



GLOBAL JOURNAL OF SCIENCE FRONTIER RESEARCH: D
AGRICULTURE AND VETERINARY
Volume 18 Issue 2 Version 1.0 Year 2018
Type: Double Blind Peer Reviewed International Research Journal
Publisher: Global Journals
Online ISSN: 2249-4626 & Print ISSN: 0975-5896

Technological Strategy for Diagnosis of Phenological Damage in Wheat Crops

By Silvia Soledad Moreno Gutiérrez, Alfredo Toriz Palacios,
Sócrates López Pérez & Abraham Sánchez López

Autonomous University of the State of Hidalgo

Abstract- An analysis of damage caused by climate change on the wheat crop in each of its stages of development was carried out, for this, a Backpropagation Artificial Neural Network and an analysis module for the permanence of climatic conditions were used, ten variables were used meteorological and 68685 daily records from various regions of the world, using 79% for training and 21% to validate the network. Regarding the analysis of the damage by stage of development in function of the climate, that is to say, of fenológico damage, the criteria proposed by the Organization of the United Nations for the Feeding and the Agriculture (FAO) and the scale Zadoks were considered. The technological strategy reached an accuracy of 84%, making it suitable for diagnosing phenological damage in the wheat plant, and constitutes an alternative to strengthen sustainable adaptation strategies and food security.

Keywords: *artificial neural networks, phenological damage, wheat, technological strategy, climate change.*

GJSFR-D Classification: *FOR Code: 070199*



Strictly as per the compliance and regulations of:



© 2018. Silvia Soledad Moreno Gutiérrez, Alfredo Toriz Palacios, Sócrates López Pérez & Abraham Sánchez López. This is a research/review paper, distributed under the terms of the Creative Commons Attribution-Noncommercial 3.0 Unported License (<http://creativecommons.org/licenses/by-nc/3.0/>), permitting all non commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

Technological Strategy for Diagnosis of Phenological Damage in Wheat Crops

Estrategia Tecnológica Para Diagnóstico De Daño Fenológico En Cultivos De Trigo

Silvia Soledad Moreno Gutiérrez ^α, Alfredo Toriz Palacios ^σ, Sócrates López Pérez ^ρ
& Abraham Sánchez López ^ω

Resumen- Se realizó un análisis de daño ocasionado por el Cambio Climático sobre el cultivo de trigo en cada una de sus etapas de desarrollo, para ello, se empleó una Red Neuronal Artificial Backpropagation y un módulo de análisis de permanencia de condiciones climáticas, se emplearon diez variables meteorológicas y 68685 registros diarios provenientes de diversas regiones del mundo, empleando el 79% para entrenamiento y el 21% para validar la red. Respecto al análisis del daño por etapa de desarrollo en función del clima, es decir, de daño fenológico, se consideraron los criterios propuestos por la Organización de las Naciones Unidas para la Alimentación y la Agricultura (FAO) y la escala Zadoks. La estrategia tecnológica alcanzó una precisión del 84%, por lo que es adecuada para diagnosticar daño fenológico en la planta de trigo, y constituye una alternativa de fortalecimiento a las estrategias de adaptación sustentables y a la seguridad alimentaria.

Palabras clave: redes neuronales artificiales, daño fenológico, trigo, cambio climático.

Abstract- An analysis of damage caused by climate change on the wheat crop in each of its stages of development was carried out, for this, a Backpropagation Artificial Neural Network and an analysis module for the permanence of climatic conditions were used, ten variables were used meteorological and 68685 daily records from various regions of the world, using 79% for training and 21% to validate the network. Regarding the analysis of the damage by stage of development in function of the climate, that is to say, of phenological damage, the criteria proposed by the Organization of the United Nations for the Feeding and the Agriculture (FAO) and the scale Zadoks were considered. The technological strategy reached an accuracy of 84%, making it suitable for diagnosing phenological damage in the wheat plant, and constitutes an alternative to strengthen sustainable adaptation strategies and food security.

Keywords: artificial neural networks, phenological damage, wheat, technological strategy, climate change.

Author α σ: Universidad Popular Autónoma del Estado de Puebla.
e-mail: silvia-soledad.moreno@upaep.edu.mx

Author ρ: Universidad Autónoma del Estado de Hidalgo.

Author ω: Benemérita Universidad Autónoma de Puebla.

