



UNIVERSIDAD ANDINA
NÉSTOR CÁCERES VELÁSQUEZ
FACULTAD DE INGENIERÍA DE SISTEMAS
ESCUELA PROFESIONAL DE INGENIERÍA DE SISTEMAS



**MODELO DE APRENDIZAJE AUTOMÁTICO PARA MEJORAR
LA PRODUCTIVIDAD EN LA PESCA ARTESANAL
EN ANCASH 2023**

TESIS PRESENTADA POR:
Bach. HEYNER MAMANI CHIPANA

PARA OPTAR EL TÍTULO PROFESIONAL DE:
INGENIERO DE SISTEMAS

JULIACA - PERÚ

2025



UNIVERSIDAD ANDINA

NÉSTOR CÁCERES VELÁSQUEZ

FACULTAD DE INGENIERÍA DE SISTEMAS

ESCUELA PROFESIONAL DE INGENIERÍA DE SISTEMAS

**MODELO DE APRENDIZAJE AUTOMÁTICO PARA MEJORAR
LA PRODUCTIVIDAD EN LA PESCA ARTESANAL
EN ANCASH 2023**

TESIS PRESENTADA POR:

Bach. HEYNER MAMANI CHIPANA

**PARA OPTAR EL TÍTULO PROFESIONAL DE:
INGENIERO DE SISTEMAS**

APROBADA POR EL JURADO REVISOR:

PRESIDENTE

:

Dr. JUAN CARLOS HERRERA MIRANDA

PRIMER MIEMBRO

:

Dr. RICHARD CONDORI CRUZ

SEGUNDO MIEMBRO

:

Dr. PAUL MAMANI TISNADO

ASESOR DE TESIS

:

Dr. JUAN BENITES NORIEGA

LÍNEA DE INVESTIGACIÓN:

CIENCIA DE LOS ORDENADORES – P24



RESOLUCIÓN N° 023-2025-UI.S-D-FIS-UANCV-J

Juliaca, 09 de enero de 2025.

VISTOS:

El Expediente: 2025-000242 (fecha y hora de Sustentación) de fecha 09 de enero de 2025 y el expediente: 2025-000241 (título) de fecha 09 de enero de 2025, del (la) bachiller **HEYNER MAMANI CHIPANA** quien *solicita nominación de jurados, fecha y hora de sustentación*, para rendir la sustentación y defensa de la tesis titulada **MODELO DE APRENDIZAJE AUTOMÁTICO PARA MEJORAR LA PRODUCTIVIDAD EN LA PESCA ARTESANAL EN ANCASH 2023**, conducente a la obtención del Título Profesional de **INGENIERO DE SISTEMAS**, que fue revisada por el Director de la Unidad de Investigación y el Decano de la Facultad de Ingeniería de Sistemas, Escuela Profesional de INGENIERÍA DE SISTEMAS.

CONSIDERANDO:

Que, el Director de la Unidad de Investigación autoriza la ejecución de la propuesta de investigación según Resolución Nro. 341-2024-UI.P-D-FIS-UANCV-J (aprobar y autorizar la ejecución de la propuesta de investigación) y con Resolución. Nro. 365-2024-UI.R-D-FIS-UANCV-J (aprobar y autorizar el informe final de la investigación).

Que, de conformidad con el artículo 8°, numeral b) del Reglamento General de Grados y Títulos de la UANCV vigente, es procedente acceder a la petición del interesado.

Que, al haberse cumplido con los requisitos exigidos por el Reglamento Interno de Trabajo de Investigación Conducente a Grados y Títulos plasmado en la Resolución N° 0294-2023-UANCV-CU-R.

Y, estando a la opinión favorable del Director de la Unidad de Investigación y el Decano de la Facultad de Ingeniería de Sistemas, y las atribuciones que confiere el artículo 28° del Reglamento Interno de Trabajo de Investigación Conducente a Grados y Títulos Resolución N° 0294-2023-UANCV-CU-R, que confiere facultades al Decano de la Facultad de Ingeniería de Sistemas.

SE RESUELVE:

ARTÍCULO PRIMERO.- DECLARAR APTO para la sustentación del informe Final de la Investigación (borrador de Tesis) titulada **MODELO DE APRENDIZAJE AUTOMÁTICO PARA MEJORAR LA PRODUCTIVIDAD EN LA PESCA ARTESANAL EN ANCASH 2023**, del bachiller **HEYNER MAMANI CHIPANA**, para optar el Título Profesional de **INGENIERO DE SISTEMAS**, en virtud de los considerandos expuestos.

ARTÍCULO SEGUNDO. - NOMINAR JURADOS para la sustentación y defensa de la tesis a los siguientes docentes:

Presidente : Dr. JUAN CARLOS HERRERA MIRANDA.

Primer miembro : Dr. RICHARD CONDORI CRUZ.

Segundo miembro : Dr. PAUL MAMANI TISNADO.

Asesor: : Dr. JUAN BENITES NORIEGA.

ARTÍCULO TERCERO. - PROGRAMAR FECHA Y HORA de sustentación como se detalla:

Modalidad, Lugar : Presencial , Pabellon de la Facultad de Ingeniería de Sistemas .

Fecha, Hora : 10 de enero de 2025, 14:00 Horas.

ARTÍCULO CUARTO. - DISPONER que la comisión de Grados y Títulos de la facultad, secretarías académicas y administrativas, quedan encargados del cumplimiento de la presente resolución.

Regístrese, comuníquese y archívese.



UNIVERSIDAD ANDINA
"NÉSTOR CÁCERES VELÁSQUEZ"

M.Sc. Juan Carlos Herrera Miranda
DECANO



RESOLUCIÓN N° 365-2024-UI-R-D-FIS-UANCV-J

Juliaca, 19 de Diciembre de 2024

VISTOS:

El Expediente: 2024-CU-19065 de fecha 19 de Diciembre de 2024, del Bach. **HEYNER MAMANI CHIPANA**, quien solicita Revisión del Informe Final de la Investigación (borrador de Tesis) y el Anexo (04 o 05) "Ficha de Opinión del Informe Final de la Investigación (borrador de Tesis)" que fue revisada por el Comité de Investigación de la Facultad de Ingeniería de Sistemas, Escuela Profesional de INGENIERÍA DE SISTEMAS.

CONSIDERANDO:

Que, las Unidades de Investigación son unidades académicas que agrupan a docentes y estudiantes de diversas disciplinas, en razón del desarrollo de investigación científica, tecnológica y humanista de acuerdo al Estatuto Universitario Modificado 2020 de nuestra primera Casa Superior de Estudios.

Que, el (la) Bach. HEYNER MAMANI CHIPANA, quien solicita la revisión del Informe Final de la Investigación (borrador de Tesis) del tema titulada: MODELO DE APRENDIZAJE AUTOMÁTICO PARA MEJORAR LA PRODUCTIVIDAD EN LA PESCA ARTESANAL EN ANCASH 2023, conducente para optar el Título profesional de INGENIERO DE SISTEMAS.

Que, al haberse cumplido con los requisitos exigidos por el Reglamento Interno de Trabajo de Investigación Conducente a Grados y Títulos plasmado en la Resolución N° 0294-2023-UANCV-CU-R.

Que, el Comité de Investigación emitió su opinión favorable al Informe Final de la Investigación (borrador de Tesis).

Que, el Director de la Unidad de Investigación de la Facultad de Ingeniería de Sistemas, Escuela Profesional de INGENIERÍA DE SISTEMAS, corroboro el asesoramiento en el Informe Final de la Investigación (borrador de Tesis) del ASESOR Dr. JUAN BENITES NORIEGA,

Estando, la opinión favorable del Comité de Investigación, en concordancia con el Reglamento Interno de Trabajo de Investigación Conducente a Grados y Títulos Resolución N° 0294-2023-UANCV-CU-R, de conformidad a lo que establece la Ley Universitaria N° 30220, Ley de Creación de la UANCV N° 23738 y Modificatoria N° 24661 y el Estatuto de la UANCV, que confiere facultades al Decano de la Facultad de Ingeniería de Sistemas.

SE RESUELVE:

ARTICULO PRIMERO. - APROBAR Y AUTORIZAR EL INFORME FINAL DE LA INVESTIGACIÓN (Borrador de Tesis) para la **REVISIÓN DE SIMILITUD TURNITIN**, del tema titulado: **MODELO DE APRENDIZAJE AUTOMÁTICO PARA MEJORAR LA PRODUCTIVIDAD EN LA PESCA ARTESANAL EN ANCASH 2023**, presentado por el (la) Bach. **HEYNER MAMANI CHIPANA**, para optar el Título Profesional de INGENIERO DE SISTEMAS, en virtud de los considerandos expuestos.

ARTICULO SEGUNDO. - RATIFICAR, como ASESOR al **Dr. JUAN BENITES NORIEGA**.

ARTICULO TERCERO. - DISPONER que la facultad, secretarías académicas y administrativas, quedan encargados del cumplimiento de la presente resolución.

Regístrese, comuníquese y archívese.



UNIVERSIDAD ANDINA
"NÉSTOR CÁCERES VELÁSQUEZ"

M.Sc. Juan Carlos Herrera Miranda
DECANO

C.c
Arch 2024
JCHM/ v1.1
Distribución: Asesor de Tesis, Interesado

Ciudad Universitaria Urbanización Taparachi Km 4.5 Salida Puno - Juliaca



RESOLUCIÓN N° 341-2024-UI.P-D-FIS-UANCV-J

Juliaca, 12 de noviembre de 2024

VISTOS:

El Expediente: 2024-013859 de fecha 12 de noviembre de 2024, del (la) Bach. **HEYNER MAMANI CHIPANA**; con el cual solicita Revisión de la Propuesta de Investigación y el Anexo (02 o 03) "Ficha de Opinión de la Propuesta de Investigación" que fue revisada por el Comité de Investigación de la Facultad de Ingeniería de Sistemas, Escuela Profesional de INGENIERÍA DE SISTEMAS.

CONSIDERANDO:

Que, las Unidades de Investigación son unidades académicas que agrupan a docentes y estudiantes de diversas disciplinas, en razón del desarrollo de investigación científica, tecnológica y humanista de acuerdo al Estatuto Universitario Modificado 2020 de nuestra primera Casa Superior de Estudios.

Que, el (la) Bach. HEYNER MAMANI CHIPANA, solicito la revisión y aprobación de la Propuesta de Investigación de la tesis titulada: MODELO DE APRENDIZAJE AUTOMÁTICO PARA MEJORAR LA PRODUCTIVIDAD EN LA PESCA ARTESANAL EN ANCASH 2023; conducente para optar el Título Profesional de INGENIERO DE SISTEMAS.

Que, al haberse cumplido con los requisitos exigidos por el Reglamento Interno de Trabajo de Investigación Conducente a Grados y Títulos plasmado en la Resolución N° 0294-2023-UANCV-CU-R.

Que, el Comité de Investigación ha emitido opinión favorable a la propuesta de investigación.

Que, el Director de la Unidad de Investigación de la Facultad de Ingeniería de Sistemas, Escuela Profesional de INGENIERÍA DE SISTEMAS, ratifico la propuesta del Asesor Dr. JUAN BENITES NORIEGA, quien debe estar acreditado y facultado para orientar y ayudar al asesorado en el proceso de elaboración del trabajo de investigación (Tesis).

Estando, la opinión favorable del comité de Investigación, en concordancia con el Reglamento Interno de Trabajo de Investigación Conducente a Grados y Títulos, Resolución N° 0294-2023-UANCV-CU-R, de conformidad a lo que establece la Ley Universitaria N° 30220, Ley de Creación de la UANCV N° 23738 y Modificatoria N° 24661 y el Estatuto de la UANCV, que confiere facultades al Decano de la Facultad de Ingeniería de Sistemas.

SE RESUELVE:

ARTÍCULO PRIMERO. - APROBAR Y AUTORIZAR LA EJECUCIÓN DE LA PROPUESTA DE INVESTIGACIÓN, titulada: **MODELO DE APRENDIZAJE AUTOMÁTICO PARA MEJORAR LA PRODUCTIVIDAD EN LA PESCA ARTESANAL EN ANCASH 2023**, presentado por el (la) Bach. **HEYNER MAMANI CHIPANA**, para optar el Título Profesional de INGENIERO DE SISTEMAS, en virtud de los considerandos expuestos.

ARTÍCULO SEGUNDO. - RECONOCER, como ASESOR al Dr. **JUAN BENITES NORIEGA**.

ARTÍCULO TERCERO. - DISPONER que la facultad, secretarías académicas y administrativas, quedan encargados del cumplimiento de la presente resolución.

Regístrese, comuníquese y archívese.



UNIVERSIDAD ANDINA
"NÉSTOR CÁCERES VELÁSQUEZ"

M.Sc. Juan Carlos Herrera Miranda
DECANO



12% Similitud general

El total combinado de todas las coincidencias, incluidas las fuentes superpuestas, para ca...

Filtrado desde el informe

- Bibliografía
- Coincidencias menores (menos de 10 palabras)

Fuentes principales

- 8%  Fuentes de Internet
- 3%  Publicaciones
- 9%  Trabajos entregados (trabajos del estudiante)

Marcas de integridad

N.º de alertas de integridad para revisión

Los algoritmos de nuestro sistema analizan un documento en profundidad para buscar inconsistencias que permitirían distinguirlo de una entrega normal. Si advertimos algo extraño, lo marcamos como una alerta para que pueda revisarlo.

Una marca de alerta no es necesariamente un indicador de problemas. Sin embargo, recomendamos que preste atención y la revise.



Metadatos complementarios



Título de la Tesis	
MODELO DE APRENDIZAJE AUTOMÁTICO PARA MEJORAR LA PRODUCTIVIDAD EN LA PESCA ARTESANAL EN ANCASH 2023	
Datos de autor	
Nombres y apellidos	HEYNER MAMANI CHIPANA
Tipo de documento de identidad	DNI
Numero de documento de identidad	61604629
URL de ORCID	https://orcid.org/0000-0001-9738-7798
Datos de asesor	
Nombres y apellidos	JUAN BENITES NORIEGA
Tipo de documento de identidad	DNI
Numero de documento de identidad	06195745
URL de ORCID	https://orcid.org/0000-0003-3842-8435
Datos de jurado	
Presidente del jurado	
Nombres y apellidos	JUAN CARLOS HERRERA MIRANDA
Tipo de documento de identidad	DNI
Numero de documento de identidad	29606930
Miembro del jurado 1	
Nombres y apellidos	RICHARD CONDORI CRUZ
Tipo de documento de identidad	DNI
Numero de documento de identidad	02442917
Miembro del jurado 2	
Nombres y apellidos	PAUL MAMANI TISNADO
Tipo de documento de identidad	DNI
Numero de documento de identidad	01314987



Datos de investigación	
Línea de investigación	Ciencia de los ordenadores – P24
Grupo de investigación	No aplica.
Agencia de financiamiento	Sin financiamiento.
Ubicación geográfica de la investigación	País: Perú Departamento: Ancash Provincia: Ancash Distrito: Huaraz PESCA ARTESANAL EN ANCASH Coordenadas: Latitud: -15.4852419 Longitud: -70.127318 URL Maps: https://maps.app.goo.gl/cMGXkYKh6t5AFv1M6 
Año o rango de años en que se realizó la investigación	Noviembre 2024 – Enero 2025
URL de disciplinas OCDE https://concytec-pe.github.io/Peru-CRIS/vocabularios/ocde_ford.html	Ingeniería de sistemas y comunicaciones https://purl.org/pe-repo/ocde/ford#2.02.04 Ingeniería de procesos https://purl.org/pe-repo/ocde/ford#2.04.02



UNIVERSIDAD ANDINA
"NÉSTOR CÁCERES VELÁSQUEZ"
DIRECCIÓN
M.Sc. Juan Carlos Herrera Miranda
DIRECTOR (e)
Unidad de Investigación FIS

DECLARACIÓN DE AUTENTICIDAD Y RESPONSABILIDAD

Yo HEYNER MAMANI CHIPANA, identificado con DNINro. 61604629, en mi condición de egresado de:☒ Escuela Profesional☐ Programa de Segunda Especialidad,☐ Programa de Maestría o DoctoradoINGENIERÍA DE SISTEMASinformo que he elaborado el/la ☒ Tesis o ☐ Trabajo de Investigación, ☐ Trabajo Académico
denominada:MODELO DE APRENDIZAJE AUTOMÁTICO PARA MEJORAR LA
PRODUCTIVIDAD EN LA PESCA ARTESANAL EN ANCASH 2023Asesorado por: Dr. JUAN BENITES NORIEGA

Es un tema original.

Declaro que el presente trabajo de tesis es elaborado por mi persona y **no existe plagio/copia** de ninguna naturaleza, en especial de otro documento de investigación (tesis, revista, texto, congreso, o similar) presentado por persona natural o jurídica alguna ante instituciones académicas, profesionales, de investigación o similares, en el país o en el extranjero.

Dejo constancia que las citas de otros autores han sido debidamente identificadas en el trabajo de investigación, por lo que no asumiré como tuyas las opiniones vertidas por terceros, ya sea de fuentes encontradas en medios escritos, digitales o Internet.

Asimismo, ratifico que soy plenamente consciente de todo el contenido de la tesis y asumo la responsabilidad de cualquier error u omisión en el documento, así como de las connotaciones éticas y legales involucradas.

El incumplimiento de lo declarado da lugar a responsabilidad del declarante, en consecuencia; a través del presente documento asumo frente a terceros, la Universidad Andina Néstor Cáceres Velásquez y/o la Administración Pública toda responsabilidad que pueda derivarse por el trabajo final presentado. Lo señalado incluye responsabilidad pecuniaria incluido el pago de multas u otros por los daños y perjuicios que se ocasionen.

Juliaca 31 de OCTUBRE del 2025
Firma del Asesor
(obligatoria)
Firma del Estudiante
(obligatoria)
Huella



DEDICATORIA

A mi familia.



AGRADECIMIENTO

A la empresa de produccion.



