

Algoritmos de aprendizaje automático y teledetección para la conservación de la biodiversidad

Dr. Francisco Javier Sahagún Sánchez
Departamento de Políticas Públicas



CUCEA
El mejor lugar para el talento

CIBERTIC²⁰²⁵

Situación actual de la biodiversidad

- Actividades humanas producen transformación acelerada de los ambientes naturales.
- Amenazas relacionadas con deforestación, fragmentación, incendios forestales, alteración de ciclos biogeoquímicos y cambio climático, entre otros.
- Los impactos se traducen en cambios en las coberturas terrestres.
- Se incrementa de la presión sobre los ecosistemas y los hábitats naturales.
- Produce pérdida de biodiversidad y servicios ecosistémicos.



Retos para la conservación



El manejo y la conservación de la biodiversidad requieren de información actualizada, precisa y espacialmente explícita.

El mapeo temático de los elementos se vuelve esencial para la gestión y el monitoreo ambiental.

El desarrollo y aplicación de tecnologías como el aprendizaje automático y la teledetección son clave en la planificación territorial y la gestión ambiental.


¿Qué es el aprendizaje automático?

Machine learning


Campo de estudio que permite a las computadoras aprender de los datos sin ser explícitamente programadas.

Las computadoras identifican patrones a través de algoritmos y a partir de los datos y la experiencia (prueba y entrenamiento).

Relevante en distintos campos de conocimiento, incluidos la ecología, la conservación y las ciencias ambientales.



Campo multidisciplinar



Métodos de aprendizaje automático



Aprendizaje supervisado

Arboles de decisión

Naive Bayes

Maquina de vectores de soporte



Aprendizaje no supervisado

Agrupamiento de medias de K



Aprendizaje basado en instancias

k vecinos más cercanos



Aprendizaje conjunto

Bosque aleatorio




Redes neuronales

Redes neuronales supervisadas


Redes neuronales no supervisadas

Redes neuronales reforzadas


Algoritmos utilizados en ecología y ciencias ambientales



Bosque aleatorio
(RF)



Lógica difusa




Redes neuronales
artificiales (ANN)


Máquinas de
vectores de
soporte (SVM)



Árboles de decision



Algoritmos
genéticos



Clasificadores
Bayesianos

¿Qué es la teledetección?

Recolección de información sobre un objeto a distancia por un sensor remoto.

Satélites (Sentinel-2, Landsat, etc), Drones, Fotografías, LiDAR, RADAR, otras.

Provee información en una alta gama de resoluciones y coberturas.

Facilita el análisis de cambios a corto y largo plazo.

Es útil para monitoreo ambiental y de la superficie terrestre.



Integración de la teledetección y los algoritmos de aprendizaje




Los datos de sensores remotos (RS) son esenciales para evaluar los procesos de cambio en los usos del suelo.

La información es comúnmente analizada con algoritmos de aprendizaje automático.

Facilitan la modelación y predicción de la dinámica de los cambios ambientales.

Su uso combinado es clave para la gestión territorial, el monitoreo de recursos y la conservación de la biodiversidad.



Uso de algoritmos de aprendizaje automático en ecología y conservación

Modelos de distribución de especies (SDM).

Identificación de especies.

Clasificación y análisis de cambio en el uso del suelo.

Identificación de zonas prioritarias.

Manejo de recursos.

Protección y seguridad del medio ambiente.


Cambio climático.

Algunos ejemplos de aplicación

- Predicción de expansión de especies invasoras.
- Identificación de especies (imágenes, sonidos, genes).
- Estimación del estado de conservación de especies.
- Interpolación espacial de variables ambientales.
- Inferencia de parámetros geofísicos.
- Análisis de efectos de la urbanización.
- Riesgo de expansión de enfermedades.
- Predicciones meteorológicas y ambientales.
- Clasificación de muestras ambientales.
- Predicción de riesgos químicos (mutagenicidad, carcinogenicidad, biodegradabilidad).
- Identificación de fuentes de contaminación del aire.
- Modelación de escenarios de efecto invernadero.

Caso de estudio: Recuperación de la cubierta forestal en el Parque Nacional Cofre de Perote

- Localizado en Veracruz.
- 4250 msnm – 11530 ha.
- Ecosistema montano prioritario.
- Coberturas de bosques de coníferas y pastizales.
- Importancia ecológica por servicios ecosistémicos.
- Problemas por expansión de actividades agrícolas y turísticas.



