir los gastos de producción y la mitad al final del despliegue.

El precio de recurrente por dron se fija a 6 veces el de mantenimiento para cubrir no solo este gasto, sino también el de mejora del algoritmo, la tecnología...

Precio drones		
Dron [inicial]	4000	€/dron
Dron [recurrente]	600	€/dron al año

Tabla 7.8: Precios

7.4. Proyecciones de crecimiento en mercado

En esta sección se define el crecimiento esperado del mercado en 10 años. Se consideran dos mercados potenciales, primeramente el mercado español, y en segundo lugar el mercado europeo. Además, se tienen en cuenta los siguientes datos:

- Se necesita un dron por cada 2 kilómetros, como se define en el anexo A.
- España tiene 8.000 kilómetros de costa.
- Europa tiene 382.000 kilómetros de costa.
- Se hace la consideración de que el 50 % de la costa estará cubierta por drones; ya que parte serán acantilados, ciudades... que no los necesiten.

A continuación, en azul se muestran las hipótesis de crecimiento de la cuota de mercado. El año 0, corresponde con el despliegue del piloto en un pueblo de España, el año 1 con el despliegue en una comunidad autónoma y crece hasta el despliegue en toda España, teniendo en cuenta la aparición de competidores. En el caso europeo, en el año 4 se considera un despliegue en Francia y se expande por Europa hasta conseguir un 45 % de cuota de mercado.

Año	Cuota de mercado		Km totales controlados		Km aplicables		Drones totales		Total drones
	España	Europa	España	Europa	España	Europa	España	Europa	
0	2%	0	160	0	80	0	40	0	40
1	13%	0	1.040	0	520	0	260	0	260
2	25%	0	2.000	0	1.000	0	500	0	500
3	30%	0	2.400	0	1.200	0	600	0	600
4	40%	1,3%	3.200	5.000	1.600	2.500	800	1.250	2.050
5	45%	5%	3.600	19.100	1.800	9.550	900	4.776	5.676
6	50%	7%	4.000	26.740	2.000	13.370	1.000	6.686	7.686
7	50%	15%	4.000	57.300	2.000	28.650	1.000	14.326	15.326
8	50%	25%	4.000	95.500	2.000	47.750	1.000	23.876	24.876
9	50%	35%	4.000	133.700	2.000	66.850	1.000	33.426	34.426
10	50%	45%	4.000	171.900	2.000	85.950	1.000	42.976	43.976

Tabla 7.9: Crecimiento del mercado

Se puede ver que se alcanza una suma total de 43 mil drones al final de 10 años. Potencialmente, se podría considerar a partir del año 10, la expansión en otros continentes.

7.5. Proyecciones financieras

Finalmente, en esta sección se evaluarán las proyecciones financieras del proyecto, teniendo en cuenta la evolución esperada del mercado y la evolución asociada en costes e ingresos.

7.5.1. Evolución anual de costes e ingresos

En esta sección, se consideran los costes e ingresos individuales definidos previamente, y se asocia su crecimiento en relación al crecimiento en el tiempo de la venta de drones.

Ingresos											
	Año 0*	Año 1	Año 2	Año 3	Año 4	Año 5	Año 6	Año 7	Año 8	Año 9	Año 10
Número total drones	40	260	500	600	2050	5676	7686	15326	24876	34426	43976
Incremento en drones	40	220	240	100	1450	3626	2010	7640	9550	9550	9550
Ingresos por venta	160.000 €	880.000 €	960.000 €	400.000 €	5.800.000 €	14.504.000 €	8.040.000 €	30.560.000 €	38.200.000 €	38.200.000 €	38.200.000 €
Ingresos por suscripción	24.000 €	156.000 €	300.000 €	360.000 €	1.230.000 €	3.405.600 €	4.611.600 €	9.195.600 €	14.925.600 €	20.655.600 €	26.385.600 €
Ingresos totales	184.000 €	1.036.000 €	1.260.000 €	760.000 €	7.030.000 €	17.909.600 €	12.651.600 €	39.755.600 €	53.125.600 €	58.855.600 €	64.585.600 €
Costes											
Inversión inicial	22.175 €										
COGS	77.000 €	423.500 €	462.000 €	192.500 €	2.791.250 €	6.980.050 €	3.869.250 €	14.707.000 €	18.383.750 €	18.383.750 €	18.383.750 €
Reparación y mantenimiento	3.969 €	25.800 €	49.615 €	59.538 €	203.423 €	563.234 €	762.688 €	1.520.811 €	2.468.465 €	3.416.118 €	4.363.772 €
Infraestructura											
TPU	12.000 €	12.000 €	12.000 €	12.000 €	12.000 €	12.000 €	12.000 €	12.000 €	12.000 €	12.000 €	12.000 €
Bases de datos	5.000 €	5.000 €	5.000 €	5.000 €	5.000 €	10.000 €	10.000 €	10.000 €	15.000 €	15.000 €	15.000 €
Servidor	2.000 €	2.000 €	2.000 €	2.000 €	2.000 €	4.000 €	4.000 €	4.000 €	6.000 €	6.000 €	6.000 €
Web	100 €	100 €	100 €	100 €	100 €	200 €	200 €	200 €	300 €	300 €	300 €
Total	19.100 €	19.100 €	19.100 €	19.100 €	19.100 €	26.200 €	26.200 €	26.200 €	33.300 €	33.300 €	33.300 €
Número controladores (1x300 drones)	1	1	2	2	7	19	26	52	83	115	147
Alquiler	3.360 €	3.360 €	6.720 €	6.720 €	23.520 €	63.840 €	87.360 €	174.720 €	278.880 €	386.400 €	493.920 €
Incremento hardware	6.000 €	- €	12.000 €	- €	42.000 €	78.000 €	78.000 €	246.000 €	252.000 €	480.000 €	480.000 €
Total	9.360 €	3.360 €	18.720 €	6.720 €	65.520 €	141.840 €	165.360 €	420.720 €	530.880 €	866.400 €	973.920 €
Total infraestructura	28.460 €	22.460 €	37.820 €	25.820 €	84.620 €	168.040 €	191.560 €	446.920 €	564.180 €	899.700 €	1.007.220 €
Sueldos											
CEO + directivos [numero]	1	1	1	1	1	2	2	3	4	5	6
CEO [salario total]	20.000 €	20.000 €	20.000 €	20.000 €	20.000 €	40.000 €	40.000 €	60.000 €	80.000 €	100.000 €	120.000 €
Ingeniero de software [numero]	0,5	1	2	2	2	3	3	3	3	3	4
Ingeniero de software [salario total]	19.000 €	38.000 €	76.000 €	76.000 €	76.000 €	114.000 €	114.000 €	114.000 €	114.000 €	114.000 €	152.000 €
Científico de datos [numero]	0	0	0	0	1	1	1	2	2	2	2
Científico de datos [salario total]	- €	- €	- €	- €	39.000 €	39.000 €	39.000 €	78.000 €	78.000 €	78.000 €	78.000 €
Representante de ventas [numero]	0,5	1	1	1	1	2	2	3	3	3	4
Representante de ventas [salario total]	12.100 €	29.800 €	30.600 €	25.000 €	79.000 €	187.040 €	122.400 €	368.600 €	445.000 €	445.000 €	466.000 €
Ingeniero de hardware [numero]	0,5	1	2	2	2	3	3	3	4	4	4
Ingeniero de hardware [salario total]	14.500 €	29.000 €	58.000 €	58.000 €	58.000 €	87.000 €	87.000 €	87.000 €	116.000 €	116.000 €	116.000 €
Planificador del despliegue técnico [numero]	0,5	2	4	4	6	6	8	8	10	10	12
Planificador del despliegue técnico [salario total]	12.500 €	50.000 €	100.000 €	100.000 €	150.000 €	150.000 €	200.000 €	200.000 €	250.000 €	250.000 €	300.000 €
Controlador [numero]	0,5	1	2	2	7	19	26	52	83	115	147
Controlador [salario total]	12.000 €	24.000 €	48.000 €	48.000 €	168.000 €	456.000 €	624.000 €	1.248.000 €	1.992.000 €	2.760.000 €	3.528.000 €
Total salarios	90.100 €	190.800 €	332.600 €	327.000 €	590.000 €	1.073.040 €	1.226.400 €	2.155.600 €	3.075.000 €	3.863.000 €	4.760.000 €

