VI CONGRESO NACIONAL DE CAMBIO CLIMÁTICO
& IX SIMPOSIO NACIONAL MARINO COSTERO

Del píxel al carbono

Comparación de modelos de aprendizaje automático para la clasificación de uso de la tierra y estimación indirecta de carbono en contextos tropicales de Guatemala



Rodrigo Josué de la Roca González · Visión Mundial Guatemala
Asesor de investigación: MsC. Edson Hernandez

Sesión: Monitoreo geoespacial para la gestión climática y marino-costera

Octubre de 2026

1. Problema país: monitorear carbono en paisajes tropicales

La clasificación de uso y cobertura es el primer paso antes de estimar carbono de forma indirecta.



Alta heterogeneidad
estructural de los bosques



Elevada
diversidad biológica



Grandes
extensiones territoriales



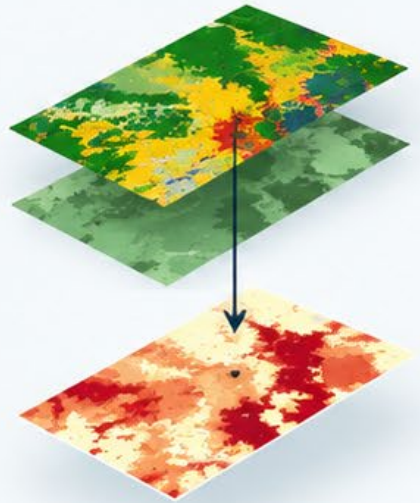
Bajos presupuestos
para inventarios tradicionales



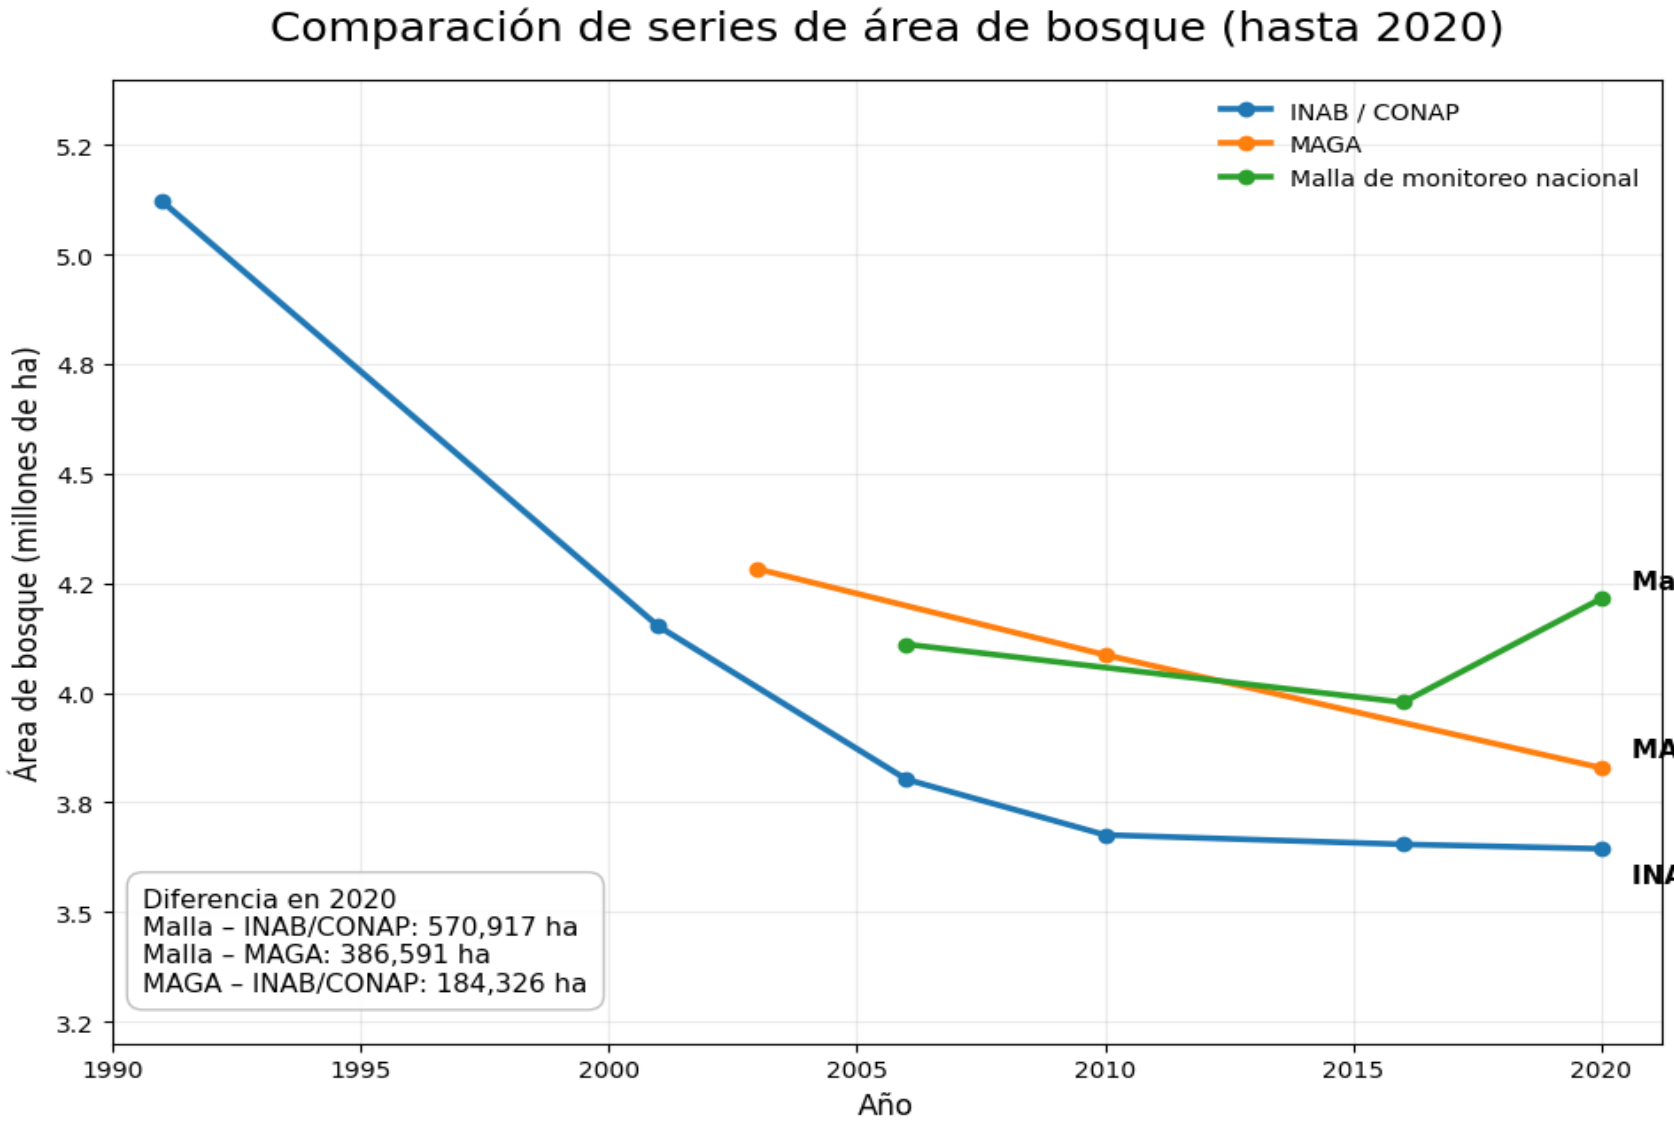
Altos costos operativos
y tiempos prolongados