ÍNDICE

DEDICATORIA.....	i
AGRADECIMIENTO	ii
ÍNDICE.....	iii
ÍNDICE DE TABLAS	vi
ÍNDICE DE FIGURAS	vii
RESUMEN	viii
ABSTRACT	x
INTRODUCCIÓN	xii

CAPÍTULO I

ASPECTOS GENERALES

1.1. Descripción del problema.....	1
1.1.1 A nivel Internacional	1
1.1.2 A nivel nacional.....	2
1.1.3 A nivel local.....	2
1.2. Formulación del problema	3
1.2.1 Problema principal	3
1.2.2 Problemas específicos.....	3
1.3. Justificación de la investigación.....	3
1.3.1 Justificación teórica	3
1.3.2 Justificación practico.....	4
1.3.3 Justificación metodológica	4



1.4. Objetivos	5
1.4.1 Objetivo general.....	5
1.4.2 Objetivos específicos	5
1.5. Importancia.....	5
1.6. Limitaciones.....	6

CAPÍTULO II

FUNDAMENTOS TEÓRICOS

2.1. Antecedentes.....	8
2.1.1 Internacionales.	8
2.1.2 Nacionales	11
2.1.3 Locales	13
2.2. Marco epistemológico.....	15
2.3. Estado del arte	17
2.4. Bases teóricas	19
2.5. Marco conceptual	38
2.6. Hipótesis.....	40
2.6.1 Hipótesis general	40
2.6.2 Hipótesis específicas	41

CAPÍTULO III

METODOLOGÍA Y RESULTADOS

3.1. Métodos de investigación	42
3.1.1 Tipo de investigación	43



3.1.2 Nivel.....	43
3.1.3 Diseño	44
3.2. Modalidad de estudio de casos	45
3.2.1 Población	45
3.2.2 Muestra.....	46
3.3. Métodos y técnicas de recogida de información	46
3.3.1 Criterios de Inclusión	47
3.3.2 Criterios de Exclusión	48

CAPÍTULO IV

RESULTADOS

4.1. Análisis de datos	50
4.2. Diseminación de los hallazgos	81
CONCLUSIONES	84
RECOMENDACIONES	86
REFERENCIAS BIBLIOGRÁFICAS.....	88
APÉNDICES	92
Apéndice 2 Instrumentos	94
Apéndice 3 Validez de instrumentos	98
Apéndice 4 Tratamiento de datos	100
Apéndice 5 Otros.	101



ÍNDICE DE TABLAS

Tabla 1 Promedio de Capturas y Factores Ambientales por Ubicación	52
Tabla 2 promedios de capturas en kilogramos para las ubicaciones de pesca artesanal	66
Tabla 3 promedio de capturas en kilogramos para cada mes del año	67
Tabla 4 esfuerzo promedio en horas de faena dedicadas	69
Tabla 5 promedio de capturas en kilogramos asociado a diferentes rangos de esfuerzo	70
Tabla 6 promedio de capturas en kilogramos según rangos de temperatura del agua	71



ÍNDICE DE FIGURAS

Figura 1 Capturas y Factores Ambientales por Ubicación	52
Figura 2 Resultados de Capturas y Factores	53
Figura 3 Importancia de las Variables en el Modelo Predictivo	57
Figura 4 Capturas Mensuales En La Pesca Artesanal	59
Figura 5 Relación Entre Temperatura Del Agua Y Capturas	61
Figura 6 Relación Entre Corrientes Marinas Y Capturas	62
Figura 7 Relación Entre Salinidad Y Capturas	64
Figura 8 Relación entre Capturas Reales y Predichas	73
Figura 9 promedio de capturas	75
Figura 10 matriz de correlación	76
Figura 11 Interpretación del Histograma: Distribución de Errores (Capturas Reales - Capturas Predichas)	78



RESUMEN

La presente investigación tiene como objetivo desarrollar un modelo de aprendizaje automático que permita mejorar la productividad en la pesca artesanal en la región de Áncash durante el año 2023. A partir de un análisis de datos históricos y actuales, se busca identificar los factores clave que influyen en la productividad, optimizar las actividades de pesca y validar el modelo mediante métricas de desempeño. El estudio adopta un enfoque cuantitativo, de tipo aplicado, con un diseño metodológico no experimental. Se utilizarán técnicas descriptivas, correlacionales y predictivas para analizar una población de 5,500 registros de datos relacionados con la actividad pesquera. Las técnicas de recolección de datos en esta investigación son la observación de los pescadores así como la recolección y análisis de documentos y cuestionarios. Para la elaboración del modelo que se propone en este proyecto se utilizarán técnicas de machine learning, como las redes neuronales, árboles de decisión y algoritmos de regresión. Este modelo se utilizará para determinar la predicción de las coordenadas de las zonas de pesca y los parámetros que contribuirán a la optimización del esfuerzo pesquero. Se prevé que las predicciones del modelo sean evaluadas a través de técnicas tradicionales de comparación computacional, en función de la precisión, la exhaustividad, la puntuación F1 y el error absoluto medio (MAE), para que se pueda informar de la mejora del modelo respecto a los métodos tradicionales. Los propósitos de la elaboración del modelo son el incremento de la productividad de las actividades pesqueras y el mejoramiento de la toma de decisiones, el adelanto en la reducción de los costos que son perdidos en actividades pesqueras, la rentabilidad de actividades pesqueras y el incremento en la eficiencia de las actividades pesqueras.



Más importante aún, el modelo busca contribuir a la sostenibilidad de la pesca artesanal y del ecosistema marino. La investigación ofrece al sector de la pesca artesanal un enfoque novedoso, que integra herramientas tecnológicas avanzadas para optimizar las actividades pesqueras, promover la sostenibilidad del sector y equilibrar el ecosistema.

Palabras clave: Aprendizaje automático, Pesca artesanal, Productividad, Sostenibilidad, Optimización.



ABSTRACT

The objective of this research is to develop a machine learning model that will improve productivity in artisanal fishing in the Ancash region during 2023. Based on an analysis of historical and current data, the aim is to identify the key factors that influence productivity, optimize fishing activities, and validate the model using performance metrics. The study adopts a quantitative, applied approach with a non-experimental methodological design. Descriptive, correlational, and predictive techniques will be used to analyze a population of 5,500 data records related to fishing activity. The data collection techniques used in this research include observation of fishermen and the collection and analysis of documents and questionnaires. Machine learning techniques such as neural networks, decision trees, and regression algorithms will be used to develop the model proposed in this project. This model will be used to predict the coordinates of fishing areas and the parameters that will contribute to the optimization of fishing effort. The model's predictions are expected to be evaluated using traditional computational comparison techniques, based on accuracy, completeness, F1 score, and mean absolute error (MAE), so that the improvement of the model over traditional methods can be reported. The purposes of developing the model are to increase the productivity of fishing activities and improve decision-making, advance the reduction of costs lost in fishing activities, increase the profitability of fishing activities, and increase the efficiency of fishing activities.

More importantly, the model seeks to contribute to the sustainability of artisanal fishing and the marine ecosystem. The research offers the artisanal



fishing sector a novel approach that integrates advanced technological tools to optimize fishing activities, promote the sustainability of the sector, and balance the ecosystem.

Keywords: Machine learning, Artisanal fishing, Productivity, Sustainability, Optimization.

INTRODUCCIÓN

La pesca artesanal representa una actividad económica esencial en muchas comunidades costeras, especialmente en la región de Áncash, donde es una fuente significativa de empleo e ingresos. Dicho lo anterior, este sector enfrenta efectos por la disminución en los niveles de captura sustentables, falta de tecnologías de optimización de operaciones, y prácticas tradicionales que limitan la productividad adaptables en prácticas tradicionales.

La falta de tecnologías de optimización de operaciones sumados a la captura sustentable van de la mano, y la complejidad de los modelos en aprendizaje automático que permiten analizar la data, sumados a los patrones y determinar las condiciones respetuosas y operacionales a la pesca (los modelos de aprendizaje automático en este caso son los que permiten analizar la captura en la data empírica y los registros de la jornada) permiten optimizar la productividad en respetando la sostenibilidad de los recursos marinos..

La presente investigación tiene como objetivo desarrollar un modelo de aprendizaje automatizado para optimizar la productividad dentro de la actividad pesquera artesanal de la provincia de Ancash para el año 2023. Mediante el análisis de datos relevantes para demostrar el potencial de este modelo para transformar la actividad pesquera y hacerla más eficiente en resultados medibles y replicables, el modelo será diseñado y validado a través de métricas de rendimiento productivo.

Este estudio destaca por la forma en que combina la incorporación equilibrada y sin precedentes de avances tecnológicos e innovadores en una actividad económica con décadas de antigüedad. Los resultados esperados no



solo mejorarán los márgenes de rentabilidad y aportarán una mayor eficiencia a las comunidades locales [...], sino que también preservarán los ecosistemas marinos. Por lo tanto, este estudio presenta un enfoque único y equilibrado para el desarrollo socioeconómico del sector pesquero artesanal en Perú.

Este estudio se organiza en cinco secciones. El capítulo I, El problema, explica el problema, la importancia de esta investigación y establece los objetivos generales y específicos. El capítulo II, Marco teórico, presenta los conceptos relevantes, los antecedentes y la base científica del estudio sobre el aprendizaje automático y la productividad pesquera. El capítulo III, «Metodología de la investigación», delinea el diseño metodológico y el enfoque cuantitativo con las técnicas de recopilación y análisis de datos. En el capítulo IV, «Resultados», se presentan las conclusiones que evalúan el impacto del modelo en la productividad pesquera utilizando diferentes medidas de rendimiento. Por último, en las «Conclusiones» se presentan las principales contribuciones de la investigación y en las «Recomendaciones» se proponen estrategias para la aplicación y la replicación del modelo en otros entornos.

Este trabajo abre aún más oportunidades para integrar la tecnología en las actividades económicas tradicionales y promueve el desarrollo sostenible, lo que beneficia tanto a las comunidades como al medio ambiente, ya que proporciona soluciones innovadoras para los retos actuales de la pesca artesanal.



CAPÍTULO I

ASPECTOS GENERALES

1.1. Descripción del problema

1.1.1 A nivel Internacional

La pesca sigue siendo muy importante para las economías costeras de todo el mundo. Proporciona empleo, ingresos y contribuye a la seguridad alimentaria. Sin embargo, este sector sigue enfrentándose a retos como el cambio climático y la falta de tecnologías pesqueras. La Organización de las Naciones Unidas para la Alimentación y la Agricultura afirma que la inmensa mayoría de los pescadores del mundo, alrededor del 90 %, son artesanos; sin embargo, la mayoría trabaja en condiciones poco productivas debido a la ineficiencia de las tecnologías pesqueras y a una planificación deficiente.

Por ello, han surgido tecnologías basadas en inteligencia artificial que han demostrado su eficacia para optimizar las actividades pesqueras en países como India y Noruega. Estas tecnologías proporcionan pronósticos sobre las condiciones de pesca.

Identificar patrones climáticos y mejorar la sostenibilidad, destacando la necesidad de implementar enfoques similares en otros contextos.

1.1.2 A nivel nacional

La pesca artesanal es una de las actividades económicas más importantes para las comunidades costeras de Perú y representa el 10% de la captura total de pescado del país. La región de Áncash, con su rica biodiversidad marina, es estratégicamente importante para esta actividad. Sin embargo, existen varios factores que afectan la productividad de los pescadores artesanales, como la falta de acceso a información sobre las condiciones meteorológicas y marítimas, la dependencia de técnicas de pesca tradicionales y el escaso uso de tecnología moderna. Todos estos factores han generado incertidumbre en las capturas, lo que ha reducido los ingresos de los pescadores. Si bien el gobierno de Perú ha implementado algunos programas de apoyo a los pescadores, el uso de tecnologías como el aprendizaje automático sigue siendo bajo. La introducción de dichas tecnologías generaría cambios radicales en el sector, especialmente al empoderar a los pescadores para que tomen decisiones más informadas y eficientes respecto a su actividad pesquera.

1.1.3 A nivel local

Los pesqueros artesanales de la región de áncash establecen condiciones difíciles de leve a moderado de sostenibilidad y productividad de la pesquería. Además de ello, el cambio climático y la falta de herramientas de introprecisión y de predicción de zonas y de épocas de pesca óptimas, estos factores mantienen el ciclo vicioso. El conocimiento por tradición popular y de la ineficiencia del proceso pesquero, que se mueve hacia la suerte como principal variable de captura, es un elemento colateral que afecta las condiciones de las comunidades. En la actualidad, la predicción de las capturas a partir de un

modelo de aprendizaje automático es factible y se puede aplicar, a fin de ofrecer a los pescadores un sistema que complemente sus prenociones y mejore de manera efectiva los bajos resultados actuales, desde un costo a sus operaciones..

1.2. Formulación del problema

1.2.1 Problema principal

¿¿Cómo desarrollar un modelo de aprendizaje automático que permita mejorar la productividad en la pesca artesanal en la región de Áncash durante el año 2023??

1.2.2 Problemas específicos

1. ¿Qué factores clave y datos históricos y actuales influyen en la productividad de la pesca artesanal en la región de Áncash?
2. ¿Cómo diseñar e implementar un modelo de aprendizaje automático que optimice las actividades de pesca artesanal en la región?
3. ¿Qué tan efectivo es el modelo propuesto para mejorar la productividad, según las métricas de desempeño utilizadas en su validación?

1.3. Justificación de la investigación

1.3.1 Justificación teórica

Las prácticas pesqueras artesanales dentro del sector siguen enfrentándose a retos en términos de bajos niveles de productividad, sobreexplotación de los recursos y falta de soluciones tecnológicas adecuadas y sofisticadas para optimizar los procesos. Sin embargo, la ausencia de las soluciones tecnológicas sofisticadas mencionadas anteriormente contrasta fuertemente con la gran capacidad del aprendizaje automático para procesar

conjuntos de datos complejos y aparentemente intratables, en particular los de variables oceanográficas y climáticas, que influyen en los patrones de captura. El presente trabajo tiene como objetivo fusionar diversos ámbitos teóricos plagados de lagunas para promover la integración de la inteligencia artificial y las prácticas pesqueras sostenibles con el fin de abordar los retos ancestrales de la pesca artesanal. Además, nuestro objetivo es sentar las bases para futuros estudios sobre la aplicación de tecnologías emergentes en sectores atrasados, mostrando formas de hacerlo.

1.3.2 Justificación práctico

La investigación se enfoca en el impacto de la optimización de la pesca artesanal en la Región Áncash. A partir de la construcción de un modelo de aprendizaje automático para la localización de zonas con potencial de pesca, se conseguirán datos que determinen los momentos de captura, así como las condiciones climáticas que presentan las zonas de pesca. A partir de estas optimizaciones, los pescadores podrán aumentar la eficiencia de sus capturas, reduciendo sus costos fijos, y aumentar la eficiencia de sus operaciones disminuyendo la utilización de métodos empiristas. A crecimiento de los ingresos que se obtiene de este modelo también se verá disminuida la presión sobre el ecosistema marino y se mejorará la calidad de vida de la población de los asentamientos costeros.

1.3.3 Justificación metodológica

Este estudio se basa en la metodología cuantitativa y la recolección, así como en el tratamiento de antecedentes y datos presentes en la actividad de la pesca artesanal. Se espera construir un modelo que, a partir de la pesquería, pueda ser optimizado en las actividades potencialmente aprovechables. Usando

herramientas de machine learning, como las redes neuronales y la clasificación, se espera construir un modelo. Se utilizarán, como indicadores de la validación del modelo y de la garantías de su aplicabilidad a la realidad, la precisión, la sensibilidad y la F-Measure. Este modelo permite el análisis del problema en forma rigurosa y con base en la evidencia, con lo que se garantiza la confiabilidad y la pertinencia del resultado del problema, desde la perspectiva de los artesanos pesqueros de la región Áncash.

1.4. Objetivos

1.4.1 *Objetivo general*

Desarrollar un modelo de aprendizaje automático que permita mejorar la productividad en la pesca artesanal en la región de Áncash durante el año 2023.

1.4.2 *Objetivos específicos*

1. Analizar datos históricos actuales sobre la pesca artesanal en la región.
2. Diseñar e implementar un modelo de aprendizaje automático para optimizar las actividades de pesca artesanal.
3. Validar el modelo propuesto mediante métricas de desempeño y evaluar su impacto potencial en la productividad.

1.5. Importancia

Relevancia Académica:

El estudio contribuye al campo del aprendizaje automático y su aplicación en actividades económicas tradicionales como la pesca artesanal. Esto amplía el conocimiento sobre cómo la inteligencia artificial puede integrarse en

contextos no industriales para resolver problemas específicos relacionados con la sostenibilidad y la productividad.

Impacto Tecnológico:

La aplicación de un modelo de aprendizaje automático en la actividad pesquera a pequeña escala supone una innovación que podría sentar un precedente para otras comunidades pesqueras de la costa peruana y del mundo. Esta investigación explica cómo la intersección entre innovación y tecnología puede mejorar la actividad pesquera, que durante mucho tiempo se ha practicado de forma tradicional.

Contribución Social y Económica:

Las actividades del sector pesquero en Ancash permiten a muchas familias obtener su sustento. El aumento de la productividad de la pesca no solo devengará mayores ingresos a los pescadores, sino que también mejora la seguridad alimentaria, la sostenibilidad de los recursos y el bienestar de las comunidades.

Relevancia Local:

Este estudio puede ofrecer herramientas concretas a los pescadores de Ancash para superar los problemas relacionados con la variabilidad de las capturas y la gestión ineficiente de los recursos. Esto puede mejorar la calidad de vida de las comunidades costeras.

1.6. Limitaciones

Delimitación geográfica:

Este estudio se llevará a cabo en la región de Áncash, Perú, concretamente en las comunidades costeras que practican la pesca artesanal como principal actividad económica.



Delimitación temporal:

El estudio se centrará en el año 2023 como referencia principal de datos, acompañado de datos históricos de los últimos cinco años. Este último conjunto de datos se utilizará en el desarrollo y la validación del modelo de aprendizaje automático.

Delimitación temática:

La restricción estará puesta en el análisis de la productividad en el área de la pesca artesanal, considerando variables como el clima, los bancos de pesqueros, la eficiencia de toda la pesca, etc. No se considerarán las variables de mercadeo y distribución del pescado.

Delimitación Tecnológica:

Podrás desarrollarse y experimentarse con datos y tecnología de dominio público, específicamente, con la programación en Python y sus bibliotecas de código abierto. No habrá otros tipos de tecnologías de fuera aprendiendo la máquina.

Delimitación de recursos:

Con esta investigación, se obtendrán datos disponibles a nivel local, como registros históricos de capturas pesqueras, así como conjuntos de datos del clima y de oceanografía en organizaciones pertinentes, porque no hay posibilidad de obtener datos en tiempo real por motivos logísticos y de presupuesto.

Estas delimitaciones otorgan al alcance de la investigación la mayor integridad y factibilidad en relación a la a los objetivos planteado

.

.



CAPÍTULO II

FUNDAMENTOS TEÓRICOS

2.1. Antecedentes

2.1.1 Internacionales.

León y González (2019): En el estudio "Impacto de Machine Learning en la pesca sostenible en comunidades costeras de España" León y Gonzalez analizan el uso de elementos de machine learning en la pesca y su sostenibilidad en comunidades costeras de España. Predicen localizaciones óptimas de pesca y periodos óptimos de captura a través de la predicción de la captura. Utilizan algoritmos de aprendizaje supervisado a partir de datos de condiciones climáticas y de pesca. El estudio mejora la eficacia de la pesca en un 25\% y disminuye el tiempo de la búsqueda de áreas a pescar. Esto demuestra el uso de machine learning para la solución de problemas de la sostenibilidad de la pesca artesanal con pocos recursos, sobreexplotacion y calma. León y Gonzalez mencionan que la clave es el machine learning, sobre datos y usuarios, en este caso, los pescadores. Esto demuestra el uso de machine learning en la pesca y balance de productividad y sostenibilidad.(León & González, 2019).



Kim et al. (2021): Kim y su equipo crearon un modelo de aprendizaje profundo para ajustar las predicciones de la pesca a pequeña escala en Corea del Sur. El trabajo utilizó datos satelitales y registros históricos de capturas para pronosticar las condiciones marinas, incluida la temperatura del agua y la presencia y densidad de los bancos de peces. Mediante el uso de redes neuronales convolucionales y recurrentes, se logró una mejora del 30 % en la identificación de las zonas más propicias para la pesca. Además, se produjo una reducción significativa de los costes operativos, gracias a la capacidad del modelo para reducir el tiempo dedicado a la búsqueda de zonas de pesca adecuadas. La investigación demostró que la tecnología de aprendizaje profundo, además de mejorar la eficiencia operativa, también produce un resultado neto positivo para el medio ambiente al aliviar las presiones medioambientales insostenibles del exceso de pesca en las zonas disponibles. Kim et al. señalan la necesidad de contar con infraestructuras tecnológicas adecuadas y flujos de datos en tiempo real para garantizar la eficiencia de la aplicación de estas herramientas. (Kim et al., 2021).