Tabla 7.10: Evolución de costes e ingresos

En primer lugar, se muestran los ingresos de la venta de drones cada año y los ingresos recurrentes por los drones totales desplegados.

En segundo lugar, se definen los costes. Por un lado los COGS (*cost of goods sold*) y el mantenimiento, son proporcionales al número de drones vendidos. Por otro lado, se puede ver la evolución en las infraestructuras:

- **HW Cloud para desarrollo:** se ve que no es necesario aumentarlo en gran medida ya que el algoritmo desarrollado es el mismo para todos los drones. Los recursos se llegan a triplicar para responder al aumento en el número de datos recogidos y de servidores para la conexión de clientes.
- **Centro de control:** se define un número máximo de 300 drones por cada controlador. El crecimiento tanto en superficie de las oficinas/centros de con-

trol, como de el HW necesario; está definido por el número de controladores asociados al número de drones.

Finalmente, hay una evolución en el personal en plantilla. El número de personas en el equipo directivo está relacionado con las necesidades de la expansión internacional, al igual que el número de representantes de ventas. El número de ingenieros de SW y HW también aumenta con el paso del tiempo hasta triplicar su tamaño. A partir del año 5 se contrata un ingeniero de datos. Y finalmente, los responsables de despliegue, que realizan los proyectos por parejas, también aumentan con el aumento en el número de proyectos. Es importante remarcar, que en el año 0 hay muchos puestos en los que hay 0.5 personas debido a que se contratan a partir del mes 6, cuando se lanza el piloto.

7.5.2. Cuenta anual de resultados

La evolución vista en el apartado 7.5.1, hace que haya una evolución en la cuenta anual de resultados, generando más o menos beneficios netos para la compañía. La cuenta de resultados se muestra a continuación, teniendo en cuenta un interés del 4 % anual sobre la inversión inicial y unos impuestos del 25 %.

Cuenta de resultados	Año 0	Año 1	Año 2	Año 3	Año 4	Año 5	Año 6	Año 7	Año 8	Año 9	Año 10
Ingresos por venta de drones	160.000 €	880.000 €	960.000 €	400.000 €	5.800.000 €	14.504.000 €	8.040.000 €	30.560.000 €	38.200.000 €	38.200.000 €	38.200.000 €
Ingresos por suscripción	24.000 €	156.000 €	300.000 €	360.000 €	1.230.000 €	3.405.600 €	4.611.600 €	9.195.600 €	14.925.600 €	20.655.600 €	26.385.600 €
Ingresos netos totales	184.000 €	1.036.000 €	1.260.000 €	760.000 €	7.030.000 €	17.909.600 €	12.651.600 €	39.755.600 €	53.125.600 €	58.855.600 €	64.585.600 €
COGS	77.000 €	423.500 €	462.000 €	192.500 €	2.791.250 €	6.980.050 €	3.869.250 €	14.707.000 €	18.383.750 €	18.383.750 €	18.383.750 €
Beneficio bruto	107.000 €	612.500 €	798.000 €	567.500 €	4.238.750 €	10.929.550 €	8.782.350 €	25.048.600 €	34.741.850 €	40.471.850 €	46.201.850 €
Margen bruto	58%	59%	63%	75%	60%	61%	69%	63%	65%	69%	72%
Gastos											
Infraestructura	22.460 €	22.460 €	25.820 €	25.820 €	42.620 €	90.040 €	113.560 €	200.920 €	312.180 €	419.700 €	527.220 €
Salarios	90.100 €	190.800 €	332.600 €	327.000 €	590.000 €	1.073.040 €	1.226.400 €	2.155.600 €	3.075.000 €	3.863.000 €	4.760.000 €
Mantenimiento	3.969 €	25.800 €	49.615 €	59.538 €	203.423 €	563.234 €	762.688 €	1.520.811 €	2.468.465 €	3.416.118 €	4.363.772 €
OPEX total	116.529 €	239.060 €	408.035 €	412.358 €	836.043 €	1.726.314 €	2.102.648 €	3.877.331 €	5.855.645 €	7.698.818 €	9.650.992 €
EBITDA	-	9.529 €	373.440 €	389.965 €	155.142 €	3.402.707 €	9.203.236 €	6.679.702 €	21.171.269 €	28.886.205 €	32.773.032 €
Depreciación	1.200 €	1.200 €	2.400 €	2.400 €	8.400 €	22.800 €	31.200 €	62.400 €	99.600 €	138.000 €	176.400 €
EBIT	-	10.729 €	372.240 €	387.565 €	152.742 €	3.394.307 €	9.180.436 €	6.648.502 €	21.108.869 €	28.786.605 €	32.635.032 €
Intereses (al 4%)	887 €	887 €	887 €	887 €	887 €	887 €	887 €	887 €	887 €	887 €	887 €
EBT	-	11.616 €	371.353 €	386.678 €	151.855 €	3.393.420 €	9.179.549 €	6.647.615 €	21.107.982 €	28.785.718 €	32.634.145 €
Impuestos (25%)	-	€	92.838 €	96.669 €	37.964 €	848.355 €	2.294.887 €	1.661.904 €	5.276.996 €	7.196.430 €	8.158.536 €
Beneficio neto	-	11.616 €	278.515 €	290.008 €	113.891 €	2.545.065 €	6.884.662 €	4.985.711 €	15.830.987 €	21.589.289 €	24.475.608 €

