



Foto: José Paruelo

APLICACIÓN DE ALGORITMOS DE APRENDIZAJE Y “GEMELOS DIGITALES” EN LA TOMA DE DECISIONES EN SISTEMAS AGROPECUARIOS: el caso de la productividad forrajera del campo natural

Ing. Agr. PhD José M. Paruelo¹
Lic. Cs. Biol. Dr. Marcos Texeira²
Lic. Física. PhD Fernando Tomasel³

¹INIA La Estanzuela /IFEVA, Facultad de Agronomía, UBA - CONICET/IECA, Facultad de Ciencias - Udelar
²IFEVA, Facultad de Agronomía - UBA - CONICET
³Department of Electrical and Computer Engineering - Colorado State University

El campo natural es un ecosistema clave en Uruguay desde un punto de vista productivo y ambiental. La sostenibilidad ambiental, económica y social de los sistemas ganaderos basados en pastizales naturales depende de su adecuada gestión. Disponer de herramientas que anticipen la disponibilidad forrajera mejora la planificación. Este artículo presenta un enfoque innovador para la prospección de la oferta forrajera del campo natural a través de la modelización híbrida, una fusión de métodos paramétricos y aprendizaje automático, y la generación de “gemelos digitales”.

PRONOSTICAR PARA PLANIFICAR: LA NECESIDAD DE MODELOS

Un proceso de toma de decisiones orientado a mejorar la sostenibilidad de los sistemas ganaderos extensivos requiere información que anticipe el comportamiento de los recursos forrajeros. Esto permite ajustar cargas, planificar

descansos, generar o usar reservas, vender o comprar hacienda, entre otras medidas de manejo. Ejecutar estas estrategias implica una serie de acciones previas a su implementación. Por ejemplo, una suplementación efectiva requiere de la selección del mejor suplemento para cada categoría de hacienda, evaluar su disponibilidad y precio, su compra y traslado, etc. Estimar la disponibilidad

forrajera de cada potrero con 1-2 meses de anticipación es una pieza clave para generar manejos sostenibles en lo ambiental y productivo.

Los modelos predictivos más frecuentemente utilizados suponen una relación lineal entre las variables independientes y dependientes, es decir, un cambio en una cantidad resulta en un cambio proporcional en una cantidad relacionada. Esto no debiera sorprendernos, la tendencia a asumir linealidad en la resolución de problemas es común debido a su simplicidad y facilidad de comprensión. Operativamente, los modelos lineales también son más fáciles de generar e implementar. Aunque esta suposición simplifica el análisis, también puede llevar a interpretaciones erróneas o a una comprensión incompleta de los problemas. La realidad es que la naturaleza es frecuentemente no lineal, es decir que la relación entre las variables de interés no es proporcional. Los modelos no lineales tienen mayor potencial para describir sistemas complejos, pero son más difíciles de desarrollar: mientras que hay una sola forma de conectar dos variables a través de una relación lineal, existen infinitas maneras de conectar las mismas dos variables con una relación no lineal.

Las Redes Neuronales Artificiales (RNA) son herramientas comúnmente usadas en el análisis y modelado de sistemas complejos. Las RNA son algoritmos del campo del aprendizaje automático, una rama de la Inteligencia Artificial (IA). El aprendizaje automático se enfoca en el desarrollo de métodos que permiten a las máquinas aprender y mejorar a partir de la experiencia, es decir, los datos. Esta área incluye técnicas como el aprendizaje supervisado, no supervisado y por refuerzo, y es fundamental en muchas aplicaciones modernas de IA, desde el reconocimiento de voz hasta la toma de decisiones autónoma en sistemas complejos. Las RNAs son especialmente conocidas por su habilidad para identificar patrones complejos en grandes volúmenes de datos.

A pesar de su importancia y capacidad, el uso indiscriminado de RNA en el modelado y predicción de datos conlleva riesgos significativos. Uno es la sobredependencia en estas herramientas, que puede resultar en una comprensión superficial de los fenómenos estudiados al ignorar los procesos subyacentes. Las RNA también pueden generar resultados engañosos o sesgados si los datos de entrenamiento no son de calidad o no representan adecuadamente la diversidad del fenómeno. Por último, la complejidad interna de las RNA hace difícil comprender cómo llegan a una predicción específica, y esto puede limitar la comprensión última del sistema.