I. INTRODUCCIÓN

A nivel internacional el trigo es considerado alimento clave para la supervivencia humana y forma parte de la dieta básica, se ubica en el segundo lugar mundial por su producción y consumo (Reynolds et al., 2016), debido a que muestra un fuerte impacto sobre la seguridad alimentaria y el desarrollo económico mundial, el trigo representa un cultivo prioritario.

Al mismo tiempo, como consecuencia de la época moderna y su industrialización (Serrano, 2015), y con ello el incremento de gases efecto invernadero (Sapkota et al., 2015), el fenómeno conocido globalmente como Cambio Climático (CC), de unas décadas a la fecha, ha significado drásticos incrementos en la temperatura global (Singh y Singh, 2015), fuertes cambios en los patrones meteorológicos y grave impacto sobre la agricultura según Basche, et al., (2016), debido a la cercana relación existente entre el desarrollo del cultivo y las condiciones climatológicas favorables (Reeves, Thomas y Ramsay, 2016). Según estudios efectuados por Izumi y Ramankutty (2016), la variabilidad del rendimiento de cultivos de cereal básico, en un 21% ha sido consecuencia de la presencia de temperaturas extremas, generalmente altas, encontrándose el trigo (*Triticum aestivum* L.) entre una de las especies más afectadas (Jones y Phillips, 2016).

El CC ha significado volatilidad de precios e incremento de las importaciones de cereal básico (Butt et al., 2016), la proyección de su rendimiento al año 2050, expone un escenario desolador, donde el trigo aparece como uno de los cereales cuyo rendimiento disminuirá drásticamente, ya que las temperaturas continuarán incrementando (Torres, 2017), el déficit de trigo provocará reducción de la ingesta calórica diaria (Tesfaye et al., 2015), presión demográfica en sistemas de alimentos (Massawe, Mayes y Cheng, 2016), en caso de no contar con estrategias de adaptación eficaces (ver figura 1), no obstante, la demanda continuará incrementando al año 2030 (ver figura 2).




Figura 1: Disminución proyectada del rendimiento de cereales debido al CC en el año 2050, sin adaptación (%). Fuente: elaboración propia con datos de Reeves, Thomas y Ramsay (2016)

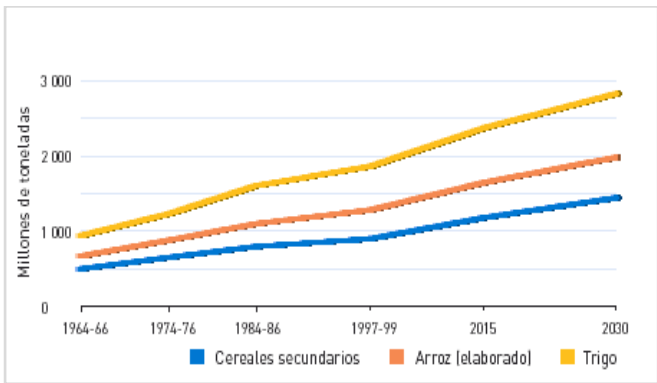


Figura 2: Tendencias de demanda mundial de cereales. Fuente: FAO. Agricultura mundial: hacia los años 2015/2030. Informe resumido (2002)

En la búsqueda de alternativas que apoyen al sector cerealista a reducir las pérdidas económicas y de cultivos, así como la vulnerabilidad de sus cultivos de trigo ante la variabilidad climática, ha llevado a cabo diversos trabajos de investigación, así como múltiples desarrollos tecnológicos, que contribuyan a enfrentar con eficiencia y eficacia el reto del CC y a mantener los niveles óptimos de producción.

La literatura revisada expresa el trabajo relacionado, no obstante, en el presente apartado se mencionan únicamente las propuestas de mayor representatividad.

- Modelos de Simulación de Cultivos, son sistemas de software capaces de analizar comportamientos posibles del cultivo, algunos de mayor uso son:
 - CERES en trigo (Gallo, 2015), inadecuado en algunos casos pues requiere grandes cúmulos de información (Zheng, Cai, Yu y Hoogenboom, 2017) e inadecuado al simular altas temperaturas (Gaydon et al., 2017).
 - El Simulador de Sistemas de Producción Agrícola APSIM con resultados satisfactorios, requiere ajustes para países asiáticos (Gaydon et al., 2017).
- Modelos fenológicos y predictivos, son capaces de obtener información del impacto del CC sobre el desarrollo fenológico del cultivo, sin embargo, han sido analizados concluyendo deficiencias al representar altas temperaturas (Asseng et al., 2015), además de enfoques únicamente locales (Arnell, 2016).
- Sistemas inteligentes. Las técnicas de Inteligencia Artificial han participado en el apoyo al sector cerealista expone Barrero et al., (2016), sobre todo en la clasificación y predicción a través de las Redes Neuronales Artificiales (RNA), considerada como la técnica de mayor preferencia en el sector, que ha mostrado superioridad predictiva sobre las técnicas tradicionales (Tripathi, 2015; Mansourian et al., 2017, Lv et al., 2015), aun cuando el sector del