Tabla 7.11: Cuenta de resultados

Se puede ver la evolución del beneficio neto para la compañía a lo largo de 10 años en la imagen 7.3.




Figura 7.3: Beneficio neto

En el año 0 hay unas pérdidas de aproximadamente 11.000 €, una cifra totalmente normal en una empresa recién creada. A partir del año 1, se recuperan las pérdidas y generan beneficios a raíz del despliegue del primer proyecto importante.

7.5.3. Análisis del valor actual neto del proyecto

Finalmente, se decide hacer un análisis del valor actual neto del proyecto. Se utilizan las cuentas de resultados presentadas anteriormente para calcular el valor del proyecto a día de hoy.

En el año 0, el flujo de caja negativo (CAPEX) corresponde a la inversión inicial. Por otro lado, en el año 10 hay un flujo de caja asociado al valor terminal. Este valor depende del resultado de ese año, de la tasa de crecimiento perpetuo y del WACC (*Weighted cost of capital*). Se considera un WACC de 25 % que, pese a ser una cifra relativamente alta, es la que se está utilizando en empresas de *private equity* para start-ups. También se fija el crecimiento al 7 %, siendo pesimistas con el crecimiento esperado real ya que se considera que el proyecto tiene una proyección y potencial crecimiento mundial.

DCF	Año 0	Año 1	Año 2	Año 3	Año 4	Año 5	Año 6	Año 7	Año 8	Año 9	Año 10
EBIT	- 10.729 €	372.240 €	387.565 €	152.742 €	3.394.307 €	9.180.436 €	6.648.502 €	21.108.869 €	28.786.605 €	32.635.032 €	36.374.458 €
-Impuestos	- €	92.838 €	96.669 €	37.964 €	848.355 €	2.294.887 €	1.661.904 €	5.276.996 €	7.196.430 €	8.158.536 €	9.093.393 €
+Depreciación	1.200 €	1.200 €	2.400 €	2.400 €	8.400 €	22.800 €	31.200 €	62.400 €	99.600 €	138.000 €	176.400 €
OCF	- 9.529 €	280.602 €	293.295 €	117.178 €	2.554.352 €	6.908.349 €	5.017.798 €	15.894.274 €	21.689.776 €	24.614.495 €	27.457.465 €
-CAPEX	- 22.175 €										
-Cambio en NWC											
FCF	1.825 €	156.000 €	300.000 €	360.000 €	1.230.000 €	3.405.600 €	4.611.600 €	9.195.600 €	14.925.600 €	20.655.600 €	26.385.600 €
Valor terminal											156.847.733 €
FCF+VT	1.825 €	156.000 €	300.000 €	360.000 €	1.230.000 €	3.405.600 €	4.611.600 €	9.195.600 €	14.925.600 €	20.655.600 €	183.233.333 €

Tabla 7.12: Flujos de caja

Se calcula el VAN descontando los flujos de caja y se obtiene que el proyecto tiene una valoración de 24,2 millones de euros.

Finalmente, como resulta muy complejo calcular el WACC para una empresa que no está creada y también predecir la tasa de crecimiento perpetuo, se hace un análisis de sensibilidad para diferentes valores.

Crecimiento \ WACC		10%	15%	20%	25%	30%	35%
2%		151.397.692 €	66.864.887 €	35.420.771 €	20.747.173 €	12.996.737 €	8.558.053 €
3%		169.563.390 €	71.045.732 €	36.813.392 €	21.307.080 €	13.249.906 €	8.682.323 €
4%		193.784.321 €	75.986.729 €	38.380.092 €	21.920.312 €	13.522.551 €	8.814.610 €
5%		227.693.625 €	81.915.926 €	40.155.684 €	22.594.868 €	13.817.006 €	8.955.716 €
6%		278.557.580 €	89.162.723 €	42.184.932 €	23.340.429 €	14.136.000 €	9.106.554 €
7%		363.330.838 €	98.221.218 €	44.526.373 €	24.168.830 €	14.482.733 €	9.268.166 €
8%		532.877.355 €	109.867.855 €	47.258.053 €	25.094.690 €	14.860.986 €	9.441.749 €
9%		1.041.516.906 €	125.396.705 €	50.486.403 €	26.136.283 €	15.275.264 €	9.628.685 €
10%			147.137.094 €	54.360.423 €	27.316.755 €	15.730.969 €	9.830.575 €

Tabla 7.13: Análisis de sensibilidad

Se puede ver que en el mejor de los casos el VAN es de más de 1.000 millones de euros; y en el peor de los casos de aproximadamente 10 millones de euros. Siguiendo la norma general que dice que para VAN mayor que 0 se hace un proyecto, se puede afirmar que este proyecto es viable económicamente.

7.6. Conclusiones

En esta sección se ha realizado un análisis de la evolución de costes e ingresos asociados a un crecimiento estimado del mercado.

Se puede ver que con las estimaciones hechas se pierde dinero el año 0, pero a partir del año 1 se recupera. Lo que implica que es una empresa que puede dar beneficios a largo plazo. Además, cuando se hace el análisis del VAN, hasta en el peor de los casos se obtiene una valoración de 10 millones de euros. Por lo que tendría que haber una gran diferencia entre las estimaciones actuales y las reales para que la empresa no fuese rentable.