LA PRODUCCIÓN DE FORRAJE Y SU COMPLEJIDAD

La producción de forraje en el campo natural es influenciada por múltiples factores como la disponibilidad de agua en el suelo, las especies

vegetales presentes, la temperatura, las características del suelo y el pastoreo. El efecto de un factor depende del nivel de los otros, y la importancia de cada factor varía en el tiempo y entre potreros. Así, el efecto de la precipitación sobre la producción de biomasa depende de la estación del año y de la biomasa verde presente. Hablamos entonces de sistemas complejos y dinámicos, con numerosas variables interconectadas y mutuamente influenciadas.

Modelar estos sistemas requiere un entendimiento profundo de los procesos ecológicos involucrados (consumo de agua, disponibilidad de nutrientes, competencia entre especies, efectos de la herbivoría, etc.). Entender no alcanza, la disponibilidad y calidad de los datos pueden afectar la precisión del modelo. El tipo de datos disponible y su resolución espacial (por potrero o por departamento) y temporal (diarios o anuales) son consideraciones críticas en la generación de modelos. La comprensión y las características de los datos determinará que se puedan desarrollar modelos que sean robustos y adaptables a cambios y a un flujo constante de información.

Un avance importante en la descripción de la variabilidad espacial y temporal de la productividad primaria es el uso de información provista por sensores remotos. Las estimaciones de productividad forrajera son generadas regularmente y se basan en un modelo conceptual sólido y ampliamente evaluado (ver Paruelo *et al.* 2010). En el caso de Uruguay están disponibles para todo el territorio con una resolución espacial de aproximadamente 5 hectáreas:

Acceda **AQUÍ**



LOS GEMELOS DIGITALES EN LA PLANIFICACIÓN

En la toma de decisiones en sistemas agropecuarios, los modelos predictivos y explicativos juegan un papel crucial. La literatura muestra muchos ejemplos de modelos, ya sean analíticos o numéricos, que frecuentemente representan una "instantánea estática" del sistema que puede utilizarse como referencia al momento de su publicación. Sin embargo, los sistemas agropecuarios requieren un sistema de soporte de

La producción de forraje en el campo natural forma parte de un sistema complejo y dinámico, con numerosas variables interconectadas y mutuamente influenciadas.

