



DOI: <https://doi.org/10.70208/3007.8245.v6.n1.379>

Ingeniería de resiliencia ecológica en áreas protegidas: optimización de la eficiencia homeostática en ulmus minor y populus alba mediante modelos de aprendizaje por refuerzo

Alfredo Ancasi Mamani

alam_fcav@hotmail.com

<https://orcid.org/0009-0009-0556-5418>

Investigador Centro de Investigación de Cuencas de Altura. FCAN – UTO
Bolivia

Milton Robert Pérez Lovera

fcav_uto_perez@yahoo.com

<https://orcid.org/0009-0005-2672-8475>

Investigador Laboratorio de Monitoreo y Calidad Ambiental. FCAN – UTO
Bolivia

Juan Carlos Montoya Choque

jcmchmontoya@yahoo.es

<https://orcid.org/0009-0007-4081-1624>

Investigador Centro Aguas. FCAN – UTO
Bolivia

Jhonny Antonio Bustamante Ocaña

jhonnybustamante675@gmail.com

<https://orcid.org/0009-0008-5363-3705>

Investigador Museo de Historia Natural. FCAN – UTO
Bolivia



RESUMEN

La degradación ecosistémica y la crisis climática en el altiplano boliviano demandan nuevos mecanismos de análisis de datos basados en inteligencia artificial para comprender la resiliencia forestal. Los enfoques estáticos tradicionales (mínimos cuadrados) de acuerdo con la evidencia estadística presentan limitaciones en la evaluación del estrés fisiológico bajo condiciones de altitud extrema. El trabajo de investigación propone un marco computacional basado en aprendizaje por refuerzo (RL) para evaluar la eficiencia homeostática de *Ulmus minor* y *Populus alba* a 3730 m s. n. m. Se monitorizó el intercambio gaseoso foliar bajo concentraciones iniciales normales y altas de CO₂ utilizando un analizador infrarrojo (IRGA). Los datos (1836 registros) se preprocesaron mediante filtros Savitzky-Golay y se analizó la influencia del Déficit de Presión de Vapor (VPD). El análisis de regresión clásica no evidenció un ajuste lineal significativo (P-value > 0.05); así mismo las correlaciones nulas ($R \approx 0,00$) entre la tasa de asimilación y variables ambientales confirmaron la naturaleza estocástica del sistema y la complejidad no lineal del control estomático. En consecuencia, se modeló computacionalmente a la planta como un agente que optimiza su asimilación de carbono penalizando la inestabilidad metabólica. A través de un análisis de sensibilidad, se calculó un Índice de eficiencia homeostática y un diferencial de riesgo (Δ_{Riesgo}). Los resultados indican que *Populus alba* ($\Delta_{\text{Riesgo}} = 76,96$ y $123,58$) emplea una estrategia eficiente en condiciones normales pero frágil en ambientes con fluctuaciones cambiantes. En contraste, *Ulmus minor* ($\Delta_{\text{Riesgo}} = 106,40$ y $112,28$) exhibe una sensibilidad más conservadora, sugiriendo una estrategia estomática robusta ante fluctuaciones de cambio climático. Se concluye que los algoritmos de RL proporcionan métricas termodinámicas más robustas que los promedios fisiológicos, constituyendo una herramienta bioinformática prometedora para la selección de especies en programas de restauración ecológica y áreas protegidas.

Palabras clave: Aprendizaje por refuerzo, inteligencia artificial, espacio de fase, sensibilidad, riesgo



*Ecological resilience engineering in protected areas: optimization of homeostatic efficiency in *ulmus minor* and *populus alba* through reinforcement learning models*