Por tanto, se concluye que desde un punto de vista financiero el proyecto puede constituir una empresa con beneficios y sostenible en el tiempo.

8. Conclusiones

8.1. Conclusiones del proyecto

Como se ha comentado previamente, el objetivo de este proyecto ha sido diseñar, validar y desarrollar un modelo de drones salvavidas autónomos basados en inteligencia artificial. Para ello siguiendo la metodología *lean* se han realizado tres iteraciones del modelo de negocio y finalmente, se han desarrollado las proyecciones financieras.

Primera iteración

La primera iteración estuvo basada en experimentos con el cliente a través de entrevistas y encuestas. De ella se pudieron obtener distintas conclusiones.

En primer lugar, con respecto al producto, se confirmó que se podía hacer la llamada de auxilio a través de un número de emergencias ya que **todos los usuarios llevan el móvil a la playa**. Por otro lado, se llegó a la conclusión de que se requieren **señales explícitas que anuncien la posibilidad de usar el sistema** (como banderas), ya que usar carteles sería poco eficiente y la gente no los leería ni conocería el producto. También se pudo confirmar que **la gente confiaría en el tratamiento de sus datos por una organización externa** y que irían más a la playa si fuese más segura.

Finalmente, la conclusión más importante obtenida es que **la gente no confía en sistemas puramente autónomos**, lo que obliga pivotar el modelo de negocio hacia un sistema controlado por un humano. De este modo, se propone **establecer unos centros de control** que remotamente permitan supervisar varios drones a la vez y tomar control del sistema autónomo si fuese necesario.

Segunda iteración

La segunda iteración consistió en la creación de un MVP con el fin de comprobar la viabilidad del proyecto desde un punto de vista tecnológico, y además crear un producto que pueda ser mostrado a un cliente como parte del proceso de venta.

El MVP consistió en un algoritmo de *deep learning* que desde el aire, detectase a personas en el agua. Con pocas imágenes de entrenamiento, se consiguió obtener una **precisión y exhaustividad mayores del 70 %**, lo que implica que el modelo es capaz de detectar personas y que es un problema realizable desde el punto de vista tecnológico. Además, el **tiempo de detección era de 1.2ms** por imagen, por lo que se puede realizar la detección a tiempo real.

Como elementos de mejora, se vio que para aumentar la precisión se requería **entrenar el algoritmo con más cantidad de imágenes**. También habría que tener en cuenta los otros elementos del mar, no solo los bañistas; para evitar los sesgos y falsos positivos debido a objetos desconocidos como rocas. Finalmente, se vio que para un despliegue real, donde es necesario aumentar la precisión y donde el número de imágenes será mucho mayor, es necesario **utilizar HW de procesamiento más especializado** como TPUs.

Tercera iteración

La tercera iteración estuvo basada en experimentos con el cliente. Consistió en un estudio económico sobre los costes que actuales y futuros para el cliente, entrevistas a socorristas y finalmente, una presentación del producto al cliente potencial.

En primer lugar, se pudo concluir que en base al valor de una vida estadística, este proyecto **reduciría en gran medida costes** al eliminar a través de un sistema poco costoso, los gastos por fallecimientos. En segundo lugar, se pudo ver que el sistema de salvamento por drones **resulta de gran utilidad para los servicios de socorrismo** ya implementados; ya que sería un soporte cuando estén los socorristas y ayudaría en gran medida a evitar ahogamientos cuando no estuviesen. Sin embargo, habría que realizar más entrevistas para profundizar más y obtener diferentes opiniones.

Por último, se realizó una presentación para conocer la opinión del cliente, pero no fue posible llevarla a cabo por problemas de tiempo y administración. Se incluye como próximos pasos para seguir avanzando en el desarrollo del modelo.

Estudio financiero

Finalmente, el estudio financiero incluyó costes, ingresos y proyecciones de crecimiento en el mercado. Se pudo ver que siguiendo las estimaciones de crecimiento del mercado, el proyecto tiene un flujo de caja negativo durante el año 0, pero lo recuperaría y **empezaría a tener beneficios a partir del año 1**. Calculando el VNA, se puede ver que para cualquier tasa de crecimiento y WACC es superior a 0, lo que implica que **el proyecto siempre genera valor**. Además, se considera que se termina en el año 10 con la expansión en Europa, pero potencialmente se podría ampliar para expandirse a otros continentes. Todo ello hace concluir que **el proyecto es viable económicamente y se debería llevar a cabo**.

8.2. Próximos pasos

Como se ha dicho previamente, este proyecto sigue la metodología *lean*. Esto quiere decir que aunque se han hecho 3 iteraciones, es necesario seguir iterando y probando para perfeccionar el modelo.

Para ello se definen los siguientes próximos pasos:

Con respecto a la experiencia de usuario

Previamente, se han hecho entrevistas y encuestas sobre los comportamientos de los usuarios en la playa, y su potencial forma de interactuar con el producto. Se propone como siguiente paso, comprobar la reacción del usuario en un despliegue semi-real. Para ello se puede hacer un MVP en una playa, se desplegaría el sistema de señalización pensado y las instrucciones. Se harían pruebas como encuestas para ver si los usuarios se han dado cuenta, si sabrían usarlo y cómo de efectiva ha sido la señalización. Además, se propone realizar varias simulaciones a través del despliegue de un dron de prueba para demostrar como cae un salvavidas, o como se haría un rescate y ver las reacciones reales de los usuarios al producto.

Con respecto al producto

En este proyecto, se ha desarrollado una versión básica del producto final. Todavía sería necesario hacer más iteraciones antes de conseguir un modelo que se pueda desplegar de forma real. Las siguientes modificaciones incluyen:

1. Aumentar el número de datos actuales (más imágenes y más clases) y entrenar el algoritmo de detección con un HW más potente, para crear un modelo

más complejo.

2. Implementar la lógica que diferencia un bañista de una persona que se está ahogando (en función de su posición relativa a otros objetos, de su expresión, temperatura corporal...)
3. Implementar el programa que gestione la llamada de emergencia y asociada a ella, la liberación del dron.
4. Implementar el movimiento autónomo del dron para recorrer la playa hasta detectar el ahogamiento.
5. Desplegar y probar un piloto en una playa real.