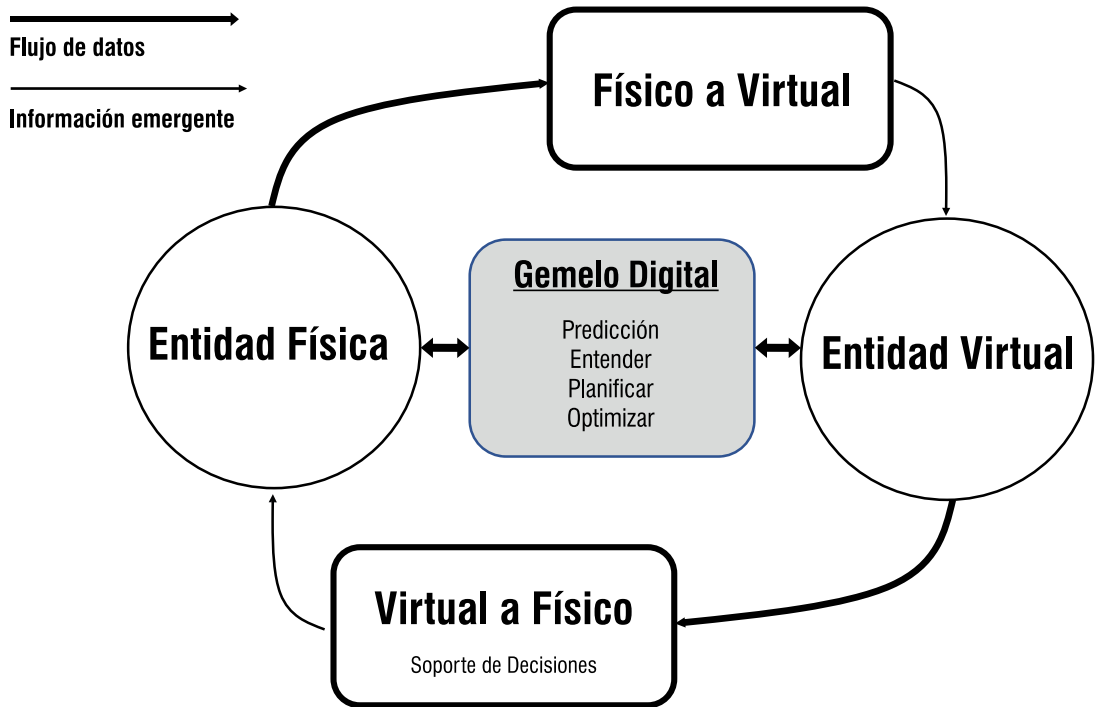


Figura 1 - Esquema conceptual de un Gemelo Digital (*Digital Twin*) modificado de Purcell and Neubauer (2023).

decisiones dinámico que se actualice constantemente con los cambios en las variables del sistema. Esto implica una relación dinámica entre los sistemas o procesos biofísicos y su representación virtual, lo que se conoce como Gemelos Digitales (GD) (Figura 1) Los GD son representaciones dinámicas actualizadas con datos en tiempo real, permitiendo simular, analizar y predecir el comportamiento de su componente biofísica. Esto permite un análisis y gestión más detallados y proactivos del sistema, facilitando la toma de decisiones basadas en simulaciones y proyecciones futuras. A diferencia de simulaciones clásicas que reproducen el comportamiento de un sistema bajo ciertas condiciones fijas, los GD son una réplica virtual dinámica del sistema real, que no solo simula, sino que se actualiza con datos de sus contrapartes físicas en tiempo real. Esto les permite predecir, basándose en el conocimiento acumulado, los patrones o tendencias históricas, y datos actuales.

MODELOS HÍBRIDOS, LO MEJOR DE DOS MUNDOS

El desafío de entender y predecir requiere de combinar el conocimiento disponible con herramientas capaces de incluir no-linealidades e interacciones entre factores. En el caso de la productividad forrajera en Uruguay, Paruelo *et al.* (2024) generaron un modelo híbrido