ABSTRACT

Ecosystem degradation and the climate crisis in the Bolivian highlands demand new data analysis mechanisms based on artificial intelligence to understand forest resilience. Traditional static approaches (least squares), according to statistical evidence, present limitations in assessing physiological stress under extreme altitude conditions. This research proposes a computational framework based on reinforcement learning (RL) to evaluate the homeostatic efficiency of *Ulmus minor* and *Populus alba* at 3730 m a.s.l. Foliar gas exchange was monitored under normal and high initial CO₂ concentrations using an infrared gas analyzer (IRGA). The data (1836 records) were preprocessed using Savitzky-Golay filters, and the influence of Vapor Pressure Deficit (VPD) was analyzed. Classical regression analysis did not show a significant linear fit (P-value > 0,05). Likewise, the null correlations ($R \approx 0,00$) between the assimilation rate and environmental variables confirmed the stochastic nature of the system and the nonlinear complexity of stomatal control. Consequently, the plant was computationally modeled as an agent that optimizes its carbon assimilation by penalizing metabolic instability. Through a sensitivity analysis, a Homeostatic Efficiency Index and a risk differential (Δ_{Risk}) were calculated. The results indicate that *Populus alba* ($\Delta_{\text{Risk}} = 76,96$ and $123,58$) employs an efficient strategy under normal conditions but is fragile in environments with changing fluctuations. In contrast, *Ulmus minor* ($\Delta_{\text{Risk}} = 106,40$ and $112,28$) exhibits a more conservative sensitivity, suggesting a robust stomatal strategy in the face of climate change fluctuations. It is concluded that RL algorithms provide more robust thermodynamic metrics than physiological averages, constituting a promising bioinformatics tool for species selection in ecological restoration programs and protected areas.

Keywords: Reinforcement learning, artificial intelligence, phase space, sensitivity, risk



INTRODUCCIÓN

El cambio climático, impulsado por la actividad humana y la acumulación de gases de efecto invernadero, está transformando los ecosistemas vulnerables de Bolivia. En las áreas protegidas y cuencas de alta montaña del Altiplano, este fenómeno no actúa solo; se suma a los impactos de la actividad minera, tanto histórica como actual. La degradación de los suelos y la contaminación por metales pesados en cuencas cerradas (endorreicas), como las de los lagos Poopó y Uru Uru, han debilitado servicios naturales, poniendo en riesgo la seguridad hídrica y la estabilidad del territorio. En este escenario, la restauración ecológica requiere la aplicación de métodos matemáticos más robustos que superen los enfoques tradicionales. Las especies forestales utilizadas para recuperar estas cuencas enfrentan condiciones extremas: falta de agua, radiación intensa y la dificultad de mantener un balance metabólico positivo en la baja presión atmosférica de las alturas. Aunque el aumento del CO₂ en el aire podría favorecer la fotosíntesis (Ruiz A., 2011), las limitaciones de la altitud (3730 m.s.n.m.) y la toxicidad de los suelos suelen anular este beneficio (Field & Mooney, 1986; Xu et al., 2016). Por ello, la fotosíntesis no debe verse como un proceso fisiológico simple y lineal, sino como un sistema de control dinámico. Es una decisión biológica donde la planta debe equilibrar constantemente la ganancia de carbono con la pérdida de agua (Allen et al., 1998).

En este contexto, la homeostasis entendida como la capacidad de un organismo para mantenerse estable frente a cambios externos se convierte en la medida de ingeniería más importante para evaluar la resiliencia vegetal. Aunque especies como el Álamo (*Populus alba*) y el Olmo (*Ulmus minor*) son valoradas por su crecimiento rápido (Gil & Vázquez, 2015), la selección de ejemplares para áreas protegidas de altura ha carecido de un análisis sobre su resistencia interna en tiempo real. Los métodos tradicionales, solo miden el resultado final, y resultan insuficientes para entender cómo estas especies ajustan su respiración (conductancia estomática) ante un entorno alterado por la actividad minería y el clima. En tal sentido, esta investigación propone el uso del Aprendizaje por Refuerzo (RL), la cual es una rama avanzada de la inteligencia artificial diseñada para resolver problemas de control óptimo.



Bajo este modelo, se considera a la planta como un agente inteligente que aprende a ejecutar acciones para maximizar una recompensa: su propia estabilidad y eficiencia. Este enfoque permite ir más allá de la descripción de morfología vegetal, ofreciendo una evaluación desde la ingeniería sobre qué especie garantiza mejor la recuperación de servicios ecológicos. En esencia, se convierte la supervivencia biológica en un proceso de optimización computacional. Esta problemática es urgente en regiones críticas como el Sitio Ramsar de los Lagos Poopó y Uru Uru, o el Parque Nacional Sajama, donde la pérdida de vegetación afecta la regulación del agua y la captura de carbono.