cereal cuenta con modelos inteligentes para evaluar el crecimiento del trigo bajo estrés por calor y considera (Boutraa et al., 2015; Ihsan et al., 2016; Sanad et al., 2016), en la construcción de modelos fenológicos, las técnicas matemáticas estadísticas, constituyen las de mayor preferencia.

Por otra parte, el sector del cereal, también ha efectuado diversas investigaciones orientadas a analizar el efecto del CC sobre cada una de las etapas fenológicas de la planta de trigo, logrando identificar aquellas de mayor resistencia y sensibilidad, a las heladas (Crimp, 2016; Frederiks et al., 2015), a las bajas temperaturas (Ji et al., 2017), así como a las temperaturas altas (Pimentel et al., 2015), por mencionar algunos, siendo la antesis la etapa más sensible (Chen et al., 2017).

A pesar de las diversas propuestas tecnológicas e investigaciones realizadas, la literatura expresa ausencia de propuestas con enfoque global, de alta precisión que apoyen la toma de decisiones del agricultor a través de la evaluación del desarrollo de sus cultivos de trigo, no se observan herramientas centradas en el monitoreo de cada etapa fenológica, en correspondencia con los factores climáticos presentes, siendo esta una actividad clave para la identificación oportuna de daño y con esto para la reducción de pérdidas y mejoramiento de la producción.

Por lo anterior, el documento expone una estrategia tecnológica que analiza el desarrollo fenológico del trigo, según su etapa y es capaz de efectuar diagnóstico de daño en caso de que las condiciones climáticas superen los umbrales soportados por la planta de trigo para un desarrollo favorable. La RNA se apoya en un modelo Backpropagation, con un enfoque global, que contribuye a reducir la incertidumbre relacionada con el desarrollo del trigo ante el CC, constituyendo una guía para el agricultor en los procesos de planeación de cultivos.

II. METODOLOGÍA

Estrategia tecnológica para diagnóstico de daño fenológico en cultivos de trigo

La estrategia se compone principalmente de una RNA de tipo Backpropagation, seguida de un bloque de resultados. La red evalúa el desarrollo del cultivo y en caso de presentarse condiciones climáticas adversas, podría diagnosticar daño fenológico, el bloque de análisis de permanencia de condiciones climáticas permite la interacción con el usuario quien ingresará datos meteorológicos para proceder a su evaluación (ver figura 3).

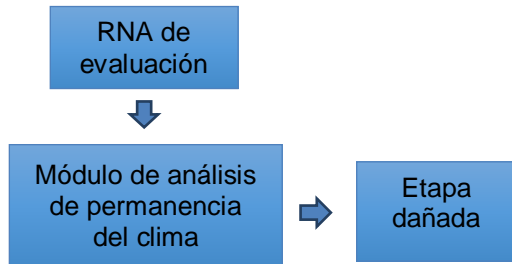


Figura 3: Estrategia tecnológica de diagnóstico de daño fenológico. Fuente: elaboración propia

a) RNA

Una RNA se refiere a un conjunto de nodos interconectados conocidos como neuronas, que tienen




Figura 4: Arquitectura de la RNA. Fuente: elaboración propia

ii. Consideraciones para el diagnóstico de daño fenológico

La identificación de daño en la planta se basa en la propuesta emitida por la Organización de las Naciones Unidas para la Agricultura y la Alimentación (FAO), correspondiente a situaciones problemáticas del cultivo de trigo ante el CC (Rawson y Macpherson, 2001), los factores climáticos que han sido considerados debido a que pueden detener o dañar el desarrollo son: estrés hídrico, temperaturas fuera de los márgenes óptimos, radiación solar baja, lluvias y vientos fuertes.