Con respecto al cliente

Previamente, se ha desarrollado una presentación para un cliente que incluía un despliegue personalizado. Sin embargo, como se ha dicho antes, no se ha podido presentar realmente por complicaciones en la administración. Por ello, el siguiente paso sería conseguir acceder a un cliente, hacer la presentación y recoger sus opiniones ante la propuesta. Además, sería interesante conseguir desarrollar un piloto que permita probar la idea y servir de campaña de marketing.

Tras la implementación del piloto y perfeccionamiento del producto, también sería necesario reevaluar los costes y fijar nuevos precios. Se ha podido ver que con el precio actual el cliente reduce en gran medida sus costes, por lo que se piensa que se podría aumentar manteniendo el atractivo del producto.

Finalmente, también sería necesario realizar más entrevistas a equipos de socorrismo. El objetivo es comparar distintas opiniones y descubrir las verdaderas necesidades de los socorristas, u otros hechos que se puedan estar pasando por alto.

8.3. Comentario final

Durante este trabajo, a través del desarrollo de hipótesis y experimentos, se ha demostrado la viabilidad del proyecto desde distintos puntos de vista, tanto de usuario como de cliente, de producto y financiero. Además, se ha perfeccionado el BMC y se han establecido los siguientes pasos para avanzar en el desarrollo del negocio.

En conclusión, se afirma que se puede desarrollar una *start up* basada en un modelo de negocio de venta, despliegue y subscripción de drones autónomos con inteligencia artificial. De este modo, en un futuro se podrá resolver la problemática de los ahogamientos en las costas y más concretamente en playas sin vigilar.

A. Anexo A: Cálculo del número de drones a desplegar por kilómetro

De cara a poder estimar el número de drones que se despliegan en una costa, es necesario definir cuantos drones se necesitan por kilómetro para funcionar de forma efectiva. Por tanto, en esta sección se decide hacer una estimación de esta cifra en base las capacidades del HW utilizado.

En primer lugar, se utilizan las características del dron definido en la sección 7.2.1. Tiene 22 minutos de autonomía y alcanza una velocidad máxima de 58 km/h. También, se utiliza la cámara óptica definida en 7.2.1 que tiene un ángulo de 60° y una proporción ancho/alto de 1,5. Finalmente, se fija una altura de vuelo de 15 metros para garantizar una foto nítida que permita al algoritmo aumentar la precisión de detección.

Teniendo estos elementos en cuenta se quiere comprobar el tiempo que un dron tardaría en hacer un rescate en una playa de un kilómetro.

Primeramente, se calcula el tiempo necesario en recorrer una vez la playa. Volando a 58 km/h, se recorrería el kilómetro en 1,03 minutos. Sin embargo, hay que tener en cuenta que hay que recorrerla varias veces para cubrir toda la profundidad. El número de veces depende de la superficie que se recoja en la foto en cada pasada. Esta superficie en función del ángulo y la altura sería la mostrada en la imagen siguiente:




Figura A.1: Superficie recogida en foto

Por lo que el dron cada minuto recorrería una franja de un kilómetro de largo y 17m de ancho.

A continuación, se estima la distribución que asocia la probabilidad de que un bañista se encuentre a una determinada distancia de la orilla de la playa y necesite un rescate. Y se calcula el tiempo medio de detectar al bañista, en función de donde está y de la probabilidad de que se encuentre ahí.

Orilla	
17 m	30,0%
35 m	60,0%
52 m	7,0%
69 m	2,0%
87 m	0,5%
104 m	0,3%
121 m	0,2%
1km	

Figura A.2: Probabilidad de que haya una persona ahogándose

Las dos primeras franjas recogen el 90 % de probabilidad ya que la gente no suele bañarse a más de 50 metros de la orilla. Por lo tanto, resulta complicado encontrar a alguien ahí. Además, la segunda franja tiene mayor probabilidad ya que está a más distancia y las víctimas de ahogamientos se suelen dar lejos de la orilla.

Numero franjas	Distancia del bañista (m)	Tiempo hasta rescate (mins)	Probabilidad	Tiempo medio (mins)
1	17,32	1,03	30%	0,31
2	34,64	2,07	60%	1,24
3	51,96	3,10	7%	0,22
4	69,28	4,14	2%	0,08
5	86,60	5,17	0,5%	0,03
6	103,92	6,21	0,3%	0,02
7	121,24	7,24	0,2%	0,01
Total				1,91

Figura A.3: Cálculo tiempo medio en base a probabilidades

En base a esas probabilidades y a la velocidad que tarda un dron en recorrer una franja; podemos ver que el tiempo medio hasta un rescate es de 1,9 minutos.

Finalmente, se puede confirmar que recorrer 1 kilómetro de playa y tardar 1.9 minutos de media en un rescate es razonable para un dron durante una maniobra de salvamento. Esto implica que sería necesario situar un dron cada dos kilómetros de playa, ya que podría intervenir en el kilómetro de su izquierda o de su derecha.

B. Anexo B: Objetivos de desarrollo sostenible

B.1. Introducción a los ODS

Los ODS (objetivos de desarrollo sostenible) son un llamamiento a todas las naciones para reducir la pobreza y desigualdad, conservar el medio ambiente y mejorar las vidas de todas las personas. Se definieron en 2015 por los miembros de la ONU y son 17 metas y 169 objetivos a cumplir antes de 2030^[77]. Las metas se centran en 5 áreas:

- **Personas:** enfocado en reducir la pobreza y las desigualdades.
- **Prosperidad:** asegurar vidas completas para todas las personas del planeta tanto económicamente, como tecnológica y socialmente.
- **Paz:** Sociedades libres de violencia.
- **Planeta:** evitar el cambio climático, usar energía limpia, garantizar la calidad del agua...
- **Asociación:** Alineación de todos los países para cumplir los objetivos y solidaridad.

Este proyecto tiene un carácter claramente social. Se trata de una nueva tecnología que a través de drones e inteligencia artificial permite salvar vidas de forma económica. De este modo se mejora la calidad de vida, la salud y además, a largo plazo, permite reducir las desigualdades en el mundo. El proyecto está alineado con varios de los ODS fijados por la ONU.



Figura B.1: Objetivos de desarrollo sostenible[77]

B.2. ODSs primarios

3. Salud y bienestar

El ODS 3 tiene como objetivos garantizar una vida sana y promover el bienestar para todas las edades, como fundamento para el desarrollo sostenible.