El uso de modelos de inteligencia artificial (aprendizaje por refuerzo) para seleccionar especies resilientes es, por tanto, una estrategia vital para la conservación de estos ecosistemas. El objetivo de este trabajo de investigación es analizar la dinámica de asimilación de CO₂ y la estabilidad homeostática en plantines de *Ulmus minor* y *Populus alba* a 3730 m.s.n.m. Para ello, se integra el uso de un analizador de gases infrarrojos con un marco de Aprendizaje por Refuerzo, permitiendo determinar científicamente su capacidad como cobertura verde en áreas naturales protegidas.

METODOLOGÍA

La investigación propone una metodología basada en el enfoque de CRISP-DM (Cross Industry Standard Process for Data Mining) y SEMMA (Sample, Explore, Modify, Model, Assess). Las cuales son utilizadas en proyectos de ciencia de datos, minería de datos, machine learning y deep learning. En este ajuste se ha contemplado 4 fases esenciales las cuáles se muestran en la ilustración 1.



Ilustración 1 Diagrama de Flujo procedimental



Fuente: Elaboración propia. Ancasi, A. (2025)


Así también el análisis de datos se realiza mediante código Python, con la aplicación de librerías especializadas.

A] Fase I. Entendimiento del tema y datos

El trabajo de investigación se llevó a cabo en los laboratorios del Departamento de Ingeniería Agrícola, Recursos Naturales y Medio Ambiente, de la Facultad de Ciencias Agrarias y Naturales de la Universidad Técnica de Oruro, situados a una altitud de 3730 m.s.n.m. Se estableció un tamaño muestral de 12 plantines, de dos años de edad, con una longitud superior a 1 metro. Se dividió la muestra en dos escenarios CO₂ inicial normal (3 por especie) y CO₂ inicial alto (3 por especie). Se registraron datos cada 2 segundos, generando 153 datos por planta y consolidando una base de datos de 1836 registros. Se utilizó el sistema de intercambio de gases Q-BOX CO650 (Qubit Biology Inc.), equipado con un analizador de gases infrarrojos (IRGA) para la medición directa. El equipo


permitió monitorear cuatro variables críticas: Concentración de CO₂ (ppm), humedad Relativa del aire (%HR), temperatura del aire en la cámara (°C), flujo de aire (l/min). Ver ilustración 2.

Ilustración 2. A. Planificación y Selección de especies forestales. B. Verificación del equipo. C. Instalación del equipo. D. Medición, toma de datos y registro



La tasa de fotosíntesis se determina mediante el diferencial de concentración de CO₂ entre la entrada y la salida de la cámara foliar, permitiendo evaluar la capacidad de respuesta de la planta ante incrementos del sustrato. Se evalúa una comparación de CO₂ inicial alta e inicial normal en ambas especies forestales para evaluar su comportamiento en el tiempo. Es importante mencionar que a la par de la fijación de carbono las estomas regulan la pérdida de agua mediante la transpiración. Esto se fundamenta en la teoría coheso-tenso-transpiratoria, donde la evaporación foliar crea la fuerza de succión necesaria para movilizar la columna de agua por todo el xilema. Evaluar esta dinámica hídrica es vital para entender la resiliencia de especies forestales, facilitando así la gestión técnica de recursos hídricos en áreas protegidas. Ver ilustración 3.

Ilustración 3 . Interacción de factores que afectan a la transpiración. (Adaptado de Azcón-Bieto y Talón, 2000.)



Tras un periodo de aclimatación de los plantines del vivero al laboratorio, se procede a la medición sistemática. Cada sesión tuvo una duración total de 10 minutos, con una frecuencia de muestreo de un dato cada 2 segundos. La frecuencia de muestreo de 2 segundos es necesaria porque los modelos de inteligencia artificial (aprendizaje por refuerzo) requieren una alta densidad de estados para aprender la política de control de las especies vegetales de forma más precisa.

