

Determinación de la contaminación por metales pesados en los sedimentos superficiales de la subcuenca del río Antabamba en un período de mediano plazo

Determination of heavy metal contamination in the surface sediments of the Antabamba River sub-basin in a medium-term period

Darío Sánchez-Castillo^A, Pablo Zuloaga-Candia^B y Karina Gamarra-Peralta^C

Resumen— La investigación aborda el grave problema ambiental de la contaminación por metales pesados en los sedimentos superficiales de la subcuenca del río Antabamba, causado por actividades mineras, antropogénicas o procesos naturales. El objetivo principal es determinar la influencia de la contaminación por metales pesados en los sedimentos superficiales de la subcuenca del río Antabamba permite predecir la calidad ambiental durante un período de mediano plazo aplicando aprendizaje automático, analizando concentraciones de metales como del cromo, y considerando los estándares de calidad vigentes. Con un enfoque aplicativo y diseño experimental correlacional, se recolectaron y analizaron 28 muestras de sedimentos en 14 estaciones. El uso de algoritmos de aprendizaje automático permite predecir los límites permisibles de contaminación con el 75% de precisión, proporcionando datos clave para la gestión ambiental por meses. Los resultados subrayan la necesidad de implementar medidas de control y el cumplimiento normativo para reducir los impactos a corto y mediano plazo, y destacan la importancia de aplicar nuevos métodos para optimizar los pronósticos y futuras investigaciones.

Palabras clave: predicción, contaminación, metales pesados, sedimentos superficiales

Abstract— The research addresses the serious environmental problem of heavy metal contamination in the surface sediments of the Antabamba River sub-basin, caused by mining, anthropogenic activities or natural processes. The main objective is to determine the influence of heavy metal contamination in the surface sediments of the Antabamba River sub-basin to predict environmental quality over a medium-term period by applying machine learning, analyzing concentrations of metals such as chromium, and considering the standards. current quality standards. With an applicative approach and correlational experimental design, 28 sediment samples were collected and analyzed at 14 stations. The use of machine learning algorithms makes it possible to predict permissible pollution limits with 75% accuracy, providing key data for environmental management and mitigation strategies for months. The results underline the need to implement regulatory control and compliance to reduce short- and medium-term impacts, and highlight the importance of applying new methods to optimize forecasts and future research

Keywords: heavy metals, prediction, pollution, surface sediments.

1 INTRODUCCIÓN

La contaminación de los sedimentos superficiales por metales pesados (CSSMP), es un desafío crítico que impacta la calidad del agua, el suelo y la salud pública, así como el desarrollo socioeconómico de las comunidades afectadas [1]. Esta problemática es particularmente grave en los Sedimentos Superficiales (SS), que están contaminadas por actividades antropogénicas o por relaves mineros con altas concentraciones de metales pesados [2].

La complejidad de la contaminación por Metales Pesados (MP) radica en la dificultad de determinar sus concentracio-

nes exactas debido al comportamiento hidrofóbico [3] y la posibilidad de que estos contaminantes se vuelvan biodisponibles bajo ciertas condiciones [4];[1]. La escorrentía superficial durante las lluvias contribuye a la elevación de estos metales en los SS [5]. Esta situación es comparable a la crisis de CSSMP en países en desarrollo. Los MP, como mercurio (Hg), plomo (Pb) y cadmio (Cd), presentan riesgos significativos para la biota acuática y la salud humana, especialmente en áreas donde la minería es predominante [7].

Los SS, son sumideros de sustancias desechadas, donde los metales pesados tienden a bioacumularse, convirtiéndose en amenazas persistentes [8].

La falta de metodologías eficaces para evaluar la calidad de



Revista de Investigación en Ciencia y Tecnología
ISSN: 2810-8124 (en línea) / ISSN: 2706-543x
Universidad Nacional Micaela Bastidas de Apurímac – Perú

Vol. 6 Núm. 2 (2024) - Publicado: 10/11/24 - [Indexaciones](#)
Número: doi.org/10.57166/riqchary/v6.n2.2024
Pág.: 49 - 54 | Recibido 28/10/2024 ; Aceptado 31/10/2024



doi.org/10.57166/riqchary.v6.n2.2024.127

Autores:

A. **ORCID iD** <https://orcid.org/0000-0001-6654-6565>

Darío Dante Sánchez Castillo, trabaja en la Escuela Profesional de Ingeniería de Minas de la Universidad Nacional Micaela Bastidas de Apurímac-Perú, dsanchez@unamba.edu.pe