En daño por estrés hídrico, considera la temperatura media, calcula el coeficiente de evapotranspiración según la etapa fenológica, identificando el número de días sin riego ni lluvia

como propósito lograr el aprendizaje de un cúmulo de datos y su comportamiento, mediante la implementación de algoritmos de aprendizaje, los cuales se basan en los principios de las redes neuronales biológicas. Cada nodo cuenta con uno o más datos de entrada, que serán procesados para la obtención de un valor de salida, el cual será evaluado mediante la función de activación apropiada (Yegnanarayana, 2009).

i. Arquitectura

La RNA se desarrolló con base en un modelo multicapa Backpropagation que cuenta con 10 variables de entrada, cada una coincide con un factor climático: Temperatura media T (°C), Temperatura máxima TM (°C), Temperatura mínima Tm (°C), Humedad relativa media H (%), Precipitación total de lluvia PP (mm), Visibilidad media VV (Km), Velocidad media del viento V (Km/h), Velocidad máxima sostenida del viento VM (Km/h), Indicador de lluvia o llovizna RA e Indicador de niebla FG.

La RNA propuesta es de 32-20-8 neuronas, respectivamente en cada una de sus capas. Como se observa en la figura 4, el total de salidas son 8 y cada una corresponde a cada etapa fenológica del trigo, cuya salida será 1 en caso de daño y -1 en caso contrario.

significativa sobre el cultivo antes de sufrir estrés, en la propuesta se expresa el daño 7 días antes de que este suceda.

En cuanto a daño por variación de temperaturas, se analiza la temperatura base y la temperatura óptima, según umbrales expresados por Rawson y Macpherson, (2001), como se muestran en la figura 5, siguiente.

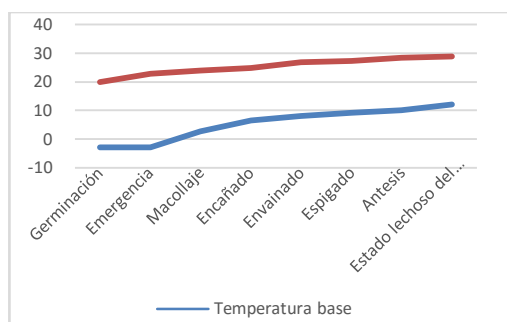


Figura 5: Temperatura base y temperatura óptima por fase de desarrollo (°C) del trigo. Elaboración propia con datos de Rawson y Mcpherson (2001).

La baja radiación solar es diagnosticada al presentarse altas temperaturas (superiores a los valores soportados por la planta en su etapa de desarrollo) y tiempo nublado.

La presencia permanente de lluvia o llovizna, así como de vientos fuertes, con base en la escala de Beaufort de 50 a 61 km/h (García et. al., 2014), también se considera causal de daño fenológico.

Cada etapa responde diferente al clima, generalmente después de varios días consecutivos de experimentar condiciones climáticas adversas, el número de días soportados difiere según la etapa y el factor climático. La pérdida de rendimiento puede considerarse hasta de un 4% por cada °C que incremente la temperatura media sobre la temperatura óptima. En el análisis del desarrollo de la planta, fueron consideradas las etapas siguientes: Germinación, Emergencia, Macollaje, Encañado, Envainado, Espigado, Antesis, Estado lechoso del grano, Estado pastoso del grano y Madurez, según escala Zadoks (Rawson y Macpherson, 2001), en ambiente húmedo, subhúmedo, semiárido y árido.

Tabla 1: Factores de daño por etapa fenológica del trigo

Etapa fenológica	Factores de daño
Germinación	H, EH, T
Emergencia	H, EH, T
Macollaje	H, EH, T, BRS
Encañado	EH, T, BRS
Envainado	EH, T, BRS
Espigado	EH, T, BRS
Antesis	EH, T, BRS, LI, VF
Estado lechoso del grano	EH, T, BRS

Causas relacionadas con factores meteorológicos. EH Estrés hídrico, T temperaturas, H Heladas, BRS Baja Radiación Solar, LI Lluvia, VF Viento fuerte. Fuente: Rawson y Macpherson (2001).

iii. Aprendizaje

En el proceso de aprendizaje se empleó el algoritmo de tipo Backpropagation, su funcionamiento

de manera general consiste en el aprendizaje de un conjunto de duplas entrada-salida determinadas, posteriormente un ciclo de propagación-adaptación en dos partes:

- 1) Se aplica el patrón de entrada como estímulo a la primera capa de neuronas, se propaga hacia adelante hasta llegar a la capa de salida y obtener un resultado que será comparado con salida deseada. La diferencia entre ambos valores, para cada una de las neuronas, constituye el error.
- 2) El error se propaga hacia atrás, partiendo de la capa de salida a la capa intermedia en cada una de sus neuronas.