B] Fase II. Procesamiento y limpieza de datos

Para la transformación de los datos recolectados en métricas, se aplica el filtro digital Savitzky-Golay (con: ventana temporal de 5, polinomio de grado 2) el cual es utilizado a mitigar el ruido estocástico del sensor de medición (IRGA) sin alterar el comportamiento biológico de la asimilación, a partir de la señal suavizada, la tasa de asimilación neta (A_n) se determina derivando el diferencial de concentración respecto al tiempo:

$$A_n \approx -\frac{\Delta[CO_2]}{\Delta t}$$

Código: Suavizado de señal y cálculo de tasa de asimilación

```
df['CO2_Smooth'] = df.groupby('ID')['CO2'].transform(
    lambda x: savgol_filter(x, window_length=5, polyorder=2)
)
df['Tasa_Fotosintesis'] = (-df['CO2_Smooth'].diff() / 0.2).clip(-10, 150)
```



Adicionalmente, se calcula el déficit de presión de vapor (VPD), aplicando la ecuación empírica de Tetens para evaluar el gradiente de estrés hídrico atmosférico. Para esto primero se procede a calcular la presión de vapor de saturación (e_s) en kilopascales (kPa) en función de la temperatura del aire (TA)

$$e_s = 0,6108 * \exp\left(\frac{17,27 * TA}{TA + 237,3}\right)$$

Posteriormente se calcula el gradiente de estrés hídrico basado en la humedad relativa (HR).

$$VPD = e_s - \left(e_s * \frac{HR}{100}\right)$$

Cuando el VPD es bajo se tiene el riesgo de una poca transpiración por parte de las plantas, limitando la absorción de nutrientes. Si el VPD es alto, se tiene el riesgo de un estrés hídrico.

Código: Cálculo de la Presión de Vapor (VPD)

```
es = 0.61078 * np.exp((17.27 * df['TA']) / (df['TA'] + 237.3))
df['VPD'] = es - (es * (df['HR'] / 100))
```

C] Fase III. Modelación


Para evaluar la interacción lineal entre las variables termodinámicas (VPD, TA, HR) con la respuesta biológica (CO₂, Tasa fotosintética) se genera matrices de correlación de Pearson. Posteriormente, se cuantifica la dependencia de la fotosíntesis mediante un modelo de regresión lineal. La robustez de este modelo estadístico se evalúa mediante el coeficiente de determinación y la prueba de F de Fisher con el P-value <0,05. Prueba bilateral.

$$R^2 = 1 - \frac{SS_{res}}{SS_{tot}}$$

Sin embargo frente a las limitaciones de la inferencia estática, el comportamiento vegetal se modeló mediante modelos de inteligencia artificial: aprendizaje por refuerzo (RL). El Aprendizaje por Refuerzo es una rama del aprendizaje automático (machine learning) donde un agente autónomo aprende a tomar decisiones secuenciales óptimas interactuando con su entorno. Basado en ensayo y error, el agente recibe recompensas positivas o penalizaciones negativas para maximizar la recompensa total a largo plazo. Ver ilustración 4.



Ilustración 4 Arquitectura general de aprendizaje por refuerzo



Se conceptualiza a la especie forestal como un agente inteligente dentro de un proceso de decisión de Markov.

Este enfoque evalúa el comportamiento vegetal en el Espacio de Fase. Se define el estado fisiológico mediante el vector de estado $X(t)$:

$$X(t) = \begin{bmatrix} A_n(t) \\ \frac{dA_n}{dt} \end{bmatrix}$$

Donde $A_n(t)$ es la tasa neta de asimilación de carbono y su derivada representa la inercia del sistema.

La evolución del estado fisiológico de la planta se rige entonces por la función de transición biológica:

$$X(t) = f(X(t), u(t), w(t))$$

En esta arquitectura, $u(t)$ representa la política de control estomático ejecutada por la planta (grado de apertura/cierre), mientras que $w(t)$ engloba las perturbaciones estocásticas del entorno ambiental (fluctuaciones de temperatura y humedad).

Para modelar este proceso de optimización, se estructura una función de recompensa instantánea (R_t). Esta función traduce el compromiso metabólico

$$R_t = \underbrace{w_1 \phi(A_n(t))}_{\text{Ganancia}} - \underbrace{w_2 \sigma^2(A_{n(t-k:t)})}_{\text{Costo de inestabilidad}} - \underbrace{w_3 T(VPD_t)}_{\text{Riesgo Hídrico}}$$

Ganancia Costo de inestabilidad Riesgo Hídrico

Los pesos sinápticos de la función representan restricciones biológicas fundamentales: Término de ganancia (W_1): Representa la eficiencia fotosintética. En términos biológicos es el flujo de electrones



para la regeneración de Ribulosa-1,5-bisfosfato (RuBP). Costo de inestabilidad (W_2): Penaliza la varianza (σ^2) y el comportamiento errático en una ventana temporal continua. Biológicamente, representa el gasto energético derivado de la síntesis y degradación enzimática innecesaria ante fluctuaciones estocásticas. (W_3): Basado en la teoría coheso-tenso-transpiratoria. A medida que el déficit de presión de vapor (VPD_t) aumenta, el potencial hídrico foliar, imponiendo una penalización exponencial.