Ali y Khan (2020) Ali y Khan analizaron las formas en que las redes neuronales artificiales pueden predecir los efectos del cambio climático en la pesca a pequeña escala en el sudeste asiático. Su estudio entrenó modelos de redes neuronales artificiales (ANN) utilizando datos históricos sobre el clima y la abundancia de especies. Los resultados mostraron que el modelo era capaz de predecir con una precisión superior al 85 % las fluctuaciones en la disponibilidad de peces debido a los cambios en la temperatura y las corrientes oceánicas. Este modelo permitió a los pescadores locales

planificar sus actividades pesqueras de manera que se maximizara su captura y se redujera el tiempo dedicado a viajes de pesca improductivos. Ali y Khan señalaron que la utilidad de estos modelos depende totalmente de la disponibilidad y el perfeccionamiento continuo de los datos contemporáneos sobre el clima y la pesca. También destacaron la necesidad de dotar a las comunidades locales de los medios necesarios para utilizar estos sistemas de forma autónoma y sostenible. (Ali & Khan, 2020).

Huang et al. (2018) Huang y sus colegas han desarrollado aplicaciones de aprendizaje automático que se utilizan en la gestión de los recursos pesqueros en China. Integrando datos climáticos, satelitales e históricos sobre la pesca, generaron un sistema predictivo capaz de discernir las zonas aptas para la pesca y la sobreexplotación sostenida. Sus modelos demostraron un 92 % de éxito en la localización de las zonas de pesca, lo que mejoró la programación de las actividades pesqueras. Los autores señalaron que estos esfuerzos contribuyeron considerablemente a reducir la sobreexplotación y a mejorar la productividad. Según Huang et al., el empleo de modelos predictivos reforzó la sostenibilidad de los recursos marinos y también proporcionó una reducción de los costes, una mayor eficiencia operativa y una mejora de los rendimientos de las capturas. (Huang et al., 2018).

Nguyen y Pham (2022) Nguyen y Pham, en el estudio realizado en Vietnam, desarrollaron un modelo de aprendizaje profundo capaz de predecir zonas de pesca en el momento, a partir de la combinación de la fotogrametría satelital, el análisis de datos en la nube y el historial de

registros meteorológicos. Gracias a la utilización de técnicas de redes neuronales profundas y análisis de big data, lograron un aumento del aproximado del 40% en el volumen de capturas. Los pescadores de la zona que reportaron haber utilizado el modelo, lograron una mayor identificación de zonas de pesca y disminuyeron de forma notable los costos de búsqueda de los cardúmenes. Asimismo, el estudio reseñó el potencial de estas tecnologías para la disminución del impacto sobre las especies de mayor explotación, y la sostenibilidad de la presión que se ejerce sobre los recursos marinos. Para concluir, Nguyen y Pham indicaron la importancia del trabajo conjunto entre los científicos y las comunidades para que la implementación de estas herramientas se lleve a cabo de forma exitosa.(Nguyen & Pham, 2022).

2.1.2 Nacionales

Guzmán y Flores (2020) En el norte de Perú, Guzmán y Flores estudiaron las relaciones entre los factores climáticos y la productividad pesquera en las comunidades costeras. Emplearon modelos estadísticos para determinar cómo variables tales como la temperatura y la salinidad de la superficie del mar influyen en la distribución de las especies. Su estudio indicó que los períodos de anomalías climáticas, como El Niño, provocaban una marcada disminución en el rendimiento pesquero. Los autores predijeron el valor de utilizar los datos como base de una herramienta de previsión para anticipar mejor esas alteraciones y, así, optimizar la planificación de las actividades pesqueras. Este precedente pone de relieve la necesidad de incorporar los datos climáticos en la gestión pesquera para

mejorar la eficiencia y la sostenibilidad de la pesca artesanal en Perú.
(Guzmán & Flores, 2020).

López y Ramos (2021) López y Ramos estudiaron los efectos de la variabilidad climática en la pesca a pequeña escala en Tumbes y describieron los impactos de los cambios de temperatura y las corrientes marinas en la disponibilidad de especies de interés. Emplearon el análisis de datos históricos para establecer algunos patrones y sugirieron el uso de modelos predictivos para informar mejor a los pescadores sobre la distribución de sus esfuerzos. Concluyeron que el uso de la tecnología en la pesca reduciría la incertidumbre y daría lugar a un aumento más sostenible del rendimiento.(López & Ramos, 2021).

Castro y Pérez (2019) En Piura, Castro y Pérez evaluaron el uso de tecnologías digitales en la pesca artesanal, haciendo hincapié en su potencial para mejorar la eficiencia de las capturas. El acceso a dispositivos tecnológicos y la formación se identificaron como obstáculos. Abogaron por el uso de modelos predictivos que integraran datos satelitales y climáticos y patrones de pesca tradicionales. Su investigación subrayó que la integración tecnológica es fundamental para la transformación de la pesca artesanal en una actividad económica más productiva y sostenible.(Castro & Pérez, 2019).

Quispe et al. (2022) Utilizando datos climáticos históricos, Quispe y su equipo implementaron un modelo predictivo para optimizar la captura de anchoveta en la costa peruana. El modelo ayudó a identificar los mejores momentos y lugares para pescar, lo que redujo los costos operativos de los

pescadores en un 20 % y aumentó el volumen de pescado capturado. Los autores señalaron que esta tecnología es aplicable a otras zonas costeras del Perú, lo que mejora la eficiencia y la sostenibilidad de la pesca a pequeña escala. (Quispe et al., 2022).

Vargas y Rivera (2020) Durante su estancia en Lambayeque, Vargas y Rivera investigaron cómo el aprendizaje automático puede mejorar la productividad de la pesca. Su modelo fusionó datos de patrones climáticos y registros pesqueros, logrando predecir con precisión las zonas óptimas para la pesca. Los autores concluyeron que estas herramientas son esenciales para abordar los problemas de la variabilidad climática y la sobreexplotación de los recursos pesqueros. (Vargas & Rivera, 2020).

2.1.3 Locales

Moreno y Delgado (2021) Las postulaciones de Moreno y Delgado sobre la productividad de la pesca artesanal en las comunidades costeras de Áncash propusieron hipótesis preliminares y determinantes de la eficiencia de captura, considerando las condiciones climáticas, las tecnologías obsoletas y la falta de acceso a información confiable sobre las zonas de pesca. Estos autores señalaron las discrepancias y las pérdidas económicas derivadas de la inadaptación de los métodos tradicionales a las condiciones climáticas cada vez más inciertas. Para mitigar estos problemas, recomendaron el desarrollo de tecnologías que permitan optimizar las actividades pesqueras y el uso de modelos predictivos basados en conjuntos de datos climáticos históricos para lograr una pesca más eficiente. Su estudio enfatizó la importancia de integrar tecnologías modernas en la región

para aumentar la eficiencia y la productividad, a la vez que se reducen los costos operativos. (Moreno & Delgado, 2021).

Pérez y Pacheco (2022) En su investigación sobre la pesca artesanal en Casma, Áncash, Pérez y Pacheco analizaron cómo las fluctuaciones climáticas impactan la actividad pesquera. Usaron datos históricos de capturas y condiciones meteorológicas para identificar patrones en la disponibilidad de especies marinas. Concluyeron que el uso de datos meteorológicos en tiempo real podría mejorar significativamente la eficiencia de los pescadores al permitirles planificar sus salidas de manera más efectiva. Los autores recomendaron desarrollar e implementar un modelo predictivo basado en aprendizaje automático que permita identificar zonas y épocas óptimas para la pesca, optimizando así los recursos y reduciendo costos operativos (Pérez & Pacheco, 2022).

Huerta y Rojas (2020) Durante su estancia en Lambayeque, Vargas y Rivera investigaron cómo el aprendizaje automático puede mejorar la productividad de la pesca. Su modelo fusionó datos de patrones climáticos y registros pesqueros, logrando predecir con precisión las zonas óptimas para la pesca. Los autores concluyeron que estas herramientas son esenciales para abordar los problemas de la variabilidad climática y la sobreexplotación de los recursos pesqueros. (Huerta & Rojas, 2020).

Cruz y Vargas (2019) El trabajo de Cruz y Vargas comprende la dependencia de los métodos tradicionales en la pesca artesanal en Chimbote, Ancash. Su investigación muestra que la falta de acceso a tecnologías modernas y fuentes de datos confiables afecta negativamente la

productividad de los pescadores, quienes dedican una cantidad excesiva de tiempo y recursos a intentar determinar los lugares de pesca. Propusieron la implementación de modelos predictivos basados en el aprendizaje automático, que incorporan datos climáticos, oceanográficos e históricos de capturas, con el fin de maximizar los resultados y minimizar los gastos operativos. Concluyeron que el uso de estas herramientas mejoraría de manera significativa la pesca artesanal en Chimbote. (Cruz & Vargas, 2019).

Alvarado y Torres (2021) Alvarado y Torres (2021) analizaron el impacto de modificaciones en el cambio climático y su impacto en pesca artesanal en la zona costera de Ancash. Estos autores encontraron que la pesca artesanal no tiene la capacidad para adaptarse a la variabilidad del clima, en gran medida, por la escasez de herramientas de planificación y predicción. Estos autores propusieron la utilización de modelos de aprendizaje automático que integren el clima y la data histórica para la predicción de ubicaciones y períodos de pesca, de esta manera la pesca y los ingresos de los pescadores se incrementarían. Estos autores demandaron la modernización de la pesca artesanal en la zona. (Alvarado & Torres, 2021).

2.2. Marco epistemológico

Esta investigación se basa en un enfoque positivista, es decir, en la idea de que el conocimiento sobre el mundo puede obtenerse a través de la observación, el análisis y la ciencia. Esto encaja perfectamente con el enfoque cuantitativo, cuyo objetivo es comprender y verificar, mediante

estadísticas y aprendizaje automático, si existen patrones relacionados con la pesca artesanal en Ancash desde el pasado hasta el presente.

El aprendizaje automático, como disciplina central del estudio, está enraizado en la epistemología computacional y el constructivismo técnico, que reconocen la capacidad de las máquinas para aprender patrones y generar conocimiento a partir de datos. Este enfoque epistemológico valora tanto la observación objetiva como la construcción de modelos predictivos basados en algoritmos que simulan la capacidad de razonamiento humano.

Por otro lado, la investigación considera los principios de la teoría del conocimiento aplicado, en la que el conocimiento generado no solo tiene un valor teórico, sino que se orienta hacia aplicaciones prácticas, como la mejora de la productividad pesquera. De esta manera, se combina la generación de conocimiento científico con su implementación directa para resolver problemas reales, lo que enfatiza el carácter aplicado de la investigación.

Por último, este marco epistemológico se complementa con una visión interdisciplinaria, que integra conceptos de las ciencias ambientales, la economía y la tecnología. Este enfoque busca abordar la cuestión de manera holística, integrando los conocimientos tradicionales sobre la pesca con el análisis moderno de datos, lo que facilita una combinación eficaz de tecnología y sostenibilidad en la pesca artesanal.

2.3. Estado del arte

Las tecnologías avanzadas, como el aprendizaje automático, en el ámbito de la productividad de la pesca artesanal ponen de manifiesto el interés que despierta en otros sectores el empleo de tecnologías avanzadas en actividades económicas tradicionales. En esta sección se examinan la bibliografía pertinente y los avances recientes en tres campos interrelacionados: la pesca artesanal, la aplicación del aprendizaje automático y la sostenibilidad de las actividades productivas.

Existen cuestiones específicas, como el agotamiento de los recursos pesqueros, la imposibilidad de los profesionales de la pesca de acceder a las tecnologías y los efectos del cambio climático. Estudios recientes han intentado demostrar la importancia de la recopilación y el análisis de datos para optimizar la gestión de las capturas pesqueras y su sostenibilidad. Por ejemplo, en la India y África Occidental se han utilizado sistemas de vigilancia por satélite y sensores para localizar los bancos de pesca productivos, lo que ha permitido mejorar la eficiencia operativa y la sostenibilidad de los recursos pesqueros disponibles.

En Perú, la pesca artesanal es una actividad clave para la economía y el sustento de las comunidades costeras. Sin embargo, la limitada implementación de tecnologías dificulta su desarrollo. A pesar de ello, iniciativas gubernamentales y privadas han comenzado a explorar la digitalización de registros de pesca y el uso de sensores climáticos para mejorar la toma de decisiones.

El aprendizaje automático ha demostrado ser una herramienta poderosa en sectores productivos y ambientales. En el ámbito pesquero, se han implementado modelos predictivos para estimar las capturas basándose en datos históricos, como temperatura del agua, salinidad y corrientes marinas. Un estudio destacado en Noruega aplicó redes neuronales para optimizar las rutas de pesca, lo que redujo costos y tiempo de operación mientras incrementó la productividad.

El aprendizaje automático y la optimización de recursos con mitigación del impacto ambiental se han demostrado en tiempo real con $\chi\rho\acute{o}\nu\omicron\upsilon\varsigma$ y la gestión de la asignación de recursos en actividades pesqueras comerciales. Se han aprendido y predicho condiciones adversas y eventos que alteran la productividad.

En América Latina, y en particular en Brasil y Chile, los programas comunitarios se han complementado con tecnologías de análisis de datos destinadas a las prácticas sostenibles aprendidas en los programas de pesca responsable. Se ha demostrado que la integración de tecnologías que mejoran la productividad promueve la conservación de los recursos del ecosistema marino y sostiene los medios de vida de las comunidades que dependen de la pesca.

La bibliografía y los avances recientes destacan la creciente relevancia de incorporar tecnologías avanzadas en el sector de la pesca artesanal. Sin embargo, en el contexto del caso peruano, la aplicación del aprendizaje automático se encuentra todavía en una fase incipiente, lo que constituye una oportunidad para introducir innovaciones en este campo. La presente

investigación pretende avanzar en el estado de la técnica mediante el desarrollo de un modelo de aprendizaje automático destinado a abordar la productividad y la sostenibilidad de la pesca artesanal en Ancash, fusionando tecnología moderna práctica y adaptada.

2.4. Bases teóricas

Las bases teóricas de esta investigación se fundamentan en conceptos y teorías clave relacionados con el aprendizaje automático, la productividad y la sostenibilidad en la pesca a pequeña escala. Dichas bases ofrecen el marco conceptual necesario para formular y justificar un modelo que contribuya a optimizar las actividades pesqueras en la región de Áncash.

2.4.1 Modelo de Aprendizaje Automático

Los modelos de aprendizaje automático son herramientas computacionales que aplican algoritmos para reconocer patrones y realizar actividades predictivas basadas en datos. En el contexto de esta investigación, el modelo se diseñará para optimizar la predicción de las condiciones y ubicaciones para las actividades pesqueras artesanales a pequeña escala.

2.4.2 Aprendizaje Automático

La inteligencia artificial tiene múltiples subcampos, entre ellos el aprendizaje automático, que estudia cómo las máquinas pueden realizar predicciones o tomar decisiones basadas en datos, sin que sean programadas explícita o manualmente. El sistema que, de acuerdo a Mitchell (1997), 'aprende' es aquel que mejora en su desempeño dotado de

experiencia. Entre las modalidades que el aprendizaje automático sostiene se encuentran:

Aprendizaje supervisado: seud de datos previamente etiquetados para el entrenamiento de modelos que se ocupan para realizar predicciones.

Aprendizaje no supervisado: el enfoque en clúster o agrupamiento de datos consiste en descubrir patrones presentes en la información sin el etiquetado.

Aprendizaje por refuerzo: la toma de decisiones se optimiza de acuerdo a las recompensas acumulativas por las decisiones tomadas.

Gracias a métodos como las redes neuronales, los árboles de decisión o la regresión logística, el aprendizaje automático hace posible la resolución de problemas complejos como la estimación de zonas de pesca en determinados momentos.

2.4.3 Tipos de Aprendizaje Automático

Aprendizaje Supervisado:

Se entrena un modelo con datos etiquetados, permitiéndole predecir valores futuros.

Ejemplo: Predicción de zonas de pesca óptimas con base en datos históricos de capturas y condiciones ambientales.

Aprendizaje No Supervisado:

Identifica patrones en datos no etiquetados, como agrupaciones o tendencias.

Ejemplo: Clustering para identificar áreas de alta actividad pesquera.

Aprendizaje por Refuerzo:

Se enfoca en la toma de decisiones mediante la maximización de recompensas acumuladas.

Ejemplo: Optimización de rutas de pesca para minimizar costos y maximizar capturas.

2.4.4 Componentes del Modelo de Aprendizaje Automático.

Datos de Entrenamiento: Conjunto de datos históricos sobre condiciones ambientales, capturas y ubicación geográfica.

Algoritmos: Redes neuronales, árboles de decisión y regresión, seleccionados según la naturaleza del problema.

Validación: Uso de métricas como precisión, recall y error absoluto medio (MAE) para evaluar la efectividad del modelo.

2.4.5 Aplicaciones en la Pesca Artesanal.

La aplicación del aprendizaje automático se ha demostrado en todas las actividades económicas. Por ejemplo, en la pesca, ha sido útil para:

La predicción de las condiciones óptimas para las capturas.

La supervisión de los recursos pesqueros.

La gestión sostenible mediante el reconocimiento de los patrones y las tendencias.

2.4.6 Productividad.

Productividad en la pesca artesanal implica que se consideran tanto las capturas obtenidas, como los recursos que se utilizan en las faenas pesqueras. Tiempo, combustible, y esfuerzo pesquero también son parte de la ecuación. Este concepto permite evaluar la eficiencia y sostenibilidad de la actividad pesquera.

Heizer y Render (2020) indican que la productividad hace referencia a la eficiencia en la obtención de resultados a partir de la utilización de recursos. En lo que se refiere a la pesca artesanal, esto se mide en términos de cantidad de capturas por unidad de tiempo o de costo.

La productividad se define como la relación de los resultados obtenidos y los recursos utilizados (Gutierrez & Heizer, 2020). En el contexto de la pesca artesanal, la productividad está influenciada por factores como:

Eficiencia operativa: Uso óptimo de recursos humanos y materiales.

Condiciones ambientales: Factores como temperatura del agua, corrientes y salinidad que afectan las capturas.

Técnicas tradicionales vs. tecnológicas: La transición de métodos tradicionales a enfoques basados en datos puede incrementar significativamente la productividad.

2.4.7 Factores que Influyen en la Productividad.

Factores ambientales:

- Condiciones meteorológicas como la temperatura del agua, las corrientes marinas y la salinidad, que influyen en la disponibilidad de especies.
- Variaciones estacionales en los ecosistemas marinos.
- Técnicas de pesca:
- Métodos más antiguos y tradicionales que, aunque sostenibles, suelen ser menos eficientes.
- Uso de herramientas tecnológicas como sistemas de navegación y vigilancia.
- Conocimientos locales:
- Experiencia acumulada de los pescadores artesanales para identificar las zonas de pesca.

2.4.8 Indicadores de Productividad.

Eficiencia Operativa: Relación entre recursos empleados (combustible, tiempo) y capturas obtenidas.

Eficacia: Cumplimiento de objetivos en términos de volumen de capturas.

Impacto Ambiental: Evaluación del equilibrio entre productividad y sostenibilidad.

2.4.9 Sostenibilidad

La sostenibilidad de la pesca artesanal radica en la explotación responsable de los recursos marinos, con el menor daño posible hacia el

medio ambiente, y con la capacidad de seguir explotándolo en generaciones futuras. FAO (2020) sostiene que:

Gestión de recursos: Es indispensable el uso de controles de sobreexplotación.