Foto: José Paruelo

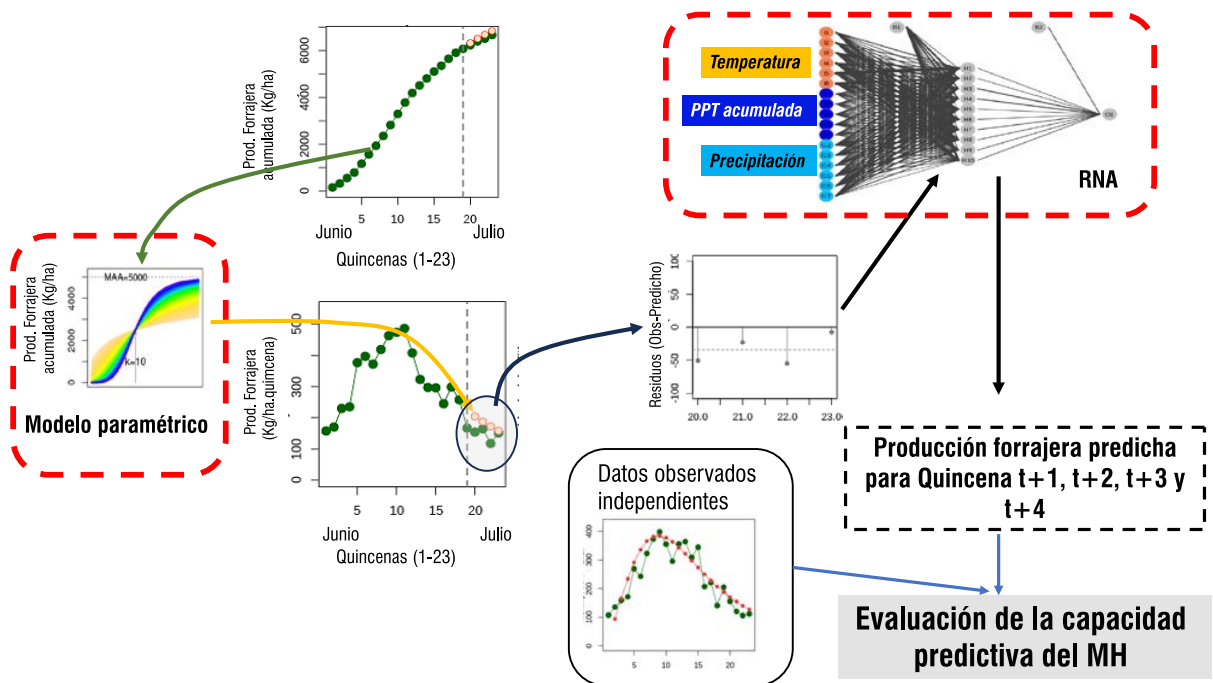


Figura 2 - Esquema general del proceso de generación y evaluación del modelo híbrido (cajas con líneas rojas cortadas) de producción forrajera para cuatro quincenas adelante. Los datos de productividad forrajera pasada (en verde) alimentan el modelo paramétrico que genera cuatro predicciones. Ese modelo genera predicciones que se contrastan con los datos observados. Los residuos (valores observados-predichos) son modelados mediante una Red Neuronal Artificial (RNA) en función de datos de temperatura y precipitación mensual previa y valores acumulados de precipitación en distintos períodos. La capacidad predictiva del MH de estimación de productividad forrajera es evaluada contra datos independientes de los usados para generar el modelo.

para predecir la producción quincenal de biomasa en pastizales naturales (Figura 2). El modelo combina un componente analítico basado en hipótesis bien fundamentadas sobre los controles ambientales de la productividad primaria y su dinámica estacional inercial, y una RNA que modela las no linealidades y las interacciones que no capturan los modelos analíticos.

En este enfoque híbrido, donde un modelo mecanístico se combina con técnicas de aprendizaje automático, modelos conceptuales basados en el conocimiento

de la historia natural y la biofísica de un sistema se complementan con RNA para, simultáneamente, generar predicciones más precisas y mejorar la comprensión del funcionamiento del agroecosistema a diferentes escalas espaciales y temporales.

Se generó un modelo híbrido para predecir la producción quincenal de biomasa en pastizales naturales. Este modelo combina el conocimiento disponible con herramientas capaces de incluir no-linealidades e interacciones entre factores.