Por otra parte el Índice de Eficiencia Homeostática (Score RL) se emplea para traducir la recompensa instantánea en una métrica empírica calculable sobre las series temporales capturadas por el equipo de medición. Este índice (Score RL) simplifica la optimización de la política estomática integrando la asimilación media y castigando linealmente la desviación estándar observada durante el periodo de evaluación:

$$Score_{RL} = \mu(A_n) - \beta * \sigma(A_n)$$

Donde μ es la asimilación media (ganancia de carbono neta esperada), σ es la desviación estándar del flujo (inestabilidad foliar), y el hiperparámetro β consolida matemáticamente la aversión al riesgo de la especie (w_2, w_3). Para el modelo nominal, se establece una tasa de penalización balanceada con $\beta=2,0$ un factor de descuento temporal $\gamma=0,95$ y una tasa de aprendizaje iterativo $\alpha=0,1$.

Código: Generación de la función de Score Homeostático

```
def calcular_score_homeostatico(grupo, beta_std=2.0):
    tasa = grupo['Tasa_Fotosintesis'].values
    # Recompensa = Promedio de asimilación - Castigo por inestabilidad
    recompensa_rl = np.mean(tasa) - (beta_std * np.std(tasa))
    return recompensa_rl)
```

D] Fase IV. Evaluación e interpretación

Finalmente se emplea el análisis de sensibilidad (escenarios) como procedimiento de validación del Score RL y diagnosticar la estrategia adaptativa subyacente de *Populus alba* y *Ulmus minor*, iterando el hiperparámetro de penalización β para simular tres perfiles de evaluación. Simulación 1: Modelo agresivo ($\beta = 0,5$) que prioriza la fotosíntesis máxima, asumiendo un entorno sin limitantes hídricas donde la inestabilidad metabólica tiene un costo nulo. Simulación 2: Modelo balanceado ($\beta = 2,0$)



que representa la homeostasis fisiológica equitativamente en la fijación de carbono y la pérdida de agua. Simulación 3: Modelo balanceado ($\beta = 5,0$) que penaliza de forma extrema cualquier inestabilidad de la asimilación, con una condición de supervivencia de desecación domina la toma de decisiones.

Para cuantificar objetivamente la resiliencia forestal, se extrajo de este análisis el diferencial de riesgo (Δ_{Riesgo}) calculado como la pérdida de eficiencia al realizar la transición de un escenario sin restricciones a uno restrictivo:

$$\Delta_{\text{Riesgo}} = \text{Score}^{(\beta=0,5)} - \text{Score}^{(\beta=5,0)}$$

La magnitud de riesgo (Δ_{Riesgo}) actúa como un indicador, donde valores bajos diagnostican una resiliencia conservadora (la especie mantiene tasas estables a pesar de la fluctuación ambiental), mientras que valores altos evidencian una sensibilidad a la varianza característica de especies oportunistas propensas al colapso bajo estrés.


RESULTADOS

Análisis de la Dinámica Temporal y el Techo Metabólico

En la Figura 1 se presenta la dinámica de la tasa de asimilación neta estimada (ppm CO₂/min) a lo largo de los 10 minutos de exposición. Se observa una respuesta claramente bifásica en ambas especies. Durante los primeros 240 segundos (4 minutos), los plantines muestran una fase de activación estomática errática. Sin embargo, el hallazgo más crítico es la convergencia hacia lo que denominamos un techo metabólico basal a partir de los 6 minutos de medición. Mientras que *Populus alba* exhibe picos de asimilación iniciales más altos, su caída es más drástica y oscilatoria. En contraste, *Ulmus minor* mantiene una trayectoria más suavizada, sugiriendo que su sistema de control amortigua mejor el estrés de la baja presión parcial de gases.



