

LIBRO DE RESÚMENES

2do Congreso Internacional de Optimización Numérica para Modelos de Clasificación en Machine Learning

Universidad Nacional Mayor de San Marcos

26–28 de octubre de 2026
Lima, Perú



Índice general

1. Presentación	1
2. Bienvenida	2
3. Organización	3
4. Información general	4
5. Programación del Congreso	5
6. Minicursos	8
Optimización Matemática para Modelos de Clasificación en Machine Learning — Julio López	8
Optimización en Variedades Riemannianas — Erik Alex Papa Quiroz	9
7. Charlas Plenarias	10
Complejidad Asintótica de algoritmos para resolver sistemas de ecuaciones li- neales y no lineales — Erik Alex Papa Quiroz	10
Nonconvex Conic Optimization for Sparse and Robust Classification — Julio López	11
Aplicación web con IA predictiva para optimizar el abastecimiento de productos en una cadena de farmacias — Miguel Angel Cano Lengua	12
Modelos de Segmentación — Yalmar Ponce Atencio	13
8. Contribuciones	14
8.1. Iniciación Científica	14
Prototipo de aplicativo móvil de un sistema de gestión de transporte universi- tario en la UNMSM: Estimación del tiempo de llegada mediante teoría de grafos y aprendizaje automático — Mileynd Jesús Aguilar Morán . .	14
Modelo Subrogado de Función de Transferencia Basado en Datos y XGBoost para la Estimación de la Presión Cerebral — José Alexis Delgado Pérez	17
8.2. Comunicaciones	19
Modelo Computacional Basado en CPSVM-L1: Para la Estratificación del Ries- go de Cáncer de Próstata en los Centros de Salud del Perú — Lenin Froy Arce Huamán	19
OPTIMACO-SVM: Una plataforma integral para el despliegue operativo de múltiples familias de máquinas de vectores de soporte — Cesar Chahuas Rebatta	21
Esquema de adquisición comprimida esteganográfica basado en matrices de medición caóticas multiescala para imágenes digitales con resistencia a reconstrucción inversa — Boris Chullo-Llave	23

Análisis estructural de formulaciones de optimización y descomposición combinatoria-geométrica del Problema del Árbol Euclidiano de Steiner en $\mathbb{R}^d$ — Carlos Robinson Cruz Cabrera	25
Un nuevo modelo de programación cónica de segundo orden para máquinas de vectores de soporte probabilísticas — Franz Richard Reynaga Buitrón	26
Selección de variables ℓ_p -SOCP sobre la variedad potencia- p : una variante de la métrica de Shahshahani — Jhon Erick Rios Cortegana	27
Máquina de Vectores Soporte No Paralela Modificada: Unicidad del Sesgo y Formulación Dual Convexa — Factor Risco Guillen	32
Una revisión sistemática de la literatura sobre el uso de la Inteligencia Artificial para el apoyo en el diagnóstico clínico — Johnny Richard Quispe Obregón	37
Simetría vs SDP de Conjuntos — Eladio Ocaña Anaya	39
Diseño de un modelo de Machine Learning para detección de anomalías en contrataciones públicas del estado peruano — Julio César Gonzales Paico	39
Método del punto proximal mediante la distancia de Bregman para problemas de equilibrio en variedades de Hadamard — Roy Sanchez Gutierrez	41
Desarrollo de un Algoritmo Proximal Alternado para Problemas de Descomposición de Dominio en EDP — Elvis Favian Caycho Villegas	43
8.3. Ponencias	46
Optimización de portafolios con restricciones mediante Particle Swarm Optimization (PSO) — Omar Briceño C.	46
De la programación lineal al Machine Learning: la convexidad como puente mediante geometría dinámica — Mariano A. González Ulloa	47
Implementación en R de un modelo logístico de ecuaciones diferenciales para simular el crecimiento de tubérculos de papa a partir de parámetros publicados — Johnny Fernando Hidalgo Rodríguez	48
Minimization Models using Proximal Comixtures — Diego J. Cornejo	53
Método Proximal Estocástico Riemanniano con Margen Geodésico Adaptativo para Clasificación de Subespacios — Josué David Fasanando Pinedo	54
Automatización mediante Inteligencia Artificial del diseño estructural de reservorios circulares para almacenamiento de agua para consumo humano como solución definitiva de la brecha de agua potable y la anemia en el Perú — Cesar E. Villar Guerra	56

Presentación

El presente volumen reúne las contribuciones del **2do Congreso Internacional de Optimización Numérica para Modelos de Clasificación en Machine Learning**, realizado en la Universidad Nacional Mayor de San Marcos, Lima, Perú, del 26 al 28 de octubre de 2026. El libro recoge trabajos en optimización matemática, programación cónica, aprendizaje automático, máquinas de vectores de soporte, métodos proximales, aplicaciones computacionales y áreas afines.

El congreso es organizado por el grupo de investigación **OPTIMACO (Optimización Matemática y Computacional)**, dedicado al desarrollo de modelos matemáticos, algoritmos de optimización y herramientas computacionales para abordar problemas de la ciencia, la ingeniería y la inteligencia artificial. Este encuentro busca promover el intercambio de ideas, resultados y experiencias entre investigadores, docentes, estudiantes y profesionales, así como fortalecer la colaboración científica en las áreas de optimización y aprendizaje automático.

La realización de este congreso se enmarca en las actividades de difusión del proyecto de investigación financiado por el **Consejo Nacional de Ciencia, Tecnología e Innovación Tecnológica (CONCYTEC)**, a través del **Programa PROCENCIA**, en el marco del concurso **E041-2024-03**, según el contrato **Nro PE501087025-2024-PROCENCIA**.

En esta edición, el congreso cuenta también con la colaboración de la *Revista Científica de Sistemas e Informática* (e-ISSN: 2709-992X), revista científica de acceso abierto fundada en 2021. Una selección de los trabajos presentados podrá ser considerada para su publicación en la revista, previa evaluación por el comité correspondiente y de acuerdo con sus políticas editoriales, procedimientos de revisión por pares y criterios de calidad.

Nota editorial: esta versión unifica el diseño de las contribuciones y utiliza la identidad gráfica actual de OPTIMACO. El contenido científico corresponde a los manuscritos proporcionados por sus autores.

Bienvenida

Estimados participantes:

En primer lugar, queremos expresarles nuestra más cordial bienvenida al **2do Congreso Internacional de Optimización Numérica para Modelos de Clasificación en Machine Learning**, un espacio académico orientado al intercambio de conocimientos, experiencias y avances en el campo de la **optimización numérica, la inteligencia artificial y el aprendizaje automático**.

Este evento reúne a investigadores, docentes, estudiantes y profesionales interesados en explorar nuevas metodologías, aplicaciones y desafíos relacionados con los modelos de clasificación y las técnicas de optimización aplicadas al *Machine Learning*.

La realización de este congreso se enmarca en las actividades de difusión del proyecto de investigación financiado por el **Consejo Nacional de Ciencia, Tecnología e Innovación Tecnológica (CONCYTEC)**, a través del **Programa Nacional de Investigación Científica y Estudios Avanzados (PROCIENCIA)**, en el marco del concurso **E041-2024-03**, según el contrato **Nro. PE501087025-2024-PROCIENCIA**.

Asimismo, expresamos nuestro especial agradecimiento a la **Universidad Nacional Mayor de San Marcos**, a través de su **Facultad de Ciencias Matemáticas**, y al **Grupo de Investigación OPTIMACO**, por su colaboración y apoyo en la organización de este encuentro académico.

Finalmente, agradecemos a todos los participantes por acompañarnos en esta segunda edición del congreso. Esperamos que las conferencias, ponencias e intercambios académicos sean una experiencia enriquecedora y contribuyan al desarrollo de nuevas ideas, investigaciones y colaboraciones.

Comité Organizador

Lima, 26 de octubre de 2026

Organización

Institución anfitriona: Universidad Nacional Mayor de San Marcos.

Grupo de investigación: OPTIMACO — Grupo de Investigación de Optimización Matemática y Computacional.

INTEGRANTES DEL COMITÉ

Presidente del Comité Organizador

Dr. Papa Quiroz Erik Alex

erikpapa@gmail.com

Presidente del Comité de Auspicios

Mg. De la Cruz Lucy Haydee

ldelacruz@unmsm.edu.pe

Presidente del Comité de Publicaciones

Dr. Cano Lengua Miguel Angel

mcanol@unmsm.edu.pe

Presidente del Comité Científico

Dr. López Luis Julio César

julio.lopez@udp.cl

Presidente de Gestión y Publicidad

Mg. Portal Cuentas Maria Teresa

mariapc41uct.2023@gmail.com

Presidente de Organización y Relaciones Institucionales

Cardenas Mariño Flor Cagniy

fcardenasm@unmsm.edu.pe

Información general

Lugar del evento

El congreso se realizará en el auditorio “**Pedro Humberto Rivera Rodríguez**”, ubicado en la **Facultad de Ciencias Matemáticas** de la Universidad Nacional Mayor de San Marcos (UNMSM), en la Ciudad Universitaria de Lima, Perú.

Como referencia para los asistentes, la ubicación de la Facultad de Ciencias Matemáticas, ver la figura:



Acceso a la Ciudad Universitaria

Para ingresar a la Ciudad Universitaria, se sugieren los siguientes accesos:

- **Puerta Nro 1:** acceso por la avenida Venezuela, junto al Estadio de San Marcos.
- **Puerta Nro 2:** acceso situado en las proximidades del cruce de las avenidas Universitaria y Venezuela.

Dentro de la Ciudad Universitaria, los participantes pueden utilizar la movilidad interna de la universidad.

Programación del Congreso

Horario	Lunes 26	Martes 27	Miércoles 28
09:00–09:30	Inscripciones		
09:30–10:00	Charla 1	Charla 7	Charla 14
10:00–10:30	Charla 2	Charla 8	Charla 15
10:30–11:00	Coffee break	Coffee break	Coffee break
11:00–11:30	Minicurso 1 (1/2)	Charla 9	Charla 16
11:30–12:00	Minicurso 1 (1/2), continuación	Charla 10	Charla 17
12:00–12:30	Plenaria 1	Minicurso 2 (2/2)	Charla 18
12:30–13:00	Plenaria 1, continuación	Minicurso 2 (2/2), continuación	
13:00–15:00	Almuerzo	Almuerzo	Almuerzo
15:00–16:00	Minicurso 2 (1/2)	Minicurso 1 (2/2)	Plenaria 3
16:00–16:30	Charla 3	Charla 11	Charla 19
16:30–17:00	Charla 4	Charla 12	Charla 20
17:00–17:30	Coffee break	Coffee break	Coffee break
17:30–18:00	Charla 5	Charla 13	Plenaria 4
18:00–18:30	Charla 6	Plenaria 2	Plenaria 4, continuación
18:30–19:00	Inauguración	Plenaria 2, continuación	Clausura

Plenaria	Minicurso	Charla	Pausa	Almuerzo	Actividad institucional
----------	-----------	--------	-------	----------	-------------------------

Plenarias

- P1:** Complejidad Asintótica de algoritmos para resolver sistemas de ecuaciones lineales y no lineales.
Dr. Erik Alex Papa Quiroz.
- P2:** Nonconvex Conic Optimization for Sparse and Robust Classification.
Dr. Julio López.
- P3:** Aplicación web con IA predictiva para optimizar el abastecimiento de productos en una cadena de farmacias.
Dr. Miguel Ángel Cano Lengua.
- P4:** Modelos de Segmentación.
Dr. Yalmar Ponce Atencio.

Minicursos

- M1:** Optimización Matemática para Modelos de Clasificación en Machine Learning (dos sesiones).
M2: Optimización en Variedades Riemannianas (Dos sesiones).

Charlas

Lunes 26

- C1:** Diseño de un modelo de Machine Learning para detección de anomalías en contrataciones públicas del estado peruano.
Julio César Gonzales Paico
- C2:** Esquema de adquisición comprimida esteganográfica basado en matrices de medición caóticas multiescala para imágenes digitales con resistencia a reconstrucción inversa.
Boris Chullo-Llave
- C3:** Modelo Subrogado de Función de Transferencia Basado en Datos y XGBoost para la Estimación de la Presión Cerebral.
José Alexis Delgado Pérez
- C4:** Optimización de portafolios con restricciones mediante Particle Swarm Optimization (PSO).
Omar Briceño C.
- C5:** Análisis estructural de formulaciones de optimización y descomposición combinatoria-geométrica del Problema del Árbol Euclidiano de Steiner en $\mathbb{R}^d$.
Carlos Robinson Cruz Cabrera
- C6:** De la programación lineal al Machine Learning: la convexidad como puente mediante geometría dinámica.
Mariano A. González Ulloa

Martes 27

- C7:** Prototipo de aplicativo móvil de un sistema de gestión de transporte universitario en la UNMSM: Estimación del tiempo de llegada mediante teoría de grafos y aprendizaje automático.
Mileynd Jesús Aguilar Morán
- C8:** OPTIMACO-SVM: Una plataforma integral para el despliegue operativo de múltiples familias de máquinas de vectores de soporte.
Cesar Chahuas Rebatta
- C9:** Máquina de Vectores Soporte No Paralela Modificada: Unicidad del Sesgo y Formulación Dual Convexa.
Factor Risco Guillen
- C10:** Selección de variables ℓ_p -SOCP sobre la variedad potencia- p : una variante de la métrica de Shahshahani.
Jhon Erick Rios Cortegana
- C11:** Un nuevo modelo de programación cónica de segundo orden para máquinas de vectores de soporte probabilísticas.
Franz Richard Reynaga Buitrón
- C12:** Modelo Computacional Basado en CPSVM-L1: Para la Estratificación del Riesgo de Cáncer de Próstata en los Centros de Salud del Perú.
Lenin Froy Arce Huamán
- C13:** Implementación en R de un modelo logístico de ecuaciones diferenciales para simular el crecimiento de tubérculos de papa a partir de parámetros publicados.
Johnny Fernando Hidalgo Rodríguez

Miércoles 28

- C14:** Una revisión sistemática de la literatura sobre el uso de la Inteligencia Artificial para el apoyo en el diagnóstico clínico.
Johnny Richard Quispe Obregón
- C15:** Simetría vs SDP de Conjuntos
Eladio Ocaña Anaya
- C16:** Método Proximal Estocástico Riemanniano con Margen Geodésico Adaptativo para Clasificación de Subespacios.
Josué David Fasanando Pinedo
- C17:** Minimization Models using Proximal Comixtures.
Diego J. Cornejo
- C18:** Desarrollo de un Algoritmo Proximal Alternado para Problemas de Descomposición de Dominio en EDP.
Elvis Favian Caycho Villegas
- C19:** Método del punto proximal mediante la distancia de Bregman para problemas de equilibrio en variedades de Hadamard.
Roy Sanchez Gutierrez
- C20:** Automatización mediante Inteligencia Artificial del diseño estructural de reservorios circulares para almacenamiento de agua para consumo humano como solución definitiva de la brecha de agua potable y la anemia en el Perú.
Cesar E. Villar Guerra

Minicursos

Optimización Matemática para Modelos de Clasificación en Machine Learning

Julio López

Universidad Diego Portales, Santiago, Chile

julio.lopez@udp.cl

Resumen.

Este curso presenta una introducción a las principales herramientas de optimización matemática utilizadas en modelos de clasificación de datos, con especial énfasis en las máquinas de vectores de soporte (SVM) y algunas de sus variantes. Se estudiarán modelos basados en la construcción de uno o más hiperplanos de separación, mostrando cómo su entrenamiento conduce, en particular, a problemas de optimización cuadrática convexa con restricciones lineales. A partir de estas formulaciones, se analizarán las condiciones de optimalidad y se derivarán los correspondientes problemas duales, destacando su interpretación y utilidad computacional.

Asimismo, se revisarán algunas herramientas numéricas para resolver estos problemas y los principales criterios utilizados para evaluar el desempeño de los clasificadores. Finalmente, se discutirán extensiones orientadas a abordar características frecuentes de los datos reales, incluyendo la selección de características relevantes, la presencia de ruido y valores atípicos (*outliers*), mostrando cómo distintas herramientas de optimización permiten incorporar estos aspectos en el diseño de modelos de clasificación.

Keywords: Optimización convexa; optimización cuadrática; máquinas de vectores de soporte (SVM).

Bibliografía

- [1] K.P. Bennett and E.J. Bredensteiner *Duality and geometry in SVM classifiers*. Proceedings of the International Conference on Machine Learning (pp. 57-64). San Francisco, California: Morgan Kaufmann Publishers, 2000.
- [2] N. Cristianini and J. Shawe-Taylor *An Introduction to Support Vector Machines and others Kernel-Based Learning Methods*, Cambridge University Press, 2000.
- [3] G. Fung and O. L. Mangasarian, *A feature selection Newton method for support vector machine classification*, Computational Optimization and Applications, 28(2):185-202, 2004
- [4] L. Li, *Selected Applications of Convex Optimization*, Springer Berlin, Heidelberg, 2015.

Optimización en Variedades Riemannianas

Erik Alex Papa Quiroz

Universidad Nacional Mayor de San Marcos, Lima, Perú

epapaq@unmsm.edu.pe

Resumen.

En este minicurso presentaremos los elementos fundamentales de la optimización en variedades Riemannianas y algunas de sus aplicaciones. Esta área de investigación ha experimentado un importante desarrollo en los últimos años, motivado, entre otros aspectos, por la necesidad de abordar problemas en los que la geometría subyacente desempeña un papel esencial. En estos casos, la estructura Riemanniana permite incorporar de manera natural la geometría y la no linealidad propias del problema, ofreciendo formulaciones que pueden resultar más adecuadas que aquellas planteadas en espacios lineales. Este enfoque ha encontrado aplicaciones, por ejemplo, en el modelamiento del cerebro, el cuerpo humano y la columna vertebral, entre otros problemas cuya estructura geométrica puede describirse de manera más apropiada mediante espacios no euclidianos. A lo largo del minicurso abordaremos la formulación de problemas de optimización sobre variedades Riemannianas, la existencia de soluciones, las condiciones de optimalidad y algunos métodos clásicos de optimización adaptados a este contexto.

Keywords: Optimización en variedades, métricas Riemannianas, condiciones de optimalidad, algoritmos geodésicos.

Bibliografía

- [1] E.A. Papa Quiroz *Método del Gradiente no Euclidiano para Optimización*. Editorial Académica Española, 2012
- [2] T. Rapcsák *Smooth Nonlinear Optimization in $\mathbf{R}^n$* , Academic Publishers, 1997.
- [3] C. Udriste *Convex Functions and Optimization Methods on Riemannian Manifolds*, Kluwer Academic Publishers, 1997.

Charlas Plenarias

Complejidad Asintótica de algoritmos para resolver sistemas de ecuaciones lineales y no lineales

Erik Alex Papa Quiroz

Universidad Nacional Mayor de San Marcos, Lima, Perú

epapaq@unmsm.edu.pe

Resumen. En esta presentación explicamos las complejidades computacionales de los algoritmos para resolver sistemas de ecuaciones lineales y no lineales. Analizamos y comparamos diversos métodos, como los métodos de Gauss, métodos LU, Cholesky, Jacobi, Gauss-Seidel, gradientes conjugados, Newton y cuasi-Newton entre otros. Este análisis es importante para obtener eficiencia en las aplicaciones en ciencia e ingeniería.

Keywords: Sistemas lineales, sistemas no lineales, eliminación Gaussiana, LU, Cholesky, gradiente conjugado, Newton.

Bibliografía

- [1] R.L. Burder, and J.D. Faires. *Análisis Numérico*. Editorial Iberoamericana. México 1995.
- [2] T. Cormen, C. Leiserson, R. Rivest, C. Stein *Introduction to algorithms* 4ta impresión, MIT Press-McGraw-Hill
- [3] L. J. Szwarcfiter, L. Markenson *Estrutura de Dados e seus Algoritmos* 2da edicao, 1994
- [4] E.R. Campelo, N. Maculan *Projeto e Análise de Algoritmos Heurísticos*. Escola Brasileira de Otimizacao, 1989.

Nonconvex Conic Optimization for Sparse and Robust Classification

Julio López

Universidad Diego Portales, Santiago, Chile

julio.lopez@udp.cl

Resumen. Sparse and robust classification plays an important role in modern machine learning, particularly in high-dimensional problems where only a subset of the available features may be relevant and the data may be affected by uncertainty. In this talk, we present a novel classification framework that combines second-order cone programming (SOCP) with nonconvex ℓ_p quasi-norm regularization ($0 < p < 1$). The resulting models exploit first- and second-order information from the data through conic constraints while simultaneously promoting sparsity in the classifier.

From a theoretical perspective, we derive explicit positive lower bounds on the magnitude of the nonzero components of any local minimizer. These bounds provide an analytical characterization of sparsity and establish theoretical guarantees for feature selection in the proposed ℓ_p -SOCP framework. We also develop an iteratively reweighted ℓ_1 algorithm specifically designed to address the resulting nonconvex optimization problems. The convergence properties of the algorithm are analyzed, including monotonic descent, boundedness of the generated sequence, and convergence to first-order stationary points.

Finally, numerical experiments on several benchmark datasets are presented to evaluate the proposed models in terms of predictive performance, feature selection, robustness, and computational efficiency. The results illustrate the potential of combining nonconvex sparsity-inducing regularization with conic optimization as a flexible framework for high-dimensional and robust classification problems.

Keywords: Nonconvex Regularization, Second-Order Cone Programming, Sparse Classification

Joint work with:

Miguel Carrasco¹, Universidad de los Andes, Chile.

Benjamin Ivorra, Angel M. Ramos², Universidad Complutense de Madrid, España

Matthieu Marechal³, Universidad Diego Portales, Chile.

Bibliografía

- [1] Carrasco, M., Ivorra, B., López, J., Marechal, M. and Ramos, A.M., *Sparse and Robust Feature Selection in SVM Classification through ℓ_p -Quasi-norms*, submitted, 2025.
- [2] Fung, G. and Mangasarian, O. L., *A feature selection Newton method for support vector machine classification*, Comp. Optim. Applic., 28(2):185-202, 2004.
- [3] Li, L., *Selected Applications of Convex Optimization*, Springer Berlin, Heidelberg, 2015.
- [4] López, J., Maldonado, S. and Carrasco, M., *Double regularization methods for robust feature selection and svm classification via dc programming*, Info. Sci., 429:377-389, 2018.
- [5] Maldonado, S. and López, J., *Alternative second-order cone programming formulations for support vector classification*. Information Sciences 268: 328-341, 2014.

¹E-mail: macarrasco@uandes.cl

²E-mail: ivorra@ucm.es; angel@mat.ucm.es

³E-mail: matthieu.marechal@udp.cl

Aplicación web con IA predictiva para optimizar el abastecimiento de productos en una cadena de farmacias

Miguel Angel Cano Lengua

Universidad Nacional Mayor de San Marcos, Lima, Perú

mcanol@unmsm.edu.pe

Resumen. El presente trabajo de investigación tiene como objetivo desarrollar una aplicación web con inteligencia artificial predictiva para optimizar la gestión de inventarios y el abastecimiento en una cadena de farmacias multisede. El problema identificado radica en la falta de integración entre sedes, lo que genera desabastecimiento de productos en algunos locales y sobrestock en otros, afectando la eficiencia operativa y la satisfacción del cliente.

Palabras clave: Inteligencia artificial; inventarios; predicción de demanda; farmacias multisede.

Introducción

La cadena de farmacias presenta pérdidas económicas asociadas a ventas no realizadas, compras urgentes, productos vencidos e inmovilización de capital por exceso de inventario. Además, esta situación afecta la continuidad del abastecimiento y la satisfacción del cliente debido a la indisponibilidad de productos esenciales.

Según Bendhi [1], una gestión deficiente de inventarios puede incrementar significativamente los niveles de sobreabastecimiento, mientras que la aplicación de modelos predictivos basados en *Machine Learning* permite reducir hasta en un 20 % el exceso de stock y optimizar los procesos de reposición. Asimismo, en [2] se señala que los modelos inteligentes aplicados a cadenas logísticas permiten reducir entre un 10 % y 35 % los niveles de inventario sin afectar el nivel de servicio, evidenciando el impacto económico que puede generar una gestión no optimizada.

Contribución Principal

El presente estudio desarrollará una aplicación web predictiva en el sector farmacéutico minorista, el cual cumple una función importante dentro de la economía y la salud pública, al asegurar el acceso de la población a medicamentos, productos OTC, artículos de higiene y cuidado personal.

En el Perú, las farmacias deben cumplir regulaciones sanitarias establecidas por DIGEMID (Dirección General de Medicamentos, Insumos y Drogas) respecto al almacenamiento, trazabilidad, control de vencimientos y comercialización de productos farmacéuticos. Además, el sector presenta alta competencia y cambios constantes en la demanda.

Conclusiones

Como resultado, se mejorará la toma de decisiones, se reducirán las pérdidas económicas y se optimizará el abastecimiento de productos, contribuyendo así a una gestión más eficiente en el sector farmacéutico.

Trabajo conjunto con

Vizcarra Vargas, Fabbio Genaro, Universidad Peruana de Ciencias Aplicadas.

Bibliografía

- [1] M. R. Bendhi, “Inventory Management: Machine Learning Predicts Demand, Reducing Excess Stock by up to 20 %,” *International Journal of Artificial Intelligence, Data Science, and Machine Learning*, vol. 4, no. 2, pp. 67–83, 2023.
- [2] Z. L. Jin et al., “Stochastic optimization of inventory at large-scale supply chains,” Publisher, City, 2025.
- [3] C.-H. Liu et al., “Development of a smartphone-based inventory management system for emergency carts,” *Journal of Medical Systems*, vol. 49, no. 1, Art. no. 133, 2025.

Modelos de Segmentación

Yalmar Ponce Atencio

Universidad Nacional de Juliaca, Puno, Perú

ytponcea.doc@unaj.edu.pe

Resumen. La segmentación de imágenes y videos está experimentando una transformación radical gracias a los modelos fundacionales de visión por computadora, desde Segment Anything Model (SAM) hasta arquitecturas más avanzadas disponibles actualmente. SAM (2023) introdujo la segmentación promptable mediante puntos, cajas y máscaras; SAM 2, que extendió estas capacidades al video incorporando memoria temporal para segmentar y seguir objetos a través de múltiples fotogramas; y SAM 3, que representa un salto hacia la segmentación basada en conceptos, permitiendo localizar, segmentar y rastrear objetos utilizando texto, ejemplos visuales o prompts interactivos. También revisaremos alternativas y extensiones como SAMURAI, orientado al seguimiento robusto de objetos mediante memoria sensible al movimiento; así como FastSAM, MobileSAM, EfficientSAM, HQ-SAM, Grounded-SAM y otros enfoques especializados, considerando sus diferencias en precisión, velocidad, consumo computacional y aplicabilidad.

Contribuciones

8.1. Iniciación Científica

Prototipo de aplicativo móvil de un sistema de gestión de transporte universitario en la UNMSM: Estimación del tiempo de llegada mediante teoría de grafos y aprendizaje automático

Mileynd Jesús Aguilar Morán

Universidad Nacional Mayor de San Marcos, Lima, Perú

mileynd.aguilar@unmsm.edu.pe

Resumen.

La incertidumbre en el tiempo de llegada afecta a las distintas rutas del transporte universitario en Cono Norte. Se propone una metodología de estimación dinámica basada en datos GPS, map matching, teoría de grafos y aprendizaje automático. El trayecto se representa mediante grafos dirigidos y ponderados con tiempos históricos; sobre ellos, el algoritmo de Dijkstra obtiene una estimación base del tiempo restante hasta el destino. Posteriormente, se evalúan Ridge, Random Forest y Gradient Boosting mediante un esquema de corrección residual. Las principales contribuciones comprenden el procesamiento de datos GPS, la construcción de grafos temporales, la estimación del ETA y la integración de la metodología en un prototipo de aplicativo móvil desarrollado en Flutter y conectado a un backend mediante una API REST. En el corte experimental actual se analizaron 973 observaciones correspondientes a 48 viajes completos. La validación cruzada agrupada por viajes obtuvo un MAE de 5.52 minutos para Dijkstra, 5.63 para Gradient Boosting, 5.72 para Ridge y 5.89 para Random Forest. En el conjunto de prueba independiente, Dijkstra obtuvo 8.10 minutos, Gradient Boosting 6.73, Ridge 6.98 y Random Forest 6.68. Los resultados muestran que Dijkstra constituye una línea base sólida, mientras que los modelos supervisados logran menores errores en el conjunto de prueba. Debido al número limitado de viajes, se requiere ampliar la validación antes de establecer la superioridad general de una estrategia.

Palabras clave: tiempo estimado de llegada, teoría de grafos, Dijkstra, aprendizaje automático, GPS.

1. Introducción

La estimación del tiempo de llegada de los vehículos es un aspecto importante en los sistemas de transporte, ya que puede verse afectada por factores como el tránsito, las detenciones durante el

recorrido y las condiciones propias de la operación. En el caso del transporte universitario, esta variabilidad dificulta que los estudiantes conozcan con anticipación el avance del vehículo y el tiempo restante estimado de su recorrido. Por ello, contar con una estimación dinámica puede resultar más útil que depender únicamente de un horario establecido. Los datos obtenidos mediante GPS permiten analizar el comportamiento espacial y temporal de los vehículos, así como reconstruir sus trayectorias [2]. A partir de este tipo de información, diversas investigaciones han abordado la estimación de tiempos de viaje mediante técnicas de aprendizaje automático [3]. En el contexto peruano, Traverso et al. [5] desarrollaron una aplicación móvil basada en aprendizaje automático para predecir el tiempo de llegada de buses en el Corredor Metropolitano de Lima. Por otra parte, los problemas de desplazamiento también pueden modelarse mediante grafos, donde los nodos y las conexiones representan diferentes puntos y tramos de una ruta. En este contexto, el algoritmo de Dijkstra permite determinar caminos de menor costo [1] y continúa siendo utilizado como base en distintos problemas relacionados con planificación de rutas y transporte [4]. En este trabajo se analiza el servicio Cono Norte del transporte universitario de la Universidad Nacional Mayor de San Marcos a partir de datos registrados por un dispositivo GPS instalado en uno de sus vehículos. Se propone una metodología que integra el procesamiento de datos GPS, map matching, grafos dirigidos y ponderados, el algoritmo de Dijkstra y modelos de aprendizaje automático para estimar el tiempo restante de recorrido. Finalmente, estos componentes se incorporan en un prototipo de aplicativo móvil conectado a un backend, desde el cual el usuario puede consultar la ubicación del vehículo y una estimación de su tiempo de llegada.

2. Contribución Principal

Los principales aportes del trabajo son:

- Procesamiento de datos GPS y aplicación de *map matching* para ubicar el vehículo dentro del trayecto.
- Construcción de grafos dirigidos y ponderados con pesos temporales obtenidos a partir de viajes históricos.
- Estimación del tiempo restante hasta el destino mediante el algoritmo de Dijkstra [1].
- Evaluación de Ridge [6], Random Forest [7] y Gradient Boosting [8] mediante un esquema de corrección residual del ETA.
- Integración de la metodología propuesta en un prototipo de aplicativo móvil desarrollado en Flutter, con comunicación al backend mediante una API REST.

La estimación base se expresa como

$$\text{ETA}_{\text{base}} = (1 - \alpha)w_{e_{\text{actual}}} + \sum_{e \in P^*} w_e, \quad (8.1)$$

donde α representa la fracción recorrida de la arista actual, $w_{e_{\text{actual}}}$ su tiempo mediano y P^* el camino de menor costo temporal obtenido mediante Dijkstra hasta el destino.

Para la evaluación de los modelos de aprendizaje automático se define el residuo

$$r = \text{ETA}_{\text{real}} - \text{ETA}_{\text{base}}, \quad (8.2)$$

y la estimación corregida se obtiene mediante

$$\text{ETA}_{\text{ML}} = \text{máx}(0, \text{ETA}_{\text{base}} + \hat{r}), \quad (8.3)$$

donde $\hat{r}$ representa la corrección residual estimada por el modelo.

Como variables de entrada se utilizaron características temporales, espaciales y operativas derivadas de los registros GPS y de la representación de la ruta mediante grafos. Entre ellas se consideraron la posición del vehículo dentro del recorrido, la distancia de la observación GPS respecto a la trayectoria de referencia y el ETA base obtenido mediante el algoritmo de Dijkstra.

En el corte experimental actual se analizaron 973 observaciones de estimación correspondientes a 48 viajes completos. La separación de los datos se realizó por viajes completos para evitar fuga de información entre entrenamiento y evaluación.

Cuadro 8.1: Resultados obtenidos en la validación cruzada y en el conjunto de prueba independiente.

Método	MAE CV	MAE Test
Dijkstra	5.52	8.10
Ridge	5.72	6.98
Random Forest	5.89	6.68
Gradient Boosting	5.63	6.73

Dado que la adquisición de datos GPS continúa y el conjunto de datos definitivo aún no ha sido consolidado, los resultados presentados corresponden al corte experimental actual y no constituyen la evaluación final del sistema.

Los resultados evidencian diferencias en el desempeño entre la validación cruzada y el conjunto de prueba independiente. Debido al número limitado de viajes independientes, estos resultados se interpretan con cautela y no permiten establecer todavía la superioridad general de un único método.

3. Conclusiones

La integración de datos GPS, *map matching* y teoría de grafos permitió desarrollar una metodología interpretable para estimar el tiempo restante del transporte universitario hasta su destino. La representación mediante grafos dirigidos y ponderados incorpora información histórica de los tiempos de viaje, mientras que Dijkstra proporciona una estimación base a partir de los costos temporales asociados a las aristas.

En la validación cruzada agrupada por viajes, Dijkstra obtuvo el menor MAE entre los métodos evaluados. Sin embargo, en el conjunto de prueba independiente los modelos supervisados alcanzaron menores valores de MAE. Esta diferencia evidencia variabilidad entre ambos esquemas de evaluación y, considerando el número limitado de viajes disponibles, no permite establecer todavía la superioridad general de una única estrategia.

La metodología desarrollada se integra en un prototipo de aplicativo móvil para la consulta de la ubicación del vehículo y del tiempo estimado de llegada.

Estos resultados corresponden a un corte experimental aún en desarrollo. Como trabajo futuro se plantea consolidar el conjunto de datos, ampliar el número de viajes, realizar la evaluación final y estudiar la extensión de la metodología a otros servicios del transporte universitario de la UNMSM.

Trabajo conjunto con

Dr. Erik Papa Quiroz, Universidad Nacional Mayor de San Marcos.

Bibliografía

- [1] E. W. Dijkstra, “A note on two problems in connexion with graphs,” *Numerische Mathematik*, vol. 1, pp. 269–271, 1959. doi: 10.1007/BF01386390.
- [2] Y. Huang, A. Abdelhalim, A. Stewart, J. Zhao, and H. Koutsopoulos, “Reconstructing transit vehicle trajectory using high-resolution GPS data,” in *2023 IEEE 26th International Conference on Intelligent Transportation Systems (ITSC)*, pp. 5247–5253, 2023. doi: 10.1109/ITSC57777.2023.10422524.
- [3] R. Jiang, D. Hu, S. I.-J. Chien, Q. Sun, and X. Wu, “Predicting bus travel time with hybrid incomplete data – a deep learning approach,” *PROMET – Traffic & Transportation*, vol. 34, no. 5, pp. 673–685, 2022. doi: 10.7307/ptt.v34i5.4052.
- [4] J. Guo, T. Liu, G. Song, and B. Guo, “Solving the robust shortest path problem with multimodal transportation,” *Mathematics*, vol. 12, no. 19, Art. no. 2978, 2024. doi: 10.3390/math12192978.

- [5] D. Traverso, G. Pacheco, S. Wong-Durand, P. Castaneda, and A. Onate-Andino, “Metropolitano Plus: A machine learning-based mobile application for predicting bus arrival times in the Corredor Metropolitano of Lima,” *Engineering, Technology & Applied Science Research*, vol. 16, no. 2, pp. 33084–33095, 2026. doi: 10.48084/etasr.14855.
- [6] A. E. Hoerl and R. W. Kennard, “Ridge regression: Biased estimation for nonorthogonal problems,” *Technometrics*, vol. 12, no. 1, pp. 55–67, 1970. doi: 10.1080/00401706.1970.10488634.
- [7] L. Breiman, “Random forests,” *Machine Learning*, vol. 45, no. 1, pp. 5–32, 2001. doi: 10.1023/A:1010933404324.
- [8] J. H. Friedman, “Greedy function approximation: A gradient boosting machine,” *The Annals of Statistics*, vol. 29, no. 5, pp. 1189–1232, 2001. doi: 10.1214/aos/1013203451.

Modelo Subrogado de Función de Transferencia Basado en Datos y XGBoost para la Estimación de la Presión Cerebral

José Alexis Delgado Pérez

Universidad Nacional Mayor de San Marcos, Lima, Perú

jose.delgado23@unmsm.edu.pe

Resumen. Este trabajo aborda el problema de la estimación no invasiva de la presión cerebral a partir de mediciones en la arteria radial. Se propone un enfoque computacional basado en Extreme Gradient Boosting (XGBoost), alimentado por una extensa base de datos hemodinámicos *in silico*. Estos datos provienen de simulaciones numéricas de la propagación de ondas de pulso en redes arteriales. Para optimizar el entrenamiento del modelo, la información morfológica de las ondas temporales se extrae utilizando la Transformada Rápida de Fourier, reduciendo la señal a un conjunto compacto de coeficientes armónicos. Las principales contribuciones incluyen el diseño de este preprocesamiento para evitar la redundancia de datos temporales y la formulación del algoritmo para mapear los coeficientes periféricos hacia los cerebrales. La evaluación numérica del modelo demuestra que esta combinación genera una función de transferencia computacionalmente ligera, validando la capacidad del algoritmo para predecir la morfología de la presión intracraneal de forma rápida, robusta y con un error de reconstrucción mínimo respecto a la simulación original.

Palabras clave: datos *in silico*, hemodinámica computacional, XGBoost, series de Fourier, extracción de características.

Introducción

La propagación de la onda de presión arterial a lo largo del sistema cardiovascular puede ser modelada numéricamente resolviendo las ecuaciones unidimensionales (1D) de Navier–Stokes. Estas simulaciones computacionales permiten generar grandes cohortes de pacientes virtuales, obteniendo datos *in silico* que detallan la dinámica de fluidos tanto en la arteria radial como en el cerebro.

El presente trabajo utiliza estos datos simulados para entrenar un modelo de *machine learning* capaz de estimar la presión intracraneal, utilizando técnicas de optimización en la extracción de características y en el aprendizaje predictivo para superar el alto costo computacional de las simulaciones dinámicas tradicionales en la práctica clínica.

Contribución Principal

En esta sección se resumen los principales aportes en el procesamiento y modelamiento de los datos:

- **Extracción óptima de características:** La información de la onda se condensa calculando los coeficientes de Fourier (a_k, b_k) , actuando como un filtro que evita la redundancia temporal de los datos.
- **Mapecto mediante Machine Learning:** Se emplea XGBoost para aprender la función de transferencia anatómica, tomando los coeficientes radiales como variables predictoras para estimar la onda cerebral.
- **Optimización numérica del modelo:** El entrenamiento resuelve iterativamente un problema de minimización donde la función objetivo regularizada se aproxima mediante una expansión de Taylor de segundo orden:

$$\mathcal{L}^{(t)} \approx \sum_{i=1}^n \left[l\left(y_i, \hat{y}_i^{(t-1)}\right) + g_i f_t(x_i) + \frac{1}{2} h_i f_t^2(x_i) \right] + \Omega(f_t), \quad (8.4)$$

donde g_i y h_i son el gradiente y hessiano que guían la dirección de la optimización del árbol f_t , permitiendo calcular analíticamente el peso óptimo de cada nodo terminal.

Conclusiones

El uso combinado de simulaciones *in silico*, extracción de características mediante series de Fourier y el algoritmo XGBoost resulta en una estrategia altamente eficiente. El principal beneficio de este enfoque es que permite procesar grandes volúmenes de datos hemodinámicos eludiendo la alta correlación entre mediciones consecutivas, generando un modelo predictivo robusto que aproxima la morfología de la presión cerebral con un costo computacional mínimo durante la inferencia.

Trabajo conjunto con

Luis Alonso Mansilla Alvarez, Laboratorio Nacional de Computación Científica (LNCC), alonso.m.alvarez@gmail.com.
 José Raúl Luyo Sánchez, Departamento de Matemática, Universidad Nacional Mayor de San Marcos, jluyos@unmsm.edu.pe.

Bibliografía

- [1] S. Watanabe, *Adan: an anatomically detailed arterial network model for computational hemodynamics*. PhD thesis (in Portuguese), Petrópolis, Brazil, 2013.
- [2] L. A. Mansilla Alvarez, D. de Oliveira Mussolin, G. Cunha-Lima, S. Garzon, L. O. Müller, P. A. Lemos, and P. J. Blanco, “Towards personalization of 1D blood flow models: sensitivity analysis and parameter calibration,” *Biomechanics and Modeling in Mechanobiology*, vol. 25, p. 67, 2026.
- [3] T. Chen and C. Guestrin, “XGBoost: A Scalable Tree Boosting System,” *Proceedings of the 22nd ACM SIGKDD International Conference*, pp. 785–794, 2016.
- [4] I. A. Qader, F. Al-Omari, S. A. Mustafa, M. Mirrahimova, N. Mishra, and P. V. Parvathy, “XGBoost with Time Series Embeddings for Stock Price Movement Prediction,” *2025 International Conference on Electrical Engineering and Informatics (ICEEI)*, 2025.

8.2. Comunicaciones

Modelo Computacional Basado en CPSVM-L1: Para la Estratificación del Riesgo de Cáncer de Próstata en los Centros de Salud del Perú

Lenin Froy Arce Huamán

Universidad Nacional Mayor de San Marcos, Lima, Perú

larceh@unmsm.edu.pe

Resumen.

El presente estudio propone un modelo computacional CPSVM-L1 (Máquina de Vectores de Soporte con Probabilidad Condicional y Regularización L1) para la estratificación probabilística del riesgo de cáncer de próstata, abordando las limitaciones del Antígeno Prostático Específico (PSA) como indicador aislado. Mediante la incorporación de una penalización L1 a la formulación primal de CPSVM, se logra un modelo parsimonioso e interpretable con selección automática de variables, transformable en un problema de programación lineal. El estudio integra variables demográficas, clínicas y de laboratorio de pacientes atendidos en centros de salud del Perú, siendo evaluado mediante precisión, sensibilidad, especificidad, exactitud balanceada, AUC-ROC, análisis de calibración y curvas de decisión clínica, con comparación del desempeño frente al PSA convencional y modelos CPSVM-L2. Este enfoque multivariable contribuye a la reducción de dimensionalidad y proporciona estimaciones probabilísticas calibradas que apoyan la toma de decisiones clínicas en la detección temprana del cáncer de próstata.

Palabras clave: Cáncer de próstata; aprendizaje automático; máquina de vectores de soporte; CPSVM; regularización L1; estratificación de riesgo; PSA; diagnóstico asistido por computadora; calibración probabilística.

1. Introducción

El cáncer de próstata constituye un importante problema de salud en la población masculina. El antígeno prostático específico (PSA) es una herramienta ampliamente utilizada para su evaluación; sin embargo, su interpretación aislada presenta limitaciones debido a que sus niveles pueden alterarse por diversas condiciones prostáticas [1], [2]. En este contexto, los métodos de aprendizaje automático permiten integrar variables demográficas, clínicas y de laboratorio para mejorar la estratificación del riesgo. Las máquinas de vectores de soporte (SVM) han demostrado utilidad en problemas de clasificación, mientras que la regularización L1 permite seleccionar variables y reducir la complejidad de los modelos [3], [4], [5]. A partir de estas consideraciones, esta investigación propone el modelo CPSVM-L1, basado en una formulación primal de una Máquina de Vectores de Soporte con Probabilidad Condicional – CPSVM-L2 [6], [7] e incorporando regularización L1. La propuesta busca integrar información clínica y de laboratorio para generar una estimación probabilística del riesgo de cáncer de próstata. El desempeño del modelo se evaluará mediante métricas de discriminación, clasificación y calibración, considerando su potencial como herramienta de apoyo a la evaluación clínica en centros de salud del Perú.

2. Contribución principal

Se propone el modelo CPSVM-L1 (ver ecuaciones (8.5)-(8.8)), que incorpora regularización ℓ_1 en una Máquina de Vectores de Soporte con Probabilidad Condicional para la estratificación probabilística del riesgo de cáncer de próstata. El aporte integra: (1) una formulación matemática novedosa transformable a programación lineal, (2) selección automática de variables mediante regularización ℓ_1 para obtener un modelo parsimonioso e interpretable, y (3) una evaluación integral comparando CPSVM-L1 frente al PSA convencional y CPSVM-L2. Esta metodología computacional complementa la evaluación clínica al integrar información clínica y de laboratorio en la estratificación de riesgo en servicios de salud del Perú.

El modelo CPSVM-L1 se formula como

$$\min_{\mathbf{w}, b, \xi} \quad \|\mathbf{w}\|_1 + \frac{C_1}{\varepsilon} \sum_{i=1}^m \xi_i - C_2 \sum_{i=1}^m y_i (\mathbf{w}^T \mathbf{x}_i + b) \quad (8.5)$$

$$\text{s.a.} \quad y_i (\mathbf{w}^T \mathbf{x}_i + b - 0.5) \geq 0.5\varepsilon - \xi_i, \quad i = 1, \dots, m, \quad (8.6)$$

$$\xi_i \geq 0, \quad i = 1, \dots, m, \quad (8.7)$$

$$0 \leq \mathbf{w}^T \mathbf{x}_i + b \leq 1, \quad i = 1, \dots, m. \quad (8.8)$$

3. Conclusiones

El modelo CPSVM-L1 establece una metodología computacional para estratificación probabilística del riesgo de cáncer de próstata mediante regularización ℓ_1 , que favorece parsimonia y selección automática de variables. La evaluación integral de discriminación, calibración y utilidad clínica, comparada con PSA y CPSVM-L2, valida su desempeño como herramienta complementaria a la evaluación médica en servicios de salud del Perú.

Trabajo conjunto con

Miguel Ángel Cano Lengua, Universidad Nacional Mayor de San Marcos, Lima, Perú. E-mail: mcanol@unmsm.edu.pe

Bibliografía

- [1] MINSA, “Cáncer de próstata: diagnóstico oportuno puede marcar la diferencia entre controlar o curar la enfermedad – Noticias – Instituto Nacional de Enfermedades Neoplásicas – Plataforma del Estado Peruano.” Accessed: Sep. 15, 2026. [Online]. Available: <https://www.gob.pe/institucion/inen/noticias/1404991-cancer-de-prostata-diagnostico-oportuno-puede-marcar-la-diferencia-entre-controlar-o-c>
- [2] P. Cornford et al., “EAU-EANM-ESTRO-ESUR-SIOG Guidelines on Prostate Cancer—2024 Update. Part I: Screening, Diagnosis, and Local Treatment with Curative Intent,” *European Urology*, vol. 86, no. 2, pp. 148–163, Aug. 2024. doi: 10.1016/J.EURURO.2024.03.027.
- [3] Uroweb, “Diagnostic Evaluation – EAU Guidelines on Prostate Cancer – Uroweb.” Accessed: Sep. 15, 2026. [Online]. Available: <https://uroweb.org/guidelines/prostate-cancer/chapter/diagnostic-evaluation>
- [4] C. C. Chang and C. J. Lin, “LIBSVM: A library for support vector machines,” *ACM Transactions on Intelligent Systems and Technology*, vol. 2, no. 3, Apr. 2011. doi: 10.1145/1961189.1961199.
- [5] B. E. Boser, I. M. Guyon, and V. N. Vapnik, “A training algorithm for optimal margin classifiers,” in *Proceedings of the Fifth Annual Workshop on Computational Learning Theory*, Pittsburgh, PA, USA: ACM, Jul. 1992, pp. 144–152. doi: 10.1145/130385.130401.
- [6] Y. H. Shao, X. J. Lv, L. W. Huang, and L. Bai, “Twin SVM for conditional probability estimation in binary and multiclass classification,” *Pattern Recognition*, vol. 136, Art. no. 109253, 2023. doi: 10.1016/j.patcog.2022.109253.

- [7] M. Carrasco, B. Ivorra, J. López, D. Morote, and A. M. Ramos, “A study of PSVM and CPSVM models: analysis, correction, and application in operations research,” *Annals of Operations Research*, pp. 1–30, Oct. 2025. doi: 10.1007/S10479-025-06880-6.

OPTIMACO-SVM: Una plataforma integral para el despliegue operativo de múltiples familias de máquinas de vectores de soporte

Cesar Chahuas Rebatta

Universidad Peruana de Ciencias Aplicadas, Lima, Perú

`cesar.chahuasrebatta@gmail.com`

Resumen.

La conversión de algoritmos de clasificación basados en optimización convexa a la toma de decisiones en tiempo real es una cuestión crítica, que a veces se pasa por alto en la literatura de investigación. En este artículo presentamos OPTIMACO-SVM, un software que agrupa cinco familias de máquinas de vectores de soporte —Soft-Margin, Twin SVM (TWSVM), Improved Twin SVM (ITWSVM), Nonparallel SVM (NPSVM) y las formulaciones multiclase nativas de Weston-Watkins y Crammer-Singer— en una plataforma funcional de extremo a extremo. Los algoritmos fueron originalmente diseñados en matlab y reimplementados en python, utilizando programación convexa disciplinada (cvxpy), y luego empaquetados bajo una interfaz de servicios unificada. La arquitectura utiliza un motor de inferencia montado sobre FastAPI, una UI construida en Angular, y un modelo de implementación con Docker como base. El proceso es automático el manejo de la ingesta de datos heterogéneos, preprocesamiento, ejecución de modelos y almacenamiento de métricas con trazabilidad. A nivel de trabajo se reportan los resultados previos sobre un problema de clasificación de biomasa marina y además otros datasets de uso común en competencias kaggle, en los cuales la plataforma posibilita la comparación del desempeño de las diferentes formulaciones en un mismo esquema de evaluación.

Palabras clave: máquinas de vectores de soporte, optimización convexa, model serving, programación cuadrática.

1. Introducción

Las máquinas de vectores de soporte (SVM) constituyen uno de los pilares de la teoría del aprendizaje estadístico. Desde la formulación clásica de margen suave propuesta por Cortes y Vapnik [6], la literatura ha producido numerosas extensiones que modifican la estructura del problema de optimización para mejorar el rendimiento o reducir el costo computacional. Entre estas extensiones destacan el Twin SVM (TWSVM) de Jayadeva et al. [1], que reemplaza el problema cuadrático único por dos problemas de menor tamaño; el Improved Twin SVM (ITWSVM) de Tian et al. [2], que introduce términos de regularización adicionales para estabilizar la solución; y el Nonparallel SVM (NPSVM) del mismo grupo de investigación [3], que emplea pérdida ε -insensible para construir hiperplanos no paralelos con mayor robustez ante ruido. Paralelamente, Weston y Watkins [4] y Crammer y Singer [5] propusieron formulaciones multiclase que evitan la descomposición en problemas binarios.

Una dificultad persistente es que estas formulaciones, a pesar de su sofisticación teórica, raramente trascienden el ámbito de los scripts de investigación o los notebooks de experimentación. Los profesionales de dominio —en nuestro caso, oceanógrafos y biólogos pesqueros— requieren herramientas

que les permitan aplicar estos clasificadores sin necesidad de comprender los detalles de la optimización primal-dual ni de manipular código directamente. Esta brecha entre el desarrollo algorítmico y su uso operativo es particularmente evidente en el sector pesquero peruano y otros sectores, procesa grandes volúmenes de datos acústicos y oceanográficos para la estimación de biomasa. El presente trabajo describe el diseño y la implementación de OPTIMACO-SVM, una plataforma que busca cerrar esta brecha. Nuestro objetivo no es proponer un nuevo algoritmo de optimización, sino construir una infraestructura que permita a los investigadores de optimización numérica ver sus formulaciones en funcionamiento dentro de un sistema productivo, y al mismo tiempo ofrecer a los usuarios de dominio una herramienta accesible para la clasificación de datos reales.

Las contribuciones principales de este trabajo son las siguientes:

1. Una abstracción de servicio que unifica cinco familias SVM distintas bajo una misma interfaz, permitiendo cambiar de formulación sin alterar el flujo de trabajo del usuario.
2. Un pipeline completo de procesamiento de datos que incluye ingesta, limpieza, ingeniería de características, partición estratificada y estandarización, garantizando que todas las formulaciones se evalúen sobre condiciones idénticas.
3. Un sistema de trazabilidad que registra cada ejecución junto con sus hiperparámetros, métricas y matrices de confusión, facilitando la reproducibilidad experimental.

2. Conclusiones y trabajo futuro

En este trabajo hemos presentado OPTIMACO-SVM, una plataforma que integra cinco familias de máquinas de vectores de soporte en un sistema funcional de extremo a extremo. La principal motivación ha sido reducir la distancia que separa las formulaciones de optimización convexa desarrolladas en entornos académicos de las herramientas que los profesionales de dominio pueden utilizar en la práctica.

La arquitectura propuesta demuestra que es posible encapsular la complejidad de solvers primal-dual, programación cuadrática y programación de segundo orden bajo una interfaz unificada sin sacrificar la capacidad de comparación entre formulaciones. El pipeline de preprocesamiento garantiza condiciones experimentales idénticas para todos los modelos, y el sistema de trazabilidad permite auditar cada ejecución de principio a fin.

Como trabajo futuro se contemplan las siguientes líneas:

1. Incorporar una cola de tareas asincrónica (Celery con Redis) para ejecutar los modelos de mayor costo computacional sin bloquear las peticiones del usuario.
2. Exponer los solvers personalizados como servicios independientes con interfaz gRPC, de modo que el frontend pueda invocar las implementaciones de investigación directamente cuando se requiera.
3. Integrar un módulo de optimización de hiperparámetros mediante búsqueda Bayesiana (Optuna), registrando automáticamente los resultados en la base de datos de ejecuciones.
4. Extender el pipeline para soportar múltiples datasets oceanográficos con alineamiento automático de esquemas y validación cruzada entre levantamientos.

Trabajo conjunto con

Miguel Ángel Cano Lengua, Universidad Nacional Mayor de San Marcos, Lima, Perú.
Correo: mcanol@unmsm.edu.pe.

Bibliografía

- [1] Jayadeva, R. Khemchandani, and S. Chandra, "Twin support vector machines for pattern classification," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 29, no. 5, pp. 905–910, 2007.
- [2] Y. J. Tian, X. C. Ju, Z. Q. Qi, and Y. Shi, "Improved twin support vector machine," *Science China Mathematics*, vol. 57, no. 2, pp. 417–432, 2014.

- [3] Y. J. Tian, Z. Qi, X. Ju, Y. Shi, and X. Liu, “Nonparallel support vector machines for pattern classification,” *IEEE Transactions on Cybernetics*, vol. 44, no. 7, pp. 1067–1079, 2014.
- [4] J. Weston and C. Watkins, “Support vector machines for multi-class pattern recognition,” in *Proceedings of the 7th European Symposium on Artificial Neural Networks (ESANN)*, pp. 219–224, Bruges, Belgium, 1999.
- [5] K. Crammer and Y. Singer, “On the algorithmic implementation of multiclass kernel-based vector machines,” *Journal of Machine Learning Research*, vol. 2, pp. 265–292, 2001.
- [6] C. Cortes and V. Vapnik, “Support-vector networks,” *Machine Learning*, vol. 20, no. 3, pp. 273–297, 1995.
- [7] Y. H. Shao, C. H. Zhang, X. B. Wang, and N. Y. Deng, “Improvements on twin support vector machines,” *IEEE Transactions on Neural Networks*, vol. 22, no. 6, pp. 962–968, 2011.
- [8] S. Boyd and L. Vandenberghe, *Convex Optimization*. Cambridge, UK: Cambridge University Press, 2004.
- [9] F. Pedregosa et al., “Scikit-learn: Machine learning in Python,” *Journal of Machine Learning Research*, vol. 12, pp. 2825–2830, 2011.
- [10] S. Diamond and S. Boyd, “CVXPY: A Python-embedded modeling language for convex optimization,” *Journal of Machine Learning Research*, vol. 17, no. 1, pp. 2909–2913, 2016.
- [11] D. Sculley et al., “Machine learning: The high interest credit card of technical debt,” in *SE4ML Workshop, NIPS*, Montreal, Canada, 2014.

Esquema de adquisición comprimida esteganográfica basado en matrices de medición caóticas multiescala para imágenes digitales con resistencia a reconstrucción inversa

Boris Chullo-Llave

Universidad Nacional Mayor de San Marcos, Lima, Perú

boris.chullo@unmsm.edu.pe

Resumen.

Este trabajo propone un esquema de adquisición comprimida esteganográfica para imágenes digitales, basado en Compressive Sensing (CS), representación multiescala mediante wavelets y matrices de medición controladas por dinámicas caóticas. La propuesta busca integrar reducción de datos y ocultamiento de información dentro del propio proceso de adquisición comprimida. La imagen se descompone en subbandas wavelet y el mensaje secreto se inserta en las mediciones comprimidas asociadas a las subbandas de detalle, evitando modificar directamente la imagen original. La reconstrucción se formula mediante optimización dispersa, mientras que la recuperación del mensaje depende de la estructura multiescala y de las claves caóticas empleadas. La evaluación considerará calidad de reconstrucción, capacidad de ocultamiento, tasa de error de bits, sensibilidad a claves incorrectas, resistencia frente a reconstrucción inversa y costo computacional.

Palabras clave: Compressive Sensing, mapas caóticos, wavelets, esteganografía, matrices de medición.

1. Introducción

Compressive Sensing (CS) permite adquirir señales dispersas o compresibles mediante un número reducido de mediciones y reconstruirlas posteriormente mediante técnicas de optimización [1, 2]. En imágenes digitales, esta propiedad resulta atractiva cuando se requiere reducir información transmitida y, simultáneamente, incorporar mecanismos de seguridad. Diversos trabajos han empleado sistemas caóticos en la construcción de matrices de medición o en procesos de cifrado asociados a CS. Wang et al. combinaron una base DWT caótica con una matriz de medición DCT caótica [4], mientras que Yang et al. propusieron una matriz Bernoulli caótica para Block Compressive Sensing [5]. Asimismo, la representación wavelet permite separar la información de aproximación y detalle, favoreciendo un tratamiento diferenciado de las subbandas [3]. En esta línea, existen trabajos de esteganografía basados en CS que insertan información en mediciones lineales [6]; sin embargo, permanece abierta la integración explícita de matrices caóticas multiescala, subbandas wavelet y ocultamiento en mediciones comprimidas.

2. Contribución Principal

La propuesta plantea una matriz de medición binaria dispersa multiescala, controlada mediante secuencias caóticas, para obtener mediciones independientes por subbanda wavelet. Para $b \in \{LL, LH, HL, HH\}$, la adquisición se expresa como

$$\mathbf{y}_b = \Phi_b \mathbf{x}_b. \quad (8.9)$$

El mensaje secreto se incorpora únicamente en las mediciones de detalle:

$$\mathbf{y}'_b = \mathbf{y}_b + \alpha_b E_b(\mathbf{m}, \mathbf{k}), \quad b \in \{LH, HL, HH\}, \quad (8.10)$$

donde $E_b(\cdot)$ representa el operador de inserción controlado por la clave caótica $\mathbf{k}$.

La recuperación de la imagen se aborda mediante optimización dispersa, mientras que la recuperación del mensaje utiliza la estructura de inserción y las claves correspondientes. El esquema será evaluado mediante PSNR, SSIM y MSE para reconstrucción; BER y capacidad para recuperación del mensaje; y pruebas con claves o matrices incorrectas para analizar resistencia frente a reconstrucción inversa.

3. Conclusiones

El trabajo propone integrar adquisición comprimida, representación multiescala, caos y esteganografía en un único esquema. Su característica principal es que la información oculta se inserta directamente en las mediciones comprimidas de las subbandas de detalle, manteniendo separada la imagen original del proceso de ocultamiento. La validación experimental permitirá determinar el equilibrio entre reducción de datos, calidad de reconstrucción, recuperación del mensaje y resistencia frente a reconstrucciones no autorizadas.

Trabajo conjunto con

Dr. Miguel Ángel Cano Lengua, Universidad Nacional Mayor de San Marcos.

Bibliografía

- [1] D. L. Donoho, "Compressed sensing," *IEEE Transactions on Information Theory*, vol. 52, no. 4, pp. 1289–1306, 2006.
- [2] E. J. Candès, J. Romberg, and T. Tao, "Robust uncertainty principles: Exact signal reconstruction from highly incomplete frequency information," *IEEE Transactions on Information Theory*, vol. 52, no. 2, pp. 489–509, 2006.
- [3] S. G. Mallat, "A theory for multiresolution signal decomposition: The wavelet representation," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 11, no. 7, pp. 674–693, 1989.

- [4] Z. Wang, Z. S. Hussein, and X. Wang, “Secure compressive sensing of images based on combined chaotic DWT sparse basis and chaotic DCT measurement matrix,” *Optics and Lasers in Engineering*, vol. 134, Art. no. 106246, 2020.
- [5] C. Yang, P. Pan, and Q. Ding, “Image encryption scheme based on mixed chaotic Bernoulli measurement matrix block compressive sensing,” *Entropy*, vol. 24, no. 2, Art. no. 273, 2022.
- [6] R. Agrawal and K. Ahuja, “CSIS: Compressed sensing-based enhanced-embedding capacity image steganography scheme,” *IET Image Processing*, vol. 15, no. 9, pp. 1909–1925, 2021.

Análisis estructural de formulaciones de optimización y descomposición combinatoria–geométrica del Problema del Árbol Euclidiano de Steiner en $\mathbb{R}^d$

Carlos Robinson Cruz Cabrera

Universidad Nacional Mayor de San Marcos, Lima, Perú

carlos.cruzc@unmsm.edu.pe

Resumen.

Este trabajo presenta los resultados iniciales de mi tesis de maestría sobre el Problema del Árbol Euclidiano de Steiner (ESTP) en $\mathbb{R}^d$. En primer lugar, se desarrolla un análisis matemático comparativo de las formulaciones MMX, FM, POM, OM1, OM2 y OM3, considerando su estructura de variables, convexidad, suavidad, representación de las distancias euclidianas y calidad esperada de sus relajaciones continuas. MMX reproduce de forma directa la estructura del problema, pero es no convexo y no suave; FM conduce a una relajación cónica de segundo orden convexa, aunque conserva no suavidad; POM combina convexidad con una reformulación suave equivalente a restricciones de segundo orden; y OM1–OM3 introducen linealizaciones alternativas que pueden debilitar las cotas inferiores. En segundo lugar, se identifica la estructura combinatoria y geométrica del ESTP: la selección de aristas, conectividad, grados, eliminación de subtours y simetrías conforman la componente combinatoria, mientras que la localización de los puntos de Steiner y las longitudes euclidianas constituyen la componente geométrica continua. El acoplamiento entre ambas componentes aparece como la principal fuente de dificultad. Estos resultados sugieren conservar las restricciones cónicas y de simetría, y priorizar las restricciones de acoplamiento binario–continuo como candidatas para una futura relajación lagrangiana.

Palabras clave: árbol euclidiano de Steiner; optimización cónica; relajación continua; estructura combinatoria; optimización geométrica.

Resumen.

This work presents the initial results of my masters thesis on the Euclidean Steiner Tree Problem (ESTP) in $\mathbb{R}^d$. First, a comparative mathematical analysis of the MMX, FM, POM, OM1, OM2, and OM3 formulations is developed, considering their variable structure, convexity, smoothness, representation of Euclidean distances, and expected quality of their continuous relaxations. MMX directly represents the structure of the problem, but it is nonconvex and nonsmooth; FM yields a convex second-order cone relaxation, although nonsmoothness remains; POM combines convexity with a smooth reformulation equivalent to second-order cone constraints; and OM1–OM3 introduce alternative linearizations that may weaken lower bounds. Second, the combinatorial and geometric structure of the ESTP is identified: edge selection, connectivity, degree constraints, subtour elimination, and symmetry handling form the combinatorial component, whereas the location of Steiner points and

Euclidean edge lengths constitute the continuous geometric component. The coupling between both components emerges as the main source of difficulty. These results suggest preserving conic and symmetry constraints and prioritizing binary–continuous coupling constraints as candidates for a future Lagrangian relaxation.

Keywords: Euclidean Steiner tree; conic optimization; continuous relaxation; combinatorial structure; geometric optimization.

Bibliografía

- [1] N. Maculan, M. Fampa, H. Ouzia, and R. Pinto, “Mathematical optimization models for the Euclidean Steiner tree problem in $\mathbb{R}^d$,” *4OR*, vol. 23, pp. 353–382, 2025. doi: 10.1007/s10288-025-00604-z.
- [2] N. Maculan, P. Michelon, and A. E. Xavier, “The Euclidean Steiner tree problem in $\mathbb{R}^n$: A mathematical programming formulation,” *Annals of Operations Research*, vol. 96, pp. 209–220, 2000. doi: 10.1023/A:1018903619285.
- [3] M. Fampa and N. Maculan, “A new relaxation in conic form for the Euclidean Steiner problem in $\mathbb{R}^n$,” *RAIRO–Operations Research*, vol. 35, no. 4, pp. 383–394, 2001. doi: 10.1051/ro:2001120.
- [4] H. Ouzia and N. Maculan, “Mixed integer nonlinear optimization models for the Euclidean Steiner tree problem in $\mathbb{R}^d$,” *Journal of Global Optimization*, vol. 83, no. 1, pp. 119–136, 2022. doi: 10.1007/s10898-021-01001-6.
- [5] R. V. Pinto, H. Ouzia, and N. Maculan, “A new second-order conic optimization model for the Euclidean Steiner tree problem in $\mathbb{R}^d$,” *International Transactions in Operational Research*, vol. 30, no. 6, pp. 3886–3903, 2023. doi: 10.1111/itor.13265.
- [6] M. R. Garey, R. L. Graham, and D. S. Johnson, “The complexity of computing Steiner minimal trees,” *SIAM Journal on Applied Mathematics*, vol. 32, no. 4, pp. 835–859, 1977. doi: 10.1137/0132072.

