

Artículo

Propuesta metodológica de la caracterización fenológica espacio-temporal para la clasificación de cultivos de amapola mediante Deep Learning (CNNs)

Denzel Olvera^{1*}, Roberto Rodríguez² e Imelda Pérez Espinoza³

¹ Tecnológico Nacional de México; Instituto Tecnológico Superior de Huichapan, Ingeniería en Administración, México

² Tecnológico Nacional de México; Instituto Tecnológico Superior de Huichapan, Ingeniería en Administración, México

³ Universidad del Centro del Bajío, México

* Correspondencia: diolvera@iteshu.edu.mx

Resumen: México enfrenta un vacío de información oficial sobre cultivos ilícitos desde 2015, lo que hace urgente el desarrollo de herramientas de monitoreo modernas y de bajo costo. Este artículo presenta una propuesta metodológica para un protocolo automatizado de clasificación de cultivos de amapola. El diseño propuesto integra Series de Tiempo de Imágenes Satelitales (SITS) del satélite Sentinel-2 con una arquitectura de Red Neuronal Convolutiva Unidimensional (1D-CNN). A diferencia de los modelos estadísticos tradicionales como ARIMA, el protocolo diseñado permite extraer de forma automática la firma fenológica del cultivo, aumentando la objetividad del monitoreo. Los resultados de este estudio validan conceptualmente los componentes del protocolo, demostrando que la combinación de datos gratuitos y Deep Learning es técnicamente factible y superior a los métodos actuales. Se concluye que esta propuesta constituye una base científica sólida para implementar sistemas nacionales de vigilancia que sean sostenibles y precisos.

Keywords: NDVI; SITS; Geoespacial.

Citar este trabajo: Olvera, Denzel.; Rodríguez, Roberto.; Pérez, Imelda. Propuesta metodológica de la caracterización fenológica espacio-temporal para la clasificación de cultivos de amapola mediante Deep Learning (CNNs). *REIA* 2025, 9, 6.

Recibido: 23/01/2026
Aceptado: 19/02/2026
Publicado: 27/02/2026

1. Introducción

1.1. El problema global de los opiáceos y la amapola en México

El consumo de opiáceos constituye un problema crítico de salud pública global. La producción mundial de opiáceos ilícitos presentó un incremento significativo entre 2016 y 2017 [2]. En México, el cultivo de la amapola de opio (*Papaver somniferum*) provee el principal insumo para la heroína [1]. La existencia de estos cultivos genera graves problemas sociales, económicos y de seguridad nacional, por ello es importante tener bien identificados los cultivos de manera permanente para su combate por parte de las autoridades, impidiendo su proliferación y expansión en nuevas zonas, logrando esto a través de la tecnología que se propone implementar.

Las autoridades mexicanas y la Oficina de las Naciones Unidas Contra la Droga y el Delito (UNODC) publicaron un informe oficial del monitoreo de amapola en 2016 (datos 2014-2015) [1]. Desde entonces, la publicación de reportes continuos se ha interrumpido. Esta interrupción demuestra la dificultad de mantener programas de monitoreo de alta precisión, por lo que se requieren metodologías de bajo costo y alta objetividad.

Desde 2015, México carece de datos oficiales actualizados sobre la ubicación y extensión de los cultivos de amapola. Los métodos actuales dependen de la inspección visual humana o de modelos estadísticos clásicos que no logran diferenciar con precisión la amapola de la vegetación natural en terrenos complejos, siendo esto una actividad muy riesgosa para los cuerpos armados que se ocupan de tales operaciones en campos abiertos muy difíciles de acceder y que se convierten en enfrentamientos armados.

Por estas razones, hace falta tener a disposición una herramienta que permita un monitoreo constante y eficiente en esta práctica de seguridad nacional, ante la necesidad crítica de diseñar un protocolo técnico que pueda aprovechar la Inteligencia Artificial y los datos satelitales para resolver este vacío de información.