B. **ORCID iD** <https://orcid.org/0000-0002-3678-8894>

Pablo Ruben Zuloaga Candia, trabaja en la Escuela Profesional de Ingeniería de Minas de la Universidad Nacional Micaela Bastidas de Apurímac - Perú, pzuuaga@unamba.edu.pe

C. **ORCID iD** <https://orcid.org/0000-0002-7702-9923>

Karina Gamarra Peralta, trabaja en la Escuela Profesional de Ingeniería Informática y Sistemas de la Universidad Nacional Micaela Bastidas de Apurímac - Perú, kgamarra@unamba.edu.pe

los SS, es un obstáculo en la identificación de contaminantes en ríos como el de Antabamba, donde la contaminación es creciente [9].

se requiere la implementación de modelos predictivos basados en el aprendizaje automático para mejorar la precisión en la evaluación de la calidad de los sedimentos [9]. Estos modelos son esenciales para identificar las áreas más susceptibles a la contaminación y optimizar los controles ambientales [3].

La Fiscalización Ambiental en Apurímac, reporta 343 casos en el 2022, donde los residuos sólidos contribuyen a la contaminación, seguidos por hidrocarburos y la minería [11]. Los datos indican que, la adecuada información prevendría muchos casos de contaminación. La escasez de datos específicos limita la evaluación precisa de la calidad de los sedimentos [12]; [13]. Por lo tanto, es crucial adoptar enfoques avanzados en la gestión sostenible de los recursos naturales para mitigar el impacto de la contaminación en la región [9].

En la región de Apurímac, las actividades mineras han comprometido la calidad del suelo, incrementando la concentración de estos MP y amenaza la biodiversidad [9]. Los ríos de esta región son vitales para la agricultura y el monitoreo es esencial para evitar la contaminación [2].

TABLA 1.

Coordenadas y Zona de muestreo

Referencia	Coordenadas de Muestreo			Altitud (msnm)
	UTM			
	Zona	Este	Norte	
Puente Huancaray	18 L	0713693	8423521	2797
Puente Pichirhua	18 L	0698026	8437463	2482



Fig. 1. Río Antabamba y zonas de alta mineralización, extraído de Earth Google

2 METODOLOGÍA

2.1 Ámbito de estudio

El río Antabamba se encuentra en la región de Apurímac, Perú, y la subcuenca presenta una geografía diversa con varias zonas que tienen diferentes características ambientales que son influenciadas por actividades de origen antrópico, y naturales que ocurren en ambas márgenes [11], [14].

2.2 Tipo y nivel de investigación

La investigación es aplicada y correlacional [15], centrada en la relación entre la concentración de MP en los sedimentos del río Antabamba, comparando estos datos con estándares d El estudio adopta un enfoque retrospectivo y longitudinal. El

Los métodos tradicionales de evaluación son insuficientes, y calidad ambiental (ECA).

diseño de investigación es cuasiexperimental, con fase transversal y longitudinal [15]. La fase transversal involucra la recolección de datos en dos periodos estacionales mediante 28 muestras. La fase longitudinal aplica modelos de pronóstico en Python para proyectar la evolución de la contaminación por MP a mediano plazo.

2.3 Procedimiento

Para determinar la CSSMP del río Antabamba en un período de mediano plazo, se realizará lo siguiente:

- Determinar y analizar las concentraciones de los MP y el ECA de suelo, de acuerdo a la Normativa Nacional D. S. 011-2017-MINAM (Standard Methods, 2021; Perú, 2010), que establece los valores máximos permitidos para garantizar la conservación de la calidad ambiental [10]; [11], se analizan los datos clave que permiten caracterizar la calidad ambiental, realizar las correlaciones y se precisa la calidad ambiental.
- Precisar la calidad ambiental de la CSSMP del río Antabamba durante un periodo a mediano plazo aplicando algoritmos de aprendizaje automático.
- Precisar la calidad ambiental y el comportamiento de la CSSMP en el tiempo a mediano plazo, aplicando un modelo predictivo.

2.4 Población y muestra

La población, incluye todos los sedimentos superficiales de la subcuenca del río Antabamba, desde su origen hasta la confluencia con la subcuenca Chalhuanca.

La muestra, representativa de los SS en la subcuenca del río Antabamba es estratificada, se definieron 14 puntos de muestreo seleccionados estratégicamente a lo largo de 25 km. Considerando proximidad a proyectos mineros, diversidad geográfica y geológica, factores estacionales y accesibilidad para recolectar las muestras, con el fin de capturar la variabilidad espacial y temporal en la concentración de MP. Cada estrato representa una zona relevante del río en relación con fuentes de contaminación.

Precisar la calidad ambiental de la CSSMP del río Antabamba durante un periodo a mediano plazo aplicando algoritmos de aprendizaje automático.

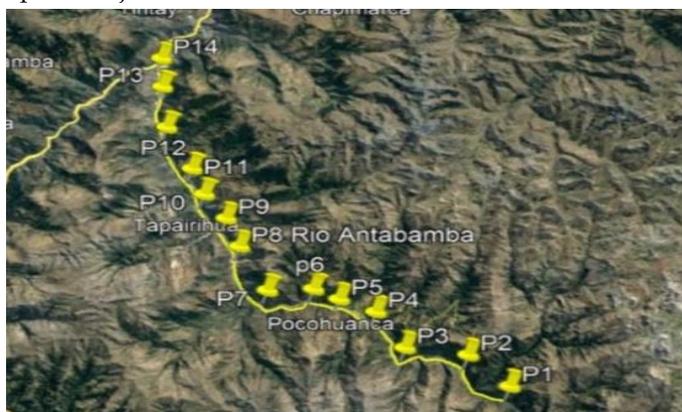


Fig. 2. Puntos de muestreo de sedimentos, extraído de Earth Google

La Fig. 2. Muestra los puntos de muestreo de sedimentosSe

establecieron modelos predictivos para precisar Iso ECAs y el comportamiento de la CSSMP en el tiempo, siendo estas recolecciones en etapas de secas y lluvias (Ver Fig. 3).



Fig. 3. Recolección de muestras de sedimentos superficiales

2.5 Materiales e instrumentos

TABLA 2
Materiales y métodos

Pasos	Materiales-Equipos	Métodos
Recolección de muestras de SS.	Baldes, frascos de polietileno y Pyrex para SS, probetas y otros. GPS, balanza digital, malla N°20.	Muestreo estratificado en 14 puntos
Análisis de SS.	Espectrofotómetro de masas con plasma acoplado por inductividad (ICP-MS). Normas Method 3051 y 6020A. -Multiparámetro.	Concentraciones de MP en laboratorio. Análisis) Normativa: ECAs
Predicción	-Laptop: Bases de datos con parámetros de ECAs, Software especializado (Python), algoritmos de ML, Herramientas de visualización y Técnicas de validación	Procesamiento y limpieza de datos Entrenamiento y validación de modelos. Predicción de ECAs durante un mediano plazo. Evaluación del rendimiento.

3 IMPLEMENTACIÓN

3.1 Origen de Datos y fuentes

Los SS, fueron analizados en el laboratorio de investigación de la Universidad Nacional de San Agustín de Arequipa. La técnica de análisis: ICP-MS. Los resultados del análisis presentaron diversas concentraciones de MP como son de: K, Ca, Ti, V, Cr, Mn, Fe, Co, Ni, Cu, Zn, Ga, As, Br, Rb, Sr, Y, Zr, Nb y Ba.

Los factores fisicoquímicos analizados en laboratorio de la EPIM-UNAMBA, fue: Milivoltios de pH (MmvpH), Potencial de Hidrógeno (pH), Potencial Redox (Mvorp), Porcentaje de Oxígeno Disuelto (%DO), Partes Por Millón de Oxígeno Disuelto (PPmDo), Conductividad Eléctrica (uS/cm), Resistividad (MΩ.cm), Partes por millón de Sólidos Disueltos Totales (PPmTds), Salinidad (Psu), Temperatura en grados Celsius (T°C) y Presión (Psi). Además, se utilizaron investigaciones científicas publicadas en revistas académicas especializadas y la norma correspondiente al D. S. N.º 011-2017-MINAM [20], para limitar la investigación. Las fuentes permiten establecer una información sólida, confiable, para el análisis

y aplicación de nuevos métodos de investigación, centradas en mostrar el comportamiento de las concentraciones MP con ECAs. Los valores de concentración están expresados en partes por millón (ppm).

```
import pandas as pd

# Datos de metales pesados
data = {
    'Cr': [9.11, 3.26, 3.30, 9.59, 23.57, 4.79, 17.08, 9.01, 6.18],
    'As': [36.20, 63.44, 28.25, 52.58, 1947.63, 42.40, 114.77, 66],
    'Cd': [0.76, 0.31, 0.06, 0.82, 13.45, 0.50, 1.19, 1.30, 0.24],
    'Ba': [95.67, 258.11, 116.18, 253.61, 147.76, 61.17, 586.46],
    'Pb': [15.24, 56.11, 6.34, 23.43, 89.54, 25.93, 49.60, 34.29],
}

df = pd.DataFrame(data)
```

Fig. 4. DataSet de concentraciones de metales pesados

3.2. Algoritmos de aprendizaje automático

3.2.1 Bagging, o "Bootstrap Aggregating: Técnica que mejora la precisión de modelos al entrenar múltiples modelos en subconjuntos aleatorios de datos y promedia sus predicciones, reduciendo la varianza y el sobreajuste de entrenamiento. Ajusta pesos de la capa de salida, permite generalizar tareas de predicción, es rápido en tiempo real [16].

3.2.2 Extreme Gradient Boosting (XGBoost). Algoritmo que entrena múltiples árboles de decisión secuencialmente, con la técnica de boosting y cada árbol corrige los errores del anterior. Es eficiente con grandes volúmenes de datos y diferentes tipos de variables [17].

3.2.3 Voting Regresso. Modelo que integra modelos de regresión para mejorar la precisión de los aspectos a desarrollar [18].

4 RESULTADOS

4.1 Estadística Inferencial

TABLA 3
Normalidad de Metales Pesados y Ecas

Metal	Estadístico	p-valor	ECAs	Estadístico	p-valor
Cr*	0.9139	0.02462	Concentra-	210.73	1.737e-46
Cd*	0.3824	8.50e-10	cion_MP *		
As*	0.3612	5.53e-10	Eca_Agricola *	915.77	1.39e-199
Pb*	0.8918	0.00738	Eca_Residencial*	996.87	3.41e-217
Ba*	0.8043	0.00013	Eca_Industrial*	32.432	9.069e-08

*Los datos NO siguen una distribución normal.

4.2 Determinación límites permisibles de MP

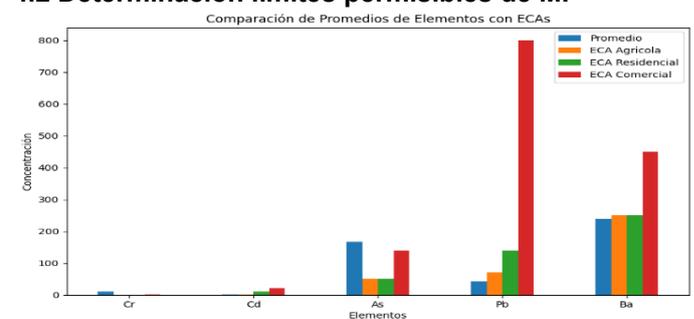


Fig. 5. Comparación de promedios de Metales Pesados con ECAs

La Fig. 5. indica que el Cr y As superan los límites permisibles de ECAs, en cambio los MP Ba, Pb y Cd se mantienen estables sin impactos negativos.

4.2 Matriz de correlación

Se obtuvo dos matrices de correlación de MP y de parámetros fisicoquímica siguientes:

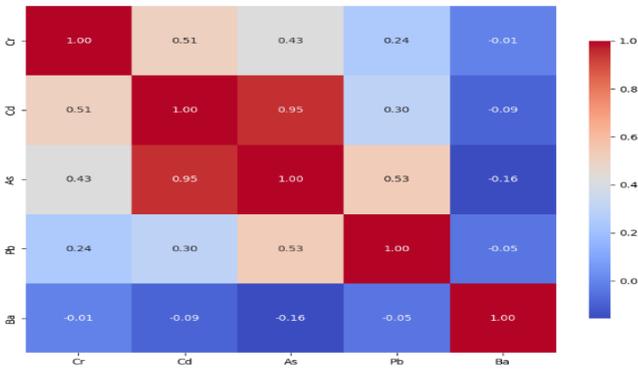


Fig. 6. Matriz de correlación de Spearman de metales pesados

La Fig. 6. Muestra la correlación de Spearman, de MP. Donde existe correlación:

- Alta y significativa entre Cr y Cd. Esto sugiere que a medida que aumenta la concentración de Cr, también tiende a aumentar la concentración de Cd, lo cual puede ser relevante en estudios de contaminación, gestión ambiental, predicción fiable y entender las relaciones clave entre MP y factores.
- Moderada y débil entre Cr y As y entre Pb y Ba, lo que indica que no es significativa. Indica que, aunque hay cierta relación, es menos confiable y podría ser influenciada por otros factores. Requiere un análisis cauteloso, por ser menos confiables.
- Sin correlación significativa entre Cr y Ba. No hay evidencia suficiente de una relación entre las concentraciones de MP y varían independientemente.
- Interdependencias complejas entre Cd y As, que pueden variar en diferentes condiciones ambientales. Necesitan métodos analíticos avanzados para entender cómo las variables interactúan en contextos más amplios.

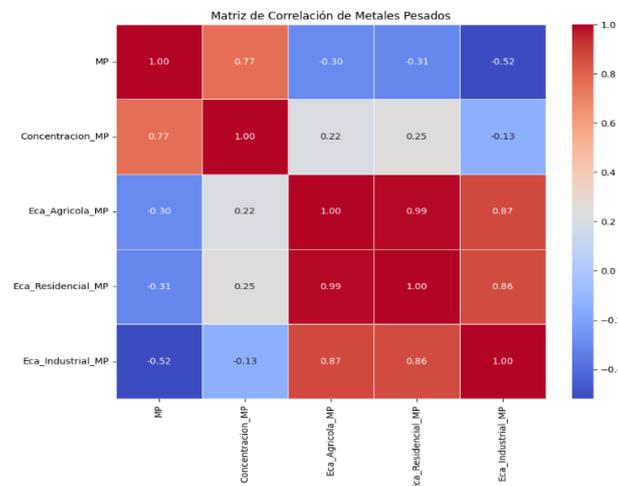


Fig. 7. Matriz de correlación de Spearman de factores fisicoquímicos

La Fig. 7, muestra la matriz de correlación de Spearman, de los MP y su concentración en distintos ECAs para usos agrícola, residencial e industrial. Esto indica que existe correlación:

- Alta y positiva entre de MP y Concentración_MP, lo que indica que a mayor concentración de MP, mayor presencia de contaminación general.
- Fuerte y positiva: de ECAs Agrícola, Residencial e Industrial entre sí, indica que los niveles de contaminación en un sector están fuertemente relacionados con los demás sectores.
- Débil y positiva de concentración de MP con los ECas agrícola y residencial. Indica que, si aumenta la concentración de MP, los ECAs tienden a verse ligeramente afectados.
- Débil y Negativa de MP con el ECAs industrial indicando que, existe incremento en la concentración de MP y no está necesariamente asociado con un empeoramiento en la adecuación ambiental, quizás debido a más tolerancia a contaminantes en estas zonas. Así mismo, de MP y ECAs, donde a mayor presencia de MP tiende a reducir la calidad ambiental en términos de diferentes usos (agrícola, residencial e industrial).
- Se muestra una relación directa entre la presencia de MP y la disminución de la calidad del ambiente según los distintos ECAs, es decir muestra el incremento de la contaminación, frente a los permisibles.

4.3 Matriz de confusión de Algoritmos

- XGBoost: muestra la efectividad del modelo en clasificar como "Permisible" o "Contaminado" los metales pesados, mostrando precisión del 100% en todos los casos analizados. Los verdaderos positivos y negativos indican alta exactitud en la clasificación, validando la eficacia del modelo en contextos donde es crucial minimizar errores de clasificación.
- Bagging: muestra un rendimiento excelente (100% de precisión) para Cr, As, Pb y Ba, mientras que el Cd alcanza un 75% de precisión, indicando posibles mejoras. Los errores ocurren en la clasificación de casos "Contaminado" como "Permisible".
- Voting (XGBoost+Bagging), revela un rendimiento excelente (100% de precisión) para todos los MP. La matriz muestra un rendimiento alto (100% de precisión) para los MP Cr, Cd, As, Pb y Ba, no existe errores en la clasificación de casos "Contaminado" para Cr, como "Permisible" para todos los casos restantes de los MP (Ver Fig. 8).

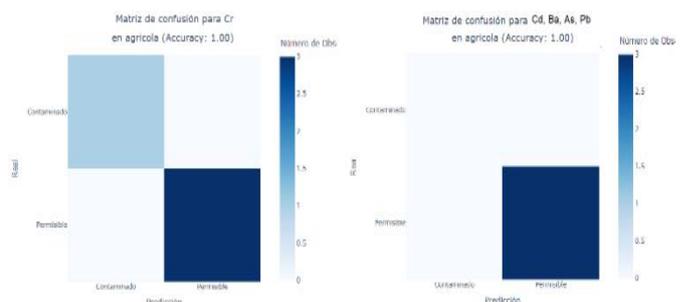


Fig. 8. Matriz de Confusión de Voting para los metales pesados con ECAs de suelo agrícola.

4.3.1 Validación Cruzada

Los algoritmos XGBoost (70%), Bagging (75%) y Voting, tienen una precisión media de 0.5375, 0.5375 y 0.5625, respectivamente, y una validez promedio de 75%, con Voting.