Foto: José Paruelo

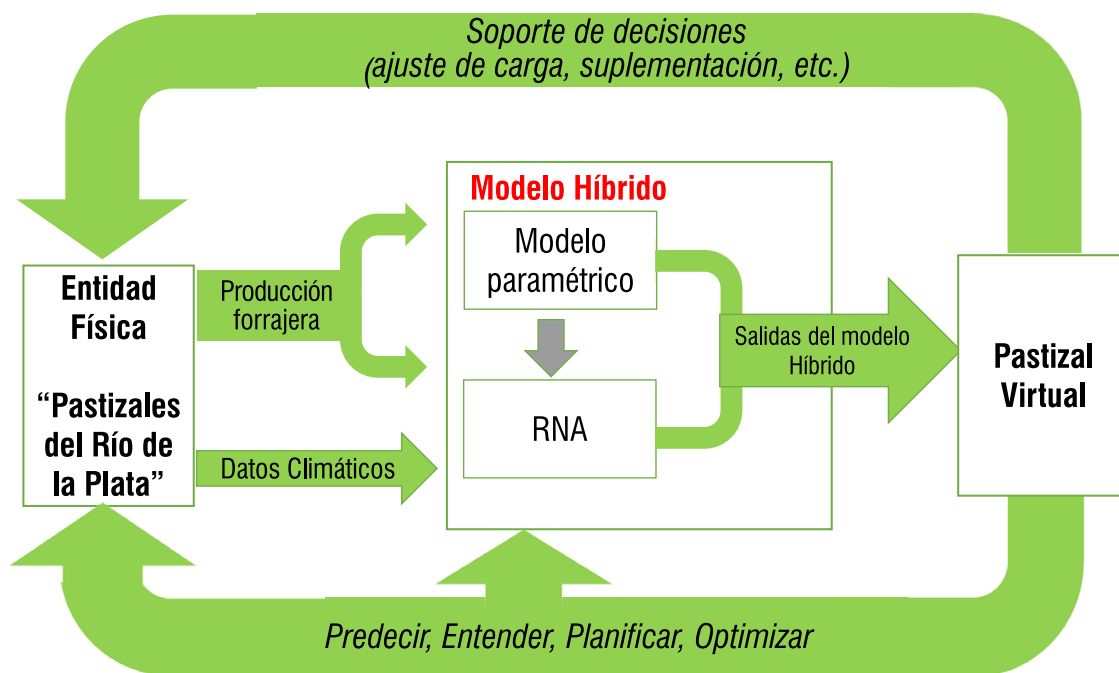


Figura 3 - Esquema conceptual del enfoque GD. La entidad virtual se genera a través del modelo híbrido desarrollado para predecir la productividad forrajera de los pastizales utilizando datos previos (efectos inerciales) y datos climáticos.

Esta fusión permite combinar la robustez y la comprensión teórica de los métodos paramétricos con la capacidad de adaptación y el aprendizaje de patrones complejos que ofrecen las RNA. Este esquema mejora la precisión y fiabilidad en la predicción de variables críticas, como la productividad de los pastizales, ofreciendo una herramienta más efectiva para la gestión y planificación. La disponibilidad de estimaciones de productividad forrajera en base a datos satelitales, junto con el enfoque de modelización híbrida y el marco conceptual de los GD ofrece una herramienta poderosa para la gestión sostenible del campo natural (Figura 3).

¿QUÉ PODEMOS HACER CON EL GEMELO DIGITAL DE LA PRODUCTIVIDAD FORRAJERA?

El modelo paramétrico genera predicciones de la productividad forrajera del campo natural para cuatro quincenas futuras.

La disponibilidad de estimaciones de productividad forrajera en base a datos satelitales, junto con el enfoque de modelización híbrida y el marco conceptual de los GD, ofrece una herramienta poderosa para la gestión sostenible del campo natural.

Cuando esas predicciones se evalúan con datos independientes de los usados para generar el modelo, la correlación entre observados y predichos es altamente significativa y, como es esperable, la correlación disminuye desde la primera a la cuarta quincena. Al considerar efectos de precipitación y temperatura no contemplados por el modelo sigmoideo, sus interacciones y no linealidades, la RNA reduce notablemente la variabilidad no explicada. En resumen, en una fecha dada se puede estimar razonablemente bien la productividad forrajera (el componente virtual del GD) para las próximas cuatro quincenas (Figura 2).

Eso permite disparar acciones de manejo a partir de cotejar la oferta predicha con la demanda de forraje. Para la próxima quincena, la productividad forrajera observada (la entidad física del GD) contribuye a ajustar las próximas predicciones.

BIBLIOGRAFÍA

Paruelo J.M., Oyarzabal M. y Oesterheld M. 2010. Capítulo IX. El seguimiento de los recursos forrajeros mediante sensores remotos: bases y aplicaciones. En: Altesor, A., W. Ayala y J. M. Paruelo. Bases Ecológicas y Tecnológicas para el manejo de pastizales. Proyecto FPTA-175, Serie: FPTA N° 26 ©, INIA ISBN: 978-9974.

Paruelo J.M., Texeira M y Tomasel F. 2024. Hybrid modeling for grassland productivity prediction: A parametric and machine learning technique for grazing management with applicability to digital twin decision systems. *Agricultural Systems* 214:20103847

Purcell W. y Neubauer T. 2023. Digital twins in agriculture: a state-of-the-art review. *Smart Agricult. Technol.* 3: 100094 <https://doi.org/10.1016/j.atech.2022.100094>.