1.2. Avances en teledetección y fenología para cultivos ilícitos

La teledetección satelital ofrece una solución eficiente para el monitoreo de territorios extensos [6], esto es posible considerando el Índice de Vegetación de Diferencia Normalizada (NDVI), ya que es la métrica estándar para evaluar la biomasa vegetal y el vigor de la vegetación [5]. El NDVI permite caracterizar el estado de la salud vegetal a lo largo del tiempo.

La caracterización fenológica resulta un factor decisivo para la identificación de cultivos ilícitos. Los cultivos de amapola presentan un ciclo fenológico distinto de la vegetación silvestre circundante. El análisis de series de tiempo de NDVI captura estos cambios espectrales temporales [7, 13]. Este análisis permite la diferenciación de cultivos mediante su firma espectral y su evolución a lo largo del tiempo donde las variables morfológicas y texturales complementan la identificación, aportando un porcentaje significativo a la clasificación [8].

1.3. Tendencias Tecnológicas: De los Modelos Geoestadísticos a la IA

Para el análisis de este fenómeno, es imperativo revisar las transiciones tecnológicas recientes que permiten o no la identificación de estos cultivos en los distintos hábitats utilizados para ello, así como en las diferentes condiciones edafoclimáticas que pudieran generar variabilidad en la eficiencia del instrumental a utilizar. De acuerdo con Box, Jenkins y Reinsel [10], los métodos iniciales se basaron en modelos de series de tiempo, como el algoritmo ARIMA. Sin embargo, como señalan Torres Gutama y Jara Obregón [11], estos enfoques resultan hoy insuficientes para procesar las grandes y complejas series de datos multiespectrales.

En este contexto, la Inteligencia Artificial (IA) surge como una herramienta que, según Riocampo y colaboradores [12], supera los algoritmos tradicionales en la detección de cultivos ilícitos utilizándola con las herramientas NDVI y ARIMA, generando con ello el protocolo propuesto en la presente investigación. A la par, las técnicas de Deep Learning han revolucionado el análisis satelital. Como bien indican Torres Gutama y Jara Obregón [11], las Redes Neuronales Convolucionales (CNNs) representan la arquitectura más efectiva para la clasificación espacial y el análisis multiespectral simultáneo.

1.4 Objetivo del Trabajo

Objetivo General. Realizar una propuesta metodológica que permita el monitoreo automatizado para clasificar el cultivo de amapola en México a través de la arquitectura de redes neuronales.

Objetivo específico. Realizar una investigación con enfoque cualitativo orientado al análisis conceptual sobre la combinación de imágenes sentinel-2 y redes neuronales.

2. Materiales y Métodos

2.1. Definición del Área de Estudio y Fuentes de Datos

Esta sección describe la estructura del protocolo propuesto. El método se fundamenta en el análisis de las Series de Tiempo de Imágenes Satelitales (SITS) para identificar el ciclo de vida (fenología) del cultivo. El área de aplicación teórica se centra en las regiones serranas de México, donde la complejidad del terreno hace que el monitoreo tradicional sea costoso e ineficiente. El protocolo está diseñado para ser autosuficiente, utilizando fuentes de datos de libre acceso para garantizar que cualquier institución pueda replicar

el monitoreo sin depender de presupuestos elevados para la adquisición de imágenes. [3, 5, 7].

2.2. *Preprocesamiento y Caracterización de Datos*

De acuerdo con Mattiuzzi y colaboradores [5], la calidad del monitoreo depende de una correcta limpieza de las nubes y sombras que afectan las imágenes de Sentinel-2. El tratamiento de la información satelital es un paso crítico para reducir el ruido espectral. Para este protocolo, se adopta el criterio de Cavalier y colaboradores [6], quienes establecen que el suavizado de las Series de Tiempo permite reconstruir la trayectoria del crecimiento vegetal de manera continua.

Como señalan Riocampo et al. [12], este preprocesamiento es lo que permite obtener una firma fenológica pura, facilitando que el algoritmo diferencie entre la vegetación natural y el ciclo específico de la amapola. Este enfoque asegura que la base de datos resultante sea robusta y esté lista para la fase de aprendizaje profundo.

