

Predicción del rendimiento del trigo para múltiples cultivares basada en factores agroclimáticos

Hoceme Degaichia^{1,§}

Touati Bakria¹

Ahcène Hakem¹

1 Centro de Investigación en Agropastoralismo (CRAPast). Djelfa, Argelia.

Autor para correspondencia: hoceme.degaichia@crapast.dz.

Resumen

Este estudio tuvo como objetivo evaluar el rendimiento de cuatro cultivares de trigo duro Odysseo, Saragola, Irid y Maestrale utilizando dos técnicas de aprendizaje automático: árboles de clasificación y regresión y árboles aleatorios. El análisis de árboles de clasificación y regresión demostró que la temperatura media anual es el factor dominante que influye en el rendimiento en todos los cultivares. Para los cultivares Saragola, Irid y Maestrale, el rendimiento aumentó significativamente cuando la temperatura media anual superó los 17.25 °C, particularmente cuando la densidad de emergencia era óptima. Por el contrario, el cultivar Odysseo mostró sensibilidad tanto a la temperatura media anual como a las semillas por espiga, con mayores rendimientos asociados a una temperatura media anual superior a 17.25 °C y semillas por espiga superiores a 33.6. El análisis de árboles aleatorios confirmó la importancia de la temperatura media anual y la densidad de emergencia, destacando su fuerte poder predictivo. Los modelos proporcionaron una mayor robustez y capacidad de generalización al reducir la varianza de predicción, lo que los convierte en herramientas fiables para la predicción del rendimiento. Estos hallazgos subrayan las respuestas específicas de cada cultivar a las condiciones agroclimáticas, donde Odysseo está influenciado tanto por la temperatura media anual como por las semillas por espiga, mientras que Saragola, Irid y Maestrale demuestran una interacción crítica entre la temperatura media anual y la densidad de emergencia. La integración de los modelos de árboles aleatorios mejora la precisión de la predicción y ofrece información valiosa para el desarrollo de estrategias de agricultura de precisión adaptadas a las condiciones ambientales.

Palabras clave:

Triticum durum, agricultura de precisión, aprendizaje automático, análisis de árboles de decisión.



Introducción

El trigo (*Triticum durum*) es un cultivo básico de importancia global, cuya producción está significativamente influenciada por factores agroclimáticos (Martínez-Moreno *et al.*, 2022). Comprender la relación entre las condiciones ambientales y el rendimiento es esencial para mejorar la productividad y garantizar la seguridad alimentaria, especialmente frente a la variabilidad climática (Shewry *et al.*, 2015). Factores clave como la temperatura media anual (TMA), la precipitación, la densidad de plantas y las características de la semilla juegan un papel crucial en la determinación del rendimiento del trigo (Kang *et al.*, 2020).

Los métodos estadísticos tradicionales, como los modelos de regresión lineal y los modelos lineales generalizados, se han utilizado ampliamente para predecir los rendimientos de los cultivos. No obstante, estos enfoques a menudo no logran capturar relaciones complejas y no lineales entre múltiples variables (Sharma *et al.*, 2021). Los avances recientes en aprendizaje automático (ML), por sus siglas en inglés proporcionan modelos más robustos y adaptables para analizar este tipo de interacciones. Los modelos basados en árboles de decisión, incluyendo árboles de clasificación y regresión (C RT) por sus siglas en inglés y bosques aleatorios (RF), por sus siglas en inglés, son especialmente adecuados para aplicaciones agrícolas debido a su capacidad para manejar relaciones no lineales y clasificar la importancia de las variables (Breiman, 2001; Sarker *et al.*, 2020).

A pesar del uso creciente de modelos ML en la agricultura, pocos estudios se han centrado en el desempeño comparativo de C RT y RF para predecir el rendimiento del trigo en múltiples variedades. Este estudio tiene como objetivo abordar esta brecha evaluando la precisión predictiva de estos modelos para cuatro variedades de trigo, identificando los factores agroclimáticos más influyentes y estableciendo reglas de decisión para la optimización del rendimiento.

Material y métodos

Material de origen y tratamientos experimentales

Cuatro cultivares de trigo duro (Odysseo, Saragola, Irid y Maestrale) fueron seleccionados para este estudio en función de su rendimiento agronómico y adaptabilidad. Estos cultivares son reconocidos comercialmente por su alto potencial de rendimiento, calidad de grano y tolerancia al estrés (De Vita *et al.*, 2007; Kabbaj *et al.*, 2017). Durante la temporada de crecimiento de 2020 se realizaron experimentos de campo en tres zonas agroclimáticas diferentes de Argelia: Annaba (Annaba), región costera con clima mediterráneo húmedo; Ouled Rahmoune (Constantine), región semiárida con precipitaciones moderadas; Oued Zenati (Guelma), región seca con disponibilidad limitada de agua.

Cada sitio experimental cubría un área de 2 500 m² y los ensayos se realizaron utilizando un diseño de bloques completos al azar (DBCA) con tres repeticiones por cultivar. Se empleó una tasa de siembra de 200 kg ha⁻¹ para lograr una densidad de plantas adecuada, promoviendo una emergencia y establecimiento uniforme de los cultivos. La fertilización de base se realizó utilizando fosfato monoamónico (MAP), por sus siglas en inglés aplicado a una dosis de 150 kg ha⁻¹ para proporcionar nutrientes esenciales para el crecimiento temprano. Además, las medidas de protección de cultivos incluyeron la aplicación de tratamientos fungicidas como Celest Xtra y Amistar Xtra, junto con Acil, para proteger las plantas de trigo frente a posibles enfermedades y mejorar el rendimiento de los cultivos.

Recolección de datos

Se recopilieron datos agroclimáticos y agronómicos durante toda la temporada de crecimiento, incluyendo la temperatura media anual (TMA) (°C), altitud, precipitación total anual (PTA) (mm), semillas por espiga (conteo), densidad de emergencia (plantas m⁻²), espigas m⁻² (conteo), macollos por planta (conteo), peso de mil granos (PMG) (g) y rendimiento práctico del trigo

(q ha⁻¹), utilizado como variable objetivo. Los datos meteorológicos se obtuvieron de la Oficina Meteorológica Nacional (Argelia), mientras que los parámetros agronómicos se midieron siguiendo procedimientos estandarizados de campo y laboratorio (Blum, 2011; Joia *et al.*, 2025).

Enfoques de modelado predictivo

Se aplicaron dos enfoques de aprendizaje automático utilizando IBM SPSS Modeler 18.0 para predecir el rendimiento del trigo: Árboles de clasificación y regresión (C&RT), un modelo basado en árboles de decisión que divide los datos en subconjuntos homogéneos con base en las variables más significativas (Breiman *et al.*, 1984); y Regresión de árboles aleatorios (RT), un método de aprendizaje por conjuntos que mejora la precisión predictiva promediando múltiples árboles de decisión (Liaw y Wiener, 2002). El desempeño del modelo se evaluó utilizando la raíz del error cuadrático medio (RECM), el error relativo (ER) y la varianza explicada (VE) (Chlingaryan *et al.*, 2018).

Importancia de variables e interpretación de los árboles de decisión

La importancia de las características se evaluó utilizando la impureza de Gini (C RT) y la importancia de permutación (RT). Los árboles de decisión generados se analizaron para cada cultivar de trigo para identificar los umbrales clave que influyen en el rendimiento del trigo (Hastie *et al.*, 2009).

Resultados

Rendimiento agronómico de cultivares de trigo duro

Los resultados destacan una variabilidad significativa en el rendimiento agronómico de los cuatro cultivares de trigo duro en tres localidades distintas (Cuadro 1). Esta variabilidad se debe principalmente a factores ambientales, particularmente a las condiciones climáticas, y a prácticas agronómicas, que se sabe que influyen en el crecimiento, el rendimiento y los rasgos fenotípicos de los cultivares de trigo (Kabbaj *et al.*, 2017; Royo *et al.*, 2020).

Cuadro 1. Rendimiento agronómico de cultivares de trigo duro.

Localidad	Cultivar	Densidad de emergencia (plantas m ⁻²)	Macollos por planta	Espigas m ⁻²	Semillas por espiga	PMG (g)	Rendimiento práctico (q ha ⁻¹)
Annaba (Annaba)	Ir#d	280.5 ±6.36	3 ±0	392 ±4.24	35.4 ±1.56	47.5 ±0.71	51.5 ±4.95
	Maestrale	269.5 ±6.36	3 ±0	380 ±7.07	35.1 ±2.69	48 ±1.41	51.5 ±3.54
	Odysseo	282 ±0	3 ±0	395 ±0	33.6 ±3.39	49.5 ±0.71	52.5 ±4.95
	Saragola	276 ±4.24	3 ±0	387 ±7.07	33.5 ±2.12	48.5 ±0.71	54 ±5.66
Ouled	Ir#d	287 ±0	3.8 ±0	563 ±0	38.5 ±0	51 ±0	35 ±3.25
Rahmoune (Canstantine)	Maestrale	292 ±0	4.6 ±0	612 ±0	39.65 ±0	50.25 ±0	35 ±3.75
	Odysseo	284 ±0	3.75 ±0	526 ±0	37.75 ±0	49.6 ±0	28 ±2.4
	Saragola	278 ±0	3.86 ±0	535 ±0	36.5 ±0	49.85 ±0	27.9 ±3.39
Oued Znati (Guelma)	Ir#d	298 ±0	5 ±0	665 ±0	35.75 ±0	49.7 ±0	31.5 ±3.96
	Maestrale	297 ±0	5 ±0	789 ±0	36.5 ±0	48.3 ±0	40 ±4.81
	Odysseo	289 ±0	6 ±0	703 ±0	39.5 ±0	48.3 ±0	40 ±3.68
	Saragola	292 ±0	5 ±0	664 ±0	37.25 ±0	51 ±0	41.5 ±4.67

En Annaba, los rendimientos prácticos fueron más altos para Saragola (54 ±5.66 q ha⁻¹), lo cual es coherente con los hallazgos de estudios previos que indican que este cultivar muestra una buena adaptación a condiciones moderadas, especialmente cuando la temperatura y la humedad

del suelo son adecuadas (Csépl# *et al.*, 2024). Los valores de PMG para Odiseo (49.5 ± 0.71 g) e Irid (47.5 ± 0.71 g) sugieren un buen potencial de llenado de grano, que es una característica deseable para la mejora del rendimiento (Maccaferri *et al.*, 2011).

La localidad de Ouled Rahmoune mostró un aumento en el macollamiento y la densidad de espigas entre cultivares, con Maestrale alcanzando la mayor densidad de emergencia (292 ± 0 plantas m^{-2}) y tasa de macollamiento (4.6 ± 0 macollos por planta). Este fenómeno puede atribuirse a condiciones favorables del suelo que probablemente favorecieron la formación de macollos y la aparición de espigas, como respaldan Kabbaj *et al.* (2017), quienes informaron que una mejor fertilidad del suelo mejora la producción de macollos y en consecuencia, incrementa el rendimiento. Sin embargo, los rendimientos prácticos fueron menores en comparación con Annaba, con Odiseo y Saragola registrando los rendimientos más bajos (28 ± 2.4 q ha^{-1} y 27.9 ± 3.39 q ha^{-1} , respectivamente). Esto sugiere que el potencial de rendimiento puede depender no solo de la densidad de espigas, sino también de la eficiencia del llenado de grano, que pudo haberse visto comprometida por condiciones climáticas subóptimas durante el periodo de llenado de grano (Royo *et al.*, 2020).

Oued Znati mostró la mayor productividad global, especialmente para el cultivar Saragola, que alcanzó un rendimiento práctico de 41.5 ± 4.67 q ha^{-1} con un PMG de 51 ± 0 g. Esta localidad también demostró una capacidad superior de macollamiento y densidad de espigas para todos los cultivares, con Odiseo alcanzando 703 ± 0 espigas m^{-2} y 6 ± 0 macollos por planta. Además, los altos valores de PMG observados en esta localidad indican condiciones favorables para el llenado de granos, un determinante crítico del rendimiento (Kabbaj *et al.*, 2017).

Desempeño del modelo predictivo

El modelo de regresión de árboles aleatorios mostró una fuerte capacidad predictiva para la estimación del rendimiento del trigo, con una varianza explicada del 70.4%, lo que sugiere que las variables agroclimáticas y agronómicas seleccionadas explican una proporción sustancial de la variabilidad del rendimiento. La raíz del error cuadrático medio (RECM) fue de 7.395, lo que indica un nivel moderado de desviación entre los valores predichos y los observados. Además, el error relativo de 0.296 sugiere un desempeño rendimiento del modelo bastante confiable (Cuadro 2).

Cuadro 2. Métricas del desempeño del modelo de regresión de árboles aleatorios para la predicción del rendimiento práctico del trigo.

Parámetros del modelo	Entrada
Variable objetivo	Rendimiento práctico de trigo
Método de generación del modelo	Regresión de árboles aleatorios
Número de entradas predictoras	7
Raíz del error cuadrático medio (RECM)	7.395
Error relativo (ER)	0.296
Varianza explicada (VE)	0.704

Estos resultados demuestran la robustez de las técnicas de aprendizaje automático en la predicción de rendimientos agrícolas, lo que se alinea con estudios previos que destacan la eficacia de modelos basados en árboles de decisión para predecir las respuestas de los cultivos a factores ambientales (Chlingaryan *et al.*, 2018; López-Granados *et al.*, 2020).

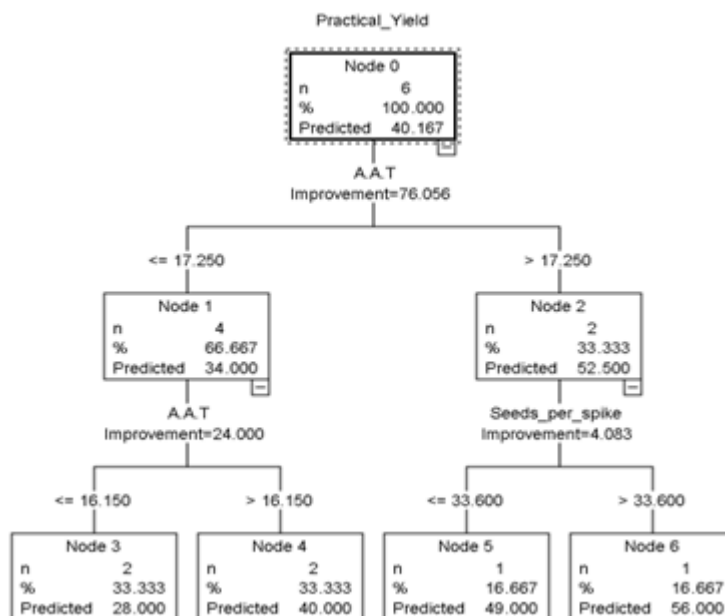
Factores agroclimáticos y agronómicos que afectan al rendimiento del trigo

El análisis C RT reveló que la TMA fue la variable dominante que influyó en el rendimiento de los cultivares Saragola, Irid y Maestrale, con la densidad de emergencia jugando también un papel significativo. En cambio, para el cultivar Odiseo, el rendimiento estuvo principalmente influenciado por la TMA y el número de semillas por espiga.

Cultivar Odysseo

Para Odysseo, el árbol de decisión de C RT identificó la TMA como el principal determinante de la variación del rendimiento. Cuando la TMA ≤ 16.15 °C, el rendimiento medio fue de 28 q ha⁻¹, lo que representa una reducción significativa debido a condiciones de temperatura subóptimas. Para una TMA entre 16.15 °C y 17.25 °C, el rendimiento aumentó a 34 q ha⁻¹, mostrando un impacto positivo de temperaturas más altas en el desarrollo de granos. Cuando la TMA superó los 17.25 °C, el rendimiento alcanzó 52.5 q ha⁻¹, si las semillas por espiga eran más de 33.6. Estos hallazgos sugieren que el cultivar Odysseo responde favorablemente a temperaturas más cálidas, con un rendimiento mejorando a medida que la TMA supera los 17.25 °C. El papel fundamental de la densidad de semillas resalta aún más la importancia de optimizar la fertilidad de las espigas bajo regímenes variables de temperatura (Figura 1).

Figura 1. Análisis de árboles de regresión para predecir el rendimiento de trigo en el cultivar Odysseo.

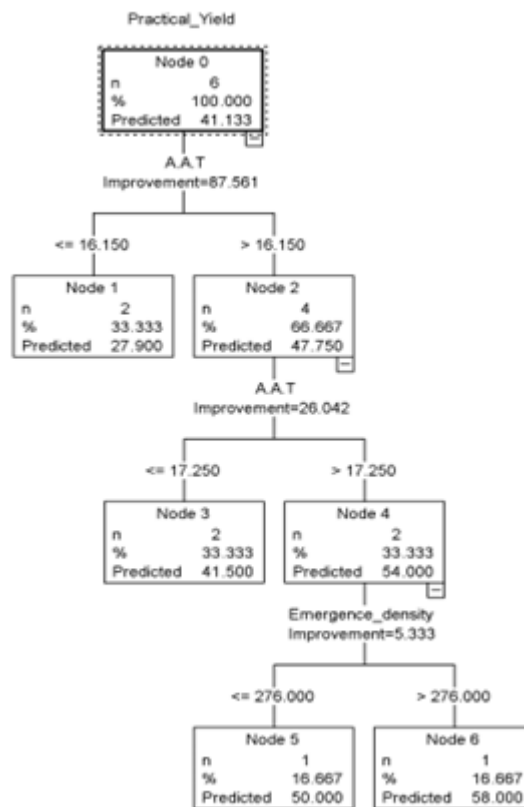


Cultivar de Saragola

En Saragola, el rendimiento fue muy sensible a la TMA y a la densidad de emergencia. Cuando la TMA estuvo por debajo de 16.15 °C, el rendimiento descendió a 38 q ha⁻¹, lo que indica un impacto negativo de las temperaturas más bajas en el llenado de grano. Cuando la TMA superó los 16.15 °C y la densidad de emergencia fue óptima, el rendimiento aumentó a 51 q ha⁻¹, demostrando el efecto combinado de la temperatura y la gestión agronómica sobre la productividad. Estos resultados destacan que el cultivar Saragola es menos tolerante a bajas temperaturas, requiriendo condiciones más cálidas para una expresión óptima del rendimiento. Esto coincide con informes previos sobre variedades de trigo duro que muestran un desarrollo reducido de granos en climas más fríos (Ferrise *et al.*, 2019) (Figura 2).



Figura 2. Análisis de árboles de regresión para predecir el rendimiento de trigo en el cultivar de Saragola.




Cultivar Irid

El modelo de árboles de decisión del cultivar Irid identificó la TMA y la densidad de emergencia como los principales determinantes del rendimiento. Cuando la TMA estuvo por debajo de 17.25 °C, el rendimiento se mantuvo bajo, lo que sugiere que el cultivar Irid requiere temperaturas más altas para el desarrollo del grano. Cuando la TMA superó los 17.25 °C, el rendimiento aumentó significativamente, especialmente cuando la densidad de plantas fue alta. Este comportamiento indica que el cultivar Irid se beneficia de temperaturas más altas, pero la densidad de plantas también juega un papel crucial para lograr una alta productividad. Este hallazgo es coherente con estudios que enfatizan el papel del peso del grano como componente primario del rendimiento en el trigo (Lobell *et al.*, 2017) (Figura 3).