Punto crítico

Si la clasificación falla, el error se propaga al mapa de carbono.



2. ¿Por qué importa reducir el error?



Malla de monitoreo nacional: 4.215 Mha

MAGA: 3.829 Mha

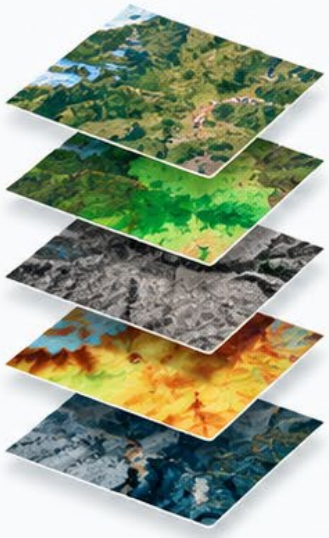
INAB / CONAP: 3.644 Mha

3. La propuesta: Un algoritmo que genere un mapa confiable

Utilizar algoritmos de aprendizaje automático para clasificar la cobertura y uso de la tierra a escala país, y evaluar cual ofrece el major equilibrio entre precision, estabilidad y capacidad de generalización

1 Datos del territorio

Imágenes satelitales
y predictores ambientales

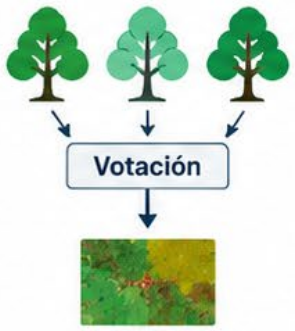


2 Tres algoritmos de diferente naturaleza

Misma tarea de clasificación, misma información

Random Forest

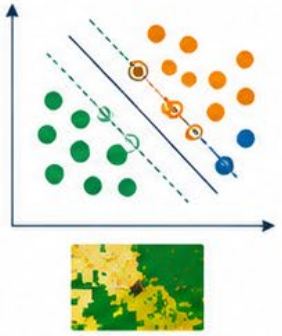
Ensembles de árboles
de decisión



Combina muchas
decisiones para clasificar.

Support Vector Machine

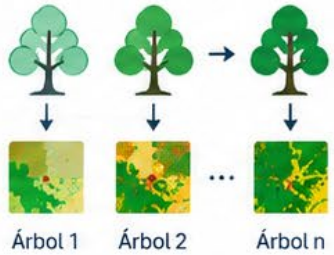
Clasificación basada
en márgenes



Encuentra la frontera
que mejor separa las clases.