El proceso se repite, por cada capa y cada neurona hasta que todas hayan recibido un error, el cual describirá su aportación al error total, con base en cada error, se actualizan los pesos de cada neurona Yegnanarayana (2009).

a. Algoritmo

Inicialización aleatoria de W^N y b^N

Hacer lte = 1 hasta epocas

Hacer j=1 hasta m

1. Propagar hacia adelante (la entrada hacia la salida)

$$a^N = f^N (W^N a^{N-1} + b^N) \text{ Para toda } N \quad (1)$$

2. Propagar hacia atrás

$$e_j = t_j - a_j^n \quad (2)$$

$$s^n = -2 F'(r^n) e_j \quad (3)$$

$$s^{N-1} = F'(r^{N-1})(W^N)^T s^N \text{ Para toda } N \in [n \dots, 3] \quad (4)$$

3. Actualizar para toda N

$$W^N = W^N - \alpha s^N (a^{N-1})^T \quad (5)$$

$$b^N = b^N - \alpha s^N \quad (6)$$

Fin

Fin

Donde:

- W Vector de pesos
- b Polarización
- e Error
- r Salida antes de la función de activación
- t Salida esperada
- s Sensibilidad de la neurona
- α Tasa de aprendizaje (para el presente trabajo es de .01)
- N Número de capas
- m Total de patrones de entrada
- a Salida obtenida
- f Función de activación

Se empleó la función de activación sigmoide logística para la 1ª y 2ª capa, y la función lineal en la capa de salida.

$$f(r) = \frac{1}{(1 + e^{-r})} \quad (7)$$

Para realizar el proceso de aprendizaje de la RNA se organizaron los datos mediante una matriz integrada por 10 columnas (variables meteorológicas) y 53,585 filas (registros diarios), extraídos de la Base de Datos (BD) *tutiempo.net.*, provenientes de estaciones meteorológicas ubicadas en diferentes regiones del mundo, de enero de 1990 mayo de 2017.

Para alcanzar eficiencia en el aprendizaje, los datos fueron normalizados a través de la ecuación siguiente

$$Valor_Normalizado_n = Valor_n / Valor_Maximo \quad (8)$$

El proceso concluyó al obtener resultados favorables superiores al 80% de precisión, expresados en la figura 6.

b) Módulo de análisis de permanencia

Con base en el diagnóstico heurístico emitido por la RNA, el módulo de análisis de permanencia del clima, efectúa conteo de número de días consecutivos en los que tales condiciones están presentes, de igual forma, este módulo permite la interacción con el agricultor, quien podrá capturar los datos climáticos actuales o futuros, con el propósito de conocer de manera oportuna la posibilidad de daño sobre el cultivo. Lo anterior se realiza con base en la expresión siguiente.

$$Si (td_i \geq 2) \text{ entonces } (df_i = 1)$$

Donde:

- td días consecutivos con clima adverso
- df daño fenológico
- i factor climático (i = 1..6)

III. RESULTADOS

A partir de la BD *tutiempo.net.*, se extrajo un total de 68,685 registros meteorológicos diarios, donde el 79% fue empleado para el aprendizaje de la RNA y 21% para validarla, todos ellos provenientes de diversas regiones del mundo.

Al finalizar el entrenamiento la RNA, se alcanzó una eficiencia de aprendizaje superior al 90%, luego de su validación mediante patrones diferentes a los

empleados para el aprendizaje, la red obtuvo alta precisión en sus diagnósticos superior al 80%. La figura 6 concentra los resultados obtenidos.




Figura 6: Resultados de validación de la RNA

Posteriormente la red realizó evaluación de cultivos de trigo ubicados en zonas de la República Mexicana, a través de 200 registros de datos climáticos diarios, el diagnóstico de daño emitido se empleó como entrada al módulo de análisis de permanencia de los factores climáticos, con el propósito de identificar la situación del cultivo respecto a posibles daños en alguna de sus etapas fenológicas, los resultados obtenidos fueron correctos en la totalidad de los casos, es decir, la salida obtenida coincidió con la salida esperada.

Para el desarrollo de la RNA se empleó el software científico Matlab versión 2017a.

IV. CONCLUSIONES

El CC constituye un fenómeno no controlado que ocasiona graves daños sobre el desarrollo de los cultivos de trigo, esto a consecuencia de la relación inversa que mantiene con su rendimiento y calidad (Zhao et al., 2017). La mitigación y la adaptación sustentables constituyen un reto importante para la agricultura en todo el mundo, a mediano y largo plazo, se vislumbra un panorama catastrófico para la seguridad alimentaria mundial en caso de no construir estrategias de mitigación y adaptación eficaces.