2.3. *Modelo de Clasificación Basado en Deep Learning*

La elección de la arquitectura es el núcleo de la propuesta técnica. Siguiendo el marco de trabajo de Ismail y colaboradores [14], se define el uso de una Red Neuronal Convolutiva Unidimensional (1D-CNN). Este modelo es superior para este propósito porque, como bien indican Torres Gutama y Jara Obregón [11], las CNNs tienen la capacidad única de extraer características jerárquicas tanto espaciales como temporales sin necesidad de intervención manual.

El diseño del modelo se estructura bajo los estándares técnicos de Peña et al. [8], utilizando funciones de activación Sigmoide para la clasificación binaria y el optimizador Adam para garantizar la eficiencia computacional. Esta configuración, en palabras de Torres Gutama y Jara Obregón [11], representa el estado del arte en la identificación de cultivos complejos mediante inteligencia artificial, validando así la arquitectura elegida para este protocolo nacional.

2.3.1. *Arquitectura y entorno de ejecución*

El diseño del protocolo se fundamenta en el uso de una Red Neuronal Convolutiva Unidimensional (1D-CNN). Siguiendo la línea de investigación de Ismail y colaboradores [14], esta arquitectura es óptima para procesar las firmas fenológicas contenidas en las series de tiempo. Para su implementación, se define un entorno basado en Python, utilizando TensorFlow y Scikit-learn, herramientas que son consideradas el estándar técnico según Torres Gutama y Jara Obregón [11].

La arquitectura propuesta recibe como entrada un tensor con la secuencia temporal del NDVI (T) por cada píxel (N) [14]. Los componentes del diseño son:

- Capas Convolutivas (Conv1D): Diseñadas con filtros de tamaño $k=3$ para extraer los patrones de crecimiento del cultivo sin intervención manual [11].
- Capa de Pooling: Incluida para simplificar los datos y asegurar que el modelo sea robusto frente a variaciones climáticas [14].
- Capa de Salida: Utiliza una función Sigmoide para generar una clasificación binaria (Presencia/Ausencia de Amapola) [8].

2.3.2. *Estrategia de Muestreo y Datos Satelitales*

El propósito de este trabajo es demostrar que los datos de Sentinel-2 son suficientes para este monitoreo [5]. El protocolo define una frecuencia de observación de 5 a 10 días, lo que permite capturar el ciclo de vida completo de la amapola [6, 7].

Como parte del diseño innovador, el protocolo integra una fase de clustering (K-means) previa al entrenamiento [3]. Esta etapa no supervisada tiene el objetivo de organizar las curvas de vegetación por similitud espectral. Esto permite que, al implementar el modelo, se pueda diferenciar con precisión la amapola de otros cultivos

con ciclos similares, resolviendo el problema de los falsos positivos que afecta a los métodos tradicionales [12].

2.4. Evaluación de la Viabilidad Metodológica

Para la evaluación del protocolo, se proponen métricas estándar de clasificación, incluyendo Precisión Global, Coeficiente Kappa, y F1-Score [8, 11]. Se realiza una comparación conceptual del rendimiento esperado de la 1D-CNN frente a modelos tradicionales (como ARIMA) para justificar la inversión en IA [10]. El principal objetivo es demostrar que la integración Sentinel-2 + CNNs reduce la necesidad de la costosa verificación en campo y proporciona una alta objetividad en la identificación de cultivos [7].

3. Resultados

Los resultados esperados de este estudio no consisten en pruebas de campo, sino en la validación técnica de los componentes que integran el protocolo a implementar. A continuación, se detallan los hallazgos que demuestran por qué este diseño es técnicamente viable para resolver el vacío de información en México.

3.1. Estructura de la firma fenológica

El primer resultado del protocolo sería la transformación de datos crudos en un formato apto para la Inteligencia Artificial. El diseño logra convertir las imágenes de Sentinel-2 en vectores que contienen la historia clínica (curva de NDVI) de cada píxel. El hallazgo principal aquí es que, al suavizar estas curvas, se obtiene una "firma fenológica" única que permite distinguir el crecimiento de la amapola frente a la vegetación natural. Este vector resultante es lo que garantiza que el modelo no dependa de interpretaciones visuales subjetivas.

3.2. Configuración de la Arquitectura 1D-CNN

El resultado central es la definición de una arquitectura de Red Neuronal Convolutiva Unidimensional (1D-CNN) optimizada para datos geoespaciales. A diferencia de los modelos estadísticos tradicionales, el diseño de esta red permite aprender automáticamente los momentos críticos del ciclo del cultivo, como el pico de madurez y la velocidad de marchitamiento. El modelo resultante está diseñado para integrar tanto los datos de salud vegetal (NDVI) como la geometría de las parcelas, asegurando que la clasificación final sea robusta y difícil de confundir con otros tipos de vegetación.

3.3. Representación del flujo de trabajo

Como producto final de la investigación, se presenta el esquema operativo de tres fases (Figura 1). Este flujo de trabajo demuestra que es posible pasar de la adquisición de imágenes gratuitas a un modelo clasificador binario sin necesidad de procesos manuales costosos. Este diseño constituye la prueba de que el monitoreo automatizado es factible con la tecnología disponible actualmente.

Figura 1. Protocolo metodológico propuesto para la clasificación de cultivos de amapola mediante 1D-CNN y SITS de Sentinel-2, detallando las fases de adquisición de datos, preprocesamiento fenológico y el diseño del modelo clasificador binario.



Fuente: Elaboración propia.

4. Discusión

Esta sección analiza la viabilidad del protocolo propuesto y su capacidad para resolver el vacío de información sobre cultivos ilícitos en México centrandose en la superioridad del diseño basado en AI frente a las limitaciones de los métodos actuales.

4.1. Justificación del cambio tecnológico

La solidez de este protocolo reside en el cambio de paradigma hacia la automatización. Al contrastar esta propuesta con la estadística clásica, observamos que modelos como ARIMA [10] imponen limitaciones críticas al depender de la modelación explícita del analista. En contraposición, el enfoque de Ismail et al. [14] sobre las 1D-CNN permite que el modelo aprenda implícitamente las dependencias temporales no lineales.

4.2. Viabilidad Operativa y sostenibilidad

Asimismo, la integración de Sentinel-2 refuerza la viabilidad operativa. Como mencionan Mattiuzzi y colaboradores [5], la clave para identificar cultivos complejos como la amapola o el cannabis no reside solo en la imagen estática, sino en capturar las características fenológicas a lo largo del tiempo [6, 7]. Al utilizar recursos de libre acceso, este diseño aborda el vacío de información nacional, proporcionando una base científica que, en palabras de Peña et al. [8], reduce drásticamente la dependencia de la costosa, lenta y por demás peligrosa de la verificación manual de campo.

4.3. Impacto en la seguridad nacional y políticas públicas

La implementación de un diseño automatizado como el propuesto permite que las instituciones recuperen la capacidad de monitoreo perdida desde 2015. Al eliminar la ambigüedad en la identificación de parcelas, se facilita la toma de decisiones basada en evidencia científica y no en estimaciones empíricas. Este protocolo constituye una base tecnológica sólida para que el Estado mexicano cuente con una herramienta objetiva, auditable y de bajo costo para enfrentar el problema de los opiáceos.

5. Conclusiones

Este estudio fundamenta que el diseño de un protocolo automatizado para el monitoreo de amapola en México es técnica y operativamente viable. A partir de los hallazgos presentados, se concluye lo siguiente:

- **Eficacia de la Inteligencia Artificial:** La arquitectura 1D-CNN es la herramienta más adecuada para este problema. Como sostienen **Ismail y colaboradores [14]**, su capacidad para aprender automáticamente la firma fenológica del cultivo elimina la dependencia de modelos estadísticos manuales, como el algoritmo **ARIMA [10]**, reduciendo el error humano en la identificación.
- **Sostenibilidad del Protocolo:** El uso de imágenes de **Sentinel-2** confirma que es posible establecer un sistema de vigilancia constante sin costo por adquisición de datos. Esto resuelve el obstáculo financiero que, como se ha descrito, detuvo el monitoreo oficial en 2015.
- **Aporte Metodológico:** La **fundamentación técnica** de este protocolo proporciona a las instituciones una base científica sólida. Este diseño permite la transición de una gestión basada en estimaciones a una toma de decisiones sustentada en evidencia técnica y objetiva.
- **Agenda de Investigación:** Se contempla una etapa futura de pruebas del sistema propuesto para analizar el impacto del uso de software libre y clusters de imágenes gratuitas. Esta línea de trabajo busca extender las aplicaciones del protocolo a diferentes tipos de cultivos y diversas extensiones territoriales en el contexto nacional.

Contribución: Conceptualización, Denzel Olvera; metodología, Roberto Rodríguez e Imelda Pérez.

Financiamiento: Esta investigación no recibió financiamiento externo.

Agradecimientos: Se agradece al comité editorial, al cuerpo revisor de este artículo, además del apoyo y facilidades recibidas del doctor Octavio Guerrero Andrade.

Conflicto de interés: “Los autores declaran no tener conflicto de intereses”.

Glosario

1D-CNN	Red Neuronal Convolutiva Unidimensional. Arquitectura de Deep Learning optimizada para analizar y clasificar datos secuenciales o temporales, como las series de tiempo de NDVI.
Adam	Optimizador Adam. Algoritmo de optimización utilizado durante el entrenamiento de una red neuronal para ajustar los pesos del modelo y minimizar la función de pérdida (Loss Function).
ARIMA	Modelo Autorregresivo Integrado de Medias Móviles. Técnica estadística tradicional para el análisis y pronóstico de series de tiempo.
Binary Cross-Entropy	Función de Pérdida de Entropía Cruzada Binaria. Función de pérdida (Loss Function) estándar utilizada para medir el error de un modelo en tareas de clasificación con dos clases (clasificación binaria).
Clustering	Agrupamiento (o Clasificación No Supervisada). Técnica de Machine Learning que organiza conjuntos de datos (en este caso, los vectores de series de tiempo de NDVI) en grupos (clusters) en función de la similitud de sus características, sin utilizar etiquetas predefinidas. Ayuda a identificar patrones fenológicos naturales en el terreno antes del etiquetado para el entrenamiento supervisado.
Deep Learning	Aprendizaje Profundo. Subcampo de la Inteligencia Artificial (IA) que utiliza redes neuronales con múltiples capas para aprender patrones complejos directamente de los datos.

Fenología	Estudio de los ciclos de vida y las etapas de desarrollo de las plantas, crucial para diferenciar el ciclo de la amapola.
Loss Function	Función de Pérdida (o Costo). Métrica que cuantifica el error o la diferencia entre la predicción del modelo y el valor real durante el entrenamiento.
NDVI	Índice de Vegetación de Diferencia Normalizada. Métrica que indica el vigor o salud de la vegetación en una escala de -1 a +1.
NDWI	Índice de Agua de Diferencia Normalizada. Métrica que evalúa la cantidad de agua presente en la vegetación o el nivel de humedad del suelo.
Ortorrectificación	Proceso de corrección geométrica aplicado a las imágenes satelitales para eliminar las distorsiones causadas por el relieve del terreno.
Pooling	Capa de Pooling (Submuestreo). Operación utilizada en las CNNs para reducir la dimensionalidad temporal de la información y hacer el modelo más robusto.
Sentinel-2	Misión satelital (ESA) utilizada como fuente de datos. Destaca por su alta resolución temporal.
Sigmoide	Función de Activación Sigmoide. Función utilizada en la capa de salida de una red neuronal para generar una probabilidad de clasificación entre 0 y 1, ideal para clasificación binaria.
SITS	Series de Tiempo de Imágenes Satelitales. Secuencia cronológica de imágenes adquiridas repetidamente sobre la misma área.
UNODC	Oficina de las Naciones Unidas contra la Droga y el Delito. Organismo que monitorea los cultivos ilícitos a nivel global.
VHR	Muy Alta Resolución. Se refiere a imágenes satelitales con resoluciones espaciales de 1 metro o menos.