Figura. 1. Dinámica de asimilación de carbono en altura




Estabilidad del Sistema en el Espacio de Fase

La Figura 2 muestra el diagrama de Espacio de Fase, que relaciona la concentración de CO₂ en la cámara frente a la velocidad de respuesta (Tasa de Asimilación). La figura es fundamental para diagnosticar la salud del controlador estomático. Los bucles observados representan la Histéresis del sistema.

Se evidencia que *Ulmus minor* genera trayectorias que convergen rápidamente hacia un atractor de punto fijo con bucles de histéresis estrechos, lo que en ingeniería equivale a un sistema de control eficiente con baja pérdida de energía por retardo. Mientras, la trayectoria de *Populus alba* es divergente y amplia, reflejando una incapacidad metabólica para estabilizar el intercambio gaseoso bajo condiciones de alta radiación y altitud, lo que incrementa su vulnerabilidad hídrica.

Figura. 2. Espacio de fase: Histéresis y control estomático


Espacio de Fase: Histéresis y Control Estomático



Matrices de Correlación y Justificación del Modelado No Lineal

En la Figura 3 se presentan las matrices de correlación de Pearson (Heatmaps) para ambas especies forestales. Un resultado contraintuitivo pero revelador es la presencia de correlaciones nulas o cercanas a cero ($R \approx 0,00$) entre la Tasa de Fotosíntesis y la concentración de CO₂. La falta de correlación lineal observada sugiere que las especies forestales podrían estar priorizando mecanismos de estabilidad interna, lo cual es característico de un sistema de control no lineal complejo. El *Populus alba* p-value: 0,6667 y en el *Ulmus minor* p-value: 0,7461. En ambos casos el p-value > 0,05. De no significancia estadística. Se observa que las variables de: CO₂, temperatura del aire y humedad relativa en *Populus alba* están más fuertemente vinculadas al déficit de presión de vapor (VPD) en comparación al *Ulmus minor*, lo que confirma su alta sensibilidad al aire seco del Altiplano. Estos mecanismos de autorregulación son esenciales en la gestión de Áreas Protegidas.

Figura. 3. Matriz de correlación Pearson (Olmo y Álamo)



Cuantificación de la Resiliencia mediante el Score RL

Para realizar la comparación objetiva entre especies, se calcula el Índice de eficiencia homeostática basado en el modelo de aprendizaje por refuerzo (RL). Los valores numéricos consolidados se presentan en la siguiente tabla, donde se desglosa la relación entre eficiencia (media de asimilación) e inestabilidad (varianza de la respuesta). Ver tabla 1.

Tabla 1 Resiliencia mediante el Score de aprendizaje por refuerzo RL

Especie	Condición inicial de CO ₂	Score	Rank
		(Eficiencia – inestabilidad)	
Álamo	Alta CO ₂	-48,87	Último
Álamo	normal CO ₂	-28,03	Primero
Olmo	Alta CO ₂	-39,29	Tercero
Olmo	normal CO ₂	-39,15	Segundo


De acuerdo a la tabla de resultados se puede mencionar que:

La implementación del algoritmo de aprendizaje por refuerzo bajo una política balanceada ($\beta= 2,0$) revela divergencias sustanciales en la asimilación de carbono. El *Populus alba* (Álamo) alcanza su máxima eficiencia homeostática bajo condiciones de concentración inicial de CO₂ normal, logrando un Score RL de -28,03 (mejor optimización energética en ambiente tranquilo). No obstante, ante



concentraciones altas, su rendimiento decae a -48,86 (Su sistema se vuelve caótico e inestable). Por su parte, el *Ulmus minor* (Olmo) demuestra un rendimiento inferior pero aparentemente más constante entre escenarios, con scores de -39,29 (CO₂ alta) y -39,15 (CO₂ normal). Estos datos se visualizan comparativamente en la Figura 4, que muestra el score final de resiliencia.

Figura. 4. Índice de eficiencia Homeostática



Análisis de sensibilidad y resiliencia

Al someter los datos de las especies forestales al diferencial de políticas de recompensa, el *Ulmus minor* presentó una sensibilidad más estable en ambas condiciones y bajo tres escenarios, con valores cercanos, con $\Delta_{\text{Riesgo}} = 112,28$ y $106,40$. Esto diagnostica al *Ulmus minor* como una especie de resiliencia conservadora (robusta ante fluctuaciones de cambio climático, conservadora en condiciones de estrés), mientras que el *Populus alba* adopta una política de evitación inestable frente al estrés del entorno $\Delta_{\text{Riesgo}} = 76,96$ y $123,58$ (eficiente en condiciones normales pero frágil con ambientes que fluctúan). Ver tabla 2.