En apoyo a las estrategias de adaptación sustentables, concentradas en el cómo cultivar el trigo, la estrategia propuesta ofrece información que expresa cuándo reforzar su manejo en correspondencia con la variabilidad climática, luego de su validación y pruebas, se concluye que la RNA expuesta es adecuada para el diagnóstico de daño fenológico por etapa de desarrollo del trigo, permitiendo el monitoreo permanente y por tanto la identificación oportuna de daños posibles, ofrece al agricultor una herramienta que complementa el manejo de cultivo tradicional con el uso de modelos inteligentes, alternativa que representa una estrategia competitiva, apoyada en una estrategia tecnológica de alta precisión, como elemento fortalecedor de la planeación estratégica de los cultivos, el mejoramiento de la producción, la reducción de pérdidas y la seguridad alimentaria.

REFERENCES RÉFÉRENCES REFERENCIAS

1. Arnell, N. W. (2016). The global-scale impacts of climate change: the QUEST-GSI project. *Climatic Change*, 134(3), 343-352.
2. Asseng, S., Ewert, F., Martre, P., Rötter, R. P., Lobell, D. B., Cammarano, D. & Reynolds, M. P. (2015). Rising temperatures reduce global wheat production. *Nature Climate Change*, 5(2), 143-147.
3. Barrero, O., Rojas, D., González, C., & Perdomo, S. (2016). Weed detection in rice fields using aerial images and neural networks. In *Signal Processing, Images and Artificial Vision (STSIVA), 2016 XXI Symposium on* (pp. 1-4). IEEE.
4. Basche, A. D., Archontoulis, S. V., Kaspar, T. C., Jaynes, D. B., Parkin, T. B., & Miguez, F. E. (2016). Simulating long-term impacts of cover crops and climate change on crop production and environmental outcomes in the Midwestern United States. *Agriculture, Ecosystems & Environment*, 218, 95-106.
5. Boutraa, T., Akhkha, A., & Al-Shoaibi, A. K. (2015). Evaluation of growth and gas exchangerates of two local saudiwheatcultivarsgrownunderheat stress conditions. *Pak. J. Bot*, 47(1), 27-34.
6. Chen, Y., Zhang, Z., Tao, F., Palosuo, T., & Rötter, R. P. (2017). Impacts of heat stress on leaf area index and growth duration of winter wheat in the North China Plain. *Field Crops Research*.
7. Crimp, S. J., Zheng, B., Khimashia, N., Gobbett, D. L., Chapman, S., Howden, M., & Nicholls, N. (2016). Recent changes in southern Australian frost occurrence: implications for wheat production risk. *Crop and Pasture Science*, 67(8), 801-811
8. FAO (2002). Agricultura mundial: hacia los años 2015/2030. Informe resumido. <http://www.fao.org/docrep/004/y3557s/y3557s08.htm#l>
9. Frederiks, T. M., Christopher, J. T., Sutherland, M. W., & Borrell, A. K. (2015). Post-head-emergence frost in wheat and barley: defining the problem, assessing the damage, and identifying resistance. *Journal of experimental botany*, 66(12), 3487-3498.
10. Gallo, A. (2015). Assessment of the climate change impact and adaptation strategies on Italian cereal production using high resolution climate data.
11. García, M., Ulloa, H., Ramírez, H., Fuentes, M., Arias, S., & Espinoza, M. (2014). Comportamiento de los vientos dominantes y su influencia en la contaminación atmosférica en la zona metropolitana de Guadalajara, Jalisco, México. *Revista Iberoamericana de Ciencias*, 1, 97-116.
12. Gaydon, D. S., Wang, E., Poulton, P. L., Ahmad, B., Ahmed, F., Akhter, S., & Choudhury, B. U. (2017).

- Evaluation of the APSIM model in cropping systems of Asia. *Field Crops Research*, 204, 52-75.
13. Ihsan, M. Z., El-Nakhlawy, F. S., Ismail, S. M., & Fahad, S. (2016). Wheat phenological development and growth studies as affected by drought and late season high temperature stress under arid environment. *Frontiers in plant science*, 7.
 14. Iizumi, T., & Ramankutty, N. (2016). Changes in yield variability of major crops for 1981–2010 explained by climate change. *Environmental Research Letters*, 11(3), 034003.
 15. Ji, H., Xiao, L., Xia, Y., Song, H., Liu, B., