

Influencia de la regionalización en modelos predictivos de heladas para cultivos frutihortícolas en la Patagonia argentina

Pablo Rosales¹, Matías Micheletto², Carlos De Marziani²
{prosales@unpata.edu.ar, matias.micheletto@uns.edu.ar,
marziani@unpata.edu.ar}

¹ UNPSJB

² IIDEPyS UNPSJB-CONICET

Abstract. La predicción de heladas es un desafío central para la protección de cultivos frutihortícolas, ya que depende de complejas interacciones entre factores meteorológicos, geográficos y microclimáticos. Si bien los modelos numéricos globales pueden anticipar eventos fríos, su precisión disminuye cuando no consideran las condiciones locales. Factores regionales como la topografía, la vegetación, el viento, la humedad del suelo y la dinámica atmosférica influyen en las temperaturas nocturnas y la formación de heladas, lo que requiere modelos calibrados localmente. Este trabajo en progreso enfatiza la integración de información geográfica multizona y climatología de sitio en modelos predictivos para mejorar la gestión del riesgo. Los estudios de caso emplearán datos meteorológicos de la Cuenca del Golfo San Jorge y del noreste de Santa Cruz, Argentina.

Palabras Clave: Meteorología · predicción de heladas · microclima · agricultura de precisión

Impact of Regionalization on Predictive Models of Frost for Horticultural and Fruit Crops in Patagonia, Argentina

Abstract. Frost prediction is a major challenge for protecting fruit and vegetable crops, as it depends on complex interactions among meteorological, geographical, and microclimatic factors. While global numerical models can forecast cold events, their accuracy decreases when local conditions are overlooked. Regional features—such as topography, vegetation, wind, soil moisture, and atmospheric dynamics—shape nocturnal temperatures and frost formation, requiring locally calibrated models. This work in progress emphasizes the integration of multi-zone geographic and site-specific climate data to improve predictive models and support risk management. Case studies will use meteorological data from the San Jorge Gulf Basin and northeastern Santa Cruz, Argentina.

Keywords: Meteorology · frost prediction · microclimate · precision agriculture

1 Introducción

La ocurrencia de heladas representa una de las principales amenazas climáticas para la producción frutihortícola, especialmente en regiones donde los cultivos coinciden con estaciones de transición o climas templados. Desde el punto de vista agroclimático, se considera helada al fenómeno que se produce cuando la temperatura del aire, medida a 1.5 metros sobre el nivel del suelo en condiciones de abrigo, desciende hasta igualar o superar en descenso los 0°C. Este umbral térmico marca el punto crítico a partir del cual el agua contenida en los tejidos vegetales puede congelarse, provocando daños en la estructura celular de hojas, flores y frutos, con consecuencias que afectan tanto la cantidad como la calidad de la producción.

Las heladas no constituyen un fenómeno uniforme, sino que responden a diversas causas de origen atmosférico y local [1]. Según su mecanismo de formación, las heladas se clasifican en advectivas y radiativas. Las advectivas ocurren por el ingreso de masas de aire frío a gran escala, generando descensos de temperatura amplios y homogéneos. Las radiativas se producen en noches despejadas y calmas, cuando la superficie pierde calor por radiación, con enfriamientos más intensos en zonas bajas o de escasa pendiente.

El presente trabajo en progreso aborda la relevancia de desarrollar modelos predictivos de heladas ajustados a las particularidades geográficas, con el objetivo de reducir la incertidumbre en la toma de decisiones agrícolas y mejorar la gestión del riesgo climático en sistemas productivos frutihortícolas.

2 Trabajos previos

La predicción de heladas ha sido abordada en la literatura desde enfoques empíricos, estadísticos y, en los últimos años, mediante técnicas de aprendizaje automático y redes neuronales. La diversidad de aproximaciones refleja tanto la complejidad del fenómeno como la importancia de considerar condiciones locales en el modelado.

En la provincia de San Juan, Masanet et al. [3] desarrollaron un modelo de análisis y visualización de datos meteorológicos provenientes de estaciones automáticas, con el propósito de asistir al productor en la toma de decisiones sobre medidas de protección frente a heladas. El enfoque pone especial énfasis en la recolección de datos locales y en la importancia de adaptar las herramientas tecnológicas a las particularidades climáticas de cada zona.

Complementariamente, Cortez et al. [4] plantearon una solución que no solo busca predecir la ocurrencia de heladas, sino también su intensidad y duración. Para ello, utilizaron técnicas de clasificación y regresión sobre series temporales de datos meteorológicos, haciendo foco en el preprocesamiento y en la reducción de desbalance de clases, factores determinantes en la calidad de las predicciones.

Por su parte, Talsma et al. [5] aplicaron modelos de redes neuronales profundas y aprendizaje automático a la predicción de heladas en entornos agrícolas, utilizando datos meteorológicos históricos. Su trabajo evidencia la capacidad de modelos de aprendizaje profundo para generalizar, aunque también concluye que la precisión de las predicciones mejora significativamente cuando se incorporan datos geográficamente representativos y de alta resolución, reforzando la importancia de la regionalización en la construcción de modelos.

En conjunto, estos antecedentes respaldan la necesidad de diseñar modelos de predicción ajustados a las características locales de cada región, dado que las heladas son eventos que dependen tanto de factores globales como de microclimas específicos.

Aunque los trabajos revisados emplean técnicas como redes neuronales feedforward, clasificadores bayesianos, k-Nearest Neighbors y regresión lineal, no abordan las redes Long Short-Term Memory (LSTM). Estas son ideales para series temporales, capturando patrones de dependencia a largo plazo en datos secuenciales, como los fenómenos climáticos de heladas, donde condiciones previas influyen significativamente. Las LSTM superan limitaciones de redes recurrentes tradicionales al mitigar problemas de gradiente mediante mecanismos de memoria, siendo una herramienta robusta para modelar dinámicas temporales complejas en entornos agrícolas.

3 Metodología

Se seleccionaron tres zonas del sur de Argentina —Comodoro Rivadavia, Los Antiguos y Ushuaia— con diversidad topográfica y climática para evaluar la variabilidad espacial de las heladas y la necesidad de modelos predictivos específicos por región. La diferencia en altitud, cercanía al mar y régimen de vientos permite explorar la dependencia entre ubicación geográfica y el diseño de los modelos.

Se recopilaron variables meteorológicas de cada región, incluyendo temperatura, humedad, punto de rocío, sensación térmica, precipitaciones y viento, agregando una etiqueta de helada. Inicialmente se consideró temperatura menor que 0°C, pero se reconoce que otras variables influyen según la región. El procesamiento se realizó en Google Colab usando pandas, numpy, tensorflow y scikit-learn.

El modelo predictivo se basa en redes LSTM, diseñadas para series temporales. A diferencia de las redes feedforward, las LSTM retienen información a lo largo del tiempo mediante compuertas de memoria, lo que resulta útil para anticipar heladas considerando la evolución de variables meteorológicas en días previos.

Las LSTM superan las limitaciones de las RNN tradicionales al evitar la pérdida de información por desvanecimiento del gradiente. Sus compuertas permiten aprender dependencias de corto y largo plazo, capturando patrones meteorológicos complejos que métodos tradicionales no detectan, lo que justifica su uso como núcleo del modelo.

El flujo de trabajo metodológico constó de tres etapas principales:

- **Análisis exploratorio de datos (EDA):** identificación de patrones generales, outliers y distribución estadística de las variables relevantes.
- **Acondicionamiento de datos:** limpieza, normalización y preparación de las series temporales para su uso en el modelo de predicción.
- **Modelado predictivo:** implementación de una red neuronal secuencial compuesta por una capa LSTM con activación ReLU, seguida de una capa de regularización Dropout (tasa 0.2), una capa Dense intermedia de 32 neuronas con activación ReLU y una capa de salida Dense con activación sigmoid para estimar la probabilidad de ocurrencia de heladas. La Figura 1 muestra el diagrama de bloques de la estructura secuencial del modelo predictivo generada con la funcionalidad `plot_model` de la librería Keras ³.

