



Doi: <https://doi.org/10.70577/asce.v5i3.928>

Recibido: 2026-06-28

Aceptado: 2026-07-08

Publicado: 2026-07-28

Algoritmos de Regresión del Proceso Gaussiano para la Predicción de Agua para Riego

Gaussian Process Regression Algorithms for Irrigation Water Prediction

Autor(s)

Ing. Tamara Liriana Briones Lascano ¹

tbriones@uagraria.edu.ec

<https://orcid.org/0009-0002-1706-8880>

Universidad Agraria del Ecuador

Guayaquil - Ecuador

Ing. Jhonny Choez Burgos ²

jchoez@uagraria.edu.ec

<https://orcid.org/0000-0003-3001-4561>

Universidad Agraria del Ecuador

Guayaquil - Ecuador

Como Citar

Briones Lascano, T., & Choez Burgos, J. (2026). Algoritmos de Regresión del Proceso Gaussiano para la Predicción de Agua para Riego. *ASCE MAGAZINE*, 5(3), 1182-1192. <https://doi.org/10.70577/asce.v5i3.928>



Resumen

A medida que el cambio climático afecta la producción de alimentos y el precio del agua aumenta, la forma en que se gestiona el agua para la agricultura se ha convertido en un asunto de enorme importancia y creciente atención y urgencia. La Ciencia de Datos, en este sentido, aparece como una herramienta clave que nos puede ayudar a maximizar los recursos hídricos con ayuda de algoritmos de predicción. Una revisión sistemática del uso de algoritmos de regresión del proceso gaussiano para predecir la demanda de agua de riego. Incluye los fundamentos teóricos del GPR, así como sus aplicaciones hidrogeológicas y agrícolas. Según los principales resultados obtenidos, la Regresión del Proceso Gaussiano (GPR) es una técnica firme y precisa para predecir la demanda de agua y como cuantifican la incertidumbre y se adapta bien a datos escasos o dispersos.

La investigación enfatiza ciertas variables como la temperatura, humedad del suelo, índices de vegetación, entre otros fenómenos que se estudiaron. Aquí se presenta la necesidad de contar con modelos híbridos que eviten las limitaciones de la Regresión de Proceso Gaussiano.

Se concluye que la integración del GPR y otras herramientas que provienen de la disciplina de la ciencia de datos logra una administración anticipada, duradera del agua. El riego agrícola ofrece un aumento importante en su eficacia

Palabras clave: Regresión del Proceso Gaussiano (GPR), Riego agrícola, Ciencia de Datos, Predicción de la demanda de agua, Gestión del agua, Incertidumbre



Abstract

Effective water stewardship in agriculture commands global attentiveness, particularly considering climate change and its effect on food security. Consequently, Data Science offers itself as a crucial tool, maximizing water resources by applying powerful predictive models. This document shares a comprehensive literature examination of current research. It concentrates on employing Gaussian Process Regression (GPR) algorithms to forecast irrigation water needs. The analysis also explores the theoretical bedrock of GPR alongside its hydrological and agricultural applications, something quite essential.

Key discoveries indicate that GPR provides a dependable and precise method for forecasting water demand. Specifically, it can quantify uncertainty. Also, it's useful when dealing with datasets that are either limited or scattered. The research highlights some essential variables: atmospheric temperature, soil moisture, and even vegetation indices. These factors are critically important in predictive analysis, which are quite important. Emphasis is also given to hybrid models; they help overcome limitations in Gaussian Process Regression.

The presented investigation reveals integrating GPR with other data science instruments promotes a more proactive and sustainable plan for water management. So, agricultural irrigation systems' performance see marked gains, supporting enhanced decisions on allocating resources alongside long term water preservation plans.

The investigation conclusively highlights the substantial promise inherent within data-centric approaches like Gaussian Process Regression, establishing them as vital for fostering enduring agricultural practices amid a global landscape defined by environmental challenges and diminishing resources.

Keywords: Gaussian Process Regression (GPR), Agricultural Irrigation, Data Science, Water Demand Prediction, Water Management, Uncertainty.

Introducción

El agua es, un bien escaso fundamental para la seguridad alimentaria mundial; cuya relevancia es incuestionable. La combinación de una población en auge, y las consecuencias del cambio climático, amplifican sin cesar la demanda sobre los recursos hídricos. La agricultura es, el mayor usuario de agua dulce a nivel mundial, lo que la ha llevado a ocupar un lugar central en esta crisis; ahora enfrentada al deber de elevar la productividad por cada gota de agua empleada, esto es la eficiencia del uso del agua (Mansour et al., 2022). Resulta urgente modernizar los sistemas tradicionales de riego, usualmente poco eficaces y fundamentados en presunciones, y reemplazarlos por la agricultura de precisión, indispensable para la perdurabilidad del sector (Ajith et al., 2025).