Figura 3. Análisis de árboles de regresión para predecir el rendimiento de trigo en el cultivar Irid.

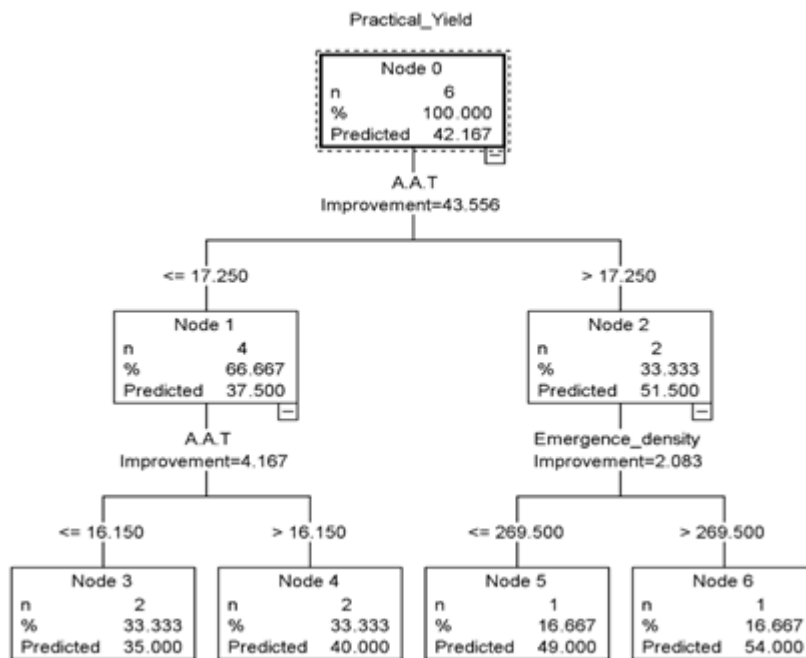


Cultivar Maestrale

El análisis C RT para el cultivar Maestrale indicó una fuerte dependencia de la TMA y la densidad de emergencia. El rendimiento se mantuvo bajo cuando la TMA estuvo por debajo de 17.25 °C, probablemente debido a malas condiciones de llenado de grano. Cuando la TMA superó los 17.25 °C, el rendimiento mejoró significativamente, siempre que la densidad de emergencia fue óptima. Estos resultados sugieren que Maestrale requiere tanto temperaturas cálidas como una densidad adecuada de emergencia para una productividad óptima. La interacción entre temperatura y densidad de plantas está bien documentada en la fisiología del trigo, donde una baja densidad de emergencia puede agravar los efectos negativos de temperaturas subóptimas (Trnka *et al.*, 2021) (Figura 4).



Figura 4. Análisis de árboles de regresión para predecir el rendimiento de trigo en el cultivar Maestrale.



Los cultivares Saragola e Irid dependen en gran medida de la TMA y la densidad de emergencia, con una mejora significativa del rendimiento cuando la TMA supera los 16.15 °C y 17.25 °C, respectivamente, y la densidad de emergencia es óptima. El cultivar Maestrale muestra un comportamiento similar al de Irid, con un aumento de rendimiento vinculado a un TMA superior a 17.25 °C y una densidad de emergencia favorable.

Conclusiones

El cultivar Odyseo demostró mayor resiliencia a las fluctuaciones de temperatura, beneficiándose especialmente de temperaturas más altas. No obstante, su productividad depende fuertemente de una alta densidad de emergencia, lo que indica la importancia de una siembra densa y uniforme, especialmente en regiones más cálidas.

Los cultivares Saragola, Irid y Maestrale mostraron una mayor sensibilidad tanto a la temperatura como a la densidad de emergencia, lo que implica que estas variedades requieren una calibración más precisa de la tasa de semillas y calendarios de siembra adaptados bajo condiciones climáticas cambiantes para evitar pérdidas en el rendimiento. Las recomendaciones prácticas para mejorar la gestión de los cultivos de trigo incluyen: 1) adaptar la densidad de siembra según el cultivar y el régimen de temperatura esperado: adoptar tasas de semillas más altas para Odyseo en zonas cálidas y ajustar finamente las densidades para otros cultivares basándose en modelos predictivos de emergencia; 2) integrar datos agroclimáticos en tiempo real para ajustar las prácticas de manejo, especialmente en cuanto a la fecha de siembra y la preparación del campo; y 3) emplear zonas de gestión específicas del sitio utilizando reglas de decisión derivadas de los modelos para optimizar los insumos (fertilizantes, riego) donde tendrán mayor efecto en el rendimiento.

La comparación entre los modelos de C RT y RF reveló sus fortalezas complementarias en la predicción del rendimiento del trigo y en el desarrollo de reglas de decisión aplicables. Los RF proporcionaron conocimientos sólidos y generalizables debido a su naturaleza de conjunto, convirtiéndola en una herramienta valiosa para la toma de decisiones agronómicas basadas en datos. Dadas los resultados prometedores, las herramientas de inteligencia artificial (IA), especialmente las basadas en aprendizaje automático y algoritmos de aprendizaje por conjuntos,

ofrecen un potencial significativo para refinar las predicciones de rendimiento y apoyar decisiones agronómicas adaptativas. Los sistemas impulsados por IA pueden integrar dinámicamente datos de múltiples fuentes (satélite, sensores, previsiones meteorológicas) para proporcionar recomendaciones específicas del sitio en tiempo real, fomentando la transición hacia la agricultura de precisión y la producción de trigo resiliente al clima.

Agradecimientos

Esta investigación fue financiada por la Dirección General de Investigación Científica y Desarrollo Tecnológico (DGRSDT, por sus siglas en francés)-Argelia y el CRAPast, Argelia. Los autores expresan su agradecimiento a la Dirección General de Investigación Científica y Desarrollo Tecnológico (DGRSDT, por sus siglas en francés-Argelia) y al CRAPast, Argelia.

Bibliografía

- 1 Blum, A. 2011. Plant breeding for water-limited environments. Springer Science Business Media. ISBN: 978-1-4419-7490-7. 68-69 pp.
- 2 Breiman, L. 2001. Random Forests. Machine Learning. 45(1):5-32.
- 3 Chlingaryan, A.; Sukkarieh, S. and Whelan, B. 2018. Machine learning approaches for crop yield prediction and nitrogen status estimation in precision agriculture: a review. Computers and Electronics in Agriculture. 151(1):61-69.
- 4 Csépl#, M.; Puskás, K.; Vida, G.; Mészáros, K.; Uhrin, A.; Tóth, V.; Ambrózy, Z.; Grausgruber, H.; Bonfiglioli, L.; Pagnotta, M. A.; Urbanavi####, I.; Mikó, P. and Bányai, J. 2024. Performance of a durum wheat diversity panel under different management systems. Cereal Research Communications. 52(1):489-502.
- 5 De Vita, P.; Mastrangelo, A. M.; Matteu, L.; Mazzucotelli, E. and Cattivelli, L. 2007. Genetic improvement effects on yield stability in durum wheat genotypes grown in Italy. Field Crops Research. 100(1):133-141.
- 6 Ferrise, R.; Moriondo, M. and Bindi, M. 2019. Climate change impacts on wheat and maize production in Europe and adaptation options. Agricultural Systems. 175(1):112-124.
- 7 Hastie, T.; Tibshirani, R. and Friedman, J. 2009. The elements of statistical learning: data mining, inference, and prediction 2nd Ed. Springer Science Business Media. 745-763 pp.
- 8 Joia, S.; Siddiqi, R. A. and Singh, T. P. 2025. Study of physicochemical properties, amino acid composition and fatty acid profile of bitter himalayan wild apricot kernel: a step towards its valorization. Waste Biomass Valor. 16(1):1-12.
- 9 Kabbaj, H.; Sall, A. T.; Al-Abdallat, A.; Geleta, M.; Amri, A.; Filali-Maltouf, A.; Belkadi, B.; Ortiz, R. and Bassi, F. M. 2017. Genetic diversity within a global panel of durum wheat (*Triticum durum*) landraces and modern germplasm reveals the history of alleles exchange. Frontiers in Plant Science. 8(1):1-13.
- 10 Kang, Y.; Khan, S. and Ma, X. 2020. Climate change impacts on crop yield, crop water productivity and food security. A review. Progress in Natural Science: Materials International. 19(2):166-173.
- 11 Liaw, A. and Wiener, M. 2002. Classification and regression by random Forest. R News. 2(3):18-22.
- 12 Lobell, D. B. and Asseng, S. 2017. Comparing estimates of climate change impacts from process-based and statistical crop models. Environmental Research Letters. 12(1):1-12.
- 13 López-Granados, F.; Jurado-Expósito, M.; Peña, J. M. and Serrano, N. 2020. Precision agriculture for weed management. Weed Science. 68(3):171-190.

- 14 Maccaferri, M.; Sanguineti, M. C.; Demontis, A.; El-Ahmed, A.; Garcia-Moral, L.; Maalouf, F.; Nachit, M.; Nserallah, N.; Ouabbou, H.; Rhouma, S.; Royo, C.; Villegas, D. and Tuberosa, R. 2011. Association mapping in durum wheat grown across a broad range of water regimes. *Journal of Experimental Botany*. 62(2):409-438.
- 15 Martínez-Moreno, F.; Ammar, K. and Solís, I. 2022. Global changes in cultivated area and breeding activities of durum wheat from 1800 to date: a historical review. *Agronomy*. 12(5):1-17.
- 16 Royo, C.; Soriano, J. M. and Villegas, D. 2020. Assessing the adaptation of durum wheat genotypes to Mediterranean environments. *Euphytica*. 216(5):1-14.
- 17 Sarker, I. H.; El-Gayar, O. and Badar, M. A. 2020. Machine Learning: a review of applications in agriculture. *Agronomy*. 10(4), 563-582.
- 18 Sharma, R.; Shukla, S. and Shukla, A. K. 2021. Machine learning in agriculture: A review. *Journal of Applied and Natural Science*. 13(1):64-71.
- 19 Shewry, P. R. and Hey, S. J. 2015. The contribution of wheat to human diet and health. *Food and Energy Security*. 4(3):178-202.
- 20 Trnka, M.; Rötter, R. P.; Ruiz-Ramos, M.; Kersebaum, K. C.; Olesen, J. E.; Žalud, Z. and Semenov, M. A. 2021. Adverse weather conditions for European wheat production will become more frequent with climate change. *Nature Climate Change*. 11(7):675-680.



Predicción del rendimiento del trigo para múltiples cultivares basada en factores agroclimáticos

Journal Information
Journal ID (publisher-id): remexca
Title: Revista mexicana de ciencias agrícolas
Abbreviated Title: Rev. Mex. Cienc. Agríc
ISSN (print): 2007-0934
Publisher: Instituto Nacional de Investigaciones Forestales, Agrícolas y Pecuarias

Article/Issue Information
Date received: 01 October 2025
Date accepted: 01 January 2026
Publication date: 01 January 2026
Publication date: Jan-Feb 2026
Volume: 17
Issue: 1
Electronic Location Identifier: e3892
DOI: 10.29312/remexca.v17i1.3892

Categories

Subject: Artículos

Palabras clave:

Palabras clave:

Triticum durum

agricultura de precisión

aprendizaje automático

análisis de árboles de decisión

Counts

Figures: 4

Tables: 2

Equations: 0

References: 20