LightGBM

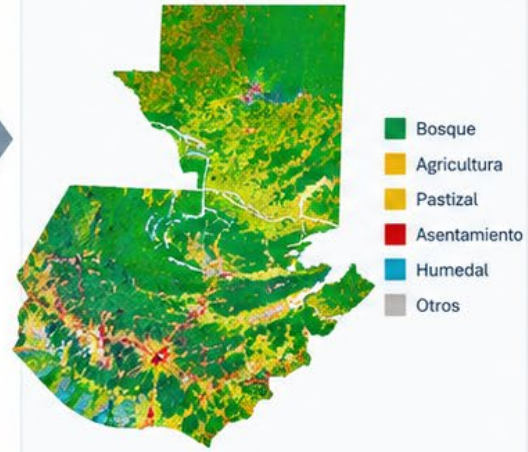
Gradient boosting eficiente
y predictivo



Aprende de los errores
y los corrige paso a paso.

3 Mapa de cobertura y uso de la tierra

Clasificación a escala país



Objetivo:

Seleccionar el algoritmo que ofrece el mejor equilibrio entre precisión, estabilidad y capacidad de generalización para generar un mapa confiable de cobertura y uso de la tierra en Guatemala.

4. Objetivos

Objetivo general

Evaluar y comparar modelos de aprendizaje automático para clasificar la cobertura y uso de la tierra y **sustentar la estimación indirecta de carbono** en Alta Verapaz.

Buscando el mejor equilibrio entre precisión, estabilidad y generalización en un paisaje tropical heterogéneo.



Específicos

1. **Identificar las variables clave**

Determinar qué variables predictoras contribuyen más al desempeño clasificatorio de los modelos evaluados.

2. **Optimizar los modelos**

Ajustar hiperparámetros para maximizar la generalización y estabilidad en la clasificación de cobertura y uso de la tierra.

3. **Evaluar el desempeño**

Analizar la precisión, estabilidad y capacidad de generalización de los modelos mediante métricas de desempeño, para la estimación indirecta de carbono.

5. Metodologia y alcance del estudio



6. ¿Por qué 5 tipos de variables?

Cada una de las variables aporta una dimension distinta del paisaje que facilita la clasificación de coberturas similares o ambiguas.



Ópticas

Color y reflectancia

Diferencia coberturas por su respuesta espectral.

¿Qué aporta al modelo?

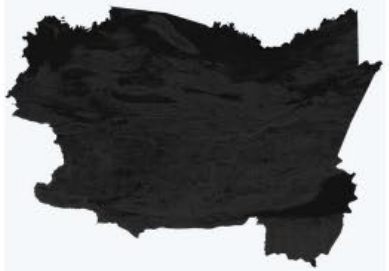


NDVI / índices

Vigor de vegetación

Resume actividad fotosintética y condición del dosel.

¿Qué aporta al modelo?



GLCM / textura

Patrón y estructura

Captura rugosidad, homogeneidad y organización espacial.

¿Qué aporta al modelo?



Topografía

Relieve del terreno

Representa elevación, pendiente y gradientes ambientales.

¿Qué aporta al modelo?



Radar SAR

Estructura y humedad

Aporta información aun con nubosidad y responde al dosel.

¿Qué aporta al modelo?

28 variables

7. Validación y selección del modelo

Se utilizaron dos conjuntos de datos: uno para entrenar y otro para validar el producto final.

1,968
muestras de referencia



1 — Entrenamiento y evaluación interna

Se entrenan y comparan modelos usando validación cruzada.

80%
1,574
entrenamiento

Algoritmos evaluados
- Random Forest
- SVM
- LightGBM

Validación cruzada
5-fold CV
Durante el entrenamiento

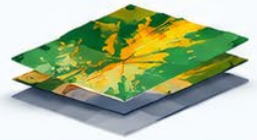
Métricas (interna)
- Macro-F1 (promedio de clases)
- Kappa (concordancia)
- Estabilidad (entre folds)
- Gap (generalización)

2 — Validación independiente del producto final

Se evalúa el mapa final con muestras que no participaron en el entrenamiento ni en el ajuste.

20%
394
validación independiente

Mapa predicho
(modelo seleccionado)



Muestras de validación
394 muestras reservadas

Métricas (independiente)
- Macro-F1 (promedio de clases)
- Kappa (concordancia)

8. Resultados: Variables dominantes

La importancia de variables confirma que el paisaje tropical no se separa solo por color.