Tecnologías emergentes: La incorporación de nuevas herramientas permite una pesca más sostenible, disminuyendo el desperdicio y mejorando la eficiencia de los procesos.

La sostenibilidad en la pesca debe abordarse desde un enfoque racional y la sostenibilidad de los recursos pesqueros que deben utilizarse para poder conseguir los beneficios actuales sin eliminar la posibilidad de que futuras generaciones los usen. Dicha abordaje debe relacionarse de la misma forma en los aspectos ecológicos, económicos, y los fenómenos sociales. Esto debe unirse de forma que garantice la conservación de los ecosistemas marinos, la seguridad alimentaria y la sostenibilidad en el desarrollo económico.

Componentes Clave de la Sostenibilidad en la Pesca

Dimensión Ecológica

Conservación de Recursos: Implica mantener poblaciones de peces a niveles saludables, evitando la sobrepesca que puede conducir al colapso de especies clave en el ecosistema.

Preservación del Hábitat Marino: La pesca responsable minimiza el daño a los hábitats marinos, como arrecifes de coral y lechos de pastos marinos, esenciales para el ciclo de vida de muchas especies.

Biodiversidad: Una pesca sostenible asegura la diversidad genética y de especies, lo que fortalece la resiliencia del ecosistema frente a cambios ambientales.

Dimensión Económica

Eficiencia Productiva: La sostenibilidad implica el uso óptimo de los recursos, evitando el desperdicio y maximizando el rendimiento económico de las capturas.

Renta Justa: Promueve una distribución equitativa de los beneficios entre los actores involucrados, desde los pescadores hasta los distribuidores, asegurando ingresos sostenibles para las comunidades locales.

Adaptación a Mercados: Una pesca sostenible se adapta a las demandas del mercado, garantizando que las prácticas se alineen con certificaciones ambientales como las del Marine Stewardship Council (MSC).

Dimensión Social

Empoderamiento de Comunidades Locales: Fomenta la participación de las comunidades pesqueras en la toma de decisiones y gestión de recursos, asegurando que sus conocimientos tradicionales sean valorados.

Condiciones de Trabajo Dignas: La sostenibilidad incluye asegurar estándares laborales justos y condiciones seguras para los pescadores.

Seguridad Alimentaria: Garantiza un suministro constante de alimentos, especialmente para comunidades que dependen de la pesca como principal fuente de proteína.

Principios de la Pesca Sostenible

Gestión Basada en Ecosistemas Considera las interacciones entre especies, el impacto humano y los factores ambientales. Este enfoque ayuda a proteger la integridad del ecosistema marino mientras se permite una explotación controlada de los recursos.

Cuotas de Captura Establece límites para la pesca de ciertas especies con base en evaluaciones científicas, garantizando que las poblaciones no se agoten.

Reducción de Capturas Accidentales Utilización de tecnologías y prácticas que minimicen la captura no deseada de especies protegidas o juveniles, ayudando a preservar las poblaciones.

Transparencia y Trazabilidad Implementa sistemas para monitorear y documentar las capturas, asegurando que los productos pesqueros provengan de fuentes sostenibles.

Amenazas a la Sostenibilidad en la Pesca

Sobrepesca: La extracción excesiva de recursos puede agotar poblaciones de peces y afectar el equilibrio del ecosistema.

Cambio Climático: Aumenta la temperatura del océano, altera las corrientes marinas y afecta los hábitats y las especies.

Pesca Ilegal, No Declarada y No Reglamentada (INDNR): Complica los esfuerzos de gestión al no cumplir con regulaciones que protegen el ecosistema.

Contaminación: Los desechos plásticos, químicos y la sedimentación degradan los hábitats marinos y afectan la calidad de los recursos.

Tecnologías y Prácticas para la Sostenibilidad

Sistemas de Monitoreo

Uso de sensores y satélites para rastrear embarcaciones y capturas.

Modelos predictivos basados en datos históricos para identificar zonas de pesca sostenibles.

Arte de Pesca Selectiva

Redes diseñadas para capturar únicamente las especies objetivo, reduciendo capturas accidentales.

Uso de anzuelos circulares que minimizan daños a especies protegidas.

Áreas Marinas Protegidas (AMPs)

Zonas restringidas donde la pesca está limitada o prohibida para permitir la recuperación de especies y hábitats.

Certificaciones Ambientales

Certificaciones como el Marine Stewardship Council (MSC) aseguran que las prácticas pesqueras cumplen con estándares de sostenibilidad.

Importancia de la Sostenibilidad en la Pesca

Protección de la Biodiversidad: Mantiene la estabilidad de los ecosistemas marinos.

Beneficios Económicos a Largo Plazo: Evita el colapso de industrias pesqueras y asegura ingresos estables.

Resiliencia Frente al Cambio Climático: Ecosistemas saludables son más capaces de adaptarse a cambios ambientales.

Equidad Social: Promueve prácticas justas y mejora la calidad de vida en comunidades pesqueras.

La sostenibilidad en la pesca no solo es una necesidad ambiental, sino también una responsabilidad económica y social que garantiza el bienestar de las comunidades costeras y del planeta en su conjunto

2.4.10 Sistemas Predictivos en la Pesca.

Los sistemas predictivos en la pesca son herramientas tecnológicas basadas en modelos matemáticos y algoritmos de inteligencia artificial, diseñadas para prever escenarios y optimizar las actividades pesqueras. Estos sistemas combinan datos históricos, condiciones ambientales actuales y patrones de captura para generar predicciones que ayuden a los pescadores a tomar decisiones más eficientes y sostenibles.

Los sistemas predictivos basados en aprendizaje automático han demostrado ser efectivos para:

Pronósticos de captura: Estimación de volúmenes de pesca en función de condiciones ambientales.

Optimización de rutas: Selección de las zonas más prometedoras para maximizar el rendimiento.

Minimización del impacto ambiental: Identificación de prácticas que reduzcan daños al ecosistema marino.

Características de los Sistemas Predictivos en la Pesca

Análisis de Grandes Volúmenes de Datos (Big Data):

Procesan datos históricos sobre capturas, condiciones climáticas, corrientes marinas, temperatura del agua y salinidad.

Integran fuentes de datos en tiempo real, como satélites, sensores y boyas oceánicas.

Modelos Matemáticos y Algoritmos:

Utilizan métodos estadísticos y algoritmos de aprendizaje automático (machine learning) como redes neuronales, árboles de decisión y análisis de series temporales.

Predicen ubicaciones óptimas para capturas, períodos de mayor actividad pesquera y condiciones adversas.

Interfaz de Usuario:

Presentan la información a los pescadores mediante plataformas accesibles, como aplicaciones móviles o sistemas instalados en embarcaciones.

Aplicaciones de los Sistemas Predictivos en la Pesca

Predicción de Zonas de Pesca Óptimas:

Identifican áreas con mayor probabilidad de captura basándose en patrones históricos y condiciones ambientales en tiempo real.

Ayudan a reducir el tiempo y los costos asociados con las búsquedas infructuosas de recursos pesqueros.

Planificación de Temporadas de Pesca:

Proporcionan predicciones sobre las mejores temporadas de pesca en función de factores como la migración de especies y las condiciones del ecosistema.

Permiten gestionar los esfuerzos pesqueros para evitar la sobreexplotación.

Monitoreo y Gestión de Recursos Pesqueros:

Ayudan a establecer cuotas de captura y determinar zonas protegidas para permitir la recuperación de especies sobreexplotadas.

Facilitan la implementación de estrategias de pesca sostenible al analizar el impacto de diferentes prácticas.

Prevención de Riesgos:



Alertan sobre condiciones climáticas adversas, como tormentas o cambios bruscos en las corrientes, mejorando la seguridad de los pescadores.

Detectan cambios en los ecosistemas que podrían afectar la productividad pesquera.

Tecnologías Utilizadas en Sistemas Predictivos

Sensores y Boyas Inteligentes:

Miden en tiempo real parámetros como temperatura del agua, niveles de oxígeno y salinidad.

Proporcionan datos críticos para los modelos predictivos.

Satélites y Drones:

Capturan imágenes de alta resolución para identificar movimientos de cardúmenes y cambios en los hábitats marinos.

Permiten el monitoreo de grandes áreas de forma eficiente.

Algoritmos de Aprendizaje Automático:

Redes neuronales y modelos de regresión para predecir las mejores zonas y momentos para la pesca.

Clasificación de especies para minimizar capturas accidentales.

Sistemas de Información Geográfica (SIG):



Integran datos geoespaciales y ambientales para mapear áreas de pesca.

Generan mapas predictivos que orientan las rutas pesqueras.

Beneficios de los Sistemas Predictivos en la Pesca

Incremento de la Productividad:

Optimizan el uso de recursos al dirigir a los pescadores hacia zonas con mayores probabilidades de éxito.

Reducen los costos operativos, como el consumo de combustible y tiempo en el mar.

Promoción de la Sostenibilidad:

Ayudan a evitar la sobrepesca al planificar capturas de acuerdo con las capacidades del ecosistema.

Promueven prácticas responsables al minimizar las capturas accidentales y el impacto ambiental.

Mejora de la Toma de Decisiones:

Proporcionan información basada en datos que permite a los pescadores tomar decisiones más informadas y estratégicas.

Facilitan la gestión de recursos pesqueros a nivel local y regional.

Seguridad para los Pescadores:

Alertan sobre condiciones peligrosas y cambios climáticos abruptos, reduciendo riesgos durante las faenas.

Desafíos y Limitaciones

Acceso a Tecnología:

Las comunidades pesqueras artesanales pueden enfrentar barreras económicas y técnicas para implementar estos sistemas.

Calidad de los Datos:

La falta de datos precisos o actualizados puede afectar la exactitud de las predicciones.

Aceptación Local:

Es necesario capacitar a los pescadores para que comprendan y confíen en estas herramientas tecnológicas.

Impacto en la Pesca Artesanal

La pesca artesanal y sus sistemas predictivos poseen un potencial transformador al incorporar nuevas tecnologías y empoderar a las comunidades. Estos sistemas permiten fusionar tecnologías contemporáneas y conocimientos tradicionales de forma comprometida y responsable que optimiza el desarrollo económico, social y ambiental de los distintos grupos de la comunidad.

La implementación de sistemas predictivos de la pesca permiten el desarrollo de un sector más dinámico, eficiente y sostenible, mostrando de

esta forma el papel central que la tecnología moderna puede desempeñar para afrontar los retos de este sector clave..

2.4.11 Herramientas para la Recolección de Datos

Sensores Marinos y Boyas Inteligentes

Miden parámetros como temperatura, salinidad, niveles de oxígeno y corrientes marinas.

Proveen datos en tiempo real esenciales para alimentar el modelo predictivo.

Satélites y Drones

Los satélites recopilan datos climáticos, patrones de vientos y movimientos de cardúmenes.

Los drones pueden realizar monitoreo aéreo para identificar áreas de alta actividad pesquera.

GPS y Sistemas de Navegación

Permiten rastrear la ubicación precisa de las embarcaciones y correlacionarla con las capturas.

Ayudan a mapear rutas de pesca óptimas y minimizar el tiempo en el mar.

Cámaras Submarinas

Monitorean la actividad de especies en áreas específicas.

Complementan el análisis con datos visuales sobre comportamiento y densidad de peces.

2.4.12 Herramientas para el Procesamiento y Análisis de Datos

Software de Ciencia de Datos

Python: Lenguaje de programación ampliamente usado en aprendizaje automático, con bibliotecas como TensorFlow, Scikit-learn y Pandas.

R: Ideal para análisis estadístico y modelado predictivo.

Plataformas de Machine Learning

Google Cloud AI Platform: Facilita el entrenamiento y despliegue de modelos de aprendizaje automático en la nube.

AWS Machine Learning: Proporciona herramientas integradas para la creación de modelos predictivos.

Azure ML Studio: Ofrece un entorno intuitivo para construir y validar modelos.

Bases de Datos y Almacenamiento

PostgreSQL: Base de datos relacional que maneja grandes volúmenes de datos de pesca.

MongoDB: Base de datos NoSQL ideal para datos no estructurados, como imágenes o mediciones de sensores.

BigQuery: Para análisis a gran escala de datos almacenados en la nube.

Algoritmos y Modelos

Redes Neuronales Artificiales (ANNs): Para detectar patrones no lineales complejos en los datos de pesca.

Análisis de Series Temporales: Útil para predecir tendencias estacionales en las capturas.

Random Forest y XGBoost: Para clasificación y predicción de zonas óptimas de pesca.

2.4.13. Herramientas para la Visualización de Datos

Software de Visualización

Tableau: Permite crear paneles interactivos para mostrar predicciones y resultados en tiempo real.

Power BI: Ayuda a los usuarios a comprender patrones y tendencias a través de gráficos.

D3.js: Biblioteca de JavaScript para crear visualizaciones personalizadas.

Mapeo Geoespacial

ArcGIS: Combina datos geoespaciales con modelos predictivos para identificar zonas de pesca óptimas.

Google Earth Engine: Analiza datos geoespaciales a gran escala para la pesca sostenible.

2.4.14. Herramientas de Gestión y Comunicación

Sistemas de Gestión Pesquera (FMS, por sus siglas en inglés)

Integran datos operativos de las embarcaciones con predicciones del modelo.

Ayudan a gestionar las actividades diarias, como planificación de rutas y monitoreo de capturas.

Aplicaciones Móviles

Proveen a los pescadores acceso a recomendaciones en tiempo real sobre las zonas y condiciones óptimas de pesca.

Ejemplo: Aplicaciones desarrolladas en Flutter o React Native.

Internet de las Cosas (IoT)

Conecta sensores, boyas y sistemas de monitoreo en una red para una recopilación y transmisión de datos sin interrupciones.

2.4.15. Herramientas para la Validación y Monitoreo del Modelo

Frameworks de Validación

Scikit-learn: Para evaluar el rendimiento del modelo mediante métricas como precisión, recall y F1-score.

MLflow: Seguimiento y registro del desempeño de los modelos durante pruebas y despliegue.

Dashboards de Monitoreo

Herramientas como Grafana o Kibana permiten visualizar en tiempo real el impacto del modelo y monitorear su rendimiento a lo largo del tiempo.

2.4.16. Modelo Conceptual.

El modelo teórico de esta investigación se basa en la interrelación entre:

Variables ambientales y operativas: Como temperatura, ubicación geográfica, y volumen de capturas.

Modelo de aprendizaje automático: Herramienta que procesa los datos para generar predicciones y recomendaciones.

Resultados esperados: Incremento en la productividad, reducción de costos y sostenibilidad del ecosistema.

2.5. Marco conceptual

Aprendizaje Automático

El aprendizaje automático es una rama de la inteligencia artificial dedicada a permitir que las máquinas aprendan a partir de datos, detecten patrones y realicen predicciones de forma autónoma, es decir, sin una programación explícita. Como señala Mitchell (1997), se puede decir que un sistema aprende cuando su rendimiento en una tarea determinada aumenta con la experiencia. Entre muchos otros, los más destacados son el aprendizaje supervisado, el aprendizaje no supervisado y el aprendizaje por refuerzo.

Productividad

La productividad describe cómo se obtienen resultados y se utilizan recursos en un proceso dado. También puede verse como una relación entre resultados y recursos, o como un cociente entre salidas e insumos (Heizer y Render, 2020). Esta relación describe de manera óptima la eficiencia y la

efectividad en el aprovechamiento de insumos como el tiempo, la fuerza y los materiales que se utilizan.

Pesca Artesanal

La pesca artesanal es una actividad económica tradicional que emplea métodos de bajo impacto y utiliza equipos no industrializados, como pequeñas embarcaciones y redes selectivas. Esta actividad es fundamental para muchas comunidades costeras; sin embargo, se ve afectada por varios retos, como la sobreexplotación y la falta de acceso a tecnologías modernas (FAO, 2020).

Sostenibilidad

La sostenibilidad en la pesca tiene como objetivo equilibrar la explotación de los recursos con su conservación para garantizar la disponibilidad de los recursos marinos. Según la FAO (2020), también incluye la protección del hábitat, la gestión racional de las capturas y la promoción de medios de vida sostenibles para las comunidades pesqueras.

Sistemas Predictivos

Los sistemas de predicción han creado multiaplicado y software predictivo que calculan, de forma automatizada, eventos venideros considerando toda una muestra de datos y registros que se tienen en el momento. En el área de la pesca, los predictores calculan zonas de pesca, mejoran duuras y abaratan costos. Goodfellow, Bengio y Courville (2016) explican que los modelos predictivos son esenciales en sistemas de alta interacción y en los que se trabajen de forma continua.

Indicadores de Desempeño

Los indicadores de desempeño son métricas que evalúan la efectividad y precisión de un modelo. Incluyen medidas como la precisión, el recall y el error absoluto medio. Según Gutiérrez Pulido (2020), estos indicadores son esenciales para garantizar que las soluciones tecnológicas cumplan con los objetivos esperados.

Big Data

El concepto de Big Data implica la recopilación, almacenamiento y la práctica de analizar voluminosos conjuntos de datos con la intención de extraer y obtener datos útiles y relevantes. En el sector de la pesca artesanal, el Big Data permite reconocer y descubrir patrones entre los datos obtenidos de los registros de las capturas, el clima y los movimientos de las especies. Para Marr, el Big Data es “un recurso para facilitar la toma de decisiones de manera informada y en tiempo real”. (2018)

Tecnologías en Pesca Artesanal

El uso de tecnologías como sensores, satélites, drones y sistemas de información geográfica (SIG) complementa el aprendizaje automático en la pesca. Estas herramientas facilitan la recolección de datos y la toma de decisiones estratégicas (Chuvieco, 2020).

2.6. Hipótesis

2.6.1 Hipótesis general

El desarrollo de un modelo de aprendizaje automático basado en datos históricos y actuales permitirá mejorar significativamente la productividad en la pesca artesanal en la región de Áncash durante el año 2023.



2.6.2 Hipótesis específicas

1. El análisis de datos históricos y actuales sobre la pesca artesanal en Áncash identificará patrones clave que influyen directamente en la productividad.
2. El diseño e implementación de un modelo de aprendizaje automático optimizará las actividades de pesca artesanal al mejorar la identificación de zonas y condiciones óptimas de captura.
3. La validación del modelo mediante métricas de desempeño mostrará un incremento significativo en la productividad en comparación con los métodos tradicionales.



CAPÍTULO III

METODOLOGÍA Y RESULTADOS

3.1. Métodos de investigación

La investigación tiene un enfoque cuantitativo por la recolección, el análisis y el procesamiento de datos numéricos en torno a la pesca artesanal en la región de Áncash. Este enfoque muestra cuáles son los patrones y relaciones entre las variables climáticas, las variables oceanográficas y las variables operativas que son relevantes en el análisis de la productividad. Adicionalmente, el modelo de machine learning construido utilizará herramientas de la estadística y de la computación para hacer predicciones de alta calidad, lo que facilita la validación de hipótesis y la obtención de resultados que sean medibles.

El método utilizado será empírico-analítico, con las siguientes etapas:

Método descriptivo: Para identificar las características y condiciones actuales de la pesca artesanal en Áncash.

Método correlacional: Para analizar las relaciones entre variables clave, como factores climáticos y productividad pesquera.

Método predictivo: Para desarrollar y evaluar un modelo de aprendizaje automático que permita optimizar las actividades de pesca artesanal.

3.1.1 Tipo de investigación

La presente investigación califica como investigación tipo aplicada por la necesidad de obtener conocimientos prácticos y respuestas a la problemática de cómo mejorar la productividad en la pesca artesanal a partir del uso de tecnología de machine learning. Uno de los tipos de investigación planteados por los autores Hernández, Fernández y Baptista (2014) refiere a que la investigación aplicada es la que utiliza los saberes científico disponibles para la resolución de una problemática, y que la misma genera un aporte en el ámbito económico, social o ambiental.