³ <https://keras.io/>




Figura 1. Arquitectura del modelo predictivo.

Se entrenó un modelo diferente con los respectivos datasets de cada ubicación. Si bien se usaron las mismas variables (columnas) en cada dataset, el volumen de datos de cada uno es diferente, con lo cual, es esperable que la precisión de cada modelo varíe para cada región.

Cada conjunto de datos fue particionado en un 70 % para entrenamiento y un 30 % para validación y prueba. Estos últimos dos a la vez, se dividieron en 70 % para validación y 30 % prueba. Los modelos fueron entrenados durante 20 épocas utilizando un batch size de 32.

4 Resultados preliminares y discusión

Los resultados preliminares que aquí se presentan son los obtenidos al ejecutar el entrenamiento de los modelos predictivos empleando parámetros de configuración detallados en la sección anterior, los cuales son típicos en el contexto del problema presentado. La Tabla 1 presenta los valores de precisión y pérdida al evaluar el modelo con los datos de prueba.

La Figura 2 muestra la evolución de las métricas de desempeño del modelo en función de las épocas de entrenamiento para el caso particular de los datos meteorológicos medidos en la ciudad de Comodoro Rivadavia.

Cuadro 1. Resultados de validación: precisión y pérdida.

Localidad	Precisión (Accuracy)	Pérdida (Loss)
Comodoro Rivadavia	0.87	0.18
Los Antiguos	0.89	0.24
Ushuaia	0.91	0.21

5 Conclusión y futuros pasos

Los resultados preliminares obtenidos a partir del análisis de datos meteorológicos de distintas localidades de la Patagonia argentina refuerzan la hipótesis de que la predicción de heladas no puede abordarse de manera uniforme mediante modelos globales o generalistas. Por el contrario, la variabilidad climática y topográfica de la región demanda modelos ajustados a las características específicas de cada sitio o área productiva. La regionalización de los modelos predictivos permite incorporar factores locales que inciden directamente en la formación de heladas, mejorando así la precisión y confiabilidad de las alertas.




Figura 2. Evolución de las métricas de entrenamiento.

Como trabajo futuro, se plantea la ampliación de la base de datos incorporando registros de nuevas ubicaciones geográficas dentro de la zona patagónica, con el objetivo de robustecer el entrenamiento de los modelos y capturar una mayor diversidad de situaciones climáticas. Asimismo, se propone evaluar el desempeño de distintas arquitecturas de redes neuronales y métodos de aprendizaje automático, con el fin de mejorar la capacidad predictiva y reducir las tasas de error. Finalmente, se plantea como línea de desarrollo estratégico la creación de un sistema centralizado de actualización y mejora continua de modelos, que integre nuevos datos en tiempo real y permita adaptar las predicciones de manera dinámica a las condiciones específicas de cada campaña y localidad.

Referencias

1. Monteith, J. L., & Unsworth, M. H. *Principles of Environmental Physics: Plants, Animals, and the Atmosphere*. 4th ed., Academic Press, 2013.
2. Verdes, P. F., Granitto, P. M., Navone, H. D., & Ceccatto, H. A. Frost Prediction with Machine Learning Techniques. Instituto de Física Rosario (CONICET-UNR), Rosario, Argentina.
3. Masanet, M., Capraro, F., Klenzi, R., & Muñoz, M. Procesamiento de datos meteorológicos para determinar la ocurrencia de heladas en la agricultura. XXIII Workshop de Investigadores en Ciencias de la Computación, RedUNCI - UNDeC, San Juan, Argentina, 2021.
4. Cortez, J., Masanet, M., Klenzi, R., & Ortega, M. Procesamiento de datos meteorológicos para determinar la ocurrencia, intensidad y duración de heladas. Simposio Argentino de Agroinformática — 51 JAIIO, ISSN: 2451-7496, 2022.
5. Talsma, C., Solander, K.C., Mudunuru, M.K., Crawford, B., & Powell, M. Frost prediction using machine learning and deep neural network models for use on IoT sensors. *SSRN Electronic Journal*, 2022. <https://doi.org/10.2139/ssrn.4032447>.