En esta época digital, la Ciencia de Datos emerge como pilar tecnológico en la agricultura de precisión. Es el aprendizaje automático el que, tras analizar enormes conjuntos de datos, incluyendo sensores, imágenes satelitales y registros meteorológicos, permite tener modelos predictivos pueden evaluar con exactitud las necesidades hídricas de los cultivos y optimizan los calendarios de riego (Ajith et al., 2025).

Este método permite tomar decisiones sensatas y transformar la gestión hídrica de un enfoque reactivo a un modelo preventivo y basado en evidencias (Lu et al., 2022)

La GPR (Gaussain Process Regression) se induce dentro del aprendizaje supervisado. Se refiere a una técnica que hace uso de la teoría bayesiana y la estadística, cuyo propósito es la resolución de tareas que tienen que ver con la regresión y clasificación de datos (Pedregosa et al., 2011). Aunque la GPR es, como otros modelos, una caja negra, en contraposición a otros modelos, puede generar múltiples predicciones y no solo una, puesto que devuelve una predicción con incertidumbre (Wang et al., 2023).

Esta habilidad del GPR resulta crucial en la agricultura. La variabilidad natural del suelo, el clima cambiante y la dinámica del cultivo ofrecen un alto grado de riesgo e inestabilidad. Por su capacidad para modelar relaciones complejas y no lineales, el GPR es muy útil para predecir series de tiempo y espacio, y también en la hidrología y en la agricultura (Pedregosa et al., 2011).

Este artículo de revisión perspectiva, busca responder una pregunta científica primordial: ¿De qué manera la ciencia de datos puede potenciar la eficiencia del riego agrícola?

Para responder esta interrogante, la investigación examina la optimización del riego en cultivos mediante modelos predictivos; GPR es el núcleo del análisis. El agua, recurso vital escaso para la seguridad alimentaria mundial, es fundamental; su importancia, indiscutible. Un crecimiento demográfico desenfrenado, conjuntamente con los efectos del cambio climático, intensifican implacablemente la exigencia sobre nuestros recursos hídricos. La agricultura es la consumidora principal de agua dulce mundial, se ubica en el centro de esta problemática; frente a la necesidad de incrementar la productividad por cada gota usada (Mansour et al., 2022). Es crucial transformar los sistemas de riego clásicos, por la agricultura de precisión, clave para la supervivencia del sector (Ajith et al., 2025).

Material y métodos

Este documento enfocará su atención únicamente en el predicción de la Gestión del Agua en agricultura mediante el uso de la Regresión de Procesos Gaussianos (GPR).

La búsqueda se diseñó para obtener la literatura más relevante y actual sobre el tema. Esto se logró mediante la definición de términos y el uso de operadores booleanos. En este caso, la búsqueda fue (“Gaussian Process Regression” OR “GPR”) AND (“irrigation” OR “water prediction” OR “crop water demand” OR “hydrology” OR “agriculture” OR “forecasting”). Las bases de datos académicas especializadas utilizadas fueron Scopus , Web of Science y Google Scholar, aplicando criterios de inclusión y exclusión pertinentes para acotar el corpus de revisión. Se tuvieron en cuenta el resto de artículos de revistas, actas o capítulos publicados en inglés o español hasta 2025, que aplicaran o discutieran la Regresión del Proceso Gaussiano en el contexto del uso de recursos hídricos o la agricultura. Por el contrario, se excluyeron los trabajos que no se ajustaron al rango de fechas establecido, la literatura gris (como tesis no publicadas e informes técnicos no revisados por pares) así como aquellos estudios que se centraron en la tecnología de Georadar de Penetración Terrestre (GPR), pero que no están relacionados con la regresión. La selección de estudios se realizó en dos fases. En primer lugar, cribamos títulos y resúmenes para comprobar que su temática

fuera pertinente. En segundo lugar, se revisó el texto completo de los artículos preseleccionados para comprobar que cumplieran los criterios definidos.

Se estudia su habilidad para predecir variables y mejorar la eficiencia del riego.

El análisis de toda la literatura sobre la aplicación de Regresión de Procesos Gaussianos (GPR) para la gestión del agua en el contexto agrícola y en el contexto genérico. En una primera etapa se examinan estudios donde se aplica la GPR para la estimación precisa de demandas de riego y de caudales, a escala regional, en ríos y en canales de riego (Khan et al., 2012). A continuación, se examina la documentación que utiliza GPR para la estimación de la evapotranspiración, por su gran relevancia como variable hidrológica; así como para la cuantificación de la demanda hídrica de los cultivos (Nasrolahi et al., 2025).

Finalmente, se va a analizar la predicción del desempeño agrícola. Su uso como indicadora indirecta permite optimizar el riego. Por otro lado, el rendimiento apropiado es el resultado de un buen manejo hídrico (Martínez-Ferrer et al. 2021).

En este artículo se estudia la optimización del uso del agua en cultivos mediante el modelo de la Regresión del Proceso Gaussiano GPR. Los objetivos específicos de esta propuesta son: sintetizar los fundamentos teóricos de la Regresión del Proceso Gaussiano GPR, necesarios para su implementación en la predicción hidrológica agrícola; determinar las variables de entrada y fuentes de datos más convenientes para la construcción de modelos GPR. Se intenta también estudiar las ventajas y desventajas de esta técnica comparada con otros modelos predictivos de esta misma área y se pretende identificar los principales inconvenientes y posibles temas de estudio que sirvan de base a futuras investigaciones del área.

La implementación de modelos predictivos en el manejo del agua para fines agrícolas requiere comprensión suficiente de los algoritmos de aprendizaje de máquinas así como de la complejidad agrícola y medioambiental.

La regresión del proceso gaussiano es un paradigma no paramétrico del aprendizaje supervisado, que se sostiene en los principios de la probabilidad bayesiana y la estadística inferencial. (Wang et al., 2023). Frente a otras alternativas, como redes neuronales o máquinas de vectores de soporte,



este modelo no solo proporciona una predicción puntual del valor central, sino también un grado de incertidumbre expuesto a través de intervalos de confianza (Pedregosa et al., 2011). Esta salida de tipo probabilístico es especialmente útil en el sector de la decisión agraria el cual se caracteriza por el riesgo y la variabilidad.

Debido a este enfoque se afirma que no es necesario asumir una parametrización previa, sino que se utiliza un modelo puntual. Esta es una propuesta de distribución de probabilidad a priori sobre las funciones (Martínez Olmos, 2007). A esto se le denomina punto de vista del espacio de la función. La función de covarianza, o núcleo si se prefiere, es la pieza clave del GPR. Es el kernel el que juega un papel clave en la captura de las propiedades intrínsecas de los datos, modelando las relaciones que existen entre los puntos de entrada (Pedregosa et al. 2011).

En el campo de la predicción de series temporales, especialmente en hidrología y agricultura, muchas veces se requerirá de una confluencia de kernels para ajustar correctamente los diferentes componentes que caracterizan a la señal, según Pedregosa y otros (2011). Por ejemplo, un kernel RBF tendrá la capacidad de modelar tendencias de suavidad y largos periodos, y un kernel ExpSineSquared se suele aplicar para distinguir los componentes estacionales como puede ser el ciclo anual de la demanda hídrica, (Pedregosa et al., 2011).

Por su parte, el núcleo RationalQuadratic puede usarse para modelar las irregularidades en el corto y mediano plazo; el WhiteKernel típicamente se usa para modelar el ruido no correlacionado presente (Pedregosa et al., 2011).

La correcta selección y posterior construcción de esos kernels es un proceso de optimización sensible a los hiperparámetros que el propio modelo (Pedregosa et al., 2011). Un análisis en profundidad determinó la necesidad de agua de riego a nivel de condado y GPR dio los mejores resultados respecto a otras técnicas de machine learning (Khan et al. 2012) Según el modelo, las variables de entrada más influyentes fueron el area cultivada con riego, la temperatura atmosférica y el déficit de presión de vapor (Khan et al. 2012). Usando estas variables, el modelo tuvo una precisión bastante buena, con un R^2 superior a 0.97 y un error cuadrático medio RMSE de 0.06 km³, lo que demuestra que el GPR es un método adecuado para la predicción de la demanda regional (Khan et al. 2012). Igualmente, en el ámbito de la hidrología, GPR fue utilizado para la

predicción del caudal de escorrentía usando series de tiempo que evidencian datos no estacionarios (Wang et al. 2023). La capacidad del GPR para simular la complejidad no lineal de las series hidrográficas le confiere al GPR un valor de gestión de los recursos hídricos (Wang et al. 2023).

Resultados y Discusiones

La regresión de procesos gaussianos avanza con determinación en el mundo de la ciencia de datos en la agricultura de precisión. Un estudio de la literatura reciente muestra la eficacia de estos procesos en la agricultura de precisión, pero también muestra algunas de sus limitaciones, lo que ha despertado el interés en métodos más complejos.