Un nuevo modelo de programación cónica de segundo orden para máquinas de vectores de soporte probabilísticas

Franz Richard Reynaga Buitrón

Universidad Nacional Mayor de San Marcos, Lima, Perú

franz.reynaga@unmsm.edu.pe

Resumen.

Este trabajo introduce un nuevo modelo de programación cónica de segundo orden para máquinas de vectores de soporte probabilístico. La principal contribución de la investigación consiste en el planteamiento de una nueva formulación de programación cónica de segundo orden para Máquinas de Vectores de Soporte Probabilísticas (SOCP-PSVM), orientada a incorporar información probabilística y restricciones robustas en un problema de clasificación. Este nuevo modelo se establece a partir de la combinación del modelo PSVM (Probabilistic Support Vector Machine) con restricciones de tipo cónico de segundo orden asociadas a la incertidumbre de los datos. Esta formulación busca mantener la interpretación probabilística del PSVM, expresada mediante la estimación $P(y = 1|x)$, al mismo tiempo que incorpora restricciones que permitan controlar la incertidumbre asociada a las clases. Finalmente, se ha establecido la metodología para la implementación y evaluación numérica del nuevo

modelo, mediante su comparación con modelos de referencia como SVM (Support Vector Machine), PSVM, CPSVM (Conditional Support vector Machine), SOCP-SVM (Second Order Cone Programming - Support Vector Machine) y ξ -SOCP-SVM (SOCP-SVM con variables de holgura). La evaluación considerará tanto el desempeño predictivo como el costo computacional del modelo propuesto.

Palabras clave: Support Vector Machine, KKT, Optimización Matemática, Programación Cónica de Segundo Orden.

Trabajo conjunto con:

Dr. Erik Alex Papa Quiroz y Dr. Julio López Luis

Bibliografía

- [1] C. Cortes and V. Vapnik, "Support-vector networks," *Machine Learning*, pp. 273–297, 1995.
- [2] Jayadeva, R. Khemchandani, and S. Chandra, "Twin support vector machines for pattern classification," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 29, no. 5, pp. 905–910, 2007.
- [3] M. Baldomero-Naranjo, L. I. Martínez-Merino, and A. M. Rodríguez-Chía, "A robust SVM-based approach with feature selection and outliers detection for classification problems," *arXiv*, 2024.
- [4] R. Batuwita and V. Palade, "Fuzzy support vector machines for class imbalance learning," *IEEE Transactions on Fuzzy Systems*, vol. 18, no. 3, pp. 558–571, 2010.
- [5] S. Maldonado and J. López, "Alternative second-order cone programming formulations for support vector classification," *Information Sciences*, pp. 328–341, 2014.
- [6] B. Muslimin, B. Rachmadani, and Rudito, "Support Vector Machine for Classifying Prostate Cancer Data," *Jurnal Sistem Informasi dan Komputer Terapan Indonesia*, pp. 137–146, 2025.
- [7] B. A. Akinnuwesi, K. A. Olayanju, B. S. Aribisala, S. G. Fashoto, E. Mbunge, M. Okpeku, and P. Owate, "Application of support vector machine algorithm for early differential diagnosis of prostate cancer," *Data Science and Management*, pp. 1–12, 2023.
- [8] S. Boyd and L. Vandenberghe, *Convex Optimization*. Cambridge University Press, 2004.
- [9] N. Deng, Y. Tian, and C. Zhang, *Support Vector Machines: Optimization Based Theory, Algorithms, and Extensions*. Chapman and Hall/CRC, Data Mining and Knowledge Discovery Series, 2013.

Selección de variables ℓ_p -SOCP sobre la variedad potencia- p : una variante de la métrica de Shahshahani

Jhon Erick Rios Cortegana

Universidad Nacional Mayor de San Marcos, Lima, Perú

riosjhon226@gmail.com

Resumen. Este trabajo aborda la selección de variables con el modelo ℓ_p -SOCP de Carrasco et al., que, por la singularidad de $|t|^p$ en el origen ($0 < p < 1$), se resuelve sobre una aproximación con un parámetro $\varepsilon > 0$. En lugar de suavizar el objetivo, se introduce la variedad potencia- p , $\mathcal{M}_p = (\mathbb{R}^n, g_p)$, con

$$g_p = \frac{p^2}{4} \sum_i |w_i|^{p-2} dw_i^2,$$

una variante con signo de la métrica de Shahshahani. $\mathcal{M}_p$ es plana y, en su carta $u_i = \text{sgn}(w_i)|w_i|^{p/2}$, la cuasi-norma se transforma en $\|w\|_p^p = \|u\|^2$, el cuadrado de la distancia geodésica al origen: un término cuadrático suave que da una reformulación exacta, sin ε . Las principales contribuciones incluyen, además, un algoritmo sobre estratos totalmente geodésicos de $\mathcal{M}_p$ con garantías para el problema original. Los resultados numéricos en cinco bases de datos muestran que el método iguala la exactitud balanceada de la referencia y selecciona hasta un 17,7 % menos variables en alta dimensión.

Palabras clave: selección de variables, cuasi-norma ℓ_p , programación cónica de segundo orden, variedades Riemannianas, métrica de Shahshahani.

1. Introducción

En la selección de variables para clasificación en alta dimensión, las cuasi-normas ℓ_p con $0 < p < 1$ inducen mayor dispersión [1], a costa de un problema NP-difícil y de que $|t|^p$ no sea localmente Lipschitz en $t = 0$. Las formulaciones de programación cónica de segundo orden (SOCP) dan clasificadores robustos frente a la incertidumbre en los momentos de cada clase [2, 3]. Carrasco et al. [1] integraron ℓ_p en ese marco (modelo ℓ_p -SOCP), obtuvieron cotas inferiores para las componentes no nulas de los minimizadores locales y propusieron un algoritmo de ℓ_1 reponderado (IRL1) [4] que reemplaza $\|\mathbf{w}\|_p^p$ por

$$\sum_i (|w_i| + \varepsilon)^p;$$

sus garantías se refieren al problema aproximado y solo alcanzan el original cuando $\varepsilon \rightarrow 0$. Además, la aproximación sesga la selección: anular $|w_i| = a$ reduce la penalización aproximada en

$$(a + \varepsilon)^p - \varepsilon^p < a^p,$$

hasta $\varepsilon^p \approx 0.32$ menos con $\varepsilon = 10^{-5}$ y $p = 0.1$.

En este trabajo se extiende estos conceptos a variedades Riemannianas y se dota a $\mathbb{R}^n$ de una métrica Riemanniana plana, variante de la de Shahshahani (la métrica de Fisher sobre medidas positivas [5, 6]), en la que $\|\mathbf{w}\|_p^p$ es exactamente el cuadrado de la distancia geodésica al origen.

2. Contribuciones

En esta sección se resumen los principales aportes:

- Formulación de un nuevo modelo: la variedad potencia- p , con $\|\mathbf{u}\|^2$ en lugar de $\|\mathbf{w}\|_p^p$;
- diseño de un algoritmo definido en la variedad;
- resultados numéricos frente al algoritmo de [1] sobre los mismos pliegues.

El modelo ℓ_p -SOCP

Sean $\boldsymbol{\mu}_j \in \mathbb{R}^n$ y $\boldsymbol{\Sigma}_j = \mathbf{S}_j \mathbf{S}_j^\top$ la media y la covarianza de la clase $j \in \{1, 2\}$, y $\kappa_j = \sqrt{\frac{\alpha_j}{1-\alpha_j}}$, con $\alpha_j \in (0, 1)$. El modelo ℓ_p -SOCP [1] es

$$\begin{aligned} \min_{\mathbf{w}, b, \xi} \quad & \|\mathbf{w}\|_p^p + c\xi \\ \text{s.a.} \quad & (-1)^{j+1} (\mathbf{w}^\top \boldsymbol{\mu}_j + b) \geq 1 - \xi + \kappa_j \|\mathbf{S}_j^\top \mathbf{w}\|, \quad j = 1, 2, \\ & \xi \geq 0, \end{aligned} \tag{P}$$

con $c > 0$. Eliminando ξ queda $F(\mathbf{w}, b) = \|\mathbf{w}\|_p^p + cH(\mathbf{w}, b)$, con

$$H(\mathbf{w}, b) = \max\{0, h_1(\mathbf{w}, b), h_2(\mathbf{w}, b)\},$$

convexa, y

$$h_j(\mathbf{w}, b) = 1 - (-1)^{j+1} (\mathbf{w}^\top \boldsymbol{\mu}_j + b) + \kappa_j \|\mathbf{S}_j^\top \mathbf{w}\|.$$

Según [1, Teorema 3.2], toda componente no nula de un minimizador local cumple

$$|w_i| \geq L_i := \left(\frac{2p}{cD_i} \right)^{\frac{1}{1-p}},$$

con

$$D_i = |\mu_1^i - \mu_2^i| + \kappa_1 \|\mathbf{S}_1^\top \mathbf{e}_i\| + \kappa_2 \|\mathbf{S}_2^\top \mathbf{e}_i\|.$$

La variedad potencia- p : una variante de la métrica de Shahshahani

Sea $q = \frac{2}{p} > 2$ y $\Psi_p : \mathbb{R}^n \rightarrow \mathbb{R}^n$, $\Psi_p(\mathbf{u})_i = \text{sgn}(u_i)|u_i|^q$, un homeomorfismo de clase C^2 con inversa

$$u_i = \text{sgn}(w_i)|w_i|^{p/2}$$

y Jacobiano

$$J(\mathbf{u}) = \text{diag}(q|u_i|^{q-1}),$$

singular solo donde algún $u_i = 0$: allí vive la singularidad de ℓ_p .

Definición 1 (Variedad potencia- p). $\mathcal{M}_p$ es $\mathbb{R}^n$ con la estructura diferenciable en la que Ψ_p^{-1} es una carta global y con la métrica $g_p = (\Psi_p^{-1})^* \bar{g}$, donde $\bar{g}$ es la euclídea. Llamamos *carta plana* a $\mathbf{u} = \Psi_p^{-1}(\mathbf{w})$ y *estratos* a los conjuntos

$$\Sigma_I = \{\mathbf{w} : w_i = 0, i \in I\}.$$

Proposición 1 (Geometría de $\mathcal{M}_p$).

(i) Ψ_p es una isometría de $(\mathbb{R}^n, \bar{g})$ en $(\mathcal{M}_p, g_p)$; $\mathcal{M}_p$ es completa y plana.

(ii) Donde todo $w_i \neq 0$,

$$g_p = \frac{p^2}{4} \sum_i |w_i|^{p-2} dw_i^2.$$

(iii) Las geodésicas son

$$t \mapsto \Psi_p((1-t)\mathbf{u} + t\mathbf{u}')$$

y

$$d_p(\mathbf{w}, \mathbf{w}') = \|\mathbf{u} - \mathbf{u}'\|.$$

En particular,

$$d_p(0, \mathbf{w})^2 = \|\mathbf{w}\|_p^p = \|\mathbf{u}\|^2.$$

(iv) Cada estrato es cerrado y totalmente geodésico, y

$$\text{dist}_{d_p}(\mathbf{w}, \Sigma_{\{i\}}) = |w_i|^{p/2}.$$

Relación con la métrica de Shahshahani. En el ortante positivo, la métrica de Shahshahani

$$g_{\text{Sh}} = \sum_i \frac{dw_i^2}{w_i}$$

es la métrica de Fisher sobre medidas positivas [5, 6], y se aplanan con la inmersión raíz cuadrada $\mathbf{w} \mapsto 2\sqrt{\mathbf{w}}$. Para $p = 1$, la Proposición 1(ii) da

$$g_1 = \frac{1}{4} \sum_i \frac{dw_i^2}{|w_i|},$$

que en ese ortante es $\frac{1}{4}g_{\text{Sh}}$, con carta plana $\mathbf{u} = \sqrt{\mathbf{w}}$. Así, g_p varía la métrica de Shahshahani en dos sentidos: el exponente -1 del peso pasa a ser $p-2$ (y el factor, $p^2/4$), y se extiende con signo a todo $\mathbb{R}^n$. La familia $\{\mathcal{M}_p\}_{0 < p \leq 1}$ es una deformación de esa geometría, y la elección no es arbitraria.

Reformulación exacta: de $\|\mathbf{w}\|_p^p$ a $\|\mathbf{u}\|^2$

En la carta plana de $\mathcal{M}_p \times \mathbb{R}$, la función objetivo reducida se lee como

$$\Phi(\mathbf{u}, b) = \|\mathbf{u}\|^2 + cH(\Psi_p(\mathbf{u}), b) = d_p(0, \Psi_p(\mathbf{u}))^2 + cH(\Psi_p(\mathbf{u}), b).$$

Como

$$\Phi = F \circ (\Psi_p \times \text{id})$$

y $\Psi_p \times \text{id}$ es un homeomorfismo, (P) , F y Φ tienen los mismos minimizadores locales y globales, sin aproximación alguna.

Trabajar en $\mathbf{u}$ es más cómodo: el término de dispersión $\|\mathbf{u}\|^2$ es de clase C^∞ , fuertemente convexo y con gradiente $2\mathbf{u}$ globalmente Lipschitz; la no suavidad queda confinada en H , que es convexa, y la singularidad de $|t|^p$ se traslada al jacobiano $J(\mathbf{u})$, continuo, cuya entrada i -ésima simplemente se anula cuando $u_i = 0$, en lugar de producir derivadas infinitas. Así, Φ tiene la estructura suave + convexa $\circ C^2$, bien estudiada (métodos prox-lineales), y geodésicas, estratos y distancias son euclídeos en $\mathbf{u}$.

Decimos que $(\mathbf{w}, b)$ es estacionario para (P) si existe $\mathbf{v} \in \partial H(\mathbf{w}, b)$ (∂ : subdiferencial límite) con $v_b = 0$ y

$$p \operatorname{sgn}(w_i)|w_i|^{p-1} + c v_i = 0, \quad i \in \operatorname{supp}(\mathbf{w}).$$

Algoritmo sobre la variedad $\mathcal{M}_p$

Se usa la mayorante tangente

$$|s|^p \leq |t|^p + p|t|^{p-1}(|s| - |t|)$$

[4], pero solo sobre el soporte actual, con pesos exactos y sin ε . Dado $z^k = (\mathbf{w}^k, b^k)$, cada iteración anula las coordenadas con $|w_i^k| < \tau_i$ (poda con salvaguarda de descenso), obteniendo $\tilde{\mathbf{w}}^k$; fija $S_k = \operatorname{supp}(\tilde{\mathbf{w}}^k)$ y resuelve un SOCP convexo sobre el estrato $\Sigma_{S_k^c}$:

$$z^{k+1} \in \arg \min \left\{ \sum_{i \in S_k^c} p|\tilde{w}_i^k|^{p-1}|w_i| + cH(\mathbf{w}, b) + \frac{\gamma}{2} \|(\mathbf{w}, b) - (\tilde{\mathbf{w}}^k, b^k)\|^2 : w_i = 0 \quad \forall i \notin S_k \right\},$$

con $\gamma \geq 0$ y $|S_k| + 2$ variables, frente a $n + 2$ en IRL1.

3. Resultados numéricos

Se usaron cinco bases de [1] (WBC, Sonar, Colorectal, Lymphoma y Pomeroy), validación cruzada estratificada de 10 pliegues, sus hiperparámetros óptimos y $p \in \{0.1, \dots, 0.9\}$. IRL1 se reimplementó con $\varepsilon = 10^{-5}$, reproduciendo lo publicado, y ambos métodos se ejecutaron en MATLAB con CVX sobre los mismos pliegues (BACCU: exactitud balanceada).

Cuadro 8.2: $\mathcal{M}_p$ frente a IRL1 (medias sobre 10 pliegues). M/E/P: valores de p en que $\mathcal{M}_p$ es mejor/empata/es peor; N_f : número de variables; F : objetivo de (P) .

Base	d/N	N_f M/E/P	F M/E/P	BACCU M/E/P	Red. media N_f	Red. máx. N_f
WBC	0.05	0/9/0	0/9/0	0/9/0	0.0 %	0.0 %
Sonar	0.29	1/8/0	1/8/0	0/9/0	0.4 %	3.3 % ($p = 0.1$)
Colorectal	32.26	7/2/0	6/2/1	0/8/1	1.2 %	3.7 % ($p = 0.3$)
Lymphoma [†]	41.94	8/1/0	8/1/0	4/5/0	2.3 %	5.0 % ($p = 0.6$)
Pomeroy	118.80	9/0/0	9/0/0	5/1/3	6.2 %	17.7 % ($p = 0.2$)

[†] Archivo con clases de tamaños 62/34 (publicado: 58/38); sus valores publicados no son comparables.

El método obtuvo un objetivo exacto F menor o igual en 449 de los 450 casos (base, p , pliegue), mientras que IRL1 deja en Colorectal, por pliegue, entre 1955 y 1992 coordenadas no nulas menores que 10^{-5} . La reducción de variables crece con d/N (Cuadro 8.2): en Pomeroy el método usa menos variables en 9 de 10 pliegues y en ninguno más (test de signos, p -valor 0.002); en Colorectal, en 7 frente a 1 (p -valor 0.035), sin diferencias significativas en BACCU.

En Colorectal la estabilidad de la selección (índice de Nogueira et al.) coincide (0.494 con $p = 0.1$), el tiempo por pliegue del barrido en p baja de 129.5 s a 103.7 s, y la variante proximal ($\gamma = 10^{-3}$) selecciona exactamente las mismas variables en los 90 pares (pliegue, p). Como limitación, se usó una única partición por base y cinco de las diez bases; la ganancia no proviene de la curvatura ($\mathcal{M}_p$ es plana), sino de resolver el modelo exacto.

4. Conclusiones

La singularidad de ℓ_p en el modelo ℓ_p -SOCP puede tratarse sin aproximación cambiando la geometría: en la variedad potencia- p , cuya métrica varía la de Shahshahani, $\|\mathbf{w}\|_p^p$ es el cuadrado de la distancia geodésica al origen y, en la carta plana, pasa a ser $\|\mathbf{u}\|^2$. Esto da una reformulación exacta y un algoritmo MM con garantías para el problema original, sin ε , que iguala la exactitud de la referencia con menos variables en alta dimensión. Quedan como líneas futuras la validación cruzada repetida, las tasas de convergencia y otros modelos con ℓ_p .

Trabajo conjunto con

Erik Alex Papa Quiroz, Universidad Nacional Mayor de San Marcos, Lima, Perú.

Bibliografía

- [1] M. Carrasco, B. Ivorra, J. López, M. Marechal, and A. M. Ramos, “Sparse feature selection via ℓ_p -quasi-norm second-order cone programming,” *Pattern Recognition*, vol. 180, Art. no. 114043, 2026.
- [2] G. R. G. Lanckriet, L. El Ghaoui, C. Bhattacharyya, and M. I. Jordan, “A robust minimax approach to classification,” *Journal of Machine Learning Research*, vol. 3, pp. 555–582, 2002.
- [3] C. Bhattacharyya, “Second order cone programming formulations for feature selection,” *Journal of Machine Learning Research*, vol. 5, pp. 1417–1433, 2004.
- [4] E. J. Candès, M. B. Wakin, and S. P. Boyd, “Enhancing sparsity by reweighted ℓ_1 minimization,” *Journal of Fourier Analysis and Applications*, vol. 14, pp. 877–905, 2008.
- [5] S. Shahshahani, “A new mathematical framework for the study of linkage and selection,” *Memoirs of the American Mathematical Society*, vol. 17, no. 211, 1979.
- [6] S. Amari, *Information Geometry and Its Applications*. Springer, Tokyo, 2016.
- [7] J. Schwarz, S. M. Jayakumar, R. Pascanu, P. E. Latham, and Y. W. Teh, “Powerpropagation: A sparsity inducing weight reparameterisation,” in *Advances in Neural Information Processing Systems*, vol. 34, 2021.
- [8] H. Attouch, J. Bolte, and B. F. Svaiter, “Convergence of descent methods for semi-algebraic and tame problems,” *Mathematical Programming*, vol. 137, pp. 91–129, 2013.

Máquina de Vectores Soporte No Paralela Modificada: Unicidad del Sesgo y Formulación Dual Convexa

Factor Risco Guillen

Universidad Nacional Mayor de San Marcos, Lima, Perú

factor.risco@unmsm.edu.pe

Resumen. Este trabajo aborda la falta de unicidad del sesgo en la máquina de vectores soporte no paralela (NPSVM), donde el término de sesgo de cada hiperplano queda fuera de la parte cuadrática del objetivo y, por ello, distintos solvers de programación cuadrática pueden devolver clasificadores distintos sobre los mismos datos. Se propone la NPSVM modificada (mod-NPSVM), que añade un término $\frac{1}{2}b_k^2$ a cada subproblema, de modo que la función objetivo es estrictamente convexa en el par (w_k, b_k) . Las principales contribuciones son: la existencia y unicidad de la solución primal para cualquier valor de los parámetros de regularización, la verificación de la condición de Slater (dualidad fuerte), la formulación dual con Hessianas semidefinidas positivas sin hipótesis sobre el rango de los datos, y la extensión directa con kernel. Un ejemplo mínimo verificable a mano muestra la no unicidad en la NPSVM original y su eliminación en la mod-NPSVM. El aporte es teórico; la evaluación experimental comparativa está en curso.

Palabras clave: máquinas de vectores soporte, hiperplanos no paralelos, convexidad estricta, unicidad del sesgo, dualidad fuerte, truco del kernel.

1. Introducción

La máquina de vectores soporte (SVM) [1] busca un único hiperplano de margen máximo resolviendo un programa cuadrático de tamaño m , el número de muestras. Un solo hiperplano se ajusta mal cuando las dos clases tienen distribuciones muy distintas, como en el patrón *cross-planes* de la Figura 8.1. Los modelos de hiperplanos no paralelos sustituyen ese hiperplano único por dos, uno por clase, y resuelven dos problemas más pequeños e independientes.

La TWSVM [2] inicia esta familia, pero su dual exige invertir $\mathbf{H}_k^\top \mathbf{H}_k$, que es singular si $m_k < n + 1$. La TBSVM [3] corrige esto con una regularización cuadrática sobre $(\mathbf{w}_k, b_k)$, aunque su extensión no lineal obliga a reformular el primal. La ITWSVM [4] evita las inversas con una variable auxiliar y admite kernel en el dual, a costa de duales de tamaño m . La NPSVM [5] usa la pérdida ε -insensible sobre la clase propia y la pérdida hinge sobre la clase opuesta, no requiere inversas y admite kernel directo en el dual (véanse también las revisiones [6, 7]).

Queda sin resolver una limitación estructural de la NPSVM: la regularización

$$\frac{1}{2} \|\mathbf{w}_k\|^2$$

no incluye a b_k . El vector $\mathbf{w}_k^*$ resulta único, pero b_k^* no necesariamente [8], y solvers distintos pueden devolver fronteras de decisión distintas para una misma instancia, lo que compromete la reproducibilidad.

2. Contribución Principal

En esta sección se resumen los principales aportes:




Figura 8.1: Un hiperplano único frente a dos hiperplanos no paralelos en el patrón *cross-planes*.

- formulación de un nuevo modelo (mod-NPSVM) con sesgo regularizado;
- desarrollo teórico: existencia y unicidad de $(\mathbf{w}_k^*, b_k^*)$, condición de Slater y dualidad fuerte, Hessianas duales semidefinidas positivas;
- extensión con kernel directamente sobre el dual, sin reformular el primal;
- un contraejemplo mínimo que evidencia la no unicidad en la NPSVM original.

Modelo

Sean $\mathbf{A}_1 \in \mathbb{R}^{m_1 \times n}$, $\mathbf{A}_2 \in \mathbb{R}^{m_2 \times n}$ las matrices de cada clase,

$$\mathbf{H}_k = [\mathbf{A}_k \quad \mathbf{e}_k], \quad \mathbf{v}_k = \begin{pmatrix} \mathbf{w}_k \\ b_k \end{pmatrix} \in \mathbb{R}^{n+1}.$$

Para $k = 1, 2$, la mod-NPSVM es

$$\begin{aligned} \min_{\mathbf{w}_k, b_k} \quad & \frac{1}{2} (\|\mathbf{w}_k\|^2 + b_k^2) + c_2^k \sum_{i=1}^{m_k} I_\varepsilon((\mathbf{A}_k \mathbf{w}_k)_i + b_k) \\ & + c_1^k \sum_{i=1}^{m_j} L_{\text{hinge}}(1 - (-1)^k ((\mathbf{A}_j \mathbf{w}_k)_i + b_k)), \quad j \neq k, \end{aligned} \quad (1)$$

con $c_1^k, c_2^k > 0$,

$$I_\varepsilon(t) = \max\{0, |t| - \varepsilon\}, \quad L_{\text{hinge}}(t) = \max\{0, t\}.$$

La única diferencia con la NPSVM [5] es el término $\frac{1}{2} b_k^2$.

Con variables de holgura, el primer subproblema es

$$\begin{aligned} \min_{\mathbf{v}_1, \boldsymbol{\eta}_1, \boldsymbol{\eta}_1^*, \boldsymbol{\xi}_2} \quad & \frac{1}{2} \|\mathbf{v}_1\|^2 + c_2^1 \mathbf{e}_1^\top (\boldsymbol{\eta}_1 + \boldsymbol{\eta}_1^*) + c_1^1 \mathbf{e}_2^\top \boldsymbol{\xi}_2 \\ \text{s.a.} \quad & \mathbf{H}_1 \mathbf{v}_1 \leq \varepsilon \mathbf{e}_1 + \boldsymbol{\eta}_1, \\ & -\mathbf{H}_1 \mathbf{v}_1 \leq \varepsilon \mathbf{e}_1 + \boldsymbol{\eta}_1^*, \\ & \mathbf{H}_2 \mathbf{v}_1 \leq -\mathbf{e}_2 + \boldsymbol{\xi}_2, \\ & \boldsymbol{\eta}_1, \boldsymbol{\eta}_1^*, \boldsymbol{\xi}_2 \geq 0. \end{aligned} \quad (8.11)$$

El segundo es análogo, con la restricción cruzada

$$\mathbf{H}_1 \mathbf{v}_2 \geq \mathbf{e}_1 - \boldsymbol{\xi}_1.$$

No unicidad en la NPSVM y su corrección

Lema 1. Sea $n = 1$, $\mathbf{A}_1 = [0]$, $\mathbf{A}_2 = [3]$, $\varepsilon = 2$, y

$$c_1^1 = c_2^1 = 1.$$

En la NPSVM original, el conjunto de soluciones óptimas del primer subproblema es

$$\{(0, b) : b \in [-2, -1]\},$$

con valor óptimo 0. En la mod-NPSVM, con los mismos datos y parámetros, la solución es única:

$$(w^*, b^*) = \left(-\frac{3}{10}, -\frac{1}{10}\right),$$

con valor óptimo $\frac{1}{20}$.

Idea. El objetivo original es

$$\frac{1}{2}w^2 + \max(0, |b| - 2) + \max(0, 3w + b + 1),$$

suma de términos no negativos, que se anula exactamente en

$$w = 0, \quad b \in [-2, -1].$$

En la mod-NPSVM el término $\frac{1}{2}b^2$ obliga a minimizar $\frac{1}{2}(w^2 + b^2)$ sobre

$$3w + b + 1 = 0,$$

cuyo único minimizador es la proyección del origen sobre esa recta.




Figura 8.2: Meseta de sesgos óptimos en la NPSVM y mínimo único en la mod-NPSVM (Lema 1).

Existencia y unicidad

Teorema 1. Sea $\varepsilon \geq 0$ y $c_1^k, c_2^k > 0$ arbitrarios. Para cada $k \in \{1, 2\}$, el subproblema de la mod-NPSVM tiene exactamente una solución óptima $\mathbf{v}_k^* = (\mathbf{w}_k^*, b_k^*)$, y las variables de holgura óptimas quedan determinadas por $\mathbf{v}_k^*$.

Idea. Al eliminar las holguras se obtiene

$$F(\mathbf{v}_k) = \frac{1}{2}\|\mathbf{v}_k\|^2 + g(\mathbf{v}_k),$$

con g convexa. Entonces F es continua, estrictamente convexa y coerciva, y por tanto tiene un único minimizador. Dado $\mathbf{v}_k^*$, cada holgura es el menor valor compatible con sus restricciones porque su coeficiente de costo es positivo.

El punto

$$\bar{\mathbf{v}}_1 = 0, \quad \bar{\boldsymbol{\eta}}_1 = \bar{\boldsymbol{\eta}}_1^* = (\varepsilon + 1)\mathbf{e}_1, \quad \bar{\boldsymbol{\xi}}_2 = 2\mathbf{e}_2$$

satisface todas las restricciones con desigualdad estricta; así se cumple la condición de Slater, se tiene dualidad fuerte y las condiciones KKT son necesarias y suficientes.

Formulación dual y kernel

Con multiplicadores $\boldsymbol{\alpha}_1, \boldsymbol{\alpha}_1^* \in \mathbb{R}^{m_1}, \boldsymbol{\beta}_2 \in \mathbb{R}^{m_2}$, el dual del primer subproblema es

$$\begin{aligned} \min_{\boldsymbol{\alpha}_1, \boldsymbol{\alpha}_1^*, \boldsymbol{\beta}_2} \quad & \frac{1}{2} \mathbf{x}^\top \mathbf{Q}_1 \mathbf{x} + \begin{pmatrix} \varepsilon \mathbf{e}_1 \\ \varepsilon \mathbf{e}_1 \\ -\mathbf{e}_2 \end{pmatrix}^\top \mathbf{x} \\ \text{s.a.} \quad & 0 \leq \boldsymbol{\alpha}_1 \leq c_2^1 \mathbf{e}_1, \\ & 0 \leq \boldsymbol{\alpha}_1^* \leq c_2^1 \mathbf{e}_1, \\ & 0 \leq \boldsymbol{\beta}_2 \leq c_1^1 \mathbf{e}_2, \end{aligned} \tag{2}$$

con

$$\mathbf{x} = \begin{pmatrix} \boldsymbol{\alpha}_1 \\ \boldsymbol{\alpha}_1^* \\ \boldsymbol{\beta}_2 \end{pmatrix}$$

y

$$\mathbf{Q}_1 = \begin{pmatrix} \mathbf{H}_1 \mathbf{H}_1^\top & -\mathbf{H}_1 \mathbf{H}_1^\top & \mathbf{H}_1 \mathbf{H}_2^\top \\ -\mathbf{H}_1 \mathbf{H}_1^\top & \mathbf{H}_1 \mathbf{H}_1^\top & -\mathbf{H}_1 \mathbf{H}_2^\top \\ \mathbf{H}_2 \mathbf{H}_1^\top & -\mathbf{H}_2 \mathbf{H}_1^\top & \mathbf{H}_2 \mathbf{H}_2^\top \end{pmatrix},$$

donde

$$\mathbf{H}_i \mathbf{H}_j^\top = \mathbf{A}_i \mathbf{A}_j^\top + \mathbf{e}_i \mathbf{e}_j^\top.$$

Como

$$\mathbf{Q}_1 = \mathbf{N} \mathbf{N}^\top, \quad \mathbf{N} = \begin{pmatrix} \mathbf{H}_1 \\ -\mathbf{H}_1 \\ \mathbf{H}_2 \end{pmatrix},$$

se cumple

$$\mathbf{x}^\top \mathbf{Q}_1 \mathbf{x} = \|\mathbf{N}^\top \mathbf{x}\|^2 \geq 0$$

para todo $\mathbf{x}$, sin ninguna hipótesis sobre el rango de $\mathbf{H}_1, \mathbf{H}_2$, incluso si $n \geq m_k$.

El vector primal se recupera con

$$\mathbf{v}_1^* = \mathbf{H}_1^\top (\boldsymbol{\alpha}_1^* - \boldsymbol{\alpha}_1) - \mathbf{H}_2^\top \boldsymbol{\beta}_2,$$

y, por el Teorema 1, todo dual óptimo conduce al mismo $\mathbf{v}_1^*$.

El segundo subproblema es análogo, con signo opuesto en los bloques cruzados de $\mathbf{Q}_2$. Para el caso no lineal basta sustituir

$$\mathbf{A}_i \mathbf{A}_j^\top \longrightarrow K(\mathbf{A}_i, \mathbf{A}_j^\top)$$

y conservar $\mathbf{e}_i \mathbf{e}_j^\top$; la factorización

$$\mathbf{Q}_1^\kappa = \tilde{\mathbf{N}} \tilde{\mathbf{N}}^\top,$$

con $\tilde{\mathbf{N}}$ construida con la representación aumentada $[\phi(\mathbf{x})^\top \ 1]$, mantiene $\mathbf{Q}_1^\kappa \succeq 0$. La regla de decisión asigna $\mathbf{x}$ a la clase del hiperplano con menor distancia normalizada.

Cuadro 8.3: Propiedades estructurales (m_j : tamaño de la clase opuesta, $m = m_1 + m_2$).

Modelo	Vars. duales	Inversas	b_k^* único	Kernel sin reformular primal
TWSVM	m_j	Sí	No	No
TBSVM	m_j	Sí	Sí	No
ITWSVM	m	No	Sí	Sí
NPSVM	$2m_k + m_j$	No	No	Sí
mod-NPSVM	$2m_k + m_j$	No	Sí	Sí

Comparación con la familia Twin SVM

La mod-NPSVM conserva el costo dual de la NPSVM y añade la unicidad de $(\mathbf{w}_k^*, b_k^*)$ sin resolver sistemas lineales adicionales. Su Hessiana dual, de orden $2m_k + m_j$, es mayor que la de la ITWSVM (orden m); la ventaja es estructural (unicidad, sin inversas, kernel directo), no de tamaño.

3. Conclusiones

Añadir $\frac{1}{2}b_k^2$ a cada subproblema de la NPSVM basta para garantizar una única solución primal $(\mathbf{w}_k^*, b_k^*)$ para cualquier valor de los parámetros de regularización, con dualidad fuerte y duales convexos con Hessianas semidefinidas positivas, sin perder la extensión directa con kernel. Queda pendiente la evaluación experimental comparativa (TWSVM, TBSVM, ITWSVM, NPSVM y mod-NPSVM con distintos solvers de programación cuadrática). Como líneas futuras se plantean cotas de generalización para la regla de decisión por proximidad, la consistencia estadística del minimizador empírico y una formulación multiclase nativa que preserve la unicidad y el kernel directo.

Trabajo conjunto con

Erik Alex Papa Quiroz, Facultad de Ciencias Matemáticas, Universidad Nacional Mayor de San Marcos, Perú.

Julio López, Facultad de Ingeniería y Ciencias, Universidad Diego Portales, Chile.

Financiado por CONCYTEC-PROCIENCIA (concurso E041-2024-03, proyecto PE501087025-2024-PROCIENCIA) y ANID FONDECYT Chile (proyecto 1230694).

Bibliografía

- [1] C. Cortes and V. Vapnik, “Support-vector networks,” *Machine Learning*, vol. 20, no. 3, pp. 273–297, 1995.
- [2] Jayadeva, R. Khemchandani, and S. Chandra, “Twin support vector machines for pattern classification,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 29, no. 5, pp. 905–910, 2007.
- [3] Y.-H. Shao, C.-H. Zhang, X.-B. Wang, and N.-Y. Deng, “Improvements on twin support vector machines,” *IEEE Transactions on Neural Networks*, vol. 22, no. 6, pp. 962–968, 2011.
- [4] Y. Tian, X. Ju, Z. Qi, and Y. Shi, “Improved twin support vector machine,” *Science China Mathematics*, vol. 57, no. 2, pp. 417–432, 2014.
- [5] Y. Tian, Z. Qi, X. Ju, Y. Shi, and X. Liu, “Nonparallel support vector machines for pattern classification,” *IEEE Transactions on Cybernetics*, vol. 44, no. 7, pp. 1067–1079, 2013.
- [6] Y. Tian and Z. Qi, “Review on: twin support vector machines,” *Annals of Data Science*, vol. 1, no. 2, pp. 253–277, 2014.
- [7] M. Tanveer, T. Rajani, R. Rastogi, Y.-H. Shao, and M. A. Ganaie, “Comprehensive review on twin support vector machines,” *Annals of Operations Research*, vol. 339, no. 3, pp. 1223–1268, 2024.

- [8] N. Deng, Y. Tian, and C. Zhang, *Support Vector Machines: Optimization Based Theory, Algorithms, and Extensions*. CRC Press, 2012.

Una revisión sistemática de la literatura sobre el uso de la Inteligencia Artificial para el apoyo en el diagnóstico clínico

Johnny Richard Quispe Obregón

Universidad Nacional Mayor de San Marcos, Lima, Perú

johnnyrichard.quispe@unmsm.edu.pe

Resumen. Esta revisión sistemática analiza el uso de la inteligencia artificial (IA) como apoyo al diagnóstico clínico, con énfasis en modelos de clasificación, aprendizaje profundo y estrategias de optimización. Siguiendo las directrices PRISMA, se realizó una búsqueda en Scopus que identificó 771 registros; después del cribado y la evaluación de elegibilidad, se incluyeron 34 estudios. Las investigaciones abordaron cerebro, pulmón, colon, ojos, mama, vejiga y ganglios linfáticos. Predominaron las redes neuronales convolucionales, el análisis automatizado de imágenes médicas, el aumento de datos, la transferencia de aprendizaje, los modelos generativos y la integración multimodal. Asimismo, se identificaron métodos de optimización del desempeño, entre ellos algoritmos genéticos, evolución diferencial y otras estrategias orientadas al ajuste de arquitecturas y a la mejora de la precisión. El rendimiento se evaluó principalmente mediante exactitud, precisión, sensibilidad, especificidad, puntuación F1, área bajo la curva, coeficiente Dice e intersección sobre unión. En general, los estudios reportaron resultados favorables en tareas de clasificación, detección y segmentación; sin embargo, la heterogeneidad de bases de datos, enfermedades y métricas limitó la comparación directa. Se concluye que la IA puede fortalecer el diagnóstico clínico, siempre que los modelos cuenten con validación externa, explicabilidad, protección de datos y supervisión profesional.

Palabras clave: inteligencia artificial, machine learning, clasificación de datos, optimización de modelos, diagnóstico clínico.

1. Introducción

La inteligencia artificial se ha consolidado como una herramienta de apoyo para procesar imágenes médicas, señales biomédicas, historias clínicas y otras fuentes de información utilizadas en la detección y clasificación de enfermedades [1, 2]. En este contexto, el aprendizaje profundo, los modelos multimodales y las técnicas de optimización permiten mejorar el ajuste y la capacidad predictiva de los modelos, aunque persisten retos asociados con la generalización, la explicabilidad y la validación clínica [3]. El objetivo de esta revisión sistemática fue identificar los modelos y métodos de IA utilizados como apoyo al diagnóstico clínico, las áreas médicas abordadas, las métricas de evaluación, los resultados de desempeño y las principales innovaciones reportadas en la literatura.

2. Contribución Principal

La revisión permitió sintetizar los siguientes aportes metodológicos y computacionales:

- Aplicación de una revisión sistemática basada en PRISMA, con 771 registros identificados en Scopus y 34 estudios incluidos en la síntesis cualitativa [4].

- Identificación de seis grupos metodológicos predominantes: arquitecturas de aprendizaje profundo, análisis inteligente de imágenes médicas, aumento de datos, optimización del desempeño, redes neuronales convolucionales y métodos multimodales.
- Síntesis de ocho métricas recurrentes para clasificación, detección y segmentación: exactitud, precisión, sensibilidad, especificidad, F1, AUC, Dice e IoU.
- Identificación de estrategias de optimización y ajuste, incluyendo evolución diferencial para aprender arquitecturas de redes profundas [5] y algoritmos genéticos combinados con DenseNet para clasificación de severidad de cáncer de pulmón [6].
- Reconocimiento de limitaciones comunes: heterogeneidad de bases de datos y métricas, escasa validación externa, necesidad de explicabilidad y protección de datos.

3. Conclusiones

Los resultados muestran que el aprendizaje profundo y, en particular, las redes neuronales convolucionales constituyen los enfoques más frecuentes para apoyar el diagnóstico clínico. Las técnicas de optimización, aumento de datos, transferencia de aprendizaje y fusión multimodal contribuyen al ajuste y a la generalización de los modelos. No obstante, la evidencia revisada no permite establecer un único modelo superior, debido a la diversidad de enfermedades, bases de datos y métricas utilizadas. Como líneas futuras se recomienda comparar modelos bajo condiciones homogéneas, ampliar la validación externa en hospitales y profundizar en modelos multimodales, IA explicable y métodos robustos para escenarios con pocos datos.

Trabajo conjunto con: Miguel Ángel Cano Lengua, Universidad Nacional Mayor de San Marcos, Lima, Perú. Correo: mcanol@unmsm.edu.pe

Bibliografía

- [1] P. Rajpurkar, E. Chen, O. Banerjee, and E. J. Topol, “AI in health and medicine,” *Nature Medicine*, vol. 28, pp. 31–38, 2022. <https://doi.org/10.1038/s41591-021-01614-0>
- [2] J. N. Acosta, G. J. Falcone, P. Rajpurkar, and E. J. Topol, “Multimodal biomedical AI,” *Nature Medicine*, vol. 28, pp. 1773–1784, 2022. <https://doi.org/10.1038/s41591-022-01981-2>
- [3] S. Azizi et al., “Robust and data-efficient generalization of self-supervised machine learning for diagnostic imaging,” *Nature Biomedical Engineering*, vol. 7, pp. 756–779, 2023. <https://doi.org/10.1038/s41551-023-01049-7>
- [4] D. Moher, A. Liberati, J. Tetzlaff, D. G. Altman, and PRISMA Group, “Preferred reporting items for systematic reviews and meta-analyses: The PRISMA statement,” *Annals of Internal Medicine*, vol. 151, no. 4, pp. 264–269, 2009.
- [5] S. Belciug, “Learning deep neural networks’ architectures using differential evolution. Case study: medical imaging processing,” *Computers in Biology and Medicine*, vol. 146, p. 105623, 2022. <https://doi.org/10.1016/j.compbiomed.2022.105623>
- [6] T. Arthi, S. Premkumar, S. Sivakumar, and N. Partheeban, “Leveraging DenseNet and Genetic Algorithms for Lung Cancer Severity Classification,” in *2023 1st International Conference on Optimization Techniques for Learning (ICOTL)*, pp. 1–6, IEEE, 2023. <https://doi.org/10.1109/ICOTL59758.2023.10435208>

Simetría vs SDP de Conjuntos

Eladio Ocaña Anaya

Instituto de Matemática y Ciencias Afines (IMCA), Lima, Perú

eocana@imca.edu.pe

Resumen. La simetría y la SDP (semi-definida positiva) de una matriz A o un subespacio lineal E o un conjunto arbitrario F , son propiedades aparentemente independientes una de la otra. Cuando A , E o F es SDP, esta es "simétrica" de un cierto orden, definición que será dada en esta charla. En efecto, la "simetría" indica que tan integrable es la propiedad SDP. Estas relaciones serán estudiadas tanto en el enfoque discreto (clásico) como en el enfoque continuo (menos clásico). En el campo de la economía, uno de los efectos de este tema es la existencia de la función de utilidad u (directa/indirecta) a partir de un conjunto de información G , la demanda: En efecto u es la integral de G , y por lo tanto G es el conjunto de demandas asociadas a dicha función de utilidad.

Palabras clave: Simetría, Semi-definida positiva, Integrabilidad, Funciones de utilidad.

Diseño de un modelo de Machine Learning para detección de anomalías en contrataciones públicas del estado peruano

Julio César Gonzales Paico

*Universidad Nacional Mayor de San Marcos, Lima,
Universidad Nacional Agraria de la Selva, Tingo María, Perú*

julio.gonzalesp@unmsm.edu.pe

Resumen. La corrupción en las instituciones públicas deteriora la confianza en los gobiernos y las contrataciones públicas se han visto afectadas por actos de corrupción en muchos países, en la última década se está tratando de abordar este problema de manera más sistemática. Este artículo tiene como objetivo diseñar un modelo de aprendizaje automático que permita identificar anomalías en las adjudicaciones del estado peruano, mediante el uso de la metodología CRISP-DM, el aprendizaje no supervisado y los datos abiertos de adjudicaciones del estado peruano para el año 2024 publicados por el OSCE (Organismo Supervisor de Contrataciones del Estado). Como resultado del modelo se encontraron algunas alertas sobre anomalías en el comportamiento de ciertos licitadores, estas alertas no concluyen casos de corrupción, pero ayudan a enfocar los recursos y esfuerzos para determinar los motivos de esos comportamientos anómalos.

Palabras clave: Corruption; Anomalies; Clustering; Machine Learning; Procurement; Public Sector

Introducción

Las contrataciones públicas se han visto afectadas por el tema de la corrupción. Existen diversos estudios que tratan de explicar los orígenes de la corrupción; algunos destacan factores psicológicos [1], falta de transparencia [2], la conciencia jurídica de la sociedad [3], la cultura y los valores de los funcionarios [4], y la situación política y económica del país [5], como aquellos que propician el incremento de la corrupción en todos los niveles de gobierno.

Asimismo, para tratar de contrarrestar la corrupción surgen diversos enfoques, como el uso de marcos legales y normativos sólidos [6, 7], el control interno [8, 9], la transparencia y acceso a la información de las instituciones [10, 11, 12], la práctica de valores y la integridad [13, 14], y la efectividad de las sanciones [15, 16].

Esta investigación busca contribuir a los mecanismos para contrarrestar la corrupción. Haciendo uso de la metodología CRISP-DM, los algoritmos de escalamiento MinMaxScaler, clusterización K-Means y de los datos abiertos sobre contrataciones públicas del Estado peruano publicados por el OSCE, se diseña un modelo para identificar comportamientos anómalos en las contrataciones. El objetivo de este modelo es acelerar la identificación de estas anomalías para enfocar mejor los recursos de investigación y análisis sobre esos casos que podrían ser indicios de alguna práctica irregular.

Contribución Principal

Esta investigación permitió contribuir con los siguientes aportes:

- Se pudo caracterizar un set de datos de contrataciones del Estado con información abierta publicada por el OSCE.
- Se pudo elaborar un modelo de aprendizaje automático utilizando algoritmos no supervisados como K-Means y DBSCAM para detectar anomalías sobre las contrataciones del Estado.
- Se comprobó la utilidad y el impacto en los resultados que puede generar el uso de las métricas correctas.
- Se demostró la utilidad de la reducción de dimensionalidad para modelar set de datos con alta dimensionalidad, como en el caso de las adquisiciones públicas.
- Se demostró la aplicabilidad del aprendizaje automático para facilitar la identificación de casos atípicos en los procesos de contrataciones del Estado; sin embargo, esta herramienta no suple la experiencia y la responsabilidad de los especialistas para tomar decisiones.

Conclusiones

En este estudio se ha diseñado un modelo de aprendizaje no supervisado haciendo uso de la metodología CRISP-DM y de los algoritmos K-Means y DBSCAM. Para la construcción de este modelo se han utilizado datos de fuente abierta sobre adjudicaciones del Estado del año 2025 publicados por el OSCE en el portal de contrataciones abiertas de la compra pública.

Como resultado del modelo encontramos algunos valores anómalos al comparar el Q de licitaciones al que se presenta cada licitador versus el Q de adjudicaciones (licitaciones ganadas). Estos valores atípicos no confirman un mal proceso o algún indicio de corrupción; sin embargo, aceleran la alerta para poder enfocar los esfuerzos en comprender el origen de tales desviaciones.

Trabajo conjunto con

Miguel Ángel Cano Lengua, Universidad Nacional Mayor de San Marcos, Lima, Perú. Correo: mcanol@unmsm.edu.pe.

Bibliografía

- [1] O. V. Dragan, G. S. Yermakova, A. M. Chvaliuk, O. G. Kurchin, and O. V. Karagodin, "Psychological aspects of corruption in public administration: Case-study of Ukraine," *Academic Journal of Interdisciplinary Studies*, vol. 9, no. 6, 2020. doi: 10.36941/AJIS-2020-0130.
- [2] T. Andrei, A. Matei, S. Stancu, and B. Oancea, "Some notes about decentralization process implications on public administration corruption in Romania," *Prague Economic Papers*, no. 1, 2009. doi: 10.18267/j.pap.339.
- [3] E. Effendi and M. Ali, "Public awareness of public administration governance and legal awareness regarding anti-corruption measures," *Corporate Law and Governance Review*, vol. 5, no. 1, 2023. doi: 10.22495/clgrv5i1p1.
- [4] C. M. Zorrilla and I. M. Carhuancho Mendoza, "Factores que inciden en la corrupción de funcionarios en el Perú," *Res Non Verba Revista Científica*, vol. 9, no. 2, 2019. doi: 10.21855/resnonverba.v9i2.213.
- [5] J. P. Palacios Garay, R. E. Rodríguez Salazar, L. Fuerte Montaña, and V. Pereyra Zaldívar, "Problemática de la corrupción en el Perú," *Rev Cienc Soc*, 2022. doi: 10.31876/rcs.v28i.38162.
- [6] J. Woolford, "Investigating corruption, maladministration and misconduct in public administration: Has South Australia struck the right balance?," *Alternative Law Journal*, vol. 48, no. 3, 2023. doi: 10.1177/1037969X231175699.
- [7] E. Antonyan and M. Polyakov, "Administrative and legal forms and methods of combating corruption in the field of public administration of the transport complex," in *Transportation Research Procedia*, 2022. doi: 10.1016/j.trpro.2022.06.261.
- [8] M. P. Sáiz-Antón, "Internal Control of Public Administrations. Its Role in Prevention and the Fight Against The Corruption of the Public Powers," *Revista Catalana de Dret Public*, vol. 60, 2020.
- [9] F. Anechiarico and J. B. Jacobs, "Panopticism and financial controls – The anti-corruption project in public administration," *Crime Law Soc Change*, vol. 22, no. 4, 1994. doi: 10.1007/BF01302925.
- [10] G. Vojkovic and T. Katulic, "Anti-corruption Measures in the New Croatian Public Administration Office Management Regulation," in *2023 46th ICT and Electronics Convention, MIPRO 2023 – Proceedings*, 2023. doi: 10.23919/MIPRO57284.2023.10159839.
- [11] A. Androniceanu, I. Georgescu, and J. Kinnunen, "Public Administration Digitalization and Corruption in the EU Member States. A comparative and Correlative Research Analysis," *Transylvanian Review of Administrative Sciences*, vol. 2022, no. 65 E-February, 2022. doi: 10.24193/tras.65E.1.
- [12] I. A. Galcerà, "Dossier on the fight against corruption within public administration," *Revista Catalana de Dret Public*, vol. 2020, no. 60, 2020. doi: 10.2436/rcdp.i60.2020.3454.
- [13] A. Graycar and A. B. Masters, "Preventing malfeasance in low corruption environments: Twenty public administration responses," in *Journal of Financial Crime*, 2018. doi: 10.1108/JFC-04-2017-0026.
- [14] C. Plischoff Varas and N. Lagos Machuca, "Implementación de sistemas de integridad como estrategia de control de la corrupción en el Gobierno Central de Chile," *Gestión y Política Pública*, vol. 30, no. 3, 2021. doi: 10.29265/gypv.v30i3.961.
- [15] F. Schatz, "Fighting corruption with social accountability: A comparative analysis of social accountability mechanisms' potential to reduce corruption in public administration," *Public Administration and Development*, vol. 33, no. 3, 2013. doi: 10.1002/pad.1648.
- [16] P. A. G. Villanueva, "Why Civil Society Cannot Battle it All Alone: The Roles of Civil Society Environment, Transparent Laws and Quality of Public Administration in Political Corruption Mitigation," *International Journal of Public Administration*, vol. 43, no. 6, 2020. doi: 10.1080/01900692.2019.1638933.

Método del punto proximal mediante la distancia

de Bregman para problemas de equilibrio en variedades de Hadamard

Roy Sanchez Gutierrez

Pontificia Universidad Católica del Perú, Lima, Perú

rwsanche@pucp.edu.pe

Resumen. Las variedades de Hadamard son variedades riemannianas completas, simplemente conexas y de curvatura seccional no positiva. La existencia de una única geodésica entre cada par de puntos permite formular problemas de optimización y métodos iterativos en espacios cuya geometría no es necesariamente euclidiana. En este marco, consideramos el problema de equilibrio asociado a una bifunción

$$F : C \times C \rightarrow \mathbb{R} :$$

hallar $x^* \in C$ tal que

$$F(x^*, y) \geq 0 \quad \text{para todo } y \in C,$$

donde C es un subconjunto cerrado y geodésicamente convexo.

A continuación, presentamos el método del punto proximal como una estrategia para aproximar una solución mediante una sucesión de problemas de equilibrio regularizados. Siguiendo el trabajo de Sharma y Reich, examinamos cómo incorporar a esta estrategia la distancia de Bregman generada por una función apropiada ϕ :

$$D_\phi(x, y) = \phi(x) - \phi(y) - \langle \text{grad } \phi(y), \text{Exp}_y^{-1}(x) \rangle_y.$$

Esta distancia generalizada permite construir una regularización adaptada a la función ϕ , aunque no es, en general, simétrica ni satisface la desigualdad triangular.

El punto central de la exposición es la dificultad que introduce la curvatura: el término de regularización de Bregman puede perder la convexidad geodésica. El artículo demuestra la convergencia del método para problemas de equilibrio monótonos bajo condiciones específicas, entre ellas la convexidad geodésica de un conjunto asociado al problema regularizado y una condición de coercividad más débil que algunas utilizadas previamente. Se comentará, finalmente, el alcance de estas hipótesis y los ejemplos numéricos presentados por los autores.

Palabras clave: variedades de Hadamard; problemas de equilibrio; método del punto proximal; distancia de Bregman; convergencia.

Artículo de referencia: S. Sharma y S. Reich, *A Bregman regularized proximal point method for solving equilibrium problems on Hadamard manifolds*.

Bibliografía

- [1] H. H. Bauschke y J. M. Borwein, “Legendre functions and the method of random Bregman projections,” *Journal of Convex Analysis*, vol. 4, no. 1, pp. 27–67, 1997.
- [2] L. M. Bregman, “The relaxation method of finding the common point of convex sets and its application to the solution of problems in convex programming,” *USSR Computational Mathematics and Mathematical Physics*, vol. 7, no. 3, pp. 200–217, 1967.
- [3] O. P. Ferreira y P. R. Oliveira, “Proximal point algorithm on Riemannian manifolds,” *Optimization*, vol. 51, no. 2, pp. 257–270, 2002.
- [4] T. Rapcsák, *Smooth Nonlinear Optimization in $\mathbb{R}^n$* . Kluwer Academic Publishers, 1997.
- [5] S. Sharma y S. Reich, “A Bregman regularized proximal point method for solving equilibrium problems on Hadamard manifolds,” *Rendiconti del Circolo Matematico di Palermo Series 2*, vol. 75, Art. no. 122, 2026.

Desarrollo de un Algoritmo Proximal Alternado para Problemas de Descomposición de Dominio en EDP

Elvis Favian Caycho Villegas

Universidad Nacional Mayor de San Marcos, Lima, Perú

favicaycho@gmail.com

Resumen. En esta presentación desarrollamos las principales ideas del paper [2] relacionado a un algoritmo proximal alternado para un problema de optimización convexa con acoplamiento débil entre variables. El método se basa en una penalización cuadrática que permite controlar la discrepancia entre las soluciones asociadas a dos subdominios. Se presenta el marco teórico de convergencia y su aplicación a un problema de descomposición de dominio para la ecuación de Poisson con condiciones de Neumann. Se demuestra que, bajo condiciones apropiadas sobre la secuencia de penalización, el algoritmo converge hacia una solución que minimiza el salto sobre la interfaz común entre los subdominios. Finalmente se discute la interpretación variacional del método y su relación con técnicas modernas de optimización convexa y descomposición de dominio.

Palabras clave: optimización convexa, algoritmo proximal alternado, descomposición de dominio, ecuación de Poisson, espacios de Hilbert.

Introducción

Los métodos proximales constituyen una herramienta fundamental en optimización convexa, análisis funcional y ecuaciones en derivadas parciales. En particular, los algoritmos alternados permiten resolver problemas que involucran varias variables mediante la optimización sucesiva de cada una de ellas.

En este trabajo se considera un problema de minimización de la forma

$$\Phi_{\gamma}(x, y) = f(x) + g(y) + \frac{1}{2\gamma} \|Ax - By\|^2,$$

donde f y g son funciones convexas, mientras que A y B son operadores lineales continuos entre espacios de Hilbert. El objetivo principal consiste en estudiar el comportamiento asintótico de un algoritmo proximal alternado cuando el parámetro de penalización varía con las iteraciones. Particularmente, se analiza el fenómeno de selección asintótica inducido por el término de acoplamiento y su aplicación a un problema de descomposición de dominio para la ecuación de Poisson con condiciones de Neumann.

Contribución Principal

En esta sección se resumen los principales aportes.

Problema abstracto

Se estudia el algoritmo

$$\begin{cases} x_{n+1} = \arg \min_{\xi} \left\{ f(\xi) + \frac{1}{2\gamma_{n+1}} \|A\xi - By_n\|^2 + \frac{\alpha}{2} \|\xi - x_n\|^2 \right\}, \\ y_{n+1} = \arg \min_{\eta} \left\{ g(\eta) + \frac{1}{2\gamma_{n+1}} \|Ax_{n+1} - B\eta\|^2 + \frac{\nu}{2} \|\eta - y_n\|^2 \right\}. \end{cases}$$

Los términos proximales estabilizan el proceso iterativo y permiten demostrar propiedades de convergencia.

Resultado teórico principal

Se demuestra que el comportamiento del algoritmo depende de la velocidad de crecimiento de la secuencia (γ_n) . Cuando

$$\left(\frac{1}{\gamma_n} \right) \in \ell^1,$$

la sucesión converge débilmente hacia un elemento del conjunto

$$C = \arg \min f \times \arg \min g.$$

Cuando

$$\left(\frac{1}{\gamma_n} \right) \notin \ell^1,$$

aparece un fenómeno de selección asintótica y el algoritmo converge hacia elementos que minimizan adicionalmente la función

$$\Psi(x, y) = \frac{1}{2} \|Ax - By\|^2.$$

Aplicación a EDP

En la aplicación considerada se descompone el dominio como

$$\Omega = \Omega_1 \cup \Omega_2 \cup \Gamma,$$

donde Γ representa la interfaz común entre los subdominios. Se consideran los espacios

$$X = H^1(\Omega_1), \quad Y = H^1(\Omega_2), \quad Z = L^2(\Gamma),$$

y los operadores traza

$$Au = u|_{\Gamma}, \quad Bv = v|_{\Gamma}.$$

En este contexto, el término de viscosidad se transforma en

$$\Psi(u, v) = \frac{1}{2} \int_{\Gamma} (u - v)^2,$$

que mide el salto entre las soluciones sobre la interfaz.

Resultado aplicado

Se demuestra que si

$$\left(\frac{1}{\gamma_n} \right) \in \ell^2$$

y la secuencia

$$(\gamma_{n+1} - \gamma_n)$$

permanece acotada, entonces toda sucesión generada por el algoritmo converge fuertemente en $H^1(\Omega_1) \times H^1(\Omega_2)$, hacia una solución que minimiza el salto sobre la interfaz.

Conclusiones

Se presentó un algoritmo proximal alternado para problemas convexos con acoplamiento débil y se estudió su comportamiento asintótico. El análisis mostró que la velocidad de decrecimiento del parámetro de penalización determina el mecanismo de selección de soluciones.

La aplicación a problemas de descomposición de dominio permitió interpretar el término de acoplamiento como una medida del salto entre soluciones sobre una interfaz común. Finalmente, se obtuvo convergencia fuerte en espacios de Sobolev para un problema de Poisson con condiciones de Neumann, mostrando el potencial de los métodos proximales en el estudio y resolución de ecuaciones en derivadas parciales.

Bibliografía

- [1] A. Cabot, H. Attouch y colaboradores, “Weak coupling, slow penalization and domain decomposition for partial differential equations,” *Journal of Mathematical Analysis and Applications*, 2012.
- [2] A. Cabot and P. Frankel, “Alternating proximal algorithms with asymptotically vanishing coupling. Application to domain decomposition for PDE’s,” *Journal of Convex Analysis*, 2012.
- [3] H. Brézis, *Functional Analysis, Sobolev Spaces and Partial Differential Equations*. Springer, 2011.
- [4] H. Attouch y J. Peypouquet, *The Dynamics of Optimization and Inverse Problems*. Springer, 2016.
- [5] J. L. Lions and E. Magenes, *Non-Homogeneous Boundary Value Problems and Applications*. Springer, 1972.
- [6] A. Quarteroni and A. Valli, *Domain Decomposition Methods for Partial Differential Equations*. Oxford University Press, 1999.

8.3. Ponencias

Optimización de portafolios con restricciones mediante Particle Swarm Optimization (PSO)

Omar Briceño C.

Escuela Peruana de Gestión de Riesgos, Lima, Perú

omar.briceno@adriskserv.com

Resumen.

La optimización de portafolios bajo condiciones reales de inversión puede requerir restricciones de cardinalidad, selección de activos y discretización de pesos que transforman el problema clásico media-varianza en un problema no convexo y combinatorio. Este trabajo analiza la aplicación de Particle Swarm Optimization (PSO) para la construcción de portafolios sujetos a restricciones de cardinalidad, pesos mínimos y máximos por activo, pesos discretos y límites asociados a medidas de riesgo y rotación. La función fitness se formula a partir del ratio de Sharpe, incorporando penalizaciones por excesos de Conditional Value-at-Risk (CVaR), máximo drawdown y turnover. La metodología se aplica a un universo de cinco activos, imponiendo una cardinalidad exacta de cuatro posiciones, pesos entre 10 % y 35 % para los activos seleccionados y asignaciones discretas en múltiplos de 5 %. El portafolio obtenido se compara con una solución de referencia basada en el enfoque clásico de Markowitz. Los resultados muestran que PSO presenta menor volatilidad anual (18.63 % frente a 19.80 %), menor CVaR diario al 95 % (2.79 % frente a 2.95 %), menor máximo drawdown en valor absoluto (27.77 % frente a 29.61 %) y menor turnover (30 % frente a 40 %). A cambio, el retorno anual disminuye de 19.87 % a 18.47 % y ratio de Sharpe de 0.9027 a 0.8837. Los resultados evidencian la utilidad de PSO como alternativa flexible cuando la factibilidad operativa y las restricciones reales de inversión forman parte explícita del problema de optimización.

Palabras clave: optimización de portafolios; Particle Swarm Optimization; metaheurísticas; restricciones de cardinalidad; CVaR.

Resumen.

Portfolio optimization under realistic investment conditions may require cardinality, asset-selection, and discrete weight constraints that transform the classical mean-variance formulation into a non-convex and combinatorial optimization problem. This paper analyzes the application of Particle Swarm Optimization (PSO) to portfolio construction under cardinality constraints, minimum and maximum asset weights, discrete weights, and limits associated with risk and portfolio turnover. The fitness function is formulated from the Sharpe ratio and includes penalties for violations of Conditional Value-at-Risk (CVaR), maximum drawdown, and turnover limits. The methodology is applied to a universe of five assets, imposing an exact cardinality of four positions, weights between 10 % and 35 % for selected assets, and discrete allocations in 5 % increments. The resulting portfolio is compared with a benchmark solution based on the classical Markowitz approach. Results show that PSO achieves lower annual volatility (18.63 % versus 19.80 %), lower daily 95 % CVaR (2.79 % versus 2.95 %), a lower maximum drawdown in absolute terms (27.77 % versus 29.61 %), and lower turnover (30 % versus 40 %). In exchange, annual return decreases from 19.87 % to 18.47 % and the Sharpe ratio from 0.9027 to 0.8837. The findings support PSO as a flexible alternative when operational feasibility and realistic investment constraints are explicitly incorporated into the portfolio optimization problem.

Keywords: Portfolio optimization; Particle Swarm Optimization; metaheuristics; cardinality constraints; CVaR.

Bibliografía

- [1] H. Markowitz, "Portfolio Selection," *The Journal of Finance*, vol. 7, no. 1, pp. 77–91, 1952. doi: 10.1111/j.1540-6261.1952.tb01525.x.
- [2] J. Kennedy and R. Eberhart, "Particle Swarm Optimization," in *Proceedings of ICNN'95 – International Conference on Neural Networks*, vol. 4, pp. 1942–1948, 1995. doi: 10.1109/ICNN.1995.488968.
- [3] T. Cura, "Particle swarm optimization approach to portfolio optimization," *Nonlinear Analysis: Real World Applications*, vol. 10, no. 4, pp. 2396–2406, 2009. doi: 10.1016/j.nonrwa.2008.04.023.
- [4] R. T. Rockafellar and S. Uryasev, "Optimization of Conditional Value-at-Risk," *The Journal of Risk*, vol. 2, no. 3, pp. 21–41, 2000. doi: 10.21314/JOR.2000.038.

De la programación lineal al Machine Learning: la convexidad como puente mediante geometría dinámica

Mariano A. González Ulloa

Pontificia Universidad Católica del Perú, Lima, Perú

mgonzal@pucp.edu.pe

Resumen.

Esta conferencia propone un recorrido desde la programación lineal hasta una primera aproximación al aprendizaje automático, con la convexidad como hilo conductor y la geometría dinámica como recurso de exploración y comprensión. El punto de partida será la interpretación geométrica de la programación lineal: la región factible, las curvas de nivel de la función objetivo y la localización de soluciones óptimas [1]. Mediante construcciones interactivas en GeoGebra [2], examinaremos qué ocurre al abandonar la linealidad y qué propiedades se conservan bajo hipótesis de convexidad. Este tránsito permitirá introducir la optimización convexa como una ampliación natural del marco inicial [3]. A continuación, una pregunta articulará el paso hacia el aprendizaje automático: ¿qué problemas de aprendizaje a partir de datos pueden formularse como la minimización de una función convexa? A partir de datos sintéticos, construiremos un modelo de regresión lineal y su función de pérdida cuadrática [4]. La exploración del espacio de parámetros permitirá visualizar cómo el ajuste del modelo corresponde a la búsqueda de un mínimo de dicha función. El propósito es mostrar una trayectoria matemática continua, en la que aprender los parámetros de un modelo adquiere una interpretación geométrica precisa. Sin suponer que todo problema de aprendizaje automático sea convexo, la conferencia destacará cómo la convexidad conecta problemas clásicos de optimización con modelos fundamentales del aprendizaje supervisado [5], y cómo la geometría dinámica puede hacer visible esa conexión.

Palabras clave: programación lineal; convexidad; optimización convexa; regresión lineal; aprendizaje automático; geometría dinámica.

Bibliografía

- [1] G. B. Dantzig and M. N. Thapa, *Linear Programming 1: Introduction*. Springer, 1997. doi: 10.1007/b97672.

- [2] M. Hohenwarter and J. Preiner, “Design guidelines for dynamic mathematics worksheets,” *Teaching Mathematics and Computer Science*, vol. 6, no. 2, pp. 311–323, 2008. doi: 10.5485/TMCS.2008.0182.
- [3] S. Boyd and L. Vandenberghe, *Convex Optimization*. Cambridge University Press, 2004. doi: 10.1017/CBO9780511804441.
- [4] G. James, D. Witten, T. Hastie, and R. Tibshirani, *An Introduction to Statistical Learning: with Applications in R*, 2nd ed. Springer, 2021. doi: 10.1007/978-1-0716-1418-1.
- [5] S. Shalev-Shwartz and S. Ben-David, *Understanding Machine Learning: From Theory to Algorithms*. Cambridge University Press, 2014. doi: 10.1017/CBO9781107298019.

Implementación en R de un modelo logístico de ecuaciones diferenciales para simular el crecimiento de tubérculos de papa a partir de parámetros publicados

Johnny Fernando Hidalgo Rodríguez

Universidad Politécnica Estatal del Carchi, Tulcán, Ecuador

johnny.hidalgo@upec.edu.ec

Resumen.

La acumulación de materia seca en los tubérculos de papa sigue típicamente una trayectoria en forma de S que puede representarse mediante una ecuación diferencial logística de primer orden. Este trabajo implementa dicho modelo en R utilizando el paquete `deSolve` y parámetros logísticos publicados, sin generar nuevas mediciones de campo. La ecuación diferencial ordinaria equivalente se resolvió numéricamente y se comparó con una serie temporal reconstruida a partir de un ajuste logístico publicado del peso seco del tubérculo (g planta⁻¹) frente a los días tras la emergencia. El desempeño del modelo se evaluó mediante el R^2 y el RMSE, y se simularon escenarios sencillos variando la tasa de crecimiento intrínseco (r) y la capacidad de carga (K). La solución numérica reprodujo la curva sigmoidea reconstruida y permitió una interpretación agronómica de situaciones como un llenado más lento o un techo de rendimiento más bajo. La contribución es de carácter metodológico: se presenta un flujo de trabajo reproducible y de bajo costo que vincula una ecuación clásica de crecimiento con software libre, apto para la capacitación agrícola y el análisis exploratorio de rendimientos. La principal limitación es la ausencia de calibración local; trabajos futuros deberían ajustar los parámetros r y K utilizando datos obtenidos directamente en campo.

Palabras clave: papa, ecuación logística, ecuaciones diferenciales ordinarias, `deSolve`, R, materia seca del tubérculo.

1. Introducción

La papa (*Solanum tuberosum* L.) es uno de los cultivos alimentarios de mayor importancia mundial por su aporte calórico, su adaptación a distintos ambientes y su papel en la seguridad alimentaria (Food and Agriculture Organization of the United Nations [FAO], 2025). Según FAOSTAT, la producción mundial alcanzó cerca de 390 millones de toneladas en 2024, con Asia como principal región productora (FAO, 2025). En sistemas agropecuarios de pequeña y mediana escala, estimar con anticipación la dinámica de llenado del tubérculo ayuda a programar riego, fertilización y fecha de cosecha.

El crecimiento de la planta y, en particular, la acumulación de materia seca en el tubérculo no es lineal. Tras la emergencia hay una fase lenta, luego un período de llenado acelerado y, cerca de la madurez, una estabilización. Esa trayectoria en forma de S ha sido descrita con funciones logísticas y de Gompertz ajustadas al tiempo cronológico o al tiempo térmico (Oliveira et al., 2016; Wen et al., 2024). Wen et al. (2024) mostraron que la acumulación de materia seca de tubérculos se ajusta de manera significativa a una ecuación logística del tipo

$$y = \frac{K}{1 + ae^{-bt}}, \quad (8.12)$$

con coeficientes de determinación altos y parámetros interpretables: K representa el máximo de materia seca y b se relaciona con la velocidad de acumulación.

Desde el punto de vista matemático, esa curva es la solución de una ecuación diferencial ordinaria (EDO) logística:

$$\frac{dY}{dt} = rY \left(1 - \frac{Y}{K}\right), \quad Y(t_0) = Y_0. \quad (8.13)$$

En esta formulación, $Y(t)$ es el peso seco de tubérculos, r es la tasa intrínseca de crecimiento y K es la capacidad de carga o rendimiento potencial. El modelo es simple, pero agronómicamente útil: un r menor describe un llenado más lento y un K menor describe un techo productivo más bajo, por ejemplo ante estrés hídrico o fotoperíodo desfavorable (Wen et al., 2024).

Los modelos mecanicistas de cultivo, como SUBSTOR-Potato o LINTUL-POTATO, representan con más detalle la fenología, la interceptación de luz y el reparto de asimilados (Kooman y Haverkort, 1995; Griffin et al., 1993, citados en enfoques de simulación de papa). Sin embargo, su parametrización exige muchos datos y no siempre es viable en un primer trabajo académico o en una revista regional. Una EDO logística no sustituye a esos modelos; ofrece una representación parsimoniosa de la curva de llenado cuando el objetivo es implementar, enseñar o explorar escenarios.

El lenguaje R permite resolver numéricamente sistemas de EDO mediante el paquete deSolve, que incorpora integradores robustos para problemas de valor inicial (Soetaert et al., 2010; R Core Team, 2025). Esta combinación es pertinente en agropecuaria porque el software es libre, reproducible y se puede documentar junto con los gráficos del ajuste.

Existe, no obstante, una dificultad práctica: no siempre se dispone de un ensayo propio con muestreos sucesivos de biomasa. En ese caso, una alternativa válida es reconstruir una serie temporal a partir de parámetros ya publicados, declarar con transparencia el origen de los datos y centrar el aporte en la implementación computacional. Wen et al. (2024) reportan, por ejemplo, para un tratamiento de día corto,

$$y = \frac{46.49}{1 + 37.63e^{-0.053t}}, \quad (8.14)$$

con y en g planta⁻¹ y t en días después de la emergencia ($R^2 = 0.97$). Esa ecuación permite generar puntos de referencia y verificar si la EDO equivalente, resuelta en R, reproduce la misma dinámica.

En este contexto, el objetivo del presente trabajo es implementar en R un modelo logístico de ecuaciones diferenciales para simular el crecimiento de tubérculos de papa a partir de parámetros publicados, evaluar la correspondencia entre la solución numérica y la serie reconstruida, e ilustrar el uso del modelo mediante escenarios de cambio en r y K .

2. Contribución Principal

Verificación de la implementación

La solución numérica de la ecuación diferencial logística, obtenida con deSolve entre los 30 y 120 días después de la emergencia, reprodujo la serie reconstruida a partir de Wen et al. (2024). En los siete tiempos de comparación, las diferencias absolutas fueron menores a 0.001 g planta⁻¹ (Tabla 8.4). Ese resultado era esperable: la EDO implementada es la forma diferencial de la misma curva logística publicada. Por tanto, esta primera comparación no demuestra un hallazgo agronómico nuevo; confirma que el script en R está correctamente formulado.

Los indicadores de correspondencia fueron:

$$R^2 = 1.000, \quad \text{RMSE} = 0.0002 \text{ g planta}^{-1}. \quad (8.15)$$

Cuadro 8.4: Peso seco de tubérculos reconstruido a partir de la ecuación publicada y peso seco simulado con la EDO en R.

t (días)	Y reconstruido (g planta ⁻¹)	Y simulado (g planta ⁻¹)	Diferencia (g planta ⁻¹)
30	5.36	5.36	0.00
45	10.41	10.41	0.00
60	18.13	18.13	0.00
75	27.24	27.24	0.00
90	35.24	35.24	0.00
105	40.63	40.63	0.00
120	43.65	43.65	0.00

Nota. Valores redondeados a dos decimales. La condición inicial fue $Y(30) = 5.36$ g planta⁻¹, $r = 0.053$ d⁻¹ y $K = 46.49$ g planta⁻¹.

El RMSE representa menos del 0.001 % de K . En términos prácticos, la curva numérica y la serie reconstruida coinciden a la escala de reporte del artículo.

La trayectoria simulada tuvo la forma de S típica del llenado del tubérculo:

- de 30 a 45 días el incremento fue de 5.05 g planta⁻¹;
- de 45 a 75 días se observó la fase más rápida (incremento de 16.83 g planta⁻¹);
- de 90 a 120 días el crecimiento se desaceleró (incremento de 8.41 g planta⁻¹) y la curva se acercó a la asíntota.

Al día 120, el modelo alcanzó 43.65 g planta⁻¹, equivalente al 93.9 % de K . Es decir, al final del intervalo todavía no se llega al máximo teórico, pero sí a la fase de estabilización.

Parámetros secundarios del escenario base

Los indicadores del escenario base se resumen en la Tabla 8.5.

Cuadro 8.5: Indicadores secundarios del escenario base.

Indicador	Valor
Tasa intrínseca (r)	0.053 d ⁻¹
Capacidad de carga (K)	46.49 g planta ⁻¹
Condición inicial ($Y(30)$)	5.36 g planta ⁻¹
Tiempo al 50 % de K	68.5 días
Peso al 50 % de K	23.25 g planta ⁻¹
Velocidad máxima $rK/4$	0.616 g planta ⁻¹ d ⁻¹
Peso al día 120	43.65 g planta ⁻¹
Fracción de K al día 120	0.939

El tiempo al 50 % de K coincide con el punto de inflexión de la logística: ahí la velocidad de acumulación es máxima. En este ejercicio esa máxima ocurrió hacia los 68–69 días después de la emergencia.




Figura 8.3: Acumulación de materia seca de tubérculos de papa (*Solanum tuberosum* L.) simulada con una ecuación diferencial logística implementada en R y valores reconstruidos a partir de la ecuación publicada por Wen et al. (2024). La línea punteada indica la capacidad de carga $K = 46.49$ g planta⁻¹.

Escenarios de simulación

Los cuatro escenarios se resolvieron con la misma condición inicial y el mismo intervalo de tiempo. Los resultados se resumen en la Tabla 8.6.

Cuadro 8.6: Peso seco simulado y parámetros derivados en cuatro escenarios del modelo logístico.

Escenario	r	K	$Y(60)$	$Y(90)$	$Y(120)$	$t_{50\%K}$	$rK/4$	$Y(120)/K$
Base	0.0530	46.49	18.13	35.24	43.65	68.5	0.616	0.939
Menor potencial ($-20\% K$)	0.0530	37.19	16.82	29.82	35.41	63.6	0.493	0.952
Llenado más lento ($-20\% r$)	0.0424	46.49	14.76	29.01	39.77	78.1	0.493	0.855
Condición combinada	0.0424	37.19	13.96	25.36	32.89	72.0	0.394	0.884

Nota. Y en g planta⁻¹. $t_{50\%K}$ es el día en que $Y = K/2$. $rK/4$ en g planta⁻¹ d⁻¹.

Comparación entre escenarios

Respecto al escenario base, el peso seco al día 120 cambió así:

- Menor potencial: $Y(120) = 35.41$ g planta⁻¹, esto es -18.9% .
- Llenado más lento: $Y(120) = 39.77$ g planta⁻¹, esto es -8.9% .
- Condición combinada: $Y(120) = 32.89$ g planta⁻¹, esto es -24.6% .

Reducir solo K tuvo un efecto casi proporcional sobre el peso final, porque la tasa r se mantuvo y la curva se acercó igualmente a su nueva asíntota (95.2 % de K). Reducir solo r no cambió el techo teórico, pero al día 120 la curva apenas llegó al 85.5 % de K : el cultivo, dentro del mismo calendario, quedó más lejos de su máximo. El escenario combinado fue el más restrictivo tanto en peso final como en velocidad máxima (0.394 g planta⁻¹ d⁻¹).

El tiempo al 50 % de K también se desplazó:

- base: 68.5 d;




Figura 8.4: Escenarios de simulación del modelo logístico: parámetros base, reducción del 20 % en la capacidad de carga (K), reducción del 20 % en la tasa intrínseca (r) y ambos cambios de manera simultánea.

- menor K : 63.6 d (la inflexión llega antes porque el techo es más bajo y Y_0 ya representa una fracción mayor de K);
- menor r : 78.1 d (el llenado se retrasa unos 10 días);
- combinado: 72.0 d.

Síntesis de lo que muestran los resultados

- El modelo diferencial implementado en R reproduce, con error numérico despreciable, la curva logística publicada.
- En el escenario base, el llenado más rápido ocurre alrededor de los 68 días después de la emergencia y al día 120 se alcanza cerca del 94 % del potencial K .
- Una caída del 20 % en K reduce el peso final en casi la misma proporción.
- Una caída del 20 % en r reduce menos el peso final, pero retrasa la fase de máxima acumulación.
- La combinación de ambos cambios produce la mayor pérdida al día 120 (−24.6 %).

Estos resultados corresponden a una simulación parametrizada con literatura, no a un ensayo de campo. Su valor está en demostrar que la implementación funciona y que el modelo responde de forma interpretable a cambios en r y K .

3. Conclusiones

La ecuación diferencial logística implementada en R reprodujo la curva de acumulación de materia seca de tubérculos obtenida a partir de parámetros publicados. La correspondencia entre la serie reconstruida y la solución numérica ($R^2 = 1.000$; RMSE = 0.0002 g planta⁻¹) verifica que el procedimiento computacional es correcto y reproducible.

En el escenario base, el modelo describió una trayectoria en forma de S, con la máxima velocidad de llenado alrededor de los 68.5 días después de la emergencia y un valor de 43.65 g planta⁻¹ al día 120, equivalente al 93.9 % de K .

Los escenarios mostraron efectos distintos de cada parámetro. Reducir K un 20 % disminuyó el peso seco final en 18.9 % y bajó el techo de la curva. Reducir r un 20 % retrasó la fase de llenado rápido

y dejó el valor al día 120 un 8.9% por debajo del caso base, aunque el máximo teórico no cambió. La reducción simultánea de ambos parámetros produjo la mayor pérdida al final del intervalo (24.6%).

El trabajo demuestra que un modelo diferencial simple, resuelto con software libre, permite simular e interpretar la dinámica de llenado del tubérculo cuando se parte de parámetros publicados. No sustituye a un ensayo de campo ni a un modelo mecanicista de cultivo. Su utilidad es metodológica y formativa: ofrece un flujo reproducible para vincular una ecuación diferencial con un problema agropecuario.

La calibración con datos locales, el uso de tiempo térmico y la validación en un ciclo independiente quedan como pasos necesarios para convertir este esquema en una herramienta de predicción.

Bibliografía

- [1] Food and Agriculture Organization of the United Nations, *FAOSTAT: Crops and livestock products*, 2025. Available: <https://www.fao.org/faostat/en/#data/QCL>
- [2] T. S. Griffin, B. S. Johnson, and J. T. Ritchie, *A simulation model for potato growth and development: SUBSTOR-Potato Version 2.0 (IBSNAT Research Report Series 02)*. Department of Agronomy and Soil Science, University of Hawaii, 1993. Available: https://pdf.usaid.gov/pdf_docs/PNABU293.pdf
- [3] P. L. Kooman and A. J. Haverkort, “Modelling development and growth of the potato crop influenced by temperature and daylength: LINTUL-POTATO,” in *Potato Ecology and Modelling of Crops under Conditions Limiting Growth*, A. J. Haverkort and D. K. L. MacKerron, Eds. Kluwer Academic Publishers, 1995, pp. 41–59. doi: 10.1007/978-94-011-0051-9_3.
- [4] J. S. Oliveira, H. E. Brown, A. Gash, and D. J. Moot, “An explanation of yield differences in three potato cultivars,” *Agronomy Journal*, vol. 108, no. 4, pp. 1434–1446, 2016. doi: 10.2134/agronj2015.0486.
- [5] R Core Team, *R: A Language and Environment for Statistical Computing*. R Foundation for Statistical Computing, Vienna, Austria, 2025. Available: <https://www.R-project.org/>
- [6] K. Soetaert, T. Petzoldt, and R. W. Setzer, “Solving differential equations in R: Package deSolve,” *Journal of Statistical Software*, vol. 33, no. 9, pp. 1–25, 2010. doi: 10.18637/jss.v033.i09.
- [7] L. Wen, M. Meng, K. Liu, Q. Zhang, T. Zhang, Y. Chen, and H. Liang, “Effect of photoperiod on dry matter accumulation and partitioning in potato,” *Agriculture*, vol. 14, no. 7, Art. no. 1156, 2024. doi: 10.3390/agriculture14071156.
- [8] H. Wickham, *ggplot2: Elegant Graphics for Data Analysis*. Springer-Verlag, 2016. Available: <https://ggplot2.tidyverse.org>

Minimization Models using Proximal Comixtures

Diego J. Cornejo

Universidad del Pacífico, Lima, Perú

dj.cornejok@up.edu.pe

Resumen. In minimization models for image recovery and data analysis problems, loss functions and linear operators are typically aggregated as an average of composite terms. We propose an alternative minimization model based on proximal comixtures, an operation which combines functions and linear operators in such a way that the proximity operator of the resulting function is computable explicitly in terms of the individual proximity and linear operators. The mathematical properties of this operation

are analyzed, and numerical illustrations of the benefits of these models are provided in the context of image recovery and machine learning applications.

Keywords: convex minimization, proximal average, proximal comixture.

1. Introduction

The objective of various tasks in the areas of inverse problems and data analysis is to determine the value of a mathematical object (an image, a signal, a set of parameters, a distribution, a covariance matrix, a spectrum, etc.) conveying information of interest using experimental measurements and some a priori knowledge (data formation model, properties of the target solution, etc.). The most prevalent minimization framework in data analysis consists in minimizing an objective function which aggregates the loss functions $(g_k)_{1 \leq k \leq p}$ and the linear operators $(L_k)_{1 \leq k \leq p}$ by means of the standard composite averaging operation $\sum_{k=1}^p \alpha_k g_k \circ L_k$. We propose the use of the *proximal comixture* $\text{pcm}_\gamma(g_k, L_k)$, a generalization of the *proximal average*, as an alternative to the standard composite average.

2. Main Contribution

This section summarizes some contributions of the work:

- we formulate the proximal comixture model

$$\min_{x \in \mathcal{H}} f(x) + (\text{pcm}_\gamma(g_k, L_k)_{1 \leq k \leq p})(x) + h(x); \quad (8.16)$$

- we show that solving (8.16) requires the splitting of only 3 terms;
- we provide an algorithm for solving (8.16), which requires minimum variable storage;
- we illustrate the proposed comixture model through several experiments.

3. Conclusions

We proposed a new minimization model based on proximal comixtures, and analyzed the mathematical properties of these aggregation operations and presented comparisons with standard composite averages. The benefits of the proximal comixtures compared to the standard composite averages in terms of modeling and algorithmic implementation were discussed. Finally, we have provided numerical illustrations in the context of image recovery and data analysis.

Joint work with:

Patrick L. Combettes¹, Department of Mathematics, NC State University, Raleigh, USA.

Bibliografía

- [1] H. H. Bauschke, R. Goebel, Y. Lucet, and X. Wang. The proximal average: Basic theory. *SIAM Journal on Optimization*, 19(2):766–785, 2008.
- [2] P. L. Combettes, Resolvent and proximal compositions. *Set-Valued and Variational Analysis*, 31(22): 29 pp., 2023.
- [3] P. L. Combettes and D. J. Cornejo. Variational analysis of proximal compositions and integral proximal mixtures. *Evolution Equations and Control Theory*, 17:106–139, 2026.
- [4] P. L. Combettes and D. J. Cornejo. Proximal comixture minimization models for image recovery and data analysis. *SIAM Journal on Imaging Sciences*, to appear.

¹This work was supported by the U.S. National Science Foundation under grant CCF-2211123. E-mail: plc@math.ncsu.edu

Método Proximal Estocástico Riemanniano con Margen Geodésico Adaptativo para Clasificación de Subespacios

Josué David Fasanando Pinedo

Universidad Nacional Mayor de San Marcos, Lima, Perú

josue.fasanando@unmsm.edu.pe

Resumen. La clasificación de datos de alta dimensión representados mediante subespacios lineales plantea dificultades asociadas con la estructura geométrica no euclídea de los datos y la variabilidad intrínseca de las clases. En este trabajo se propone un método proximal estocástico riemanniano para la clasificación supervisada de subespacios representados como puntos de la variedad de Grassmann. La propuesta incorpora un margen geodésico adaptativo determinado a partir de la dispersión intraclase, con el propósito de establecer una separación discriminativa dependiente de la geometría de cada categoría. El problema de aprendizaje se formula mediante una función de pérdida basada en distancias geodésicas y regularización, cuya optimización se realiza mediante estimaciones estocásticas del gradiente obtenidas mediante minibatches y una etapa proximal en el espacio tangente de la variedad. Asimismo, se incorpora un mecanismo adaptativo para el tamaño de paso en función de la variabilidad del gradiente estocástico. Se establecerán condiciones para analizar la convergencia del esquema propuesto y se evaluará su comportamiento mediante experimentos con conjuntos de datos de alta dimensión. El desempeño se analizará considerando precisión de clasificación, estabilidad, convergencia y costo computacional, mediante comparación con métodos riemannianos de referencia.

Palabras clave: Optimización riemanniana; variedad de Grassmann; aprendizaje automático; clasificación de subespacios; optimización estocástica.

Resumen. The classification of high-dimensional data represented by linear subspaces presents challenges associated with the non-Euclidean geometric structure of the data and the intrinsic variability of the classes. This work proposes a Riemannian stochastic proximal method for supervised classification of subspaces represented as points on the Grassmann manifold. The proposed approach incorporates an adaptive geodesic margin determined from within-class dispersion in order to establish a discriminative separation that depends on the geometry of each class.

The learning problem is formulated through a loss function based on geodesic distances and regularization, whose optimization is performed using stochastic gradient estimates obtained from mini-batches together with a proximal step in the tangent space of the manifold. In addition, an adaptive step-size mechanism based on the variability of the stochastic gradient is incorporated.

Conditions for analyzing the convergence of the proposed scheme will be established, and its computational behavior will be evaluated using high-dimensional datasets. Performance will be assessed in terms of classification accuracy, stability, convergence, and computational cost through comparisons with reference Riemannian methods.

Keywords: Riemannian optimization; Grassmann manifold; machine learning; subspace classification; stochastic optimization.

Bibliografía

- [1] R. Bergmann, H. Jasa, P. John, and M. Pfeffer, “The intrinsic Riemannian proximal gradient method for nonconvex optimization,” *arXiv preprint*, arXiv:2506.09775, 2025. <https://arxiv.org/abs/2506.09775>

- [2] B. Wang, S. Ma, and L. Xue, “Riemannian stochastic proximal gradient methods for nonsmooth optimization over the Stiefel manifold,” *Journal of Machine Learning Research*, vol. 23, no. 106, pp. 1–33, 2022. <https://jmlr.org/papers/v23/21-0314.html>
- [3] H. Wang, Z. Li, and W. Zhang, “Get the best of both worlds: Improving accuracy and transferability by Grassmann class representation,” in *Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV)*, pp. 22421–22430, 2023. <https://doi.org/10.1109/ICCV51070.2023.02054>

Automatización mediante Inteligencia Artificial del diseño estructural de reservorios circulares para almacenamiento de agua para consumo humano como solución definitiva de la brecha de agua potable y la anemia en el Perú

Cesar E. Villar Guerra

Universidad Nacional Mayor de San Marcos, Lima, Perú

iaconst4.0@gmail.com

Resumen. El presente trabajo aborda la crisis de salud pública y la brecha de agua potable y la anemia en el interior de Perú, donde la falta de infraestructura de saneamiento obliga a las poblaciones rurales a consumir agua no tratada, desencadenando altos índices de parasitosis y anemia infantil crónica. Si bien la construcción de reservorios circulares de concreto armado constituye una solución definitiva para garantizar el suministro seguro de agua potable, los métodos tradicionales de diseño estructural son lentos, costosos e ineficientes frente a la magnitud de la demanda nacional. Como respuesta, se propone el desarrollo de un aplicativo de cuarta generación basado en Inteligencia Artificial, específicamente mediante Redes Neuronales Artificiales (ANN), para automatizar el diseño de estas estructuras. La metodología consistió en la simulación paramétrica automatizada de una muestra de 500 modelos estructurales únicos mediante la API de SAP2000 bajo las normativas sismorresistentes peruanas, construyendo una base de datos robusta para el entrenamiento supervisado de la red. Los resultados muestran que la ANN predice con alta precisión los esfuerzos internos de diseño (momentos flectores y fuerzas cortantes), reduciendo drásticamente los tiempos de procesamiento en comparación con el análisis convencional de elementos finitos. El aplicativo final integra estos modelos para generar de manera instantánea memorias de cálculo, metrados y planos listos para licitación y construcción. Se concluye que esta herramienta tecnológica es una solución disruptiva viable que acelera la viabilidad de los proyectos de saneamiento, optimiza los recursos públicos y contribuye directamente a la mitigación de la brecha de agua potable y la erradicación de la anemia en el país.

Palabras clave: Deep Learning, Anemia, Automatización, Reservorios Circulares, Saneamiento.

Introducción

En el interior del Perú, las deficiencias estructurales en el acceso a agua segura y saneamiento básico representan un factor determinante en la persistencia de crisis de salud pública, tales como la anemia infantil y los impactos de las sequías estacionales. A pesar de las políticas gubernamentales y normativas existentes, persisten brechas enormes de implementación y gestión, especialmente en las regiones de

la Amazonía y la sierra rural [7]. Esta falta de acceso condena a múltiples poblaciones a depender de suministros no controlados, consolidando un escenario crónico donde la contaminación microbiológica y química, como el arsénico, actúan como un mecanismo de afectación a la salud biológica de la población vulnerable [7].

El impacto biológico de esta carencia de infraestructura es sumamente agudo. Cuando las comunidades rurales no disponen de obras físicas adecuadas de almacenamiento y distribución, se ven obligadas a abastecerse de agua superficial directamente de acequias, manantiales, ríos y quebradas, lo que eleva significativamente el riesgo de padecer déficit de hemoglobina [7]. Esta práctica sistemática conduce a la ingesta directa de patógenos del agua de consumo, reportando altas tasas de parasitosis causadas por nematodos y helmintos específicos como *Trichuris trichiura*, *Taenia* spp. y *Ascaris lumbricoides*, los cuales están directamente relacionados con la aparición de la anemia severa por pérdida de hierro [6, 8].

A nivel nacional y regional, esta problemática se agudiza al observar las severas deficiencias de infraestructura y su correlato con los indicadores de vulnerabilidad social. En el Perú, las condiciones estructurales limitan las capacidades productivas de los ciudadanos, de modo que el 51.6% de los hogares carece de un acceso integrado a los cuatro servicios básicos esenciales, entre los cuales el agua y el desagüe son fundamentales para quebrar el ciclo de la pobreza [2]. Esta alarmante carencia de servicios se manifiesta con especial crudeza en regiones del sur andino como Puno, un territorio golpeado por heladas e inseguridad hídrica en el que la falta de agua tratada se traduce directamente en que el 80% de los niños menores de tres años sufre de anemia crónica [2].

Frente a esta situación, la construcción de reservorios circulares de concreto armado para consumo humano emerge como una solución de ingeniería civil indispensable. Es fundamental recalcar que esta obra de infraestructura representa una solución definitiva al problema y no una alternativa paliativa o transitoria, ya que ataca directamente la raíz de la vulnerabilidad hídrica al garantizar la hermeticidad, potabilización y continuidad del suministro de agua potable a largo plazo.

No obstante, el diseño y cálculo manual tradicional de estos reservorios circulares resulta ineficiente, lento y costoso para la escala de demanda que exige el Perú interior. La automatización del diseño de estas infraestructuras mediante herramientas de Inteligencia Artificial (IA) representa una oportunidad disruptiva para acelerar la viabilidad de los proyectos de saneamiento, reduciendo tiempos de cálculo estructural y optimizando el uso de recursos para mitigar los impactos de la anemia y asegurar la resiliencia hídrica. Es en este contexto que se plantea y desarrolla esta investigación, orientada al desarrollo de una aplicación de cuarta generación para la automatización del diseño de reservorios de concreto armado para su construcción masiva en el Perú.

Problema general

¿De qué manera el desarrollo de una plataforma basada en Inteligencia Artificial y redes neuronales artificiales (ANN) optimizará el proceso de diseño estructural automatizado de reservorios circulares de concreto armado, como una solución definitiva para mitigar la brecha de agua potable y su impacto en la anemia infantil en el Perú?

Problemas específicos

- P1:** ¿De qué manera se puede estructurar una base de datos paramétrica y robusta de momentos flectores y fuerzas cortantes mínimos, considerando el empuje hidrostático y las demandas estructurales correspondientes a las diferentes zonas sísmicas del país?
- P2:** ¿Con qué nivel de precisión una red neuronal artificial (ANN) puede predecir los esfuerzos internos de diseño en reservorios circulares bajo solicitaciones sísmicas, reduciendo el tiempo de procesamiento en comparación con el análisis convencional por elementos finitos, para acelerar la viabilidad de los proyectos de saneamiento?

Contribución Principal

Desarrollo teórico

Para la presente investigación y desarrollo del aplicativo, la población de interés de carácter teórico-tecnológico está constituida por el universo finito de todas las configuraciones geométricas, volumétricas

y operativas posibles de reservorios circulares de concreto armado apoyados, con capacidades de mediano a mínimo volumen, proyectados para los sistemas de agua potable y saneamiento en el ámbito urbano y rural del Perú, priorizando la continuidad y hermeticidad del suministro a largo plazo.

Específicamente, las unidades de análisis que integran esta población cumplen con los siguientes criterios de inclusión homogéneos:

- **Geometría:** estructuras cilíndricas de sección delgada y simetría axial.
- **Condición de borde:** reservorios apoyados directamente sobre el terreno, con base rígida o flexible.
- **Rango de capacidades:** volúmenes de almacenamiento comprendidos entre los 10 m^3 y los 350 m^3 (rango promedio para proyectos de inversión pública en la región).
- **Criterio normativo:** estructuras sometidas a las solicitaciones de las Normas Técnicas Peruanas vigentes E.030 (Diseño Sismorresistente) y E.060 (Concreto Armado) y ACI 350, considerando los parámetros sísmicos de la Zona 4 correspondientes a la costa del Perú.

Muestra

La muestra seleccionada estará conformada por 500 muestras estructurales únicas generadas y simuladas computacionalmente mediante la Interfaz de Programación de Aplicaciones (API) de SAP2000 (software de elementos finitos para análisis estructural). Esta muestra se estructurará mediante una matriz de análisis combinatorio que cruzará paramétricamente las siguientes variables geométricas y de sitio:

- **Diámetros exteriores:** desde 2.00 m hasta 9 m, con incrementos discretos.
- **Alturas de agua (carga hidráulica):** desde 2.00 m hasta 6.00 m.
- **Espesores de pared (muro):** desde 0.175 m hasta 0.40 m.
- **Zonificación sísmica:** escenarios sísmicos específicos para la Zona 4.
- **Tipo de suelo de fundación:** perfiles de suelo según la norma E.030-2026.

Formulación de modelos

El desarrollo del estudio se ejecutará de forma secuencial a través de cuatro fases metodológicas ordenadas fuera de la implementación a una interfaz de aplicación:




Figura 8.5: Metodología de la investigación.

Fase 1. Configuración de la API y Estandarización Normativa: Se desarrollará el código fuente en el entorno de programación de cuarta generación (4GL). Se establecerá el enlace de comunicación síncrona con la Interfaz de Programación de Aplicaciones (API) de SAP2000. Se programarán las rutinas lógicas que calculan las presiones hidrostáticas e hidrodinámicas de manera automática, aplicando el modelo de masas acopladas (impulsiva y convectiva) bajo las exigencias de la Norma Técnica Peruana E.030.

Fase 2. Simulación Paramétrica y Construcción de la Base de Datos: El algoritmo ejecutará un bucle de iteración paramétrica automática para generar secuencialmente los 500 modelos que integran la muestra. Para cada variante, el software creará la geometría del tanque circular, asignará los espesores de pared, aplicará las cargas sísmicas hidrodinámicas y correrá el análisis por elementos finitos. Los diagramas de esfuerzos resultantes de cada simulación se extraerán de los nodos estructurales y se guardarán automáticamente en las Fichas de Registro Digital.

..... BASE DE DATOS: Z=0.45 Y SC=500kg/m2

La base de datos a tomar en cuenta:

	D	hm	HL	ssuelo	tp	tl	lvtecho	abertura	h_contrapiso1	mu22	mu11	mu22_serv	mu11_serv	vu23max	vu13max	mu22losa	mu11losa	vumaxlosa
0	6.775	5.950	5.750	1.20	1.00	2.35	0.35	0.65	0.025	5.488	1.448	0.380	0.076	4.358	13.742	0.997	1.981	2.687
1	3.275	4.375	4.125	1.05	0.95	2.20	0.45	0.85	0.050	4.406	1.161	0.304	0.061	3.494	11.044	0.700	1.442	1.938
2	7.075	5.475	5.100	0.85	1.15	2.70	0.30	1.10	0.025	5.137	1.361	0.357	0.071	4.122	12.921	1.022	2.031	2.756
3	8.625	2.100	1.850	1.05	0.50	2.30	0.30	0.85	0.100	2.817	0.747	0.196	0.039	2.247	7.112	1.153	2.292	3.109
4	7.900	3.825	3.525	1.25	0.30	2.10	0.05	0.65	0.000	4.003	1.061	0.278	0.056	3.193	10.069	1.142	2.170	2.944
...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...
495	3.675	6.300	5.900	1.05	0.65	2.90	0.35	0.65	0.200	5.704	1.512	0.421	0.079	4.574	14.372	0.784	1.509	1.980
496	3.325	5.700	5.425	1.00	0.90	2.20	0.35	0.85	0.000	5.316	1.402	0.368	0.074	4.246	13.310	0.705	1.400	1.900
497	7.825	7.650	7.450	0.95	0.40	1.60	0.10	0.75	0.075	6.656	1.757	0.461	0.117	5.289	16.680	1.136	2.157	2.927
498	8.550	6.675	6.625	1.05	0.75	2.20	0.45	0.60	0.025	6.124	1.616	0.449	0.085	4.865	15.366	1.197	2.279	3.092
499	3.475	3.575	3.200	1.10	0.85	2.50	0.45	0.90	0.075	3.831	1.015	0.266	0.078	3.056	9.662	0.717	1.476	1.984

Figura 8.6: Base de datos de las distintas configuraciones de reservorios circulares de agua.




Figura 8.7: Visualización de datos de entrada.

Fase 3. Arquitectura, Entrenamiento y Ajuste de la Red Neuronal (ANN): La base de datos de 500 registros se normalizará estadísticamente dentro de un rango homogéneo (por ejemplo, de 0 a 1) para optimizar la velocidad de convergencia matemática. Se estructurará la red neuronal artificial (*Feed-Forward*) definiendo el número de capas ocultas, la cantidad de neuronas por capa y las funciones de activación no lineales (como Sigmoido o ReLU). Se iniciará el proceso de aprendizaje supervisado mediante el algoritmo de retropropagación (*Backpropagation*).

Se muestran solo algunos modelos considerados para el aplicativo para predicción de los esfuerzos en los elementos estructurales como muros, losa techo, etc.

Fase 4. Validación Tecnológica y Análisis Estadístico: Se someterá a la red neuronal entrenada a un conjunto de datos de prueba (*testing*) como evaluación del rendimiento predictivo del software,




Figura 8.8: Modelo de red neuronal para predicción del momento flector mu22 (en los muros).




Figura 8.9: Modelo de red neuronal para predicción del momento flector mu11 (en los muros).

calculando el Error Medio Absoluto Porcentual (MAPE) y el coeficiente de determinación (R^2), contrastando directamente los valores de la red neuronal contra los del análisis numérico convencional para confirmar la hipótesis causal.

Implementación de modelos en interfaz para aplicaciones: Finalmente, se implementan los modelos en un aplicativo para diseño estructural de reservorios circulares de concreto armado para almacenamiento de agua y acceso a la población al agua.

Resultados numéricos

Finalmente, los modelos entrenados son implementados en un aplicativo para la predicción de los esfuerzos en los elementos de concreto armado para generación de las memorias de cálculo, planos de construcción listos para licitación-construcción y metrados de reservorios circulares de concreto armado.

Conectar la inteligencia artificial y la automatización con el corazón de nuestras comunidades. Detrás de cada cálculo optimizado y automatización de un reservorio de agua en cualquier departamento del Perú, el objetivo supremo es llevar progreso, equidad y la felicidad, sin anemia, a cada peruano.

Conclusiones

El aplicativo final desarrollado soluciona de manera integral y definitiva el problema planteado al transformar un proceso de ingeniería civil tradicionalmente lento y complejo en un sistema auto-




Figura 8.10: Modelo de red neuronal para predicción del momento flector de servicio μ_{22_serv} .




Figura 8.11: Modelo de red neuronal para predicción del momento flector de servicio μ_{11_serv} (para verificación de fisuración del muro).

matizado de alta velocidad y precisión. Al sustituir las prolongadas fases de modelamiento numérico convencional por predicciones instantáneas basadas en redes neuronales artificiales, la plataforma elimina el cuello de botella técnico que retrasa la aprobación de proyectos de infraestructura hídrica.

El software no solo optimiza el cálculo de los esfuerzos estructurales bajo exigentes criterios sísmo-resistentes, sino que automatiza la salida de los entregables críticos del proyecto: planos constructivos, memorias de cálculo y metrados. De este modo, la tecnología sirve como un puente directo para acelerar masivamente la viabilidad técnica y legal de los reservorios en las regiones más vulnerables del Perú.

Al viabilizar la construcción masiva y eficiente de estas obras de almacenamiento herméticas y seguras, el aplicativo ataca la raíz de la vulnerabilidad sanitaria, garantizando el acceso a agua potable de calidad y rompiendo el ciclo biológico de la parasitosis y la anemia infantil en las comunidades rurales.

Los modelos presentados no implican un entrenamiento con una base de datos mediana o grande, basta con el número de ejemplos planteados en esta investigación.

Los valores utilizados para el entrenamiento fueron escalados según el tipo de modelo empleado en la investigación.

Deben plantearse y entrenarse más modelos para la predicción de esfuerzos intermedios y bajos en los elementos estructurales como un soporte más integral y la posible sustitución total de los softwares de elementos finitos.

Se recomienda ampliar el entrenamiento hacia las demás zonas sísmicas del Perú como $Z = 0.35$, 0.25 y 0.1 , así como su posterior implementación en el aplicativo por el carácter de urgencia para eliminar la anemia y dar acceso masivo al recurso hídrico por la construcción de reservorios de agua




Figura 8.12: Modelo de red neuronal para predicción del cortante vu23max (en los muros).




Figura 8.13: Modelo de red neuronal para predicción del cortante vu13max (en los muros).

potable a la población del Perú.

Bibliografía

- [1] J. Canchari, "Extensión para el Modelamiento, Análisis y Diseño Automatizado de Reservorios Circulares en Sap 2000," Ponencia, XVII Congreso Nacional de Ingeniería Civil (XVII CONIC), Perú, 2009.
- [2] R. Chang y M. C. Villegas, *Los 10 números que todo peruano debe conocer: Una guía esencial para el debate económico*. Crítica, 2026.
- [3] Colegio de Ingenieros del Perú [CIP Lima], *Reporte institucional sobre la capacidad de almacenamiento hídrico e infraestructura de saneamiento en el Perú*. CIP, 2026.
- [4] M. Jimeno, *Análisis Estructural y Modelación del Reservorio Convencional*. Tesis de pregrado, Universidad Nacional del Centro del Perú, Repositorio Institucional UNCP, 2021.
- [5] Ministerio de Economía y Finanzas [MEF], *Decreto Supremo N.º 039-2026-EF: Priorización de proyectos de inversión en agua y saneamiento a nivel nacional*. Diario Oficial El Peruano, 2026.
- [6] Ministerio de Salud [MINSA], "Mecanismo causal (Parasitosis) y alta prevalencia de *Trichuris trichiura* en la sierra peruana," Biblioteca Virtual en Salud del MINSA, s.f.
- [7] Researchonline, "Prevalence of and factors associated with childhood anemia in remote villages of the Peruvian Amazon," Escuela de Higiene y Medicina Tropical de Londres, 2023.
- [8] Universidad Nacional de Cajamarca [UNC], "Asociación estadísticamente significativa entre la presencia de parásitos en el agua de consumo y la prevalencia de anemia en menores de 5 años en

Navegación

COAR 1.0

Selección una página

Diseño de 1 unidad

Información del Sistema

145300000, 20 de septiembre de 2026

DATOS ESTRUCTURA DE ALMACENAMIENTO

Seleccione el Diámetro (sin acabados) D:

Seleccione la Altura total de reservorio (desde cara superior losa cimentación a cara superior de losa techo) (Ht):

Seleccione la Altura de agua (menor a Ht) (Hl):

Seleccione la sobrecarga en techo (kg/cm2):

Coefficiente de balasto (kg/cm3):

Capacidad admisible (kg/cm2):

Seleccione Z:

Seleccione U:

Seleccione S:

Seleccione la profundidad de cimentación (Df):

Seleccione longitud de volado en techo (Ltecho):

Altura contrapiso sobre losa techo (h_contrapiso1):

Altura contrapiso sobre losa cimentación (h_contrapiso2):

Resistencia del concreto f_c (kg/cm2) en superestructura:

Resistencia del concreto f_c (kg/cm2) en cimentación:

Ancho de abertura en techo:

Seleccione Factor modificación de respuesta R:

COAR 1.0, específicamente en:

Figura 8.14: Aplicativo de cuarta generación reservorios.

RESULTADOS AL INSTANTE

Memoria_cálculo-est_01.doc descargado ✓

Planos-est_01 descargado ✓

Modelomat-est_01.sdb descargado ✓

Metrados-est_01.ex descargado ✓

Descargar Documentos

Enviar por WhatsApp

Enviar por Gmail

Desarrollado por IASOLUCIONES - 2026

Figura 8.15: Output básico (1.0) de aplicación.

la provincia de Hualgayoc,” Tesis de pregrado, Universidad Nacional de Cajamarca, Repositorio Institucional UNC, 2024.




Figura 8.16: Generación modelo matemático estructural.




Figura 8.17: Generación de plano(s) listo(s) para construcción/licitación.

Instituciones