Objetivo

Analizar la **dinámica espacio temporal** de los **cambios en la cubierta forestal y la conectividad** en el Parque Nacional Cofre de Perote.



Datos y metodología del estudio



Imágenes Sentinel-2
(2017 y 2024).
Corrección radiométrica
con Sen2Cor.



Clasificación con RF.
QGIS y SCP (Plugin de
clasificación
semiautomática).
RF - 3000 muestras de
entrenamiento y 1000
árboles aleatorios.



Validación con puntos de
control y ACATAMA.
(Evaluación de la
precisión y estimación
del área mediante mapas
temáticos).

¿Por qué usar Random Forest?

Ampliamente utilizado en ecología y teledetección.

Robusto y de facil implementación.


Alta precisión con pocos parámetros.

Método de aprendizaje por conjuntos.

Basado en conjuntos de árboles de decisión compuestos por una muestra de los datos.


Según el problema, se aplica regresión (promedio) o clasificación (mayoría de votos).

Ideal para clasificación de coberturas.



Análisis de cambio y conectividad

- Estimación de trayectorias de cambio entre usos y localización de cambios.
 - Modulo Land Change Modeler for Ecological Sustainability - TERRSET
- Determinación de tasas de cambio.
- Índice Integral de Conectividad – IIC CONEFOR Sensinode 2.6





Resultados: Cambios en la cubierta forestal



Incremento de +1,290
ha de bosque en el
parque.




Reducción de
pastizales y suelos
desnudos.



Transformación de
+380 ha en zona de
amortiguamiento.



Alta precisión de
clasificación validada.



Resultados: Conectividad estructural

Mejora en la conectividad dentro de los parches.

Aumento del flujo de procesos entre parches.

Incremento en los nodos clave de conexión.

Zonas de bosque con mayor recuperación de conectividad.

Disminución en zonas de uso tradicional y amortiguamiento.

Incremento y mejora global de la conectividad al interior del parque.

Implicaciones para la gestión del territorio.



Incremento de la conectividad mejora la resiliencia del paisaje.


Zonas transformadas requieren acciones de manejo.

Manejo adaptativo en zonas de amortiguamiento.

Reforestación, forestación y establecimiento de corredores biológicos.

Fortalecimiento de participación comunitaria en zonas de amortiguamiento.

Información generada es útil para el manejo y la restauración.



Recomendaciones generales

Recomendaciones para la adopción del uso de herramientas de aprendizaje automático

- Incrementar posibilidad de acceso a datos abiertos (Copernicus, USGS).
- Acelerar el desarrollo de habilidades y capacidades técnicas para el uso e implementación de algoritmos de aprendizaje automático en distintas plataformas (QGIS, Google Earth Engine, Python, R).
- Colectar y sumar datos de calidad para mejorar el entrenamiento de los modelos.
- Establecer alianzas entre científicos, tomadores de decisiones y otros actores relevantes.
- Comunicar los resultados obtenidos.

Recomendaciones para el uso e implementación de algoritmos de aprendizaje automático en distintas plataformas

Incrementar la posibilidad de acceso a datos abiertos

- Colectar y sumar datos de calidad para mejorar el entrenamiento de los modelos.

Acelerar el desarrollo de habilidades y capacidades técnicas para el uso e implementación de algoritmos de aprendizaje automático en distintas plataformas

- Establecer alianzas entre científicos, tomadores de decisiones y otros actores relevantes.

Comunicar los resultados obtenidos

Los métodos de aprendizaje automático pueden proporcionar información valiosa para la toma de decisiones, subsanar los vacíos de información y mejorar la comprensión de los sistemas complejos.



Conclusiones



Los algoritmos de aprendizaje automático mejoran la calidad del monitoreo ambiental. Proporcionan modelos más precisos, aceleran el desarrollo del conocimiento científico, subsanan los vacíos de información y mejoran la comprensión de los sistemas complejos.



La teledetección permite evaluar los cambios espacio-temporales con precisión y de forma eficiente.



El algoritmo de Bosque aleatorio es ideal para clasificación de coberturas y su análisis para la conservación.



El caso del Parque Nacional Cofre de Perote muestra el valor de los algoritmos de aprendizaje automático para la toma de decisiones sobre manejo y conservación.