Referencias

1. UNODC. Monitoreo de Cultivos de Amapola 2014-2015. Ciudad de México, México, 2016.
2. UNODC. Informe Mundial de Drogas 2018. Viena, Austria, 2018.
3. Mattiuzzi, M.; Bussink, C.; Bauer, T. Analysing Phenological Characteristics Extracted from Landsat NDVI Time Series to Identify Suitable Image Acquisition Dates for Cannabis Mapping in Afghanistan. *Photogrammetrie Fernerkundung Geoinformation* 2014, 5, 383–392. doi:10.1127/1432-8364/2014/00233.
4. Wang, J.-J.; Zhang, Y.; Bussink, C. Unsupervised multiple endmember spectral mixture analysis-based detection of opium poppy fields from an EO-1 Hyperion image in Helmand, Afghanistan. *Sci. Total Environ.* 2014, 476–477, 1–6. doi:10.1016/j.scitotenv.2014.01.006.
5. Pérez Cortés, L. Identificación de Vegetación en Imágenes Satelitales; Tesis de Maestría, Instituto Politécnico Nacional, México, D.F., México, 2014.
6. Gandhi, M.G.; Parthiban, S.; Thummalu, N.; Christy, A. Ndvi: Vegetation change detection using remote sensing and gis - A case study of Vellore District. *Procedia Computer Science* 2015, 57, 1199–1210. doi:10.1016/j.procs.2015.09.281.
7. Vázquez, P.; Adema, E.; Fernández, B. Dinámica de la fenología de la vegetación a partir de series temporales de NDVI de largo plazo en la provincia de La Pampa. *Ecol. Austral.* 2013, 23, 77–86. DOI:10.25260/EA.13.23.2.0.1163
8. Peña, J.M. et al. 2017. Principales variables para la detección de plántulas de amapola (*Papaver rhoeas*) en imágenes tomadas con un vehículo aéreo no tripulado. *Computers and Electronics in Agriculture*, 143:422-430. DOI: 10.1016/j.compag.2017.10.019.
9. Cruz-Cárdenas, G.; Villaseñor, J.L.; López-Mata, L.; Ortiz, E. Distribución espacial de la riqueza de especies de plantas vasculares en México. *Revista Mexicana de Biodiversidad* 2013, 84, 1189–1199. doi:10.7550/rmb.31811.
10. Box, G.E.P.; Jenkins, G.M.; Reinsel, G.C. *Time Series Analysis: Forecasting and Control*. 4th ed.; Wiley: Hoboken, NJ, USA, 2008. DOI: 10.1002/9781118674518.
11. Torres Gutama, H.H.; Jara Obregón, L.S. Análisis de técnicas de deep learning para la identificación y clasificación de cultivos. *Centrosur Agraria* 2022, 1, 1–14. doi:10.37959/revista.v1i14.202.
12. Riocampo, S.L.; Correa García, J.A.; Gómez Luévano, A.; Bermúdez García, G.S. Inteligencia artificial para la detección de la minería ilegal, deforestación y cultivos ilícitos por medio de imágenes satelitales. En *Encuentro Internacional de Educación en Ingeniería*; ACOFI: Cartagena, Colombia, 2023. <https://doi.org/10.26507/paper.2973>
13. Macías-Duarte, A.; Panjabi, A.O.; Pool, D.B.; Ruvalcaba-Ortega, I.; Levandoski, G.J. Fall vegetative cover and summer precipitation predict abundance of wintering grassland birds across the Chihuahuan desert. *Journal of Arid Environments* 2018, 156, 41–49. doi:10.1016/j.jaridenv.2018.04.012.
14. Ismail, M.; Rustowicz, R.; Chen, S.; Lary, D.J. Investigating Temporal Convolutional Neural Networks for Satellite Image Time Series Classification. 2022, 1–13. arXiv:2204.08461.