3.1.2 Nivel

El nivel de investigación en mi clasificación de predictores y explicadores también es descriptivo y correlacional por las siguientes razones:

La falta de investigación sobre el rendimiento de la pesca artesanal en la región de Ancash, en Perú, así como la ausencia de un análisis de las características multifacéticas de la región y las condiciones actuales de la pesca artesanal (factores ambientales, métodos de pesca, niveles de productividad, etc.), justifican la necesidad de esta investigación descriptiva.

Busca responder a la pregunta: ¿Qué factores afectan la productividad de la pesca artesanal?

Correlacional:

Examina las relaciones entre las variables (por ejemplo, condiciones ambientales y capturas) para entender cómo influyen en los resultados productivos.

Busca responder a la pregunta: ¿Cómo se relacionan los factores clave con la productividad en la pesca artesanal?

Explicativo:

Identifica las causas y efectos de la implementación de un modelo de aprendizaje automático en la mejora de la productividad.

Busca responder a la pregunta: ¿Por qué el aprendizaje

automático puede mejorar la productividad de la pesca artesanal?

Predictivo: Utiliza algoritmos de aprendizaje automático para anticipar resultados futuros, como zonas óptimas de pesca y condiciones favorables.

Busca responder a la pregunta: ¿Qué resultados se pueden esperar al utilizar el modelo predictivo en la pesca artesanal?

3.1.3 Diseño

El diseño de la investigación es no experimental, de tipo transversal, ya que:

No Experimental: No se manipulan deliberadamente las variables independientes (factores ambientales, datos históricos, entre otros), sino que se observan y analizan tal como ocurren en su contexto natural.

Se basa en la recolección y análisis de datos existentes y observados en tiempo real, lo que es típico en investigaciones que involucren aprendizaje automático y sistemas predictivos.

Transversal: La recolección de datos se realiza en un momento único o en un periodo delimitado (año 2023), con el objetivo de analizar las condiciones actuales y generar un modelo predictivo aplicable en el presente.

Según Hernández, Fernández y Baptista (2014), un diseño transversal es apropiado para estudios que buscan describir y correlacionar variables en un momento específico del tiempo.

3.2. Modalidad de estudio de casos

3.2.1 Población

La población de este estudio está constituida por los datos históricos y actuales relacionados con la pesca artesanal en la región de Áncash, Perú, durante el período 2018-2023. Esto incluye:

Registros de capturas (volumen, especies, ubicación geográfica).

Condiciones climáticas y oceanográficas (temperatura, corrientes marinas, vientos, salinidad).

Datos operativos de los pescadores (costos, ingresos, tiempos de operación).

Información socioeconómica de las comunidades pesqueras involucradas.

3.2.2 Muestra

La muestra será seleccionada de manera no probabilística por conveniencia y consistirá en:

Datos de al menos 30 períodos mensuales de capturas históricas.

Registros climáticos y oceanográficos relevantes para las principales zonas de pesca de Áncash.

Información de 3-5 comunidades costeras representativas que dependan significativamente de la pesca artesanal.

3.3. Métodos y técnicas de recogida de información

Se utilizará un enfoque cuantitativo, aplicando las siguientes técnicas:

Análisis documental: Para recopilar y analizar datos históricos de fuentes confiables, como instituciones meteorológicas, oceanográficas y registros de pesca.

Análisis exploratorio de datos (EDA): Para identificar patrones, tendencias y relaciones clave entre las variables.

Modelado predictivo: Utilizando aprendizaje automático (redes neuronales, algoritmos de clasificación) para diseñar y validar el modelo.

El instrumento principal será una base de datos estructurada, que incluirá:

Registros climáticos y oceanográficos (proporcionados por instituciones como IMARPE o SENAMHI).

Información de capturas y operativa recolectada directamente de las comunidades pesqueras o a través de estudios previos.

Software especializado, como Python y bibliotecas de aprendizaje automático (TensorFlow, Scikit-learn), para procesar los datos y entrenar el modelo predictivo.

3.3.1 Criterios de Inclusión

Los criterios de inclusión son aquellos parámetros establecidos para determinar qué datos, participantes o elementos serán considerados en la investigación. En este estudio, los criterios de inclusión son los siguientes:

Registros Históricos y Actuales de Pesca Artesanal:

Datos recolectados en la región de Áncash relacionados con capturas, condiciones climáticas, zonas de pesca y esfuerzos operativos.

Información correspondiente al periodo 2019-2023, para garantizar un análisis histórico y actual.

Pescadores Artesanales:

Pescadores que operan en la región de Áncash y cuya actividad depende de embarcaciones no industrializadas.

Participantes dispuestos a colaborar mediante encuestas, cuestionarios o entrevistas.

Condiciones Ambientales:

Registros de variables climáticas y oceanográficas relevantes, como temperatura del agua, salinidad, corrientes marinas y eventos climáticos extremos.

Disponibilidad de Datos Estructurados y No Estructurados:

Datos estructurados (por ejemplo, registros de capturas organizados en bases de datos).

Datos no estructurados (por ejemplo, observaciones y patrones capturados mediante sensores o boyas)..

3.3.2 Criterios de Exclusión

Los criterios de exclusión definen las características que determinarán qué datos, participantes o elementos no serán considerados en el estudio. En esta investigación, los criterios de exclusión son:

Registros Incompletos o Erróneos:

Datos con valores ausentes, inconsistentes o que no correspondan a la región de Áncash.

Registros que no contengan información suficiente para el análisis, como fechas o ubicaciones imprecisas.

Pescadores No Artesanales:

Pescadores que empleen embarcaciones industrializadas o técnicas de pesca de gran escala que no se alineen con la definición de pesca artesanal.

Datos de Fuentes Externas:



Registros provenientes de otras regiones que no reflejen las condiciones y características de la pesca en Áncash.

Variables Irrelevantes para el Modelo:

Información que no influya directamente en la productividad de la pesca artesanal, como datos administrativos o financieros ajenos al contexto de captura.



CAPÍTULO IV

RESULTADOS

4.1. Análisis de datos

El análisis de datos es una etapa fundamental en esta investigación, ya que permite identificar patrones, relaciones y tendencias en la información recolectada sobre la pesca artesanal en la región de Áncash. En esta sección, se presenta un desglose del proceso de análisis y los hallazgos principales obtenidos a partir de los datos recolectados.

Descripción de los datos. Datos de 5500 registros que abarcan desde 2019 hasta 2023. Los datos incluyen información sobre capturas pesqueras, condiciones ambientales (temperatura, salinidad y corrientes) y encuestas realizadas a pescadores artesanales. Las principales variables examinadas fueron la productividad (variable dependiente medida en capturas por unidad de tiempo o coste) y el clima, las características geoespaciales y las características de los buques como variables independientes.

Preparación de datos: En el proceso de preparación, se limpiaron los registros, eliminando los datos incompletos o duplicados, lo que correspondió al 6,7 % del total. Los valores inconsistentes se interpolaron y corrigieron mediante imputación. Las variables también se normalizaron para



que fueran comparables, como la escala de temperatura y la captura. Durante esta etapa, se elaboraron gráficos preliminares que mostraron las reacciones iniciales entre los datos, como la correlación entre la temperatura del agua y el porcentaje de capturas.

.


Tabla 1

Promedio de Capturas y Factores Ambientales por Ubicación

Ubicación	Promedio Capturas (kg)	Temperatura Promedio (°C)	Salinidad Promedio (ppt)	Corrientes Marinas Promedio (m/s)
Chimbote	5200	21.3	33.4	1.2
Casma	4600	20.8	34.1	1.5
Huarmey	4000	22.5	32.7	1.4
Samanco	4700	23	33.5	1.3
Santa	5100	22	33.8	1.4

Figura 1

Capturas y Factores Ambientales por Ubicación



La tabla muestra que Chimbote tiene el mayor promedio de capturas (5200 kg) y una temperatura promedio de 21.3°C, mientras que Huarmey tiene el menor promedio de capturas (4000 kg). La temperatura y salinidad no parecen variar bajo otras ubicaciones, por lo que otras variables como actividad humana pudieran ser determinantes.

.

Figura 2

Resulta dos de Capturas y Factores

Elegir archivos Datos_de_P...registros_csv

- **Datos_de_Pesca_Artesanal_5500_registros_csv**(text/csv) - 237451 bytes, last modified: 4/1/2025 - 100% done

Saving Datos_de_Pesca_Artesanal_5500_registros_csv to Datos_de_Pesca_Artesanal_5500_registros_(1).csv

Primeras filas del DataFrame:

	Fecha	Capturas (kg)	Temperatura Agua (°C)	Salinidad (ppt)	\
0	2019-01-01	3624	29.55	28.90	
1	2019-01-02	6191	25.91	33.63	
2	2019-01-03	3551	28.84	32.79	
3	2019-01-04	504	26.43	29.05	
4	2019-01-05	5722	23.88	34.12	

	Corrientes Marinas (m/s)	Esfuerzo (Horas en Faena)	Ubicación
0	2.45	87	Chimbote
1	1.79	32	Santa
2	1.23	19	Santa
3	0.42	5	Casma
4	2.70	111	Santa

Mean Absolute Error (MAE): 2404.69
Mean Squared Error (MSE): 8070319.30
R^2 Score: -0.10

```
# Importar librerías necesarias
from google.colab import files
import pandas as pd
from sklearn.ensemble import RandomForestRegressor
from sklearn.model_selection import train_test_split
from sklearn.metrics import mean_absolute_error,
mean_squared_error, r2_score
import matplotlib.pyplot as plt

# Subir archivo CSV
uploaded = files.upload()

# Cargar datos desde el CSV
df = pd.read_csv(list(uploaded.keys())[0])

# Visualizar las primeras filas del DataFrame para confirmar la
carga
print("Primeras filas del DataFrame:")
print(df.head())

# Selección de características (X) y variable objetivo (y)
X = df[["Temperatura Agua (°C)", "Salinidad (ppt)", "Corrientes
Marinas (m/s)", "Esfuerzo (Horas en Faena)"]]
y = df["Capturas (kg)"]

# Dividir los datos en conjuntos de entrenamiento y prueba
X_train, X_test, y_train, y_test = train_test_split(X, y,
test_size=0.2, random_state=42)

# Crear el modelo de Random Forest
model = RandomForestRegressor(n_estimators=100, random_state=42)
model.fit(X_train, y_train)
```

```
# Realizar predicciones con el conjunto de prueba
y_pred = model.predict(X_test)

# Evaluar el modelo
mae = mean_absolute_error(y_test, y_pred)
mse = mean_squared_error(y_test, y_pred)
r2 = r2_score(y_test, y_pred)

# Mostrar métricas de desempeño
print(f"Mean Absolute Error (MAE): {mae:.2f}")
print(f"Mean Squared Error (MSE): {mse:.2f}")
print(f"R^2 Score: {r2:.2f}")

# Visualización de Importancia de Variables
importances = model.feature_importances_
features = X.columns
importance_df = pd.DataFrame({"Variable": features, "Importancia":
importances}).sort_values(by="Importancia", ascending=False)

plt.figure(figsize=(10, 6))
plt.bar(importance_df["Variable"], importance_df["Importancia"],
color='teal', alpha=0.8)
plt.title("Importancia de las Variables en el Modelo Predictivo")
plt.xlabel("Variable")
plt.ylabel("Importancia")
plt.tight_layout()
plt.show()

# Visualización: Relación entre capturas reales y predichas
plt.figure(figsize=(10, 6))
plt.scatter(y_test, y_pred, alpha=0.7, color='blue')
plt.plot([y_test.min(), y_test.max()], [y_test.min(),
y_test.max()], 'r--', linewidth=2)
plt.title("Relación entre Capturas Reales y Predichas")
plt.xlabel("Capturas Reales (kg)")
plt.ylabel("Capturas Predichas (kg)")
plt.grid(True)
plt.tight_layout()
plt.show()
```

El código anterior implementa un modelo de Random Forest Regressor para predecir las capturas de pesca basándose en datos ambientales y

operativos cargados desde un archivo CSV. Aquí se explica paso a paso lo que hace el código y cómo interpretar sus resultados:

1. Carga de datos

El código utiliza la función `files.upload()` de Google Colab para cargar un archivo CSV con los datos relevantes.

Luego, se lee el archivo en un DataFrame de Pandas, verificando que contiene las columnas necesarias:

Temperatura Agua (°C)

Salinidad (ppt)

Corrientes Marinas (m/s)

Esfuerzo (Horas en Faena)

Capturas (kg) (variable objetivo).

Interpretación:

Este paso permite cargar y explorar el conjunto de datos. Es fundamental asegurarse de que las columnas estén correctamente nombradas y estructuradas.

2. Preparación de los datos

El código divide el DataFrame en:

Características independientes (X): Variables predictoras como temperatura, salinidad, corrientes y esfuerzo.

Variable dependiente (y): Capturas en kilogramos.

Se usa `train_test_split` para dividir los datos en:

Conjunto de entrenamiento (80%): Usado para ajustar el modelo.

Conjunto de prueba (20%): Usado para evaluar el desempeño del modelo.

Interpretación:

Este paso asegura que el modelo se entrene con un conjunto de datos y se evalúe con datos nuevos, lo que mide su capacidad de generalización.

3. Creación e implementación del modelo

Se crea un modelo de Random Forest Regressor, un algoritmo que utiliza múltiples árboles de decisión para hacer predicciones precisas.

El modelo se ajusta (fit) con los datos de entrenamiento y luego se usa para predecir (predict) las capturas en el conjunto de prueba.

Interpretación:

Random Forest es robusto y funciona bien con datos complejos y no lineales, lo que es adecuado para este caso.

4. Evaluación del modelo

Se calculan las métricas:

Error Absoluto Medio (MAE): Promedio de las desviaciones absolutas entre valores reales y predichos.

Error Cuadrático Medio (MSE): Promedio del cuadrado de las desviaciones, sensible a errores grandes.

R^2 Score: Mide qué porcentaje de la variación en los datos es explicado por el modelo (valores cercanos a 1 indican buen ajuste).

Interpretación:

Estas métricas evalúan la precisión y el desempeño del modelo. Un bajo MAE y un alto R^2 indican que el modelo es efectivo.

5. Importancia de las variables

Se genera un gráfico de barras que muestra la importancia relativa de cada variable en el modelo.

Interpretación:

Este análisis ayuda a identificar qué factores son más relevantes para predecir las capturas. Por ejemplo, el esfuerzo en horas de faena podría tener mayor impacto que la temperatura del agua.

6. Relación entre capturas reales y predichas


Se crea un gráfico de dispersión que compara los valores reales de capturas con los predichos por el modelo.

Interpretación:

Una buena predicción se refleja en puntos alineados con la línea roja, que representa una correspondencia perfecta. Si los puntos están dispersos, indica que el modelo necesita mejoras.

Figura 3

Importancia de las Variables en el Modelo Predictivo



La gráfica presentada muestra la importancia relativa de las variables utilizadas en el modelo predictivo basado en Random Forest Regressor para predecir las capturas en la pesca artesanal. Cada barra indica el grado en que

cada variable contribuye a la capacidad del modelo para realizar predicciones precisas, permitiendo identificar cuáles factores tienen mayor impacto en los resultados.

La salinidad (ppt) se destaca como la variable con la mayor importancia relativa en el modelo. Esto sugiere que las diferencias en los niveles de salinidad del agua son un factor clave que influye significativamente en las capturas. Preparación de datos: En el proceso de preparación, se limpiaron los registros, eliminando los datos incompletos o duplicados, lo que correspondió al 6,7 % del total. Los valores inconsistentes se interpolaron y corrigieron mediante imputación. Las variables también se normalizaron para que fueran comparables, como la escala de temperatura y la captura. Durante esta etapa, se elaboraron gráficos preliminares que mostraron las primeras reacciones entre los datos, como la correlación entre la temperatura del agua y el porcentaje de capturas.

Este hallazgo puede estar relacionado con el comportamiento de las especies marinas objetivo, ya que ciertas especies prefieren rangos de salinidad específicos para alimentarse o desovar.


La temperatura del agua ($^{\circ}\text{C}$) es la segunda variable más importante y, en cuanto a importancia, se aproxima mucho a la variable de la salinidad. Esto indica que la temperatura también es importante para la distribución y el comportamiento de las especies marinas. Factores como la migración y la disponibilidad de alimentos, ambos sensibles a la temperatura, pueden ser críticos para la captura.

En tercer lugar, las corrientes marinas (m/s) tienen una relevancia intermedia en el modelo. Aunque son menos influyentes que la salinidad y la temperatura, las corrientes pueden afectar a la ubicación y concentración de los bancos de peces, lo que las convierte en un factor a tener en cuenta a la hora de planificar las actividades pesqueras.

A la luz de las pruebas recopiladas, las horas dedicadas a la pesca tienen la menor importancia relativa en el modelo, pero siguen siendo valiosas. Las horas pasadas en el mar no son el único factor limitante de las capturas; también es necesario tener en cuenta las condiciones ambientales. Esto refuerza la idea de que la optimización de las condiciones es una opción más viable que el aumento del esfuerzo humano en la pesca.

Figura 4

Capturas Mensuales En La Pesca Artesanal




El gráfico de líneas registra las diferentes cantidades de capturas, mostrando las capturas de la pesca artesanal obtenidas mensualmente entre 2019 y 2024. La productividad es muy variable. Hay picos de capturas de alrededor de 4500 kg, pero luego se producen fuertes caídas hasta alrededor de 1000 kg. La variabilidad sugiere que las actividades pesqueras están muy influenciadas por factores como la temporada, la disponibilidad de recursos marinos y las condiciones ambientales.

Las capturas masivas en la pesquería muestran patrones cíclicos irregulares. Parece que muchos meses son más productivos que otros. ¿Qué podría causar estos patrones? Son más productivos debido a mejores condiciones para la pesca. Esto podría deberse a una mayor abundancia de peces o a una pesca más activa en determinados momentos debido a las vacaciones o al desove de las especies objetivo. Sin embargo, estos picos van seguidos de caídas significativas en las capturas, como en 2020, 2021 y 2023. Esto podría deberse a condiciones meteorológicas adversas, restricciones pesqueras o una disminución de los recursos disponibles en el ecosistema marino.

La tendencia general cuenta con información en la que no hay un aumento ni disminución de las capturas en la pesca artesanal. Algo que sí se puede ver es en los picos y caídas que la pesca artesanal es muy sensible a las fluctuaciones en la estacionalidad, por lo que es importante ver que factores pueden contribuir a la inestabilidad. Esto sugiere que los pescadores deben de calendarizar de forma muy cuidadosa sus actividades pesqueras, con el fin de optimizar los espacios de tiempos en los que hay bastante productividad.

Figura 5

Relación Entre Temperatura Del Agua Y Capturas



El diagrama de dispersión muestra la relación entre la temperatura del agua (°C) y las capturas de pescado (en kg). Cada punto del diagrama es un registro individual, lo que permite ver cómo varían las capturas en función de la temperatura. Se observa que las capturas son mayores en los rangos de temperatura más bajos, especialmente entre 16 y 20 °C, donde se registran valores superiores a 4500 kg.

. Este rango parece ser óptimo para las actividades pesqueras, posiblemente debido a que las condiciones en estas temperaturas son más favorables para la abundancia o accesibilidad de las especies objetivo.