4.3 Predicción futura por meses

El comportamiento de la predicción por meses sugiere que, a corto y mediano plazo, ciertos metales pesados como el Cr representan un riesgo ambiental pronunciado, mientras que otros, como el Cd, As, Pb o Ba podrían convertirse en un problema a largo plazo debido a su crecimiento pausado en la zona de la microcuenca del río Antabamba.

4.3.1 Resultados de predicción de contaminación de sedimentos por metales pesados.

La determinación de contaminación a mediano plazo de 3 años con los algoritmos Xgboost, Baggin y Voting. Del cual, resalta la contaminación por el MP Cr: "Cromo". Por lo tanto, el suelo no cumple con los ECAs permisibles para uso 'agrícola' ni para uso 'industrial'. Se realizará una evaluación de contaminación agrícola, ya que las muestras analizadas del río Antabamba se utilizan para actividades agrícolas en la zona.

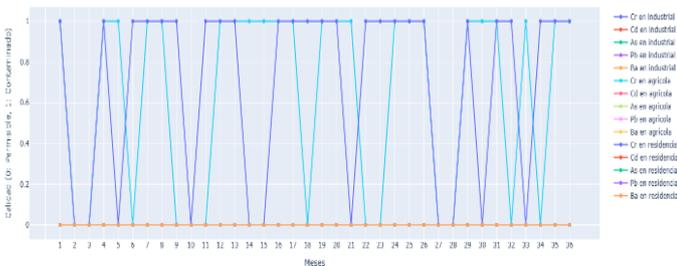


Fig. 10. Comparación de ECAs por mes con XGBoost

La Fig. 10, muestra resultados del algoritmo XGBoost, donde de 36 meses predichos de CSSMP por Cromo, 17 meses exceden los límites permitidos de ECAs, para suelo agrícola.

Los análisis de laboratorio finalizaron, en el mes de setiembre del 2023. Por lo cual, se considera agosto de 2023 como el 'mes 1' y a los meses siguientes se les asignan números consecutivos. Como sigue: 2, 3, 7, 8, 10, 12, 14, 15, 16, 19, 20, 21, 22, 24, 32, 33, 36.

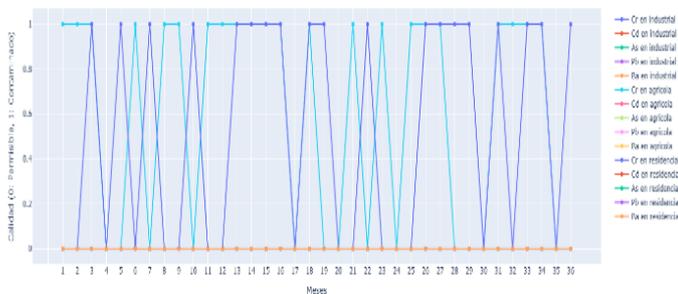
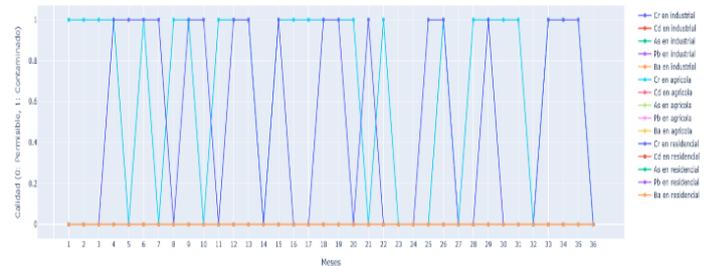


Fig. 11. Comparación de ECAs por Mes con Bagging

La Fig. 11, muestra resultados del algoritmo Bagging, donde de 36 meses predichos de contaminación por Cromo, muestra

24 meses que exceden los límites permitidos para suelo agrícola.

Se observa, la contaminación por Cr, en los meses: 2, 3, 4, 5, 7, 8, 9, 11, 12, 13, 15, 16, 18, 19, 20, 24, 25, 27, 29, 31, 32, 33, 34, 35. Fig. 12. Comparación de ECAs por Mes con Voting



La Fig. 12, muestra resultados, donde de 36 meses predichos de contaminación por Cromo, muestra 21 meses que exceden los límites permitidos para suelo agrícola.

Se observa, la contaminación por Cr, en los meses: 1, 2, 3, 4, 6, 8, 9, 11, 12, 15, 20, 22, 26, 28, 31. Por lo tanto, es necesario prever acciones de mitigación de contaminación específicas para esos meses.

4.3.2 Conclusiones de los resultados

Siendo el algoritmo Voting (XGBoost + Bagging), el algoritmo aplicado con una precisión del 75%, se determino que la CSSMP será según la Fig. 13, en un rango de 36 meses, del mes de octubre del 2023 a setiembre del 2026, e indica que: exceden los límites permitidos de ECAs, para suelo agrícola por Cr, en los meses de: octubre, noviembre y diciembre del 2023; enero, marzo, mayo, junio, agosto, septiembre y diciembre del 2024; enero, febrero, marzo, abril, mayo, julio, noviembre del 2025 y enero, febrero, marzo y abril del 2026.

5 DISCUSIÓN

La CSSMP en el río Antabamba, basada en 28 muestras analizadas con ICP-MS, mejoró su precisión de predicción de 35% a 75% mediante el algoritmo Voting Classifier (Bagging + XGBoost) [17][6]. En un periodo a mediano plazo, el 58.3% de los meses superaron los límites permisibles de ECAs agrícolas para Cr. En el río Yellow, 200 muestras analizaron CSSMP con una precisión superior al 90% usando Bagging, RDT y SVM, donde más del 40% superan límites en ECAs para Pb y Zn [6]. Las predicciones adicionales en otros ríos alcanzaron más del 90% de precisión con XGBoost y RF, donde el 60% superan los límites de ECAs [17].

Por lo tanto, se observa la alta correlación positiva entre la concentración de MP y la contaminación [6] y la relación significativa entre los ECAs agrícolas, residenciales e industriales, siendo especialmente alta en los sectores agrícola y residencial [17]. La menor correlación en el sector industrial sugiere una mayor tolerancia a la CSSMP [6]. Los resultados validan la eficacia del uso de algoritmos y su relevancia en estudios de impacto ambiental de la CSSMP [17][6].

6 CONCLUSIONES

La investigación sobre la determinación de CSSMP en la subcuenca del río Antabamba revela contaminación que excede los límites permisibles de las ECAs agrícolas, destacando: que el Cr y As representan un riesgo ambiental significativo, mientras que otros MP (Cd, Ba, Pb) permanecen dentro de los ECAs. Las variables no siguen una distribución normal, se confirman correlaciones importantes entre Cr-As y Cr-Cd y los MP con la contaminación que generaran las Concentraciones de MP, por lo que influyen fuertemente en la CSSMP.

Se destaca el uso del algoritmo ML Voting para determinar la CSSMP en un tiempo a mediano plazo. El cual, alcanzó un 75% de precisión y evidencia que el 58% de los meses (21 de 36) superan los límites permisibles de ECAs agrícolas. Así mismo, el Cr impacta negativamente la calidad ambiental.

7 RECOMENDACIONES

Es esencial aplicar control y monitoreo continuo en meses críticos para mitigar riesgos de altos ECAs y enfermedades. Se recomienda el algoritmo Voting con modelos optimizados y otros factores ambientales.

AGRADECIMIENTOS

Los autores agradecen al Vicerrectorado de Investigación de la UNAMBA, por la subvención del presente trabajo. Así mismo, a la Facultad de Ingeniería Informática y de Sistemas por la publicación de presente trabajo.

REFERENCIAS

- [1] M. Zhang, P. He, G. Qiao, J. Huang, X. Yuan, and Q. Li, "Heavy metal contamination assessment of surface sediments of the Subei Shoal, China: Spatial distribution, source apportionment and ecological risk," *Chemosphere*, vol. 223, pp. 211–222, May 2019, doi: <https://doi.org/10.1016/j.chemosphere.2019.02.058>
- [2] M. Huaranga et al., "Contaminación por metales pesados en la Cuenca del Río Moche, 1980 – 2010, La Libertad – Perú," 2010. doi: <https://doi.org/10.17268/sci.agropecu.2012.03.05>
- [3] L. Chávez and A. Flores, "Contaminación por metales pesados en sedimentos del río Antabamba, Apurímac," *Revista Local de Ciencias Ambientales de Apurímac*, vol. 6, no. 1, pp. 25–40, 2022.
- [4] P. M. Bach, W. Rauch, P. S. Mikkelsen, D. T. McCarthy, and A. Deltic, "A critical review of integrated urban water modelling – Urban drainage and beyond," *Environmental Modelling & Software*, vol. 54, pp. 88–107, Apr. 2014, doi: <https://doi.org/10.1016/j.envsoft.2013.12.018>
- [5] M. E. Mohammad, N. Al-Ansari, and S. Knutsson, "Annual Runoff and Sediment in Duhok Reservoir Watershed Using SWAT and WEPP Models," *Engineering*, vol. 08, no. 07, pp. 410–422, 2016, doi: <https://doi.org/10.4236/eng.2016.87038>
- [6] J. Feng and H. Yang, "Predicting heavy metal pollution in sediments using bagging techniques," *Environmental Monitoring and Assessment*, vol. 195, no. 3, p. 576, 2023. doi: <https://doi.org/10.1007/s10661-023-10932-2>
- [7] M. Abraham, J. A. Silva, and E. Lobo, "Assessment of heavy metals contamination in surface sediments using multivariate statistical

techniques and artificial neural networks," *Environmental Monitoring and Assessment*, vol. 188, no. 3, p. 144, 2016. doi: <https://doi.org/10.1007/s10661-015-5165-8>.

- [8] H. Ávila, E. Quintero, and N. Angulo, "Determinación de metales pesados en sedimentos superficiales costeros del sistema lago de Maracaibo, Venezuela," *Multiciencias*, vol. 14, no. 1, pp. 16–21, 2014. <https://www.redalyc.org/articulo.oa?id=90430816005>
- [9] R. Abarca and A. Vargas, "Contaminación por metales pesados en la región de Apurímac: Un análisis de la calidad del suelo," *Revista de Ciencias Ambientales*, vol. 45, no. 2, pp. 123–135, 2021.
- [10] Ministerio del Ambiente, "Informe sobre el estado de los suelos en Perú," Lima. Gobierno del Perú, 2020. <https://site.minam.gob.pe>
- [11] Oefa, "Oficina de Evaluación y Fiscalización Ambiental," 2022. [Online]. Available: <https://www.gob.pe/oefa>
- [12] L. Breiman, "Random forests," *Machine Learning*, vol. 45, no. 1, pp. 5–32, 2001. Doi: <https://doi.org/10.1023/A:1010933404324>
- [13] Vu Huy, "A Machine Learning Assessment to Predict the Sediment Transport Rate Under Oscillating Sheet Flow Conditions," *University of New Orleans*, 12-2019. <https://scholarworks.uno.edu/cgi/viewcontent.cgi?article=1134&context=honors-theses>
- [14] [SIAR, "Sistema de Información Ambiental Regional," [Online]. Available: <http://siar.regionsanmartin.gob.pe/>
- [15] M. González Mares, "Hernández-Sampieri, R. & Mendoza, C (2018). Metodología de la investigación. Las rutas cuantitativa, cualitativa y mixta," *Revista Universitaria Digital de Ciencias Sociales (RUDICS)*, vol. 10, no. 18, pp. 92–95, Jan. 2019, doi: <https://doi.org/10.22201/fesc.20072236e.2019.10.18.6>
- [16] M. R. Khan et al., "Ensemble learning methods for predicting heavy metal contamination in river sediments," *Environmental Monitoring and Assessment*, vol. 196, no. 2, p. 99, 2024. doi: <https://doi.org/10.22201/fesc.20072236e.2019.10.18.6>
- [17] Y. Wang et al., "Extreme Learning Machine for predicting sediment contamination by heavy metals," *Ecotoxicology and Environmental Safety*, vol. 238, p. 113550, 2024. doi: <https://doi.org/10.1016/j.ecoenv.2023.113550>
- [18] P. Zhang et al., "Fuzzy logic and machine learning integration for predicting heavy metal levels in sediment," *Journal of Cleaner Production*, vol. 405, p. 135450, 2023. doi: <https://doi.org/10.1016/j.jclepro.2023.135450>

BIOGRAFÍA



Darío Dante Sánchez Castillo. Egresado del Doctorado en Cs. Tecnología y Medio Ambiente de la UNAP, Maestro en Minería y Medio Ambiente. Título: Ing. Metalúrgico de la UNSAAC. Docente adscrito al departamento de Ingeniería de la UNAMBA, con experiencia en empresas mineras en instituciones estatales y privadas.



Pablo Ruben Zuloaga Candia. Doctor en Administración de la Educación, Magíster en Gestión de la Educación. Título: Ing. de Minas de la UNSAAC, con experiencia en obras mineras y civiles.



Karina Gamarra Peralta, Egresada del Doctorado de Ingeniería de Sistemas e Informática de UNMSM, M. Sc. de Informática con mención: en gestión de TIC. Título: Ing. de Sistemas. Docente adscrita al departamento de Ingeniería Informática y Sistemas de la UNAMBA.