Este proyecto está directamente alineado con este objetivo ya que aumentando la seguridad en las playas se consigue reducir el número de muertes y accidentes graves; mejorando así el bienestar de las personas y su calidad de vida. Además, se refuerza la seguridad para los grupos más vulnerables como niños y ancianos.



9. Industria, innovación e infraestructuras

El ODS 9 trata de fomentar la industrialización sostenible, creación de infraestructuras, promover el uso de nuevas tecnologías y la innovación. Todo ello con el objetivo de crear dinámicas económicas que aumenten el empleo y los ingresos.

Este proyecto basado en tecnologías tan novedosas como los drones, la inteligencia artificial y el *deep learning*, es una clara demostración de la implementación innovadora de tecnología y creación de infraestructuras sostenibles con el objetivo de fomentar la seguridad y sostenibilidad.



10. Reducción de desigualdades

Este objetivo está alineado con la dimensión social de los ODSs. Su finalidad es promover inclusión de las personas sin importar su etnia, raza, sexo, edad u orientación sexual. Además, trata de implementar políticas que lleven a la igualdad, garantizar la seguridad independientemente de la nacionalidad y dar más peso en la política mundial a los países en vías de desarrollo.

Como se dijo en la introducción, el 90 % de los ahogamientos se producen en países en vías de desarrollo. Estos países no cuentan con las mismas medidas de seguridad que los demás, debido al alto coste que tendrían. Este proyecto propone una solución de bajo coste que se podría desplegar a gran escala en estos países garantizando la seguridad y reduciendo en gran medida el número de muertes.



11. Comunidades y ciudades sostenibles

El objetivo 11 tiene que ver con la creación de ciudades sostenibles donde todas las personas tengan acceso a viviendas y servicios básicos, sistemas de transporte seguros, garantizar la urbanización inclusiva...

Este proyecto está directamente relacionado con el objetivo 11.5 ya que trata de reducir el número de muertes causadas por los desastres naturales, incluidos los relacionados con el agua y las pérdidas económicas asociados a ellos.



B.3. ODSs secundarios

7. Energía asequible y no contaminante

Este objetivo forma parte del eje relacionado con el cuidado del planeta. Sus metas son aumentar la proporción de energía renovable, invertir en tecnologías e infraestructuras impulsadas por energías limpias...

El proyecto de drones autónomos cumple de forma secundaria este objetivo al utilizar paneles solares como la principal fuente de energía para los drones. De esta forma toda la red desplegada estará alimentada con energía solar, evitando el uso



de otro tipo de energías contaminantes.

8. Trabajo decente y crecimiento económico

El objetivo 8 tiene como metas mantener el crecimiento económico, aumentar la productividad mediante la modernización y diversidad, lograr empleo pleno... Este proyecto, si finalmente se convirtiese en empresa, podría ofrecer numerosos puestos de trabajo en diferentes regiones del mundo, tanto para personas con formaciones universitarias como para las que no. Contribuyendo así a lograr el “empleo pleno”.



Bibliografía

- [1] World Health Organization. *Drowning*. "<https://www.who.int/news-room/fact-sheets/detail/drowning>.
- [2] Real Federación Española de salvamento y socorrismo. "Informe nacional de ahogamientos". En: (2020).
- [3] Statista. *Número de playas marítimas en España en 2020, por comunidad autónoma*. <https://es.statista.com/estadisticas/859375/playas-maritimas-por-comunidad-autonoma-espana/>.
- [4] David Jimenez. *Cuatro de cada diez playas en España no tienen socorrista*. https://www.cope.es/actualidad/sociedad/noticias/cuatro-cada-diez-playas-espana-tienen-socorrista-20190826_485203.
- [5] Rubén Míguez. *Los socorristas de playa reclaman una regulación nacional que determine la vigilancia para evitar ahogamientos*. <https://www.informacion.es/vega-baja/2021/08/04/socorristas-playa-reclaman-regulacion-nacional-55915900.html>.
- [6] Virginia Martinez. *¿Quién paga al socorrista?* https://elpais.com/politica/2017/08/07/actualidad/1502099394_812573.html.
- [7] Enrique Fernández. *Cuánto gana un socorrista en España: este es el sueldo y lo que necesitas hacer para conseguir el trabajo*. <https://www.businessinsider.es/cuanto-gana-socorrista-espana-881183>.
- [8] General Drones. *El material que utilizan los rescatadores en playas*. <https://generaldrones.es/material-salvamento-socorrismo/>.
- [9] <https://coastalsafetygroup.com.au/about>.
- [10] Rebecca Cairns. *Can an AI lifeguard make beaches safer?* <https://edition.cnn.com/travel/article/ai-lifeguards-smart-beaches-spc-intl/index.html>.
- [11] <https://www.sightbit.com>.

-
- [12] Sarah Wells. *AI could solve summer's deadliest problem*. <https://www.inverse.com/innovation/ai-lifeguard-to-save-the-day>.
- [13] Nacho Castañón. *El robot autónomo que jubilará a socorristas: identifica a quien se ahoga y le rescata*. https://www.lespanol.com/omicron/tecnologia/20210307/robot-autonomo-jubilara-socorristas-identifica-ahoga-rescata/563693852_0.html.
- [14] General Drones. <https://generaldrones.es/auxdron/>.
- [15] Las Naves. *Las playas de Mallorca contarán este verano con el dron de salvamento Auxdron Lifeguard del Collab*. <https://www.lasnaves.com/las-playas-de-mallorca-contaran-este-verano-con-el-dron-de-salvamento-auxdron-lifeguard-del-collab>.
- [16] Aerocamaras. *Dron Híbrido AeroHyb, el dron con más autonomía del mercado*. <https://dronehibrido.com/es/>.
- [17] Drones 'marca España' para transportar material sanitario en época de la Covid-19. https://www.consalud.es/saludigital/271/drones-transportar-material-sanitario-tiempos-covid-19_103172_102.html.
- [18] Abderahman Rejeb y col. "Humanitarian Drones: A Review and Research Agenda". En: (2021).
- [19] Javier Jiménez. *Drones, robots y satélites contra el fuego: las nuevas tecnologías van a por los incendios forestales*. <https://www.xataka.com/ecologia-y-naturaleza/drones-robots-y-satelites-contra-el-fuego-las-nuevas-tecnologias-tienen-un-papel-fundamental-en-los-incendios-forestales>.
- [20] Redacción Nius. *Salvamento Marítimo 2.0: el Gobierno invierte 19 millones en Inteligencia Artificial y drones de rescate y vigilancia*. https://www.niusdiario.es/nacional/politica/salvamento-maritimo-inteligencia-artificial-vigilancia-drones-proyecto-isar_18_3107220282.html.
- [21] Jonathan Heist. *Autonomous drone vs self-flying drones, what's the difference?* <https://dronerush.com/autonomous-drone-vs-self-flying-drones-10653/>.
- [22] SRM consulting. *Drones autónomos, definición y clasificación*. <https://srmconsulting.es/uncategorized/drones-autonomos-definicion-y-clasificacion/>.
- [23] Izan Gonzalez. *DHL comienza a usar drones autónomos en sus centros logísticos de España*. https://www.lespanol.com/omicron/tecnologia/20200617/dhl-comienza-drones-autonomos-centros-logisticos-espana/498450542_0.html.