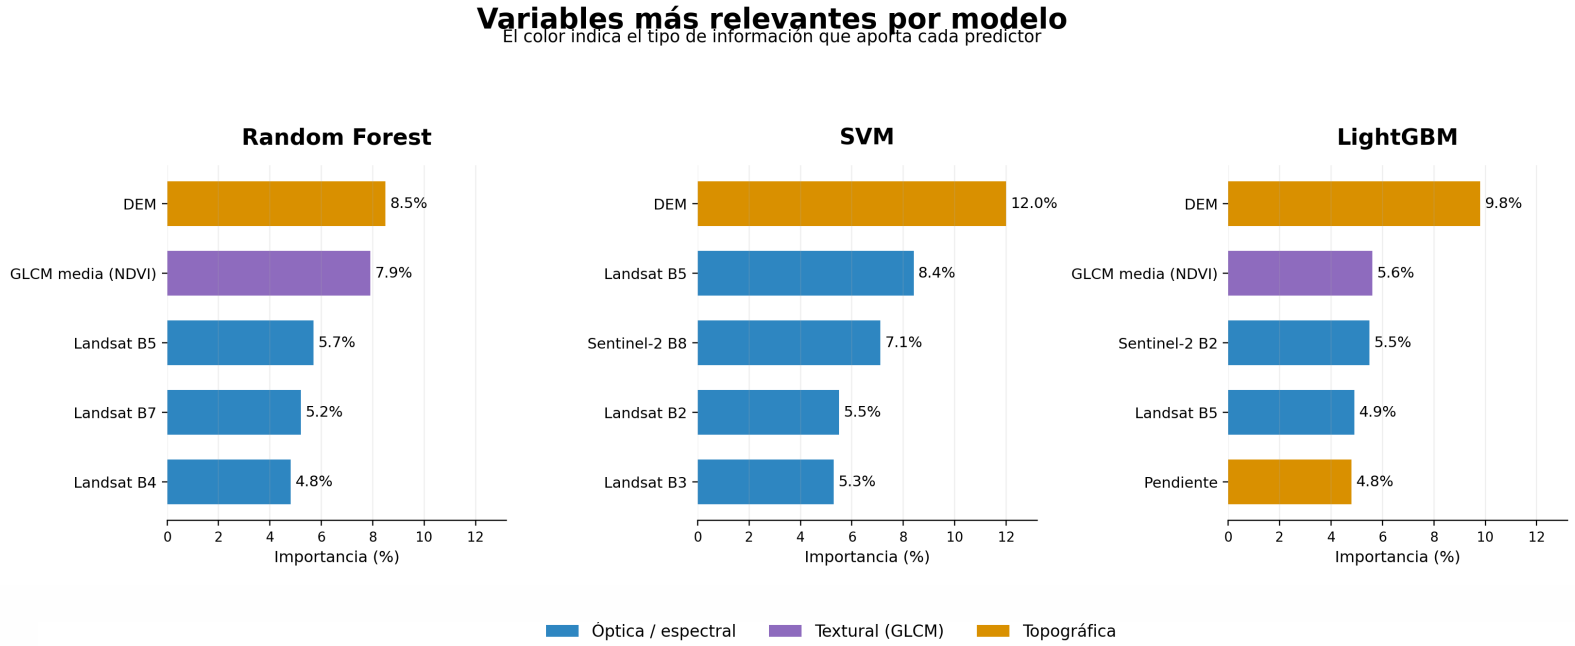
OBJETIVO

Identificar las variables predictoras más relevantes para la clasificación.

VARIABLES DOMINANTES

- ✓ **DEM** (Topografía)
- ✓ **GLCM** (Textura)
- ✓ **Bandas espectrales** (LS_B5, S2_B8)

La topografía y la textura controlan la diferenciación de cobertura, lo cual es altamente consistente con **entornos tropicales complejos**.



9. Resultados: Ajuste de hiperparametros (tuning)

El ajuste de hiperparámetros cambió el comportamiento de cada familia de algoritmos.

OBJETIVO

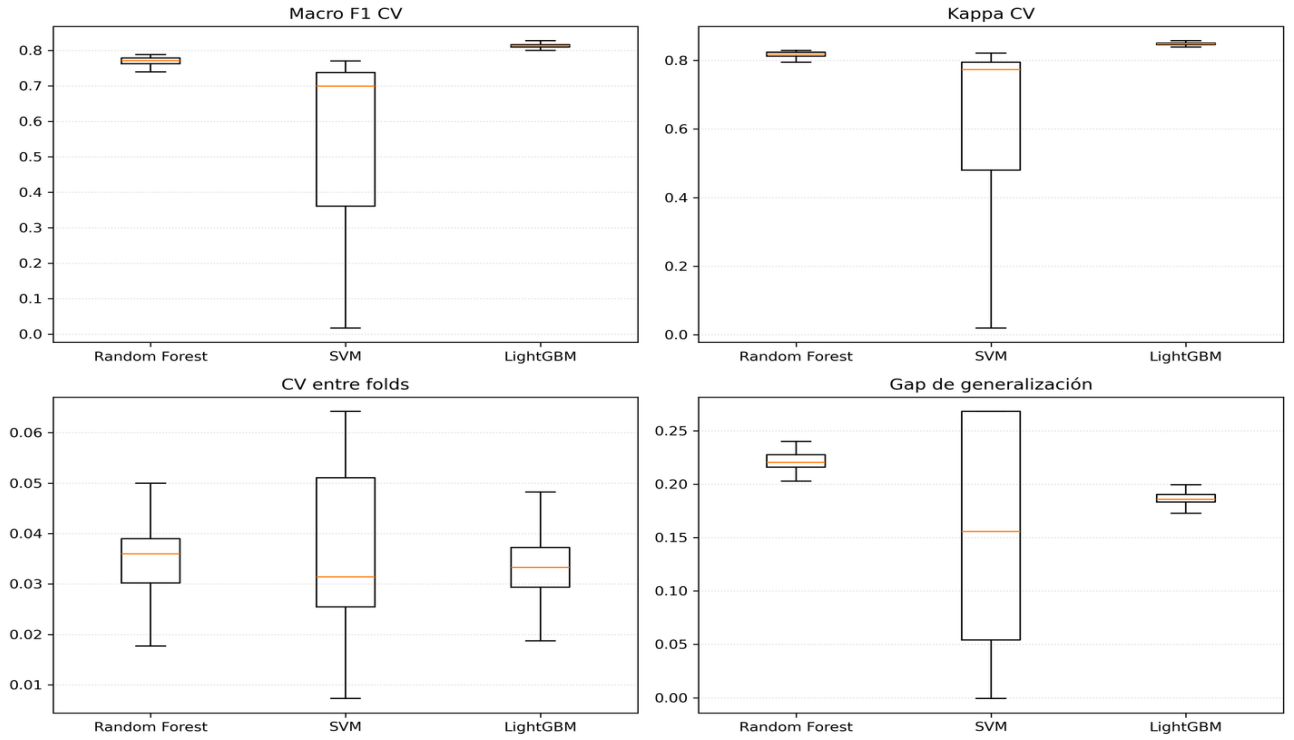
Optimizar hiperparámetros para maximizar desempeño y controlar sobreajuste.

RESULTADO

Mejora significativa tras tuning; efecto y comportamiento distinto por modelo.

COMPORTAMIENTO DIFERENCIADO

- **RANDOM FOREST:** Robusto por naturaleza, presenta mejoras moderadas y consistentes.
- **SVM:** Altamente sensible a hiperparámetros (C y γ); requiere ajuste fino riguroso.
- **LIGHTGBM:** Mayor capacidad predictiva, pero con elevado riesgo de sobreajuste si no se regulariza.



Algoritmo	No. de hiperparámetros	Hiperparámetros evaluados	No. de combinaciones
Random Forest	4	n_estimators max_features max_depth min_samples_leaf	340
SVM (RBF)	2	C gamma	40
LightGBM	6	learning_rate num_leaves n_estimators feature_fraction bagging_fraction max_depth	2,103
Total	—	—	2,483

10. Resultado: Desempeño final

La selección combina precisión, concordancia, estabilidad y capacidad de generalización.

OBJETIVO

Comparar el desempeño final y la estabilidad general de los modelos evaluados.

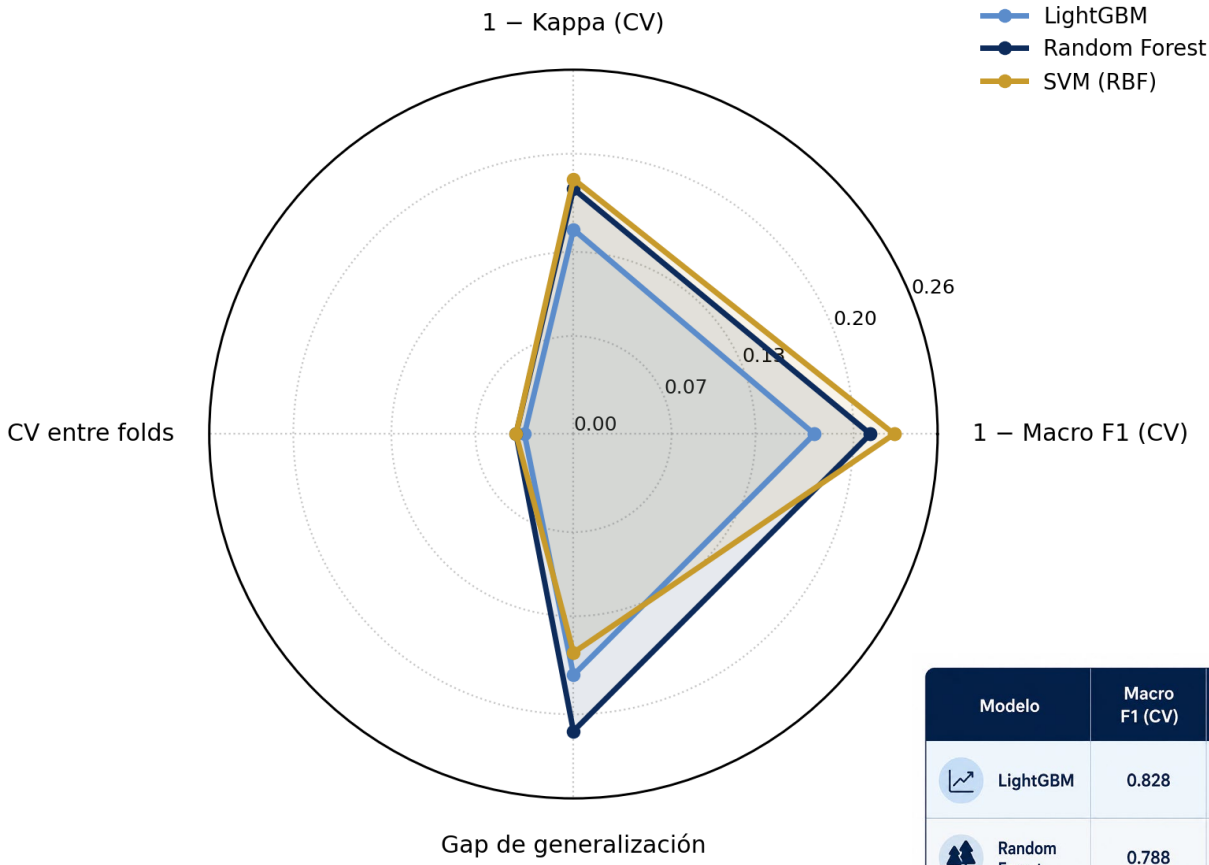
RESULTADOS CLAVE

- **LightGBM:** alcanzó la mayor precisión global y la menor variabilidad entre folds.
- **SVM:** presentó menor precisión, pero el menor gap de generalización.
- **Random Forest:** mostró un desempeño competitivo, aunque con el mayor gap de generalización.

DISCUSIÓN

LightGBM presentó el mejor equilibrio entre **precisión** y **estabilidad**. Sin embargo, la evaluación conjunta de la **variabilidad entre folds** y del **gap de generalización** evidencia que cada modelo mostró fortalezas distintas.

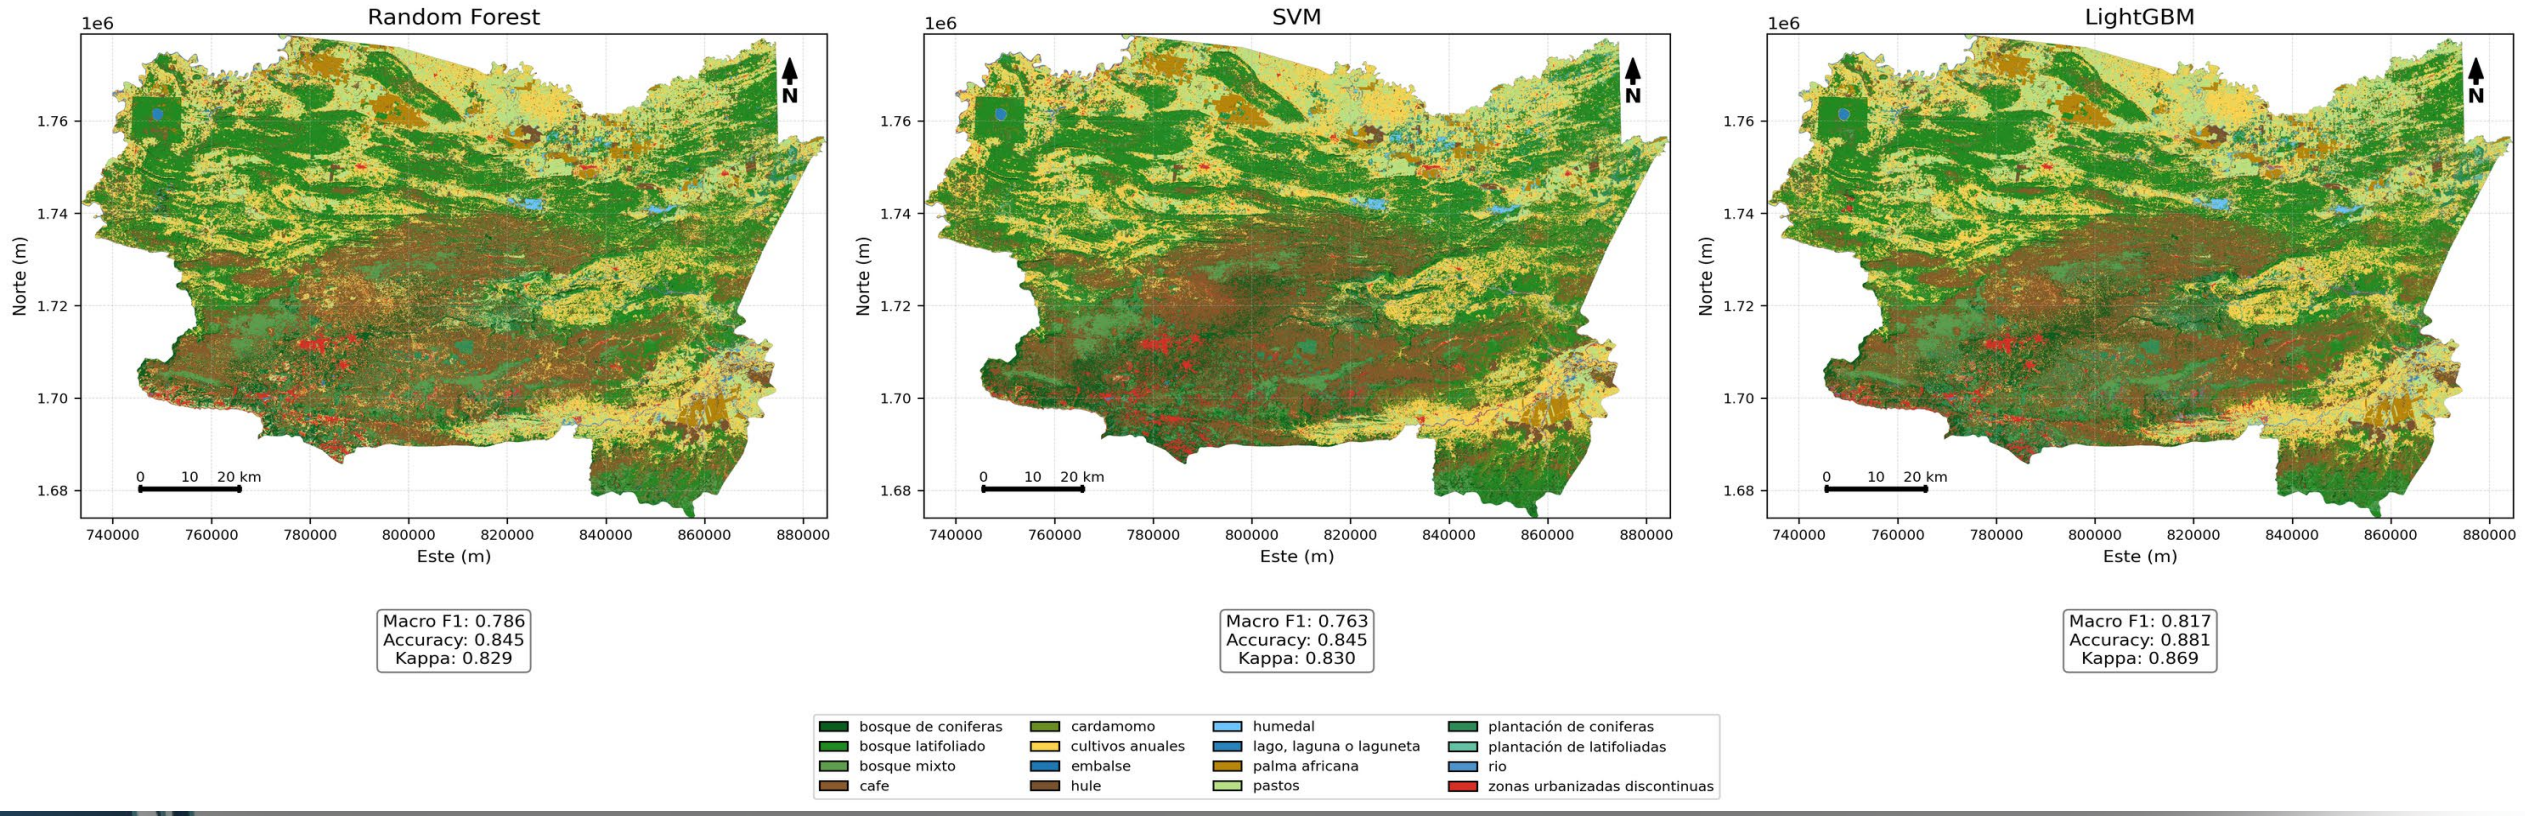
** Menores valores en todas las métricas indican mejor desempeño.*



Modelo	Macro F1 (CV)	Kappa (CV)	CV entre folds	Gap
LightGBM	0.828	0.854	0.035	0.172
Random Forest	0.788	0.825	0.041	0.212
SVM (RBF)	0.771	0.818	0.041	0.156

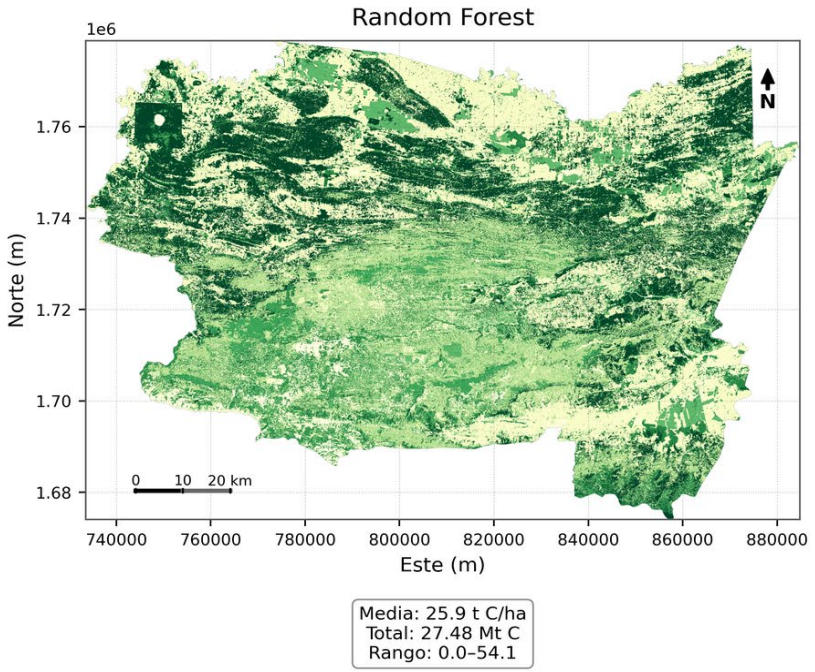
11. Comparación espacial de mapas clasificados

La diferencia entre algoritmos se observa también en el territorio, no solo en las métricas.

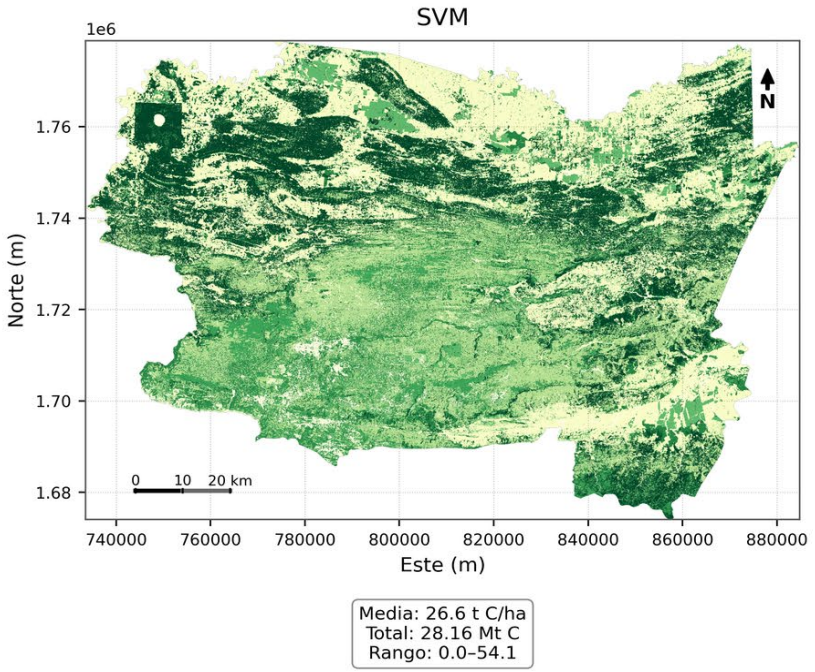


12. Del mapa al carbono: una estimación indirecta

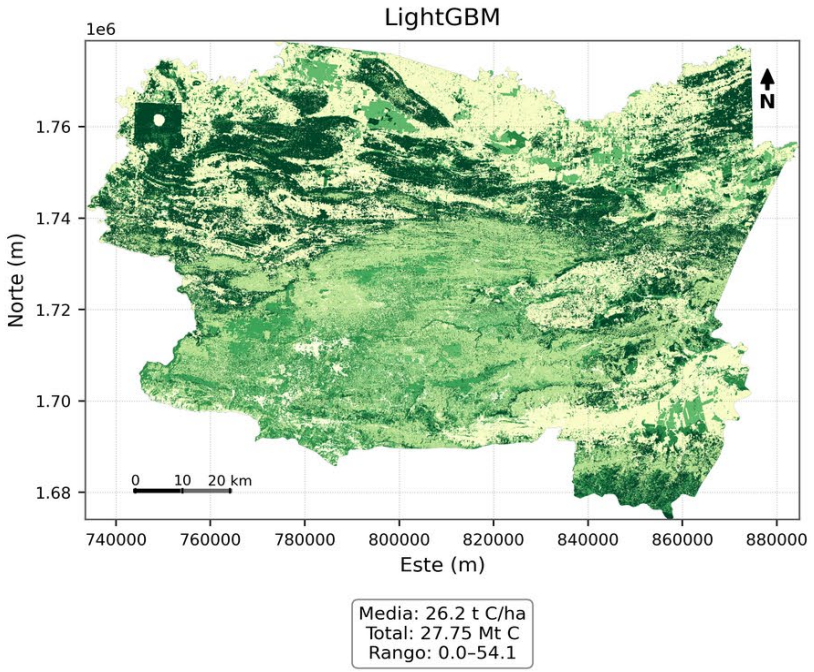
El algoritmo no predice carbono directamente: primero clasifica, luego se asigna un factor promedio por categoría.



Media: 25.9 t C/ha
Total: 27.48 Mt C
Rango: 0.0–54.1



Media: 26.6 t C/ha
Total: 28.16 Mt C
Rango: 0.0–54.1



Media: 26.2 t C/ha
Total: 27.75 Mt C
Rango: 0.0–54.1

13. Conclusiones

La tecnología es útil cuando el desempeño es trazable, reproducible y espacialmente interpretable.



Las variables topográficas, particularmente la **elevación** derivada del modelo digital de elevación, presentaron la mayor contribución al desempeño clasificatorio de los tres modelos. Las métricas texturales **GLCM** aportaron información complementaria importante para diferenciar coberturas con características espectrales o estructurales similares, las métricas ópticas entre ellas las infrarrojas fueron útiles para diferenciación de algunas coberturas, mientras que las variables radar mostraron una menor contribución relativa en las configuraciones evaluadas.



La optimización de **hiperparámetros** modificó de manera diferenciada el comportamiento de los modelos. LightGBM alcanzó el mejor equilibrio después del ajuste; Random Forest mostró un comportamiento relativamente robusto ante cambios de configuración, mientras que SVM presentó mayor sensibilidad a los parámetros **C y γ**.



La evaluación conjunta de Macro F1, Kappa, coeficiente de variación entre **folds** y **gap de generalización** demostró que ninguna métrica aislada resulta suficiente para seleccionar el modelo óptimo. **LightGBM** obtuvo los mayores valores de precisión y concordancia, así como la menor variabilidad entre **folds**.



El análisis comparativo permitió determinar que LightGBM presentó el mejor equilibrio global entre precisión, estabilidad y capacidad de generalización para la clasificación de cobertura y uso de la tierra en Alta Verapaz, lo que respalda la hipótesis alternativa de que existen diferencias en el desempeño de los modelos evaluados.

16. Recomendaciones



Validación espacial.
Aplicar esquemas por bloques para evaluar con mayor rigor la generalización territorial.



Datos complementarios.
Incorporar información estructural, como LiDAR, para mejorar la diferenciación de coberturas.



Nuevos algoritmos.
Evaluar otros modelos y estrategias de ensamblaje bajo el mismo esquema comparativo.



Incertidumbre.
Cuantificar conjuntamente la incertidumbre de la clasificación y de los factores de carbono.

¡Muchas gracias!

VI CONGRESO NACIONAL DE CAMBIO CLIMÁTICO
& IX SIMPOSIO NACIONAL MARINO COSTERO

Rodrigo Josué de la Roca González
Visión Mundial · Guatemala
rodrigodlr96@gmail.com
+502 4650 5255



Con el aval de:

2021 2030 Decenio de las Naciones Unidas de las Ciencias Oceánicas para el Desarrollo Sostenible