Tabla 2 Análisis de sensibilidad mediante escenarios de riesgo (Agresivo, balanceado, conservador)

Especie	Condición inicial de CO ₂	Escenario I	Escenario II	Escenario III	Δ_{Riesgo}
		Agresivo	Balanceado	Conservador	
		($\beta=0,5$)	($\beta=2,0$)	($\beta=5,0$)	
Álamo	Alta CO ₂	-7,671	-48,868	-131,26	123,589
Álamo	normal CO ₂	-2,377	-28,033	-79,345	76,968
Olmo	Alta CO ₂	-1,86	-39,289	-114,146	112,286
Olmo	normal CO ₂	-3,679	-39149	-110,088	106,409

El comportamiento de Score en diferentes escenarios (β) se visualiza en la Figura 5.

Figura. 5. Análisis de sensibilidad por especies



DISCUSIÓN

La integración del aprendizaje por refuerzo (RL) para cuantificar la eficiencia homeostática foliar concuerda fuertemente con la literatura computacional emergente en Ciencias Agrarias y Naturales. Malo et al. (2021) demostraron que los algoritmos de RL superan a los modelos dinámicos



tradicionales al resolver problemas de optimización estocástica en el manejo forestal continuo, modelando decisiones secuenciales ante la incertidumbre ambiental. También para abordar diversas características específicas del problema de gestión forestal, como la combinación de variables de control continuo y variables de tiempo binarias.

Así también el uso de funciones de recompensa para evaluar la vulnerabilidad ante el estrés hídrico ha sido recientemente explorado por Wang et al. (2025), quienes desarrollaron modelos de RL que optimizan dinámicamente el riego penalizando la varianza ambiental mediante incentivos negativos. Empleando redes neuronales artificiales, logrando así predicciones precisas de la evapotranspiración.

CONCLUSIONES

Existe evidencia estadística para afirmar una limitación de los modelos estáticos, esto se observa en la carencia de correlación lineal significativa sugiriendo que las respuestas estomáticas ante fluctuaciones termodinámicas en condiciones de altura obedecen a dinámicas de control óptimo no lineales. El modelo de aprendizaje por refuerzo implementado permite cuantificar esta complejidad, penalizando la inestabilidad biológica.

Los datos sugieren que mientras que el *Populus alba* exhibe una resiliencia oportunista (máxima eficiencia en condiciones basales pero alta fragilidad ante el enriquecimiento de CO₂, El *Ulmus minor* manifiesta una estabilidad robusta, manteniendo scores homeostáticos consistentes independientemente de la carga de sustrato atmosférico. El *Populus alba* podría ser preferible si es que el estrés hídrico sea moderado (condiciones estables). Mientras que *Ulmus minor* podría ser ideal para sitios con condición climática variable, mantiene su rendimiento casi idéntico aunque cambie las condiciones de CO₂.

El uso de aprendizaje por refuerzo y el análisis de espacio de fase permiten cuantificar la resiliencia vegetal de forma superior a los métodos estáticos. El Score de eficiencia homeostática integra el costo metabólico de la inestabilidad, proporcionando una métrica de ingeniería clara para la selección de especies.

El trabajo de investigación posee limitaciones, debido a su desarrollo en condiciones de laboratorio (controladas), y para la extrapolación directa a ecosistemas abiertos es necesario complementar más



pruebas. Así también es necesario incorporar otros factores de variación como el suelo, nutrición y presencia de metales pesados. Posteriores investigaciones deberían aplicar esta arquitectura de aprendizaje por refuerzo integrando redes de sensores IoT en campo abierto y monitoreos longitudinales en diferentes sitios. No obstante, este estudio establece un precedente de bioinformática viable para optimizar la toma de decisiones en la reforestación en áreas protegidas.

REFERENCIAS BIBLIOGRÁFICAS

- Allen, R. G., Pereira, L. S., Raes, D., & Smith, M. (1998). Crop evapotranspiration: Guidelines for computing crop water requirements (FAO Irrigation and Drainage Paper No. 56). FAO.
- Calbó, J., Dusenget, M. E., Duarte, A. G., Way, D. A., Ballester, F., Díaz, J., & Raghavendra, A. S. (2019). Impacto del cambio climático sobre la fotosíntesis, fotorrespiración y respiración de plantas C3.
- Carrizo, S. L., Montes de Oca, C. E., Laiño, J. E., Suarez, N. E., Vignolo, G. M., LeBlanc, J. G., & Rollán, G. C. (2016). Andean grain quinoa as source of lactic acid bacteria capable to degrade phytate and produce B-group vitamins. *Food Research International*, 89, 488–494.
- Field, C. B., & Mooney, H. A. (1986). The physiological ecology of plants under stress. *Annual Review of Plant Physiology*, 37(1), 51–69.
- Gómez del Campo, M. V. (1998). Mecanismos de adaptación a sequía: Evaluación del consumo de agua, crecimiento y desarrollo vegetativo [Tesis doctoral, Universidad Politécnica de Madrid]. Archivo Digital UPM.
- Gil, L., & Vázquez, F. J. (2015). El olmo, un árbol con futuro. *Boletín de la Sociedad Micológica Castellana*, 31, 11–18.
- Hernández, G. R. (2014). Fisiología vegetal. Departamento de Botánica, Facultad de Ciencias Forestales y Ambientales, Universidad de Los Andes.
- Intergovernmental Panel on Climate Change. (2021). *Climate change 2021: The physical science basis*. Cambridge University Press.



- Malo, P., Tahvonen, O., & Viitakangas, S. (2021). Reinforcement learning in optimizing forest management. *Canadian Journal of Forest Research*, 51(10), 1393–1409.
<https://doi.org/10.1139/cjfr-2020-0447>
- Rodríguez R., M. (2010). *Morfología y anatomía vegetal* (4.^a ed.). Kipus.
- Rodríguez R., M. (2011). *Fisiología vegetal* (2.^a ed.). Kipus.
- Rubio, J. A. (2002). Riego y aclareo: efecto de la actividad fisiológica en el control de la calidad de la uva [Tesis doctoral, Universidad Politécnica de Madrid]. Archivo Digital UPM.
- Ruiz, A. (2011). *Mecanismos fisiológicos de respuesta de la cebada al impacto de la sequía y el elevado CO₂: Adaptación al cambio climático* [Tesis doctoral, Universidad del País Vasco]. Servicio Editorial de la Universidad del País Vasco.
- Saenz, J. (2012). *La fotosíntesis, concepciones, ideas alternativas y analogías: Unidad didáctica dirigida a estudiantes de los ciclos 3 y 4 de educación básica del colegio José María Carbonell* [Tesis de maestría, Universidad Nacional de Colombia]. Repositorio Institucional.
- Santamouris, M., & Kambezidis, H. (2010). *Urban climate bioclimatic design*. James & James Science Publishers.
- Seralathan, E., Ponnusamy, V., & Hussain, M. A. (2025). Reinforcement learning based dynamic vegetation index formulation for early water stress detection. *Scientific Reports*, 15(1), 33386.
<https://doi.org/10.1038/s41598-025-33386-9>
- Socorro, A., & Cristobal, R. (2013). Fotosíntesis artificial: Comparación con el mecanismo natural. *Revista Cubana de Física*, 30(1), 9–13.
- Sofo, A., Nuzzo, V., Palese, A. M., Xiloyannis, C., & Dichio, B. (2005). Net CO₂ storage in Mediterranean olive and peach orchards. *Scientia Horticulturae*, 107(1), 17–24.
- Taiz, L., & Zeiger, E. (2002). *Plant physiology* (3.^a ed.). Sinauer Associates.
- Wang, X., Zhang, Y., Wang, X., Wang, X., Hou, Y., & Wei, R. (2025). Reinforcement learning control method for greenhouse vegetable irrigation driven by dynamic clipping and negative incentive mechanism. *Frontiers in Plant Science*, 16, 1632431.
<https://doi.org/10.3389/fpls.2025.1632431>



- Xiong, J., & Bauer, C. E. (2002). Complex evolution of photosynthesis. *Annual Review of Plant Biology*, 53, 503–521.
- Xu, X., Chen, F., & Yang, H. (2016). Impacts of climate change on terrestrial ecosystem carbon and water cycles: A review. *Agricultural and Forest Meteorology*, 222, 1–14.