-
- [24] Nicolas Puentes. *Qué es Computer Vision*. <https://www.nebulova.es/blog/computer-vision>.
 - [25] Shipra Saxena. *5 Exciting Computer Vision Applications With Relevant Datasets!* <https://www.analyticsvidhya.com/blog/2020/07/5-exciting-computer-vision-applications-with-relevant-datasets/>.
 - [26] Cooch. *AI in drones for computer vision*. <https://chooch.ai/drone-ai/>.
 - [27] CLEMENS VIERNICKEL. *Computer Vision Startups Enhancing Security Surveillance*. <https://www.siasearch.io/blog/computer-vision-startups-security-surveillance>.
 - [28] https://www.linkedin.com/posts/doronbd_robots-security-technology-activity-6891275596346056704-HoSA/.
 - [29] Shipra Saxena. *Los drones aportan nuevas soluciones a la Industria 4.0*. <https://dynatec.es/2021/01/24/los-drones-aportan-nuevas-soluciones-a-la-industria-4-0/>.
 - [30] *The best fruit pickers in the world, by FAR*. <https://www.tevel-tech.com>.
 - [31] Interaction Design Foundation. *What is Design Thinking?* <https://www.interaction-design.org/literature/topics/design-thinking>.
 - [32] Alexander Cowan. *YOUR LEAN STARTUP*. <https://www.alexandercowan.com/creating-a-lean-startup-style-assumption-set/>.
 - [33] <https://opencv.org>.
 - [34] https://www.tutorialspoint.com/opencv/opencv_overview.htm.
 - [35] Scikit learn. <https://scikit-learn.org/stable/about.html>.
 - [36] <https://pytorch.org>.
 - [37] Rahul Patwardhan. *How Does Machine Learning Encompass Computer Vision?* <https://www.weka.io/blog/computer-vision-vs-machine-learning/>.
 - [38] *Computer Vision Pipeline, Part 1: the big picture*. <https://freecontent.manning.com/computer-vision-pipeline-part-1-the-big-picture/>.
 - [39] *Computer Vision Pipeline, Part 3: image preprocessing*. <https://freecontent.manning.com/the-computer-vision-pipeline-part-3-image-preprocessing/>.
 - [40] Krut Patel. *Image Feature Extraction: Traditional and Deep Learning Techniques*. <https://towardsdatascience.com/image-feature-extraction-traditional-and-deep-learning-techniques-ccc059195d04>.
 - [41] *The Computer Vision Pipeline, Part 4: feature extraction*. <https://freecontent.manning.com/the-computer-vision-pipeline-part-4-feature-extraction/>.

- [42] Rahul Patwardhan. *Computer Vision vs. Machine Learning — How Do They Relate*. <https://www.weka.io/blog/computer-vision-vs-machine-learning/>.
- [43] Humboldt-Universität zu Berlin. *Image classification - Decision Trees*. https://pages.cms.hu-berlin.de/EOL/geo_rs/S08_Image_classification1.html.
- [44] Carolina Benton. *Cat or Dog? Introduction to Naive Bayes*. <https://towardsdatascience.com/cat-or-dog-introduction-to-naive-bayes-c507f1a6d1a8>.
- [45] Joaquín Amat Rodrigo. *Máquinas de Vector Soporte*. [https://www.cienciadedatos.net/documentos/34_maquinas_de_vector_soporte_support_vector_machinesm\unhbox\voidb@x\bgroup\let\unhbox\voidb@x\setbox\@tempboxa\hbox{a\global\mathchardef\accent@spacefactor\spacefactor}\let\beginngroup\let\typeout\protect\beginngroup\def\MessageBreak{\Omega\(Font\)}\let\protect\immediate\write\m@ne{LaTeXFontInfo:\def{}}oninputline211.}\endgroup\endgroup\relax\let\ignorespaces\relax\accent19a\egroup\spacefactor\accent@spacefactor\futurelet\@let@token\protect\penalty\@M\hskip\z@skipquinas_de_vector_soporte](https://www.cienciadedatos.net/documentos/34_maquinas_de_vector_soporte_support_vector_machinesm\unhbox\voidb@x\bgroup\let\unhbox\voidb@x\setbox\@tempboxa\hbox{a\global\mathchardef\accent@spacefactor\spacefactor}\let\beginngroup\let\typeout\protect\beginngroup\def\MessageBreak{\Omega(Font)}\let\protect\immediate\write\m@ne{LaTeXFontInfo:\def{}}oninputline211.}\endgroup\endgroup\relax\let\ignorespaces\relax\accent19a\egroup\spacefactor\accent@spacefactor\futurelet\@let@token\protect\penalty\@M\hskip\z@skipquinas_de_vector_soporte).
- [46] Onel Harrison. *Machine Learning Basics with the K-Nearest Neighbors Algorithm*. <https://towardsdatascience.com/machine-learning-basics-with-the-k-nearest-neighbors-algorithm-6a6e71d01761>.
- [47] Imad Dabbura. *K-means Clustering: Algorithm, Applications, Evaluation Methods, and Drawbacks*. <https://towardsdatascience.com/k-means-clustering-algorithm-applications-evaluation-methods-and-drawbacks-aa03e644b48a>.
- [48] *Qué son las redes neuronales y sus funciones*. <https://www.atriainnovation.com/que-son-las-redes-neuronales-y-sus-funciones/>.
- [49] Great Learning Team. *Types of Neural Networks and Definition of Neural Network*. <https://www.mygreatlearning.com/blog/types-of-neural-networks/#multilayeredperceptron>.
- [50] Sumit Saha. *A Comprehensive Guide to Convolutional Neural Networks — the ELI5 way*. <https://towardsdatascience.com/a-comprehensive-guide-to-convolutional-neural-networks-the-eli5-way-3bd2b1164a53>.
- [51] Pranoy Radhakrishnan. *What are Hyperparameters? and How to tune the Hyperparameters in a Deep Neural Network?* <https://towardsdatascience.com/what-are-hyperparameters-and-how-to-tune-the-hyperparameters-in-a-deep-neural-network-d0604917584a>.