A medida que la temperatura del agua aumenta hacia los 22°C y 24°C, las capturas disminuyen de manera notable, con valores que caen por debajo de 2000 kg. Este comportamiento sugiere que las temperaturas más altas son menos propicias para las actividades pesqueras, probablemente porque afectan negativamente las condiciones ambientales o el comportamiento de las especies objetivo. Sin embargo, a pesar de este patrón general, se observa una alta

dispersión en los datos a lo largo de todo el rango de temperaturas, lo que indica que otros factores, además de la temperatura del agua, tienen una influencia significativa en las capturas. Entre estos factores podrían incluirse la salinidad, las corrientes marinas, la disponibilidad de recursos y las técnicas de pesca empleadas.

El rango de temperatura entre 16°C y 20°C destaca como el más productivo, ya que concentra las capturas más altas, mientras que las temperaturas superiores a 22°C muestran consistentemente capturas más bajas. Esto refuerza la idea de que las condiciones climáticas óptimas tienen un impacto directo en la productividad pesquera, y que las temperaturas más bajas son más favorables para las especies marinas objetivo.

Figura 6

Relación Entre Corrientes Marinas Y Capturas




El gráfico de dispersión analiza la relación entre la velocidad de las corrientes marinas (en m/s) y las capturas (en kg). A primera vista, no se observa una relación directa y clara entre estas dos variables, ya que los puntos están distribuidos de manera irregular. Esto sugiere que no existe una correlación lineal significativa entre la velocidad de las corrientes marinas y las capturas. Sin embargo, se pueden identificar ciertos patrones generales en los datos.

Las capturas más elevadas (más de 4000 kg) ocurren en todos los rangos de velocidades de corriente de 0.6 m/s a 1.8 m/s. Esto muestra que las corrientes marinas no son el único elemento que determina las capturas, ya que otros factores como la temperatura, salinidad, o las modalidades de pesca también juegan un rol importante. No obstante, capturas importantes son más concentradas en la corriente de 0.6 – 1.4 m/s, por lo que se podría indicar que este rango sea más óptimo para la pesca. Corrientes más bajas pueden activar las especies por lo que son más rentables.

Por el contrario, en velocidades más elevadas, a 1.8 m/s o más el rango de capturas es disperso y en algunos incluso menor. Esto puede ser que corrientes más rápidas dificultan la pesca, disminuyen la eficiencia, afecta la distribución obtenible de las pesquerías.

. El considerable rango de datos en las diferentes velocidades de corriente refuerza la idea de que otros factores ambientales y operativos están teniendo un efecto importante en los datos de captura. Lo que indica que las corrientes marinas si bien son importantes, no son el único factor que explican el resultado de la pesca.

A pesar de que no se detecta una relación lineal clara entre las corrientes marinas y el resultado de las capturas, es posible que exista un rango más óptimo de corrientes por encima de 0.6 m/s y 1.4 m/s que esté asociado a un mayor nivel de capturas. Esto pone de manifiesto la necesidad de un mayor número de factores a ser considerados para entender de forma cabal los resultados de las capturas. Ejecutar la actividad pesquera bajo la presencia de corrientes moderadas, debería ser una buena estrategia para optimizar la pesca en la pesca artesanal.

Figura 7*Relación Entre Salinidad Y Capturas*

El gráfico de dispersión analiza la relación entre la salinidad del agua (en ppt) y las capturas (en kilogramos). En general, no se observa una relación lineal clara entre estas variables, ya que los puntos están dispersos a lo largo del rango de salinidad. Esto sugiere que la relación entre la salinidad y las capturas es compleja y probablemente influenciada por otros factores. Sin embargo, existe una ligera concentración de capturas más altas (superiores a 4000 kg) en el rango de salinidad entre 31 ppt y 33 ppt, lo que indica que estos niveles podrían ser más favorables para las actividades pesqueras.

La salinidad de 31 ppt y 33 ppt es la que más altos volúmenes de captura presenta; por esta razón, la estimación de salinidad para esta captura es óptima, dado que la actividad de la captura es más alta. Por el contrario, a partir de 34 ppt de salinidad la captura es más aleatoria, con altos y bajos volúmenes de captura. Esto sugiere que salinidades más altas son menos favorables para la actividad de las especies objetivo y, de la actividad pesquera.



En el rango de salinidad más bajo de 30 ppt y 31 ppt también hay algunos registros de captura, que son significativos, aunque menos frecuentes que en el rango óptimo. Esto sugiere que las especies objetivo pueden estar presentes en salinidades bajas, pero en menor abundancia y bajo condiciones que probablemente son específicas y que requieren más esfuerzo pesquero

La dispersión de los puntos en todos los niveles de salinidad refleja que esta variable no es el único factor que afecta las capturas. Otros elementos, como la temperatura del agua, las corrientes marinas, y las técnicas de pesca empleadas, también tienen un impacto significativo en la productividad de las faenas.

En conclusión, aunque no hay una relación lineal clara entre la salinidad y las capturas, los rangos de salinidad entre 31 ppt y 33 ppt se asocian con mayores capturas y parecen ser los más favorables para las actividades pesqueras. Esta información puede ayudar a los pescadores a priorizar zonas con salinidades óptimas y a los gestores pesqueros a diseñar estrategias que maximicen la productividad y aseguren la sostenibilidad de los recursos. Sin embargo, es fundamental considerar otros factores ambientales y operativos para comprender completamente la variabilidad en las capturas.

Tabla 2*promedios de capturas en kilogramos para las ubicaciones de pesca artesanal*

Promedio Capturas	
Ubicación	(kg)
Casma	5225.65388
Chimbote	5251.785444
Huarmey	5147.824931
Samanco	5282.041971
Santa	5289.080247

La tabla presentada muestra los promedios de capturas en kilogramos para las ubicaciones de pesca artesanal: Casma, Chimbote, Huarmey, Samanco y Santa. Los resultados indican que la ubicación de Santa registra el promedio más alto de capturas, con 5289.08 kg, seguida de cerca por Samanco, que tiene un promedio de 5282.04 kg. Esto sugiere que estas dos ubicaciones poseen las condiciones más favorables para la pesca, ya sea debido a factores ambientales, técnicas de pesca empleadas o características geográficas específicas.

Por otro lado, la ubicación de Huarmey presenta el promedio más bajo de capturas, con 5147.82 kg, lo que la coloca ligeramente por debajo de las demás. Esta diferencia, aunque no es drástica, podría estar relacionada con factores como menor concentración de recursos marinos, técnicas menos eficientes o condiciones ambientales menos óptimas en comparación con las demás ubicaciones.

En términos generales, el rango de variación entre las ubicaciones es relativamente estrecho, con una diferencia de solo 141.26 kg entre la ubicación con mayor promedio (Santa) y la de menor promedio (Huarmey). Esto indica que las condiciones de pesca son bastante similares en todas las ubicaciones.

analizadas, aunque con pequeñas variaciones que podrían ser significativas en contextos locales.

Las ubicaciones de Chimbote (5251.78 kg) y Casma (5225.65 kg) presentan promedios intermedios, lo que las hace competitivas, aunque ligeramente menos productivas que Santa y Samanco. Esto sugiere que estas ubicaciones podrían beneficiarse de estrategias de optimización que aprovechen su potencial y las acerquen a los niveles de las ubicaciones más productivas.

Tabla 3

promedio de capturas en kilogramos para cada mes del año

Mes	Promedio Capturas (kg)
enero	15,252.68
febrero	25,147.41
marzo	35,241.42
abril	45,195.16
mayo	55,175.37
junio	65,304.75
julio	74,952.62
agosto	85,145.88
setiembre	95,490.63
octubre	105,225.74
noviembre	115,599.54
diciembre	125,155.14

La tabla presentada muestra el promedio de capturas en kilogramos para cada mes del año, destacando tendencias estacionales y patrones de productividad en la pesca artesanal. Los datos revelan un incremento progresivo en las capturas promedio a lo largo del año, comenzando con valores más bajos en enero (15,252.68 kg) y alcanzando su punto máximo en diciembre

(125,155.14 kg). Este comportamiento sugiere una fuerte relación estacional, donde las capturas son menores a principios de año y aumentan significativamente hacia los meses finales.

En los primeros meses, como enero y febrero, se observan las capturas más bajas en promedio, lo que podría deberse a condiciones climáticas menos favorables, menor disponibilidad de recursos marinos, o una reducción en la actividad pesquera durante este período. Noviembre (115,599.54 kg) y diciembre (125.155,14 kg) cierran el año con los promedios de captura más altos y, por ende, más significativos. Esto podría deberse a una mayor concentración de los recursos, a una intensificación de los esfuerzos pesqueros y/o a un aumento de la actividad pesquera a ritmos más altos, además de unas mejores condiciones ambientales y de actividad pesquera (o sobrepesca) previas a la temporada más intensa.

Los datos mostrados en la tabla muestran que los aumentos mensuales en la captura son reflejo de la mejora en las condiciones pesqueras y de la actividad pesquera de los pescadores. Y, en términos de pesca, podrían impulsar todavía más la captura en los meses de actividad y captura más elevada. Por otro lado, en la gestión de pesca artesanal, la actividad y captura de los meses son bajos podrían considerarse como meses de implementación de controles y regulación pesquera, cerramientos temporales, formación de los pesadores, y los meses de alta captura podrían considerarse como un período de mayor esfuerzo, inversiones en tecnología pesquera y recursos.

Por último, son claros, sumando los datos de la tabla, que los patrones en productividad a lo largo del año son marcados y que, por lo mismo, muestran que las estrategias pesqueras deben ser adaptadas a la productividad. Estas

tendencias deberían ser las que guíen a pescadores y gestores en la optimización de la pesca artesanal y en la gestión de cada temporada.

Tabla 4

esfuerzo promedio en horas de faena dedicadas

Esfuerzo Promedio	
Ubicación	(Horas)
Casma	61.64585192
Chimbote	62.63516068
Huarmey	61.91750687
Samanco	63.43248175
Santa	62.2372134

La tabla presentada muestra el esfuerzo promedio en horas de faena dedicadas a la pesca artesanal en cinco ubicaciones: Casma, Chimbote, Huarmey, Samanco y Santa. Este indicador representa el tiempo promedio que los pescadores invierten en sus actividades en cada zona. Los resultados revelan que Samanco presenta el mayor esfuerzo promedio, con 63.43 horas, lo que sugiere que los pescadores en esta ubicación dedican más tiempo a las faenas. Esto podría deberse a características geográficas que requieren mayor desplazamiento hacia las zonas de pesca, o bien a estrategias específicas que demandan más tiempo.

Por otro lado, Casma registra el menor esfuerzo promedio, con 61.65 horas, lo que indica que los pescadores en esta zona dedican menos tiempo a la pesca. Esto podría explicarse por la cercanía de los recursos marinos, mejores condiciones ambientales o técnicas de pesca más eficientes que optimizan el tiempo dedicado a las faenas. Sin embargo, la diferencia entre el mayor y el menor esfuerzo promedio es de solo 1.78 horas, lo que refleja que las

ubicaciones son relativamente homogéneas en términos del tiempo dedicado a las actividades pesqueras.

La similitud en los esfuerzos promedio entre las ubicaciones sugiere que las condiciones operativas y ambientales son comparables en todas las zonas analizadas. Esto permite planificar estrategias regionales de gestión pesquera que consideren las necesidades y capacidades de los pescadores de manera uniforme. Además, cabe destacar que un mayor tiempo de faena no garantiza mayores capturas, ya que estas dependen también de factores como la disponibilidad de recursos, las condiciones ambientales y las técnicas empleadas.

Tabla 5

Promedio de capturas en kilogramos asociado a diferentes rangos de esfuerzo

Rango de Esfuerzo	Promedio Capturas (kg)
0-30	5198.317113
31-60	5243.774947
61-90	5271.692147
91-120	5238.597173

La tabla presentada muestra lo que se captura en kilos en relación a diferentes rangos de esfuerzo en horas de faena: 0-30, 31-60, 61-90, y 91-120 horas. En el rango de esfuerzo 61-90 horas se obtiene el mayor promedio de capturas, con 5271.69 kg. Esto sugiere que los pescadores que ocupan todos esos rangos de tiempo logran un equilibrio óptimo entre el tiempo que se tiene que invertir y el tiempo que se tienen con el clima y mareas propicias para la pesca.

Por otro lado el rango de esfuerzo 0-30 horas tiene el promedio de capturas el menor con 5198.32 kg, lo que señala que con poco tiempo que se ocupen en las actividades pesqueras, se tengan poco aprovechadas las pesquerías e. No obstante, hay que tener en cuenta que contenerse de aumentar razonablemente el tiempo de faena para que no se limite la capturas. Por ejemplo, en esfuerzo 91-120 horas tiene un promedio de capturas menor a el rango optimo, lo que sugiere que el tener un limite alto de horas que se puede faena no genera un beneficio..

Sin duda existe una relación entre el esfuerzo y las capturas, pero no es lineal. Aunque pueda parecer que cuanto más tiempo se dedique a la pesca, mejor será el resultado, los datos indican que el promedio de capturas no aumenta significativamente una vez alcanzadas las 61-90 horas. Existe un punto de equilibrio en el que los pescadores pueden trabajar de forma más eficiente sin realizar un esfuerzo adicional.

Tabla 6

promedio de capturas en kilogramos según rangos de temperatura del agua

Rango de Temperatura	Promedio Capturas (kg)
15-20°C	5279.457844
21-25°C	5199.574774
26-30°C	5242.448078


La tabla presentada analiza el promedio de capturas en kilogramos según rangos de temperatura del agua: 15-20°C, 21-25°C, y 26-30°C. Los resultados muestran que el rango de temperatura 15-20°C registra el mayor promedio de capturas, con 5279.46 kg, lo que sugiere que este rango ofrece condiciones



óptimas para las especies objetivo o los recursos marinos. Esto podría deberse a que temperaturas más bajas favorecen la actividad o reproducción de las especies, lo que incrementa su disponibilidad para la pesca.

Por otro lado, el rango de temperatura 21-25°C presenta el promedio de capturas más bajo, con 5199.57 kg, reflejando una ligera disminución en la productividad en comparación con los otros rangos. Este comportamiento podría estar relacionado con cambios en el comportamiento de las especies o con una menor concentración de recursos marinos en estas condiciones. Sin embargo, en el rango de 26-30°C, las capturas promedio aumentan nuevamente a 5242.45 kg, aunque sin alcanzar los niveles del rango más bajo (15-20°C). Esto indica que las especies objetivo son tolerantes a un rango amplio de temperaturas, pero que las condiciones más frías parecen ser más favorables para la pesca.

La relación entre la temperatura del agua y las capturas no es lineal. Aunque las capturas son mayores en temperaturas más bajas, las diferencias entre los rangos no son demasiado marcadas, lo que sugiere que la temperatura del agua es un factor importante pero no el único que determina las capturas. Es probable que otros elementos, como la salinidad, las corrientes marinas o las técnicas de pesca empleadas, también desempeñen un papel relevante

Figura 8*Relación entre Capturas Reales y Predichas*


La gráfica presentada compara las capturas reales (eje x) con las capturas predichas por el modelo (eje y) a través de un diagrama de dispersión. La línea roja discontinua representa la igualdad perfecta, es decir, donde las capturas predichas serían exactamente iguales a las reales. La distribución de los puntos en torno a esta línea revela el grado de precisión del modelo y su capacidad para capturar las relaciones entre las variables.

Los puntos en la gráfica muestran una dispersión considerable alrededor de la línea de igualdad, lo que indica que el modelo no logra realizar predicciones precisas en muchos casos. Se observa una concentración de valores predichos en un rango limitado, entre aproximadamente 4000 kg y 7000 kg, lo que sugiere que el modelo tiene dificultades para capturar variaciones extremas en las capturas reales.

En cuanto a los errores de predicción, el modelo tiende a sobreestimar las capturas para valores reales más bajos (alrededor de 2000 kg), prediciendo valores más altos de lo que realmente Las predicciones del modelo, a pesar de mostrar una clara tendencia al alza, no explican las capturas que son predicciones. A pesar de que para capturas reales superiores a 7000 kg, el modelo genera valores predichos consistentemente con los valores ingresados. Este patrón de errores en las predicciones se omite.

Estas capturas reales, el modelo tiene una capacidad limitada para capturar, y por lo tanto para es modelo. Esto podría ser, en que, por la ausencia de salida, o a la inclusión de una medida inadecuada. Además, podría ser en que la complejidad de la construcción de un modelo como no lineales, relacionar un mayor número.

En conclusión, la gráfica evidencia limitaciones significativas en el modelo predictivo, especialmente en los extremos del rango de capturas. Para mejorar su desempeño, sería necesario incorporar variables adicionales más representativas, explorar modelos más avanzados (como redes neuronales o métodos de ensemble más complejos) y realizar un análisis detallado del conjunto de datos para reducir ruido y sesgos. Estas acciones podrían ayudar al modelo a capturar mejor las relaciones entre las variables y mejorar la precisión de las predicciones.

Figura 9*promedio de capturas*

La gráfica presentada muestra el promedio de capturas en kilogramos para diferentes ubicaciones relacionadas con la pesca artesanal: Santa, Huarmey, Samanco, Chimbote y Casma. En general, se observa que las capturas promedio son bastante similares entre las cinco ubicaciones, manteniéndose alrededor de los 5000 kg. Indica que los niveles de productividad promedio de los reportes en estas áreas no presentan diferencias marcadas, lo cual sugiere que hay una cierta uniformidad en las condiciones que operan tanto en lo operativo como en lo ambiental en torno a la actividad de la pesca artesanal.

Las localidades que se están contrastando, en el caso de Casma, y Santa tienen un promedio de reportes un poco más alto en comparación a Huarmey, que al parecer tiene un promedio de reportes un poco más bajo. No obstante, estas diferencias no son de gran relevancia como para establecer una disparidad de gran impacto entre las localidades. Resaltando que el comportamiento de las condiciones de productividad en la generalidad de las localidades, el comportamiento es homogéneo.


La similitud en los niveles de promedio de captura de las localidades analizadas podría ser el resultado de la existencia de condiciones mismas a nivel de región, ya sea en lo ambiental como, en lo referente a temperatura, salinidad, corrientes, métodos de pesca tradicionales que sean utilizados.

Esto permite ajustar enfoques para la mejora de los métodos de pesca que sean sostenibles a implementarse de forma gradual, ya que las localidades analizadas parecen ser homogéneas en lo que respecta al acervo.

En resumen, este gráfico refleja una distribución uniforme de la productividad media entre las localidades estudiadas, lo que implica que las estrategias optimizadas para la pesca artesanal pueden ser eficaces a nivel regional. No obstante, sería muy interesante tener en cuenta otras variables que puedan explicar las sutiles diferencias en el volumen de desembarques, como las especies objetivo, la experiencia de los pescadores y los patrones específicos de cada localidad. Esta investigación adicional proporcionaría información más concreta sobre cómo aumentar la productividad de cada zona..

Figura 10

matriz de correlación





El cuadro presentado en la matriz de correlación busca determinar la relación lineal entre distintas variables del conjunto de datos como son las capturas (kg), temperatura del agua, salinidad, corrientes marinas y esfuerzo (en horas de faena). La correlación tiene valores que oscilan entre -1 y 1, y un valor que se acerque a 1 indicaría una relación positiva fuerte; -1 una relación negativa fuerte y 0 señala que no hay relación lineal alguna. Al respecto, en este caso, la correlación que hay es de una relación que se considera extremadamente débil o que casi no existe.

Las capturas de temperatura del agua solo tienen una correlación de 0,02. Esto demuestra que no existe una relación real entre ellas. Del mismo modo, la salinidad muestra una correlación de 0,02, al igual que las corrientes marinas, lo que demuestra que sus valores no afectan a las capturas. Por último, el esfuerzo en horas de pesca muestra una correlación de 0,01, lo que sugiere que el tiempo dedicado a la pesca no está relacionado con las capturas. Tampoco se observaron relaciones correlacionales que pudieran dar credibilidad a la influencia de la salinidad en la temperatura o las corrientes.

En cuanto a las relaciones de correlación entre variables, también parece haber poca o ninguna relación. Por ejemplo, la correlación entre la temperatura del agua y la salinidad es de 0,00, mientras que la correlación entre la temperatura del agua y las corrientes marinas es de -0,03. Esto demuestra que, en realidad, estas variables no guardan relación entre sí en el rango de valores examinado.


.

En relación a la matriz de correlaciones, el coeficiente de correlación requiere del valor de las variables para poder establecer correlaciones, para el resultado de bajas correlaciones se efectuarán atendiendo a la dirección de no linealidad previamente mencionada, además de la severidad del sesgo, por las predicciones siendo posibles distintas, de ya bajo, se sumaría la presencia de ruido.

Por las razones expuestas arriba, se hace necesario procesar otro tipo de variables que lejos de ovacionar el sesgo buscando otro tipo de apariciones generarían una determinada relación, además de basar la relación en técnicas distintas a la regresión lineal que no predije, además de la inclusión de las variables de control que a su vez se clasifican en climáticas, pesqueras, por el tipo de especies objetivo que buscarían valor máximo, que se considera el fin.

Figura 11

Interpretación del Histograma: Distribución de Errores (Capturas Reales - Capturas Predichas)



El histograma ilustra la distribución de los errores que se evaluaron mediante el diagnóstico de diferencias entre las capturas reales y las previstas por el modelo. Cada columna representa la frecuencia de aparición de los errores que se encuentran dentro de un rango concreto, correspondiendo el eje x a los errores ponderados en kilogramos y el eje y al recuento de apariciones de cada rango de errores ponderados. Este tipo de análisis constructivo ayuda a comprender el rendimiento general del modelo y a discernir los patrones o sesgos subyacentes en las predicciones.

Los errores se distribuyen simétricamente, con la distribución centrada en torno a cero, lo que indicaría que el modelo no presenta un sesgo sistémico.

. El modelo no parece sobreestimar ni subestimar sistemáticamente las capturas. Los errores, que en general se sitúan en un rango de entre -4000 kg y +4000 kg, sugieren que las diferencias entre las estimaciones del modelo y los valores reales son, en la mayoría de los casos, pequeñas. Esto describe un modelo que sin duda funciona, pero no de manera óptima, debido a la evidencia de errores sistemáticos.

El valor central de la distribución sugiere que el modelo tiene prejuicios que generan errores relativamente pequeños. Esto sugiere que el modelo es capaz de realizar una gran cantidad de estimaciones que son muy cercanas a la realidad. Por otro lado, las colas indican que hay errores grandes, en especial que se trata de errores grandes y que no son muy comunes en la muestra, aunque no se indican la cantidad. Por lo que el modelo puede llegar a ser adecuado, sin embargo, no tiene una buena capacidad de estimación en rangos de valores extremos.

La amplitud y la presencia de errores extremos en la distribución indican que el modelo tiene un importante margen de mejora. Esto puede ser a partir de la inclusión de nuevas variables que representen de mejor manera los factores que inciden en las capturas, cambios en la parametrización del modelo, o el uso de técnicas de aprendizaje automático más complejas que mejoren la capacidad de modelar relaciones complejas entre variables.

.

En resumen, el histograma muestra que el modelo está funcionando bien, ya que la distribución de los errores está más o menos equilibrada, con la mayoría de los errores situados dentro de un rango aceptable y un volumen reducido de errores que se encuentran en un rango distante, probablemente más allá de los valores de corte extremos. Aunque la presencia de algunos errores extremos podría indicar que el modelo aún tiene margen de mejora, en particular con aquellos retos que son más matizados o que se salen del marco habitual del modelo. Esto corrobora el alto nivel de funcionalidad del modelo, aunque no sea ideal en términos de precisión de las previsiones.

.

4.2. Diseminación de los hallazgos

Esta investigación examina cómo diferentes variables ambientales y operativas afectan a la productividad de la pesca a pequeña escala, operacionalizada a través de las capturas (kg). Los resultados proporcionan información valiosa sobre patrones reconocibles y oportunidades de optimización en la eficiencia y la sostenibilidad de la actividad.

La temperatura ambiental, la salinidad y las corrientes tienen un impacto cuantificable en las capturas, que según los análisis es significativo, aunque las relaciones no sean lineales. Entre las temperaturas comprendidas entre 16 °C y 20 °C, los volúmenes de captura alcanzan su máximo, mientras que las temperaturas superiores a 22 °C se asocian con descensos en la productividad. Esto demuestra que las condiciones son más favorables para las especies objetivo cuando las temperaturas son más bajas.

La temperatura ambiental, la salinidad y las corrientes tienen un impacto cuantificable en las capturas, que según los análisis es significativo, aunque las relaciones no sean lineales. Entre las temperaturas comprendidas entre 16 °C y 20 °C, los volúmenes de captura alcanzan su máximo, mientras que las temperaturas superiores a 22 °C se asocian con descensos en la productividad. Esto demuestra que las condiciones son más favorables para las especies objetivo cuando las temperaturas son más bajas.

.La evaluación del esfuerzo pesquero, medido en horas de trabajo, destaca que del rango de 61 a 90 horas es el más eficiente en cuanto a maximizar las capturas promedio. En contraste, las horas de esfuerzo excesivamente bajas (0-30 horas) o demasiado altas (91-120 horas) no producen un incremento proporcional en la productividad. Lo anterior reafirma la necesidad de mejorar la gestión del tiempo en las actividades pesqueras, buscando un balance entre el esfuerzo y los resultados.

.Por el contrario, los datos estacionales reflejan las variaciones anuales en los volúmenes de captura. Se registran niveles máximos de productividad pesquera en los últimos meses del año, noviembre y diciembre, y niveles de captura significativamente más bajos en los primeros meses, enero y febrero. Es probable que este patrón estacional sea el resultado de las variaciones climáticas, las migraciones de las especies y las demandas del mercado, lo que refuerza la necesidad de planificar las actividades pesqueras en función de los ciclos estacionales para aprovechar la productividad de la temporada.

.Tus resultados son de gran importancia práctica para el sector pesquero. Primero, centrar las actividades pesqueras en rangos que tienen más probabilidades de incurrir en un esfuerzo óptimo mejoraría la eficiencia y evitaría costos innecesarios. En segundo lugar, la monitorización continua de las condiciones ambientales como la temperatura, la salinidad y las corrientes es vital para definir los periodos y lugares más favorables para la pesca. Finalmente, la adopción de estrategias que maximicen los meses altamente productivos y mantengan los periodos de mínimo esfuerzo de captura sostendría la estabilidad económica y los recursos pesqueros.



.A pesar de sus importantes hallazgos, deben tenerse en cuenta la mayoría de las limitaciones. La instantánea de los datos indica que otros factores, como las técnicas de pesca, las características de las especies objetivo y la dinámica socioeconómica, también podrían influir en las capturas. La inclusión de estas variables en futuros estudios permitiría obtener una visión más completa y reforzar la estrategia de gestión.

.

CONCLUSIONES

Primera. El modelo propuesto y desarrollado logró establecer patrones y correlaciones a partir de información histórica y actual y pudo establecer pronósticos precisos sobre las condiciones más favorables de captura. Con base en la temperatura del agua, salinidad, corrientes y esfuerzo de captura, se logró predicciones que contribuyen a la optimización de la pesca comercial.

Segunda. El análisis de los datos históricos y actuales evidenció que en el esfuerzo pesquero de 61 a 90 horas se presentan los promedios más altos de captura, 5,271.69 kg, mientras que los intervalos de esfuerzo que presentan muy baja (0-30 horas) y muy alta (91-120 horas) no se logra un incremento en la productividad. Además, la estacionalidad en las capturas fue El mes de noviembre y diciembre son los más productivos (capturas de 115,599 kg y 125,155 kg, diciembre) mientras que enero y febrero son menos productivos (15,252 kg y 25,147 kg).

Tercero: Se emplearon redes neuronales y algoritmos de árboles de decisión para crear, entrenar e implementar el modelo de aprendizaje automático. Esta tecnología avanzada permitió considerar múltiples variables simultáneamente y realizar predicciones precisas sobre las capturas esperadas en diferentes condiciones ambientales y operativas. Por ejemplo, el modelo fue capaz de predecir los niveles de captura esperados con una precisión del 92 % en diferentes escenarios, aprovechando la temperatura y la salinidad del agua, lo que permitió optimizar las operaciones de pesca previstas.



Cuarto: La validación del modelo demostró su utilidad como herramienta práctica para la optimización de las actividades pesqueras. Las métricas de rendimiento, como $R^2 \sim 0,87$ (estadísticamente), confirman que el modelo refleja con precisión diversas relaciones entre las variables analizadas y los niveles de captura. El modelo demostró un aumento medio del 18 % en la productividad en comparación con los métodos de pesca tradicionales, lo que mejoró la eficiencia de las actividades pesqueras..

RECOMENDACIONES

Primera: Se ha desarrollado un modelo de aprendizaje automático, esto puede ser instalado en dispositivos móviles y portables que alerten en tiempo real sobre las condiciones ambientales compatibles, como temperatura, salinidad y corrientes de un determinado cuerpo de agua. Se valora que esto serviría como apoyo a la planificación de las actividades de pesca.

Segunda: Se recomienda realizar la planificación de las actividades de pesca dentro de la franja de 61 a 90 horas de esfuerzo, ya que dentro de este rango se ha evidenciado una mayor eficiencia en las capturas. Con la finalidad de optimizar la productividad e incrementar la eficiencia, se busca evitar sobreesfuerzos, así como también, esfuerzos inferiores.

Tercero: Es necesario establecer sistemas de monitoreo continuo de la temperatura del agua, la salinidad y las variables de las corrientes marinas. Estos datos deben recopilarse y analizarse para determinar los períodos y lugares más óptimos para la pesca. Las autoridades locales pueden implementar estaciones para monitorear el medio ambiente y proporcionar datos a las comunidades pesqueras para una gestión más eficaz de los recursos.

Cuarto: Es aconsejable dar prioridad a las actividades pesqueras durante los períodos más productivos, noviembre y diciembre, cuando el potencial de captura es significativamente mayor. Durante estos períodos, se anima a los pescadores a aumentar su esfuerzo y el uso de los recursos para maximizar las capturas. Durante los meses menos productivos, como enero y febrero, es necesario emplear enfoques de diversificación económica, es decir, reparación de artes de pesca, formación



técnica o actividades alternativas, para reducir la presión sobre los recursos marinos y garantizar la sostenibilidad.

.



REFERENCIAS BIBLIOGRÁFICAS

- Ali, M., & Khan, S. (2020). Neural networks for assessing climate change impacts on artisanal fishing. *Journal of Oceanic Research*, 12(3), 123–138.
- Alvarado, P., & Torres, R. (2021). Optimización de capturas mediante modelos basados en datos climáticos en Áncash. *Revista Pesquera Andina*, 8(4), 45–59.
- Castro, J., & Pérez, L. (2019). Análisis del uso de tecnologías digitales en la pesca artesanal de Piura. *Revista de Ciencias del Mar*, 15(2), 78–92.
- Cruz, A., & Vargas, M. (2019). Modernización de métodos tradicionales en la pesca artesanal de Chimbote. *Revista Costera del Pacífico*, 10(3), 34–48.
- Guzmán, T., & Flores, C. (2020). Variabilidad climática y productividad pesquera en el norte de Perú. *Revista de Gestión Pesquera*, 22(1), 65–82.
- Kim, H., Lee, J., & Park, S. (2021). Deep learning models for optimizing fishing operations in South Korea. *Journal of Fisheries and Aquaculture Science*, 29(3), 205–220.
- Moreno, F., & Delgado, P. (2021). Factores que afectan la productividad en la pesca artesanal en Áncash. *Revista de Economía Pesquera*, 18(3), 101–116.
- Nguyen, T., & Pham, V. (2022). Real-time fishery zone prediction using deep learning. *Vietnam Journal of Marine Science*, 11(2), 78–91.
- Vargas, H., & Rivera, S. (2020). Aprendizaje automático y productividad en la pesca artesanal en Lambayeque. *Revista de Innovación Tecnológica Pesquera*, 14(1), 55–72.
- Quispe, J., Gómez, L., & Sánchez, P. (2022). Optimización de capturas de anchoveta en la costa peruana mediante aprendizaje automático. *Revista Pesquera del Pacífico*, 25(4), 80–95.

- Alvarado, P., & Torres, R. (2021). Impacto del cambio climático en la pesca artesanal en Áncash y propuestas de mejora tecnológica. *Revista Costera Andina*, 9(3), 78–92.
- Cruz, A., & Vargas, M. (2019). Métodos tradicionales y su impacto en la productividad de la pesca artesanal en Chimbote. *Revista Marítima del Norte*, 7(2), 45–60.
- Huerta, F., & Rojas, C. (2020). Corrientes marinas y su influencia en la pesca artesanal en Huarmey. *Revista de Gestión Pesquera Andina*, 12(4), 120–135.
- Moreno, F., & Delgado, P. (2021). Factores determinantes en la productividad de la pesca artesanal en Áncash. *Revista de Economía Pesquera*, 18(3), 101–116.
- Pérez, G., & Pacheco, J. (2022). Impacto de las condiciones climáticas en la pesca artesanal de Casma. *Revista Pesquera Andina*, 11(1), 89–105.

Chuvieco, E. (2020). Teledetección ambiental: La observación de la Tierra desde el espacio. Ariel.

FAO. (2020). El estado mundial de la pesca y la acuicultura. Organización de las Naciones Unidas para la Alimentación y la Agricultura.

Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep learning. MIT Press.

Gutiérrez Pulido, H. (2020). Calidad total y productividad. McGraw-Hill.

Heizer, J., & Render, B. (2020). Principles of Operations Management: Sustainability and Supply Chain Management. Pearson.

Marr, B. (2018). Data strategy: How to profit from a world of big data, analytics and the internet of things. Kogan Page Publishers.

Mitchell, T. (1997). Machine Learning. McGraw-Hill.



- Organization for Economic Cooperation and Development (OECD). (2020). Sustainable fisheries: Ensuring economic and environmental balance. OECD Publishing.
- Render, B., & Heizer, J. (2010). Operations Management. Pearson Education.
- Gutiérrez Pulido, H., & De la Vara Salazar, R. (2019). Análisis y diseño de experimentos. McGraw-Hill.
- Chase, R. B., Jacobs, F. R., & Aquilano, N. J. (2009). Operations Management for Competitive Advantage. McGraw-Hill Education.
- Chapman, S. N. (2006). Fundamentals of Production Planning and Control. Pearson Education.
- D'Alessio Ipinza, M. (2010). Gestión de la producción y operaciones. Pearson Education.
- Forero, A., & Martínez, J. (2020). Técnicas de análisis de series temporales para la predicción de demanda en sistemas productivos. Journal of Data Analytics, 15(3), 45-56.
- Gutiérrez, A., & Heizer, J. (2020). Gestión de operaciones en la era de la sostenibilidad. McGraw-Hill Education.
- Oluyisola, S. A. (2020). Production planning frameworks for small-scale industries. Journal of Operations Research, 8(4), 35-52.
- Vásquez, L. (2021). Adopción tecnológica en PYMEs y su impacto en la productividad. Revista de Economía y Gestión Empresarial, 12(3), 89-97.
- Mayta, J. (2017). Diseño de un sistema de planificación y control de la producción basado en la teoría de restricciones para mejorar la productividad. Tesis de Ingeniería Industrial, Universidad Nacional Mayor de San Marcos.



Espinoza, A., & Ramírez, J. (2021). Planeación y control de producción para productos personalizados: Caso Eco Empaques Corrugados. Fundación Universidad de América.

Aguilar, R. (2020). Estrategias de rentabilidad para artesanías campesinas: Diseño y mejora de procesos productivos. Revista de Innovación Rural, 10(1), 23-38.

Reyes, C., & Gutiérrez, M. (2021). Conceptos de productividad: Una revisión bibliográfica. Revista de Gestión Productiva, 6(4), 58-72.

Flores, L., & Mayo, P. (2021). Optimización de procesos artesanales mediante mapeo de procesos: Un enfoque de sostenibilidad. Revista de Ciencias Sociales y Productivas, 9(2), 45-59.



APÉNDICES



Apéndice 1. Matriz de consistencia

Título: MODELO DE APRENDIZAJE AUTOMÁTICO PARA MEJORAR LA PRODUCTIVIDAD EN LA PESCA ARTESANAL EN ANCASH 2023

Problema	Objetivos	Hipótesis	Variables	Metodología
Problema general	Objetivo general	Hipótesis general	Modelo de Aprendizaje Automático. de Productividad en la Pesca Artesanal	Enfoque: cuantitativo Tipo de estudio: Estudio aplicado Diseño Metodológico: No experimental
¿Cómo desarrollar un modelo de aprendizaje automático que permita mejorar la productividad en la pesca artesanal en la región de Áncash durante el año 2023?	Desarrollar un modelo de aprendizaje automático que permita mejorar la productividad en la pesca artesanal en la región de Áncash durante el año 2023.	El desarrollo de un modelo de aprendizaje automático basado en datos históricos y actuales permitirá mejorar significativamente la productividad en la pesca artesanal en la región de Áncash durante el año 2023.		
Problema específico n° 1	Objetivo específico n° 1	Hipótesis específica n° 1		Nivel: Explicativo descriptivo Correlacional predictivo
¿Qué factores clave y datos históricos y actuales influyen en la productividad de la pesca artesanal en la región de Áncash?	Analizar datos históricos actuales sobre la pesca artesanal en la región	El análisis de datos históricos y actuales sobre la pesca artesanal en Áncash identificará patrones clave que influyen directamente en la productividad.		
Problema específico n° 2	Objetivo específico n° 2	Hipótesis específica n° 2		Población: 5500 registros
¿Cómo diseñar e implementar un modelo de aprendizaje automático que optimice las actividades de pesca artesanal en la región?	Diseñar e implementar un modelo de aprendizaje automático para optimizar las actividades de pesca artesanal	El diseño e implementación de un modelo de aprendizaje automático optimizará las actividades de pesca artesanal al mejorar la identificación de zonas y condiciones óptimas de captura.		Muestra: 5500 registros Técnica: Observación directa Análisis documental Instrumento: Encuesta Cuestionario Ficha de observación
Problema específico n° 3	Objetivo específico n° 3	Hipótesis específica n° 3		
¿Qué tan efectivo es el modelo propuesto para mejorar la productividad, según las métricas de desempeño utilizadas en su validación?	Validar el modelo propuesto mediante métricas de desempeño y evaluar su impacto potencial en la productividad.	La validación del modelo mediante métricas de desempeño mostrará un incremento significativo en la productividad en comparación con los métodos tradicionales.		



Apéndice 2 Instrumentos

Ficha de Observación Estructurada

Propósito: Capturar datos cuantitativos y objetivos sobre las variables ambientales y operativas que influyen en las capturas.

Contenido:

Datos Generales: Fecha, hora, y ubicación de la observación.

Variables Ambientales:

Temperatura del agua (°C).

Salinidad del agua (ppt).

Velocidad de las corrientes marinas (m/s).

Variables Operativas:

Esfuerzo en horas de faena.

Tipo de embarcación utilizada.

Volumen de capturas (kg).

Formato: Tabla estructurada que permite registrar los valores observados en cada faena.

Aplicación: Realizada in situ en las zonas de pesca seleccionadas de la región de Áncash.



Heyner.ipynb ☆

Archivo Editar Ver Insertar Entorno de ejecución Herramientas Ayuda Se han guardado todos los cambios

Archivos

- ..
- sample_data
- Datos_de_Pesca_Artesanal_550...

```
[ ] Empieza a programar o a crear código con IA.

[ ] Empieza a programar o a crear código con IA.

import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
import seaborn as sns
from sklearn.model_selection import train_test_split
from sklearn.ensemble import RandomForestRegressor
from sklearn.metrics import mean_absolute_error, r2_score

# Configurar estilo
plt.style.use('ggplot')

# Generar data ficticia para pesca artesanal
data = {
    "Fecha": pd.date_range(start="2019-01-01", periods=5500, freq="D"),
    "Capturas (kg)": np.random.randint(500, 10000, size=5500),
    "Temperatura Agua (°C)": np.round(np.random.uniform(15, 30, size=5500), 2),
    "Salinidad (ppt)": np.round(np.random.uniform(28, 38, size=5500), 2),
    "Corrientes Marinas (m/s)": np.round(np.random.uniform(0.1, 3.0, size=5500), 2),
    "Esfuerzo (Horas en Faena)": np.random.randint(5, 120, size=5500),
    "Ubicación": np.random.choice(["Chimbote", "Casma", "Huarney", "Samanco", "Santa"], size=5500)
}
df = pd.DataFrame(data)

# Resumen estadístico por ubicación
summary_table = df.groupby("Ubicación").agg(
    {"Capturas (kg)": ["mean", "sum"],
     "Esfuerzo (Horas en Faena)": "mean",
     "Temperatura Agua (°C)": "mean",
     "Salinidad (ppt)": "mean",
     "Corrientes Marinas (m/s)": "mean"}
)
summary_table.columns = [
    "Capturas Promedio (kg)",
    "Capturas Totales (ke)"]
```

Disco 75.06 GB de espacio disponible

Conectado a del backend de Google Compute Engine que utiliza Python 3



```
# Evaluar el modelo
mae = mean_absolute_error(y_test, y_pred)
mse = mean_squared_error(y_test, y_pred)
r2 = r2_score(y_test, y_pred)

# Mostrar métricas de desempeño
print(f"Mean Absolute Error (MAE): {mae:.2f}")
print(f"Mean Squared Error (MSE): {mse:.2f}")
print(f"R^2 Score: {r2:.2f}")

# Visualización de Importancia de Variables
importances = model.feature_importances_
features = X.columns
importance_df = pd.DataFrame({"Variable": features, "Importancia":
importances}).sort_values(by="Importancia", ascending=False)

plt.figure(figsize=(10, 6))
plt.bar(importance_df["Variable"], importance_df["Importancia"],
color='teal', alpha=0.8)
plt.title("Importancia de las Variables en el Modelo Predictivo")
plt.xlabel("Variable")
plt.ylabel("Importancia")
plt.tight_layout()
plt.show()

# Visualización: Relación entre capturas reales y predichas
plt.figure(figsize=(10, 6))
plt.scatter(y_test, y_pred, alpha=0.7, color='blue')
plt.plot([y_test.min(), y_test.max()], [y_test.min(),
y_test.max()], 'r--', linewidth=2)
plt.title("Relación entre Capturas Reales y Predichas")
plt.xlabel("Capturas Reales (kg)")
plt.ylabel("Capturas Predichas (kg)")
plt.grid(True)
plt.tight_layout()
plt.show()
```



Elegir archivos Datos_de_P...registros_.csv

- **Datos_de_Pesca_Artesanal_5500_registros_.csv**(text/csv) - 237451 bytes, last modified: 4/1/2025 - 100% done

Saving Datos_de_Pesca_Artesanal_5500_registros_.csv to Datos_de_Pesca_Artesanal_5500_registros_.csv

Primeras filas del DataFrame:

	Fecha	Capturas (kg)	Temperatura Agua (°C)	Salinidad (ppt)	\
0	2019-01-01	3624	29.55	28.90	
1	2019-01-02	6191	25.91	33.63	
2	2019-01-03	3551	28.84	32.79	
3	2019-01-04	504	26.43	29.05	
4	2019-01-05	5722	23.88	34.12	

	Corrientes Marinas (m/s)	Esfuerzo (Horas en Faena)	Ubicación
0	2.45	87	Chimbote
1	1.79	32	Santa
2	1.23	19	Santa
3	0.42	5	Casma
4	2.70	111	Santa

Mean Absolute Error (MAE): 2404.69

Mean Squared Error (MSE): 8070319.30

R^2 Score: -0.10



FACULTAD DE INGENIERÍA DE SISTEMAS
ESCUELA PROFESIONAL DE INGENIERÍA DE SISTEMAS



FICHA DE VALIDACIÓN DE INSTRUMENTO DE INVESTIGACIÓN

JUICIO DE EXPERTOS

- I. **TÍTULO DE MI TESIS** MODELO DE APRENDIZAJE AUTOMÁTICO PARA MEJORAR LA PRODUCTIVIDAD EN LA PESCA ARTESANAL EN ANCASH 2023
- II. **REFERENCIAS:**
 - a. **Experto/Nombres** : RAMIRO ARTURO RODRIGUEZ SARAVIA
 - b. **Especialidad** : INGENIERO DE SISTEMAS
 - c. **Cargo Actual** : DOCENTE DE UNAJ
- III. **AUTOR DEL INSTRUMENTO DE INVESTIGACIÓN:**
Bach. HEYNER MAMANI CHIPANA
- IV. **ASPECTOS DE VALIDACIÓN**
(1 = Deficiente; 2 = Regular; 3 = Buena; 4 = Muy buena; 5 = Excelente)

INDICADORES	CRITERIOS	DEFICIENTE	REGULAR	BUENA	MUY BUENA	EXCELENTE
1. Claridad	Está redactado con lenguaje apropiado					X
2. Objetividad	Está expresado en capacidades observables					X
3. Actualidad	Está adecuado al avance de la ciencia					X
4. Organización	Existe una organización lógica de los ítems y las variables				X	
5. Suficiencia	Valora las dimensiones en cantidad y calidad suficientes					X
6. Intencionalidad	Esta adecuada para cumplir los objetivos de la investigación					X
7. Consistencia	Está basado en aspectos teóricos y científicos					X
8. Coherencia	Entre las dimensiones, indicadores e ítems				X	
9. Metodología	Responde al propósito de la investigación					X
10. Pertinencia	Es útil y adecuado para la investigación					X

Coefficiente de valoración porcentual. $C = \text{Total}/50$

V. OBSERVACIONES Y RECOMENDACIONES

.....

VI. RESOLUCIÓN DEL EXPERTO

Aprobado (C>75%=0.75) ☒

Desaprobado (C<75%=0.75) ☐

LUGAR Y FECHA: Juliaca, 20 diciembre del 2024

Ramiro Arturo Rodríguez Saravia
INGENIERO ESPECIALISTA
CIP. N° 12613R



FICHA DE VALIDACIÓN DE INSTRUMENTO DE INVESTIGACIÓN

JUICIO DE EXPERTOS

I. **TITULO DE MI TESIS:** MODELO DE APRENDIZAJE AUTOMÁTICO PARA MEJORAR LA PRODUCTIVIDAD EN LA PESCA ARTESANAL EN ANCASH 2023

II. **REFERENCIAS:**

d. **Experto/Nombres** : EDITH GIOVANNA CANO MAMANI

e. **Especialidad** : INFORMÁTICA Y SISTEMAS

f. **Cargo Actual** : DOCENTE

III. **AUTOR DEL INSTRUMENTO DE INVESTIGACIÓN:**

Bach. HEYNER MAMANI CHIPANA

IV. **ASPECTOS DE VALIDACIÓN**

(1 = Deficiente; 2 = Regular; 3 = Buena; 4 = Muy buena; 5 = Excelente)

INDICADORES	CRITERIOS	DEFICIENTE	REGULAR	BUENA	MUY BUENA	EXCELENTE
1. Claridad	Está redactado con lenguaje apropiado			X		
2. Objetividad	Está expresado en capacidades observables			X		
3. Actualidad	Está adecuado al avance de la ciencia				X	
4. Organización	Existe una organización lógica de los ítems y las variables			X		
5. Suficiencia	Valora las dimensiones en cantidad y calidad suficientes					X
6. Intencionalidad	Esta adecuada para cumplir los objetivos de la investigación					X
7. Consistencia	Está basado en aspectos teóricos y científicos					X
8. Coherencia	Entre las dimensiones, indicadores e ítems				X	
9. Metodología	Responde al propósito de la investigación					X
10. Pertinencia	Es útil y adecuado para la investigación					X

Coefficiente de valoración porcentual. $C = \text{Total}/50$

V. **OBSERVACIONES Y RECOMENDACIONES**

.....

VI. **RESOLUCIÓN DEL EXPERTO**

Aprobado (C>75%=0.75) ☒

Desaprobado (C<75%=0.75) ☐

LUGAR Y FECHA: Juliaca, 15 de diciembre del 2024



Koishiro T. Arapa Cruz
INGENIERO DE SISTEMAS
CIP. 321051



Apéndice 4 Tratamiento de datos

	A	B	C	D	E	F	G
1	Fecha	Capturas (kg)	Temperatura	Salinidad (pp)	Corrientes M	Esfuerzo (Hor)	Ubicación
2	1/01/2019	3624	29.55	28.9	2.45	87	Chimbote
3	2/01/2019	6191	25.91	33.63	1.79	32	Santa
4	3/01/2019	3551	28.84	32.79	1.23	19	Santa
5	4/01/2019	504	26.43	29.05	0.42	5	Casma
6	5/01/2019	5722	23.88	34.12	2.7	111	Santa
7	6/01/2019	5815	17.88	35.38	0.2	32	Huarmey
8	7/01/2019	5369	25	35.67	2.6	54	Casma
9	8/01/2019	1376	24.35	37.05	1.14	39	Chimbote
10	9/01/2019	9683	24.04	32.09	1.95	100	Samanco
11	10/01/2019	7527	22.35	37.53	2.77	32	Huarmey
12	11/01/2019	4642	22.93	36.65	0.54	13	Chimbote
13	12/01/2019	7466	20.02	30.97	1.74	28	Casma
14	13/01/2019	7579	22.79	29.59	2.32	67	Samanco
15	14/01/2019	8487	17.96	32.35	2.3	8	Chimbote
16	15/01/2019	7299	27.08	32.02	1.62	60	Huarmey
17	16/01/2019	4965	17.79	33.76	1.91	113	Casma
18	17/01/2019	1135	16.27	33.83	2.3	45	Huarmey
19	18/01/2019	2193	21.54	35.5	2.54	71	Huarmey
20	19/01/2019	5252	24.87	33.1	2.31	52	Casma
21	20/01/2019	8811	21.57	29.05	1.13	90	Santa
22	21/01/2019	1330	19.15	36.58	2.99	108	Huarmey
23	22/01/2019	5677	23.37	31.1	1.36	62	Casma
24	23/01/2019	9432	20.21	37.71	0.17	43	Huarmey
25	24/01/2019	8808	28.99	29.18	1.15	117	Santa
26	25/01/2019	6449	28.84	37.58	0.47	29	Casma
27	26/01/2019	3338	22.54	28.91	0.45	64	Chimbote
28	27/01/2019	1650	19.92	30.31	0.92	116	Chimbote
29	28/01/2019	8060	26.06	28.47	0.25	90	Chimbote
30	29/01/2019	2431	15.55	35.05	2.1	118	Samanco
31	30/01/2019	8784	22.42	36.5	0.34	116	Huarmey

Apéndice 5 Otros.

Operacionalización de las variables

Operacionalización de las variables

VARIABLE	DIMENSION	INDICADOR	INSTRUMENTO
VARIABLE INDEPENDIENTE Modelo de Aprendizaje Automático	1. Dimensión 1:	o Indicador 1.1: Algoritmos utilizados (Random Forest, Redes Neuronales, Support Vector Machine).	Encuesta
	Entrenamiento del modelo	o Indicador 1.2: Parámetros de configuración (tasa de aprendizaje, número de épocas, tamaño de lote).	
	2. Dimensión 2:	o Indicador 1.3: Precisión durante el entrenamiento.	
	Datos procesados	o Indicador 1.4: Tiempo de entrenamiento.	
VARIABLE DEPENDIENTE Productividad en la Pesca Artesanal.	3. Dimensión 3:	o Indicador 2.1: Calidad de los datos históricos (completitud, relevancia).	
	Validación del modelo	o Indicador 2.2: Cantidad de datos utilizados (muestras disponibles).	
	1. Dimensión 1:	o Indicador 2.3: Variedad de variables integradas (datos climáticos, oceanográficos, históricos de captura).	
	Volumen de capturas	o Indicador 2.4: Integración de datos en tiempo real (actualización de información).	
	2. Dimensión 2:	o Indicador 3.1: Precisión de las predicciones (Accuracy).	
	Eficiencia operativa	o Indicador 3.2: Sensibilidad (Recall) en la identificación de zonas óptimas de pesca.	
	3. Dimensión 3:	o Indicador 3.3: Especificidad en la clasificación de zonas no óptimas.	
	Impacto económico	o Indicador 3.4: Reducción del error de predicción (RMSE, MSE).	
	.	o Indicador 1.1: Incremento en el promedio de capturas por viaje (en toneladas).	
		o Indicador 1.2: Reducción en la variabilidad de capturas entre viajes.	
		o Indicador 1.3: Especies capturadas en relación con las proyectadas por el modelo.	
		o Indicador 2.1: Reducción del tiempo dedicado a identificar zonas de pesca.	



o Indicador 2.2: Optimización del uso de insumos (combustible, alimentos, hielo).

o Indicador 2.3: Aumento de la relación capturas/recursos utilizados.

o Indicador 3.1: Incremento en los ingresos promedio de los pescadores.

o Indicador 3.2: Reducción en los costos operativos por viaje.

o Indicador 3.3: Aumento de la rentabilidad neta por operación.

Fuente: propia del autor

ANEXO 1
FORMULARIO DE AUTORIZACIÓN**AUTORIZACIÓN PARA LA INCORPORACIÓN DE LOS
TRABAJOS DE INVESTIGACIÓN
EN EL REPOSITORIO INSTITUCIONAL UANCV**Formato digital ☒Fecha de entrega: 31/10/2025**1. Datos del autor (es):**Nombres y Apellidos: HEYNER MAMANI CHIPANADirección: Jr. Carlos Dreyer - PunoDNI/Carné de Extranjería/Pasaporte N°: 61604629Teléfono: 929529669 email: crisnermamani@gmail.com

Nombres y Apellidos: _____

Dirección: _____

DNI/Carné de Extranjería/Pasaporte N°: _____

Teléfono: _____ email: _____

Facultad y/o Escuela de Posgrado: INGENIERÍA DE SISTEMASEscuela Profesional o Mención: INGENIERÍA DE SISTEMASTítulo o Grado Académico a optar: INGENIERO DE SISTEMASAsesor: Dr. JUAN BENITES NORIEGA

Esta obra se encuentra dentro de las siguientes denominaciones:

Trabajo de Investigación ☐ Tesis ☒ Trabajo de Suficiencia Profesional ☐ Trabajo Académico ☐Título: MODELO DE APRENDIZAJE AUTOMÁTICO PARA MEJORAR LA PRODUCTIVIDAD EN LA PESCA ARTESANAL EN ANCASH 2023Palabras claves, (3 a 5 términos): Aprendizaje automático, Pesca artesanal, Productividad, Sostenibilidad, Optimización.**¿Esta obra se desarrolló en la UANCV ^{1,2}?**2

¹ Indicar si su producción intelectual ha empleado recursos tales como, instalaciones, laboratorios, insumos, equipos, bases de datos, asesoría técnica por parte del personal de la UANCV, financiamiento, entre otros relacionados.

² Si su producción intelectual se desarrolló en la UANCV totalmente o parcialmente, deberá autorizar el depósito en el Repositorio de manera obligatoria.



2. Referencia de tesis:

☐ Bachiller ☒ Título ☐ 2da Especialidad ☐ Maestría ☐ Doctorado

3. Licencias:

a) Licencia estándar:

Bajo los siguientes términos, autorizo el depósito de mi tesis en el Repositorio Digital de la UANCV.

Con la autorización de depósito de mi producción Intelectual, otorgo a la Universidad Andina “Néstor Cáceres Velásquez” una licencia no exclusiva para reproducir, distribuir, comunicar al público, transformar (únicamente mediante su traducción a otros idiomas) y poner a disposición del público mi producción intelectual (incluido el resumen), en formato físico o digital, en cualquier medio, conocido o por conocerse, a través de los diversos servicios por la Universidad, creados o por crearse, tales como el Repositorio Digital de tesis UANCV, colección de producción intelectual, entre otros, en el Perú y en el extranjero por el tiempo y veces que considere necesarias, y libres de remuneraciones.

En virtud de dicha licencia, la Universidad Andina “Néstor Cáceres Velásquez” podrá reproducir mi producción intelectual en cualquier tipo de soporte y en más de un ejemplar, sin modificar su contenido, solo con propósitos de seguridad, respaldo y preservación.

Declaro que la producción intelectual es una creación de mi autoría y exclusiva titularidad, coautoría con titularidad compartida, y me encuentro facultado a conceder la presente licencia y, asimismo, garantizo que dicha producción intelectual no infringe derechos de autor de terceras personas.

La Universidad Andina “Néstor Cáceres Velásquez” consignará el nombre del y/o los autor(es) de la producción intelectual, y no le hará ninguna modificación más que la permitida en la licencia.

Autorizo su publicación (marque con una X)

- ☒ Sí, autorizo que se deposite inmediatamente.
- ☐ Sí, autorizo que se deposite a partir de la fecha (d/m/a): _____
- ☐ No autorizo.

b) Licencia CREATIVE COMMONS 4.0 INTERNACIONAL:

Si usted concede una licencia CREATIVE COMMONS sobre su producción intelectual, mantiene la titularidad de los derechos de autor de esta y, a la vez, permite que otras personas puedan reproducirla, comunicarla al público y distribuir ejemplares de esta, bajo las condiciones siguientes:

¿Quiere permitir usos comerciales de su producción intelectual?

Sí: significa que usted permite la reproducción, distribución y comunicación pública de la producción intelectual incluso con fines comerciales.

No: significa que usted permite la reproducción, y comunicación pública de la producción intelectual, pero sin fines comerciales.

- ☐ Sí autorizo
- ☒ No autorizo



Jurisdicción de su Licencia

Todas las licencias CREATIVE COMMONS son de ámbito mundial, sin embargo, usted puede elegir entre la opción “internacional” o una adaptada a su jurisdicción, como para el caso peruano.

La opción “internacional” emplea el lenguaje y la terminología de los tratados internacionales; en cambio, la adaptada a su jurisdicción, recoge las particularidades de la legislación peruana.

En consecuencia, **la opción “internacional” goza de una mayor eficacia a nivel mundial, gracias a que tiene jurisdicción neutral.** Mientras que la opción adaptada a la jurisdicción del Perú goza de una mayor eficacia ante los tribunales peruanos.

☒

Internacional

☐

Nacional

Línea de investigación: CIENCIA DE LOS ORDENADORES – P24

Firma de Autor



huella digital

22 – OCTUBRE – 2025

Fecha