Dentro de sus virtudes principales, el carácter de modelo caja gris del GPR –que resulta ser parcialmente interpretable– lo distingue de los enfoques caja negra como el de las redes neurales profunda (Martínez-Ferrer et al., 2021). Además, el GPR no sólo permite realizar predicciones precisas, sino que también cuantifica la incertidumbre. Esta incertidumbre asociada permite establecer intervalos de confianza fundamentales para la gestión del riesgo agrícola (Wang et al., 2023). Según los productores de cultivos y formuladores de políticas, esta información es útil para la toma de decisiones sobre la irrigación y, por tanto, la reducción del estrés hídrico. El GPR ha mostrado ser bastante robustos incluso en contextos que muestran una robusta consistencia en escenarios de datos fragmentados o escasos (Martínez-Ferrer, et al, (2021).

Una ventaja del GPR es que es una caja gris o interpretativa, a diferencia de los modelos de caja negra (Martínez-Ferrer et al. 2021). GPR no sólo produce predicciones, sino que también cuantifica la incertidumbre asociada, proporcionando intervalos de confianza, constituyen un elemento fundamental en la gestión de riesgos agrícolas (Wang et al. 2023). Los productores agrícolas igual que algunos tipos de gestores políticos requieren esta información para decidir el riego y evaluar el estrés hídrico de un cultivo. Además, las GPR demuestra tener un rendimiento notablemente robusto a datos dispersos y escasos (Martínez-Ferrer et al. 2021) . La recolección de datos en campo, a menudo costosa y restringida, busca en la agricultura. La capacidad de GPR para operar con menos muestras sin comprometer la precisión hacen de GPR una opción bastante eficaz.

Varias conclusiones se pueden extraer acerca del uso del GPR. Una de ellas señala que la calidad de la recopilación de datos del modelo GPR depende de los parámetros que controlan la instalación del sistema de detección. GPR es altamente eficiente con datos menos precisos, sin embargo, la tecnología moderna de detección remota y sensores permite la obtención de datos muy detallados y de gran densidad a bajo costo y son capaces de resolver la dificultad de GPR con espacios de alta dimensionalidad (Lu et al. 2022).

La aptitud de GPR para fusionar la información de múltiples sensores (humedad del suelo, vegetación y hasta variables del clima evidencia la transformación hacia un ecosistema integrado, donde ciencia de datos y hardware se cruzan para la gestión inteligente del agua (Ajith et al. 2025).

Conclusiones

A través de la Regresión del Proceso Gaussiano propuesto por la ciencia de datos, se plantea una poderosa herramienta para potenciar la eficiencia de riego agrícola. Según diferentes estudios el GPR es una herramienta eficiente y robusta para la estimación de variables hidro- lógicas como la demanda de agua, el escurrimiento, la productividad. También, su enfoque probabilístico, que genera intervalos de confianza junto con la predicción, es una herramienta adecuada para la toma de decisiones en ambientes naturalmente inciertos.

Como respuesta a la interrogante científica ¿De qué manera la ciencia de datos puede potenciar la eficiencia del riego agrícola? se considera al GPR con la habilidad de capacitar a agricultores y administradores de recursos hídricos, cambiándolos de un manejo reactivo a uno proactivo. Al predecir con gran precisión y en el tiempo indicado las necesidades hídricas de las cosechas, agiliza la aplicación del agua, en el lugar y momento adecuados. Esto se traduce en un importante ahorro hídrico, mayores cosechas y una reducción significativa del impacto ambiental.

Las perspectivas futuras en investigación tendrían que volcarse al desarrollo de modelos híbridos. Estos modelos deben trascender las limitaciones de GPR, en particular, su escalabilidad y sensibilidad a los hiperparámetros (Wang et al. 2023). Asimismo, resulta pertinente integrar múltiples fuentes de datos, como sensores de campo, teledetección satelital, inclusive datos meteorológicos, con el fin de aumentar la precisión y la predictiva de los modelos, permitiendo así de forma más completa la variabilidad espacial y temporal (Ajith et al. 2025).



Finalmente, la investigación debe enfocarse en la implementación de aplicaciones más accesibles y fáciles de utilizar por los agricultores para que adopción sea masiva (Martínez-Ferrer et al., 2021).