-
- [52] Adrian Rosebrock. *Intersection over Union (IoU) for object detection*. <https://pyimagesearch.com/2016/11/07/intersection-over-union-iou-for-object-detection/>.
- [53] Dishashree26 Gupta. *Transfer learning and the art of using Pre-trained Models in Deep Learning*. <https://www.analyticsvidhya.com/blog/2017/06/transfer-learning-the-art-of-fine-tuning-a-pre-trained-model/>.
- [54] Kiprono Elijah Koech. *Object Detection Metrics With Worked Example*. <https://towardsdatascience.com/on-object-detection-metrics-with-worked-example-216f173ed31e>.
- [55] Margrit Kasper-Eulaers. "Short Communication: Detecting Heavy Goods Vehicles in Rest Areas in Winter Conditions Using YOLOv5". En: (2021).
- [56] Pragati Baheti. *What is Overfitting in Deep Learning and How to Avoid It*. <https://www.v7labs.com/blog/overfitting>.
- [57] <https://github.com/tzutalin/labelImg>.
- [58] Lihi Gur Arie. *The practical guide for Object Detection with YOLOv5 algorithm*. <https://towardsdatascience.com/the-practical-guide-for-object-detection-with-yolov5-algorithm-74c04aac4843>.
- [59] <https://github.com/ultralytics/yolov5>.
- [60] <https://ultralytics.com>.
- [61] <https://cocodataset.org/#home>.
- [62] <https://alumentations.ai>.
- [63] Lihi Gur Arie. *Qué PC debo comprar para deep learning?* <https://serverguy.com/comparison/cpu-vs-gpu-vs-tpu/>.
- [64] María Anuncia Ocampo Sánchez. "VALOR MONETARIO DE UN VIDA ESTADÍSTICA Y EL CÁLCULO DE LOS COSTES SOCIALES DE LOS ACCIDENTES DE TRÁFICO". En: (2011).
- [65] *¿Cuánto cuesta una página web?* <https://tuwebdecero.com/cuanto-cuesta-una-pagina-web/>.
- [66] *¿Cuánto cuesta diseñar un logo*. <https://www.cronoshare.com/cuanto-cuesta/disenio-logotipo>.
- [67] *¿Cuánto cuesta la creación de una empresa? Precios 2022*. <https://www.easyoffer.es/blog/precio-crear-empresa/>.
- [68] <https://eswellpro.com/tienda/splash-drone-3-plus/>.

- [69] <https://es.rs-online.com/web/p/raspberry-pi/1822096?src=raspberry>.
- [70] https://www.googleadservices.com/pagead/aclk?sa=L&ai=DChcSEwiMl-fqw_33AhUC3VEKHRN-C5oYABAKGgJ3cw&ae=2&ohost=www.google.com&cid=CAESbeD2jSJ1Yod5NMsZd28YHY9J480sZTJKU1Ek_uYDbCdtU5f9r57LwLnir0j34KPplp815eNUtHTQ&sig=AOD64_1rWjW-8FREvwDyYAEtD3egBX475g&ctype=5&q=&ved=2ahUKEwiby3qw_33AhWhgs4BHabbCokQ9aACKAB6BAGBEFU&adurl=.
- [71] https://www.googleadservices.com/pagead/aclk?sa=L&ai=DChcSEwiXydf0w_33AhWNj2gJHTHOC_EYABAHGgJ3Zg&ohost=www.google.com&cid=CAESbeD2gzJbvmf4y0aIbpA7xYG-kMywb5_Y6qduAXmNdGRupz8ykJbDBJiGchB3GQ5s_N6ZLBXl6AzI1yZ_CWwJ6BzxL3xcCEoiTl2g4RMnF2WZ-V8rzfNVBRTOmXSrKy1KgI4Yw&sig=AOD64_2HUSvkJAtm-mm5Ksd3m1adrP8RzQ&ctype=5&q=&ved=2ahUKEwiEjc_0w_33AhXX_IUKHa9ZAYkQ9aACKAB6BAGBEEU&adurl=.
- [72] <https://inoxidablesdominguez.com/aros-salvavidas-chalecos-y-arneses/1341-pastilla-de-sal-para-chalecos-salvavidas.html>.
- [73] https://www.googleadservices.com/pagead/aclk?sa=L&ai=DChcSEwinh8mYxP33AhX4j2gae=2&ohost=www.google.com&cid=CAESbeD2KcRVo7_IUpkgfsh-0F9el452EJV6a_1wXD3UYSLf1E4NQ59Y29USF0b_xVcoUj-c6Iw2Q5HkHTINaXD8wdG0mZ5tK2D8G8biQSAQVqsE1GxLsig=AOD64_2-ADTuX8aTrPFuxYaNtw-Rd9cGYw&ctype=5&q=&ved=2ahUKEwjboL-YxP33AhWUwoUKHVogDogQ9aACKAB6BAGBEEU&adurl=.
- [74] https://es.farnell.com/monkmakes/sku00077/amplified-speaker-kit-for-raspberry/dp/3446778?gclid=CjwKCAjwkYGVbHArEiwA4sZLuJrptNFpar2wWklPH_6qiKywfs4HHkwxClUrFY2ECOM-KuIp4RmGRBoCoeAQAvD_BwE&mckv=s2uFYimNo_dc.
- [75] <https://cloud.google.com/tpu/pricing?hl=es>.
- [76] <https://cloud.google.com/sql/pricing#sql-server>.
- [77] ONU. *Sustainable development goals*. <https://sustainabledevelopment.un.org/?menu=1300>.