Referencias

- Alzubi, J., Nayyar, A., & Kumar, A. (2018). Machine learning from Theory to Algorithms: An Overview. IOP Conf. Series: *Journal of Physics: Conf. Series* 1142, 012012. <https://doi.org/10.1088/1742-6596/1142/1/012012>
- Avci, C., Budak, M., Yagmur, N., Bektas, B. F. (2023). Comparison between random forest and support vector machine algorithms for LULC classification. *International Journal of Engineering and Geosciences*, 8, 1, 01-10. <https://doi.org/10.26833/ijeg.987605>
- Chaturvedi, V., & de Vires, W. T. (2021). Machine Learning Algorithms for Urban Land Use Planning: A Review. *Urban Science*, 5, 68. <https://doi.org/10.3390/urbansci5030068>
- Congedo, L. (2021). Semi-Automatic Classification Plugin: A Python tool for the download and processing of remote sensing images in QGIS. *Journal of Open Source Software*, 6(64), 3172. <https://doi.org/10.21105/joss.03172>
- Dabija, A., Kluczek, M., Zagajewski, B., Raczko, E., Kycko, M., Al-Sulttani, A.H., Tardà, A., Pineda, L., & Corbera, J. (2021). Comparison of Support Vector Machines and Random Forests for Corine Land Cover Mapping. *Remote Sensing*, 13, 777. <https://doi.org/10.3390/rs13040777>
- Espinoza-Guzmán, M. A., Aragonés-Borrego, D., & Sahagún Sánchez, F. J. (2023). Evaluation of recent land-use and land-cover change in a mountain region. *Trees, Forest and People*, 11, 10037. <https://doi.org/10.1016/j.tfp.2023.100370>
- Humphries, G. R. W., Magness, D. R., & Huettmann, F. (2018). *Machine learning for ecology and sustainable natural resource management*. Springer Nature Switzerland AG. <https://doi.org/10.1007/978-3-319-96978-7>
- Mahesh. B. (2018). Machine learning algorithms – A review. *International Journal of Science and Research*, 9, 1, 381-386. <https://doi.org/10.21275/ART20203995>

Referencias

- Olofsson, P., Foody, G. M., Herold, M., Stehman, S. V., Woodcock, C. E., & Wulder, M. A., (2014). Good practices for estimating area and assessing the accuracy of land change. *Remote Sensing of Environment*, 148, 42–57. <https://doi.org/10.1016/j.rse.2014.02.015>.
- Puyravaud, J. P. (2003). Standardizing the Calculation of the Annual Rate of Deforestation. *Forest Ecology and Management*, 177, 593–596. [https://doi.org/10.1016/S0378-1127\(02\)00335-3](https://doi.org/10.1016/S0378-1127(02)00335-3)
- Sabattini, J. A., Sabattini, R. A., Muzzachiodi, N., Treisse, I., & Penco, R. (2024). Mapping of the natural and anthropic environments of Entre Rios (Argentina) using machine learning classification. *Revista de Teledetección*, 64, 49-60. <https://doi.org/10.4995/raet.2024.20831>
- Saura, S., & Torné, J. (2009). Conefor Sensinode 2.2: A software package for quantifying the importance of habitat patches for landscape connectivity. *Environmental Modelling & Software*, 24, 135-139. <https://doi.org/10.1016/j.envsoft.2008.05.005>
- Stupariu, M. S., Cushman, S. A., Plesoianu, A. I., Patru-Stupariu, I., & Fürst, C. (2022). Machine learning in landscape ecological analysis: a review of recent approaches *Landscape Ecology*, 37, 1227–1250. <https://doi.org/10.1007/s10980-021-01366-9>
- Tariq, A., Yan, J., Gagnon, A. S., Riaz, K. M., & Mumtaz, F. (2023). Mapping of cropland, cropping patterns and crop types by combining optical remote sensing images with decision tree classifier and random forest. *Geo-spatial Information Science*, 26, 3, 302-320, <https://doi.org/10.1080/10095020.2022.2100287>
- Thessen, A. E. (2016). Adoption of Machine Learning Techniques in Ecology and Earth Science. *One Ecosystem*, 1, e8621. <https://doi.org/10.3897/oneeco.1.e8621>
- Willcock, S., Martínez-López, J., Hooftman, D. A. P., Bagstad, K. J., Balbi, S., Marzo, A., Prato, C., Sciandrello, S., Signorello, G., Voigt, B., Villa, F., Bullock, J. M., Athanasiadis, L. N. (2018). Machine learning for ecosystem services, *Ecosystem Services*, 33, 165-174, <https://doi.org/10.1016/j.ecoser.2018.04.004>.

GRACIAS

francisco.sahagun@academicos.udg.mx