Referencias Bibliográficas

Ajith, S., Vijayakumar, S., & Elakkiya, N. (2025). Yield prediction, pest and disease diagnosis, soil fertility mapping, precision irrigation scheduling, and food quality assessment using machine learning and deep learning algorithms. *Discover Food*, 5(1). <https://doi.org/10.1007/s44187-025-00338-1>

Chen, M., Luo, Y., Shen, Y., Han, Z., & Cui, Y. (2020). Driving force analysis of irrigation water consumption using principal component regression analysis. *Agricultural Water Management*, 234(106089), 106089. <https://doi.org/10.1016/j.agwat.2020.106089>

Khan, M., Islam, M. Z., & Hafeez, M. (2012, December). Evaluating the Performance of Several Data Mining Methods for Predicting Irrigation Water Requirement. *Researchgate.net*. https://www.researchgate.net/publication/236894487_Evaluating_the_Performance_of_Several_Data_Mining_Methods_for_Predicting_Irrigation_Water_Requirement

Liu, X., Sang, X., Chang, J., & Zheng, Y. (2021). Multi-model coupling water demand prediction optimization method for megacities based on time series decomposition. In *Research Square*. <https://doi.org/10.21203/rs.3.rs-406939/v1>

Lu, Y., Liu, M., Li, C., Liu, X., Cao, C., Li, X., & Kan, Z. (2022). Precision fertilization and irrigation: Progress and applications. *AgriEngineering*, 4(3), 626–655. <https://doi.org/10.3390/agriengineering4030041>

Mansour, H. A., Gaballah, M. S., Khalil, S. E., & Pibars, S. K. (2022). The role of irrigation water management and improving agricultural soils in increasing crop productivity in light of the use of modern technologies. *International Journal of Health Sciences (IJHS)*, 1517–1532. <https://doi.org/10.53730/ijhs.v6ns2.5120>

Martínez Olmos, P. (2007). PROCESOS GAUSSIANOS PARA CLASIFICACIÓN APLICADOS A IGUALACIÓN Y DECODIFICACIÓN DE CANAL [UNIVERSIDAD DE SEVILLA]. <https://biblus.us.es/bibing/proyectos/use/abreproy/11482/fichero/PFC+Tema3.pdf>

Martinez-Ferrer, L., Piles, M., & Camps-Valls, G. (2021). Crop yield estimation and interpretability with Gaussian processes. *IEEE Geoscience and Remote Sensing Letters: A Publication of the IEEE Geoscience and Remote Sensing Society*, 18(12), 2043–2047. <https://doi.org/10.1109/lgrs.2020.3016140>



Masuda, R., Iwabuchi, H., Schmidt, K. S., Damiani, A., & Kudo, R. (2019). Retrieval of cloud optical thickness from Sky-View camera images using a deep convolutional neural network based on three-dimensional radiative transfer. *Remote Sensing*, 11(17), 1962. <https://doi.org/10.3390/rs11171962>

Nasrolahi, A., Sabzevari, Y., & Eslamian, S. (2025). Estimation of reference evapotranspiration using experimental models and approaches based on neural network (case study: Khorramabad City, Iran). *Water Practice & Technology*, 20(6), 1437–1449. <https://doi.org/10.2166/wpt.2025.079>

Pathirana, S., Lambot, S., Krishnapillai, M., Cheema, M., Smeaton, C., & Galagedara, L. (2023). Ground-penetrating radar and electromagnetic induction: Challenges and opportunities in agriculture. *Remote Sensing*, 15(11), 2932. <https://doi.org/10.3390/rs15112932>

Pedregosa, F., Varoquaux, G., Gramfort, A., & Michel, V. (2011). Scikit-learn: Machine Learning in Python. Github.Io. https://qu4nt.github.io/sklearn-doc-es/modules/gaussian_process.html

Sánchez-Serrano, S., Pedraza-Navarro, I., & Donoso-González, M. (2022). ¿Cómo hacer una revisión sistemática siguiendo el protocolo PRISMA?: Usos y estrategias fundamentales para su aplicación en el ámbito educativo a través de un caso práctico. *Bordón Revista de Pedagogía*, 74(3), 51–66. <https://doi.org/10.13042/bordon.2022.95090>

Wang, S., Gong, J., Gao, H., Liu, W., & Feng, Z. (2023). Gaussian process regression and cooperation search algorithm for forecasting nonstationary runoff time series. *Water*, 15(11), 2111. <https://doi.org/10.3390/w15112111>

Conflicto de intereses:

Los autores declaran que no existe conflicto de interés posible.

Financiamiento:

No existió asistencia financiera de partes externas al presente artículo.

Agradecimiento:

N/A

Nota:

El artículo no es producto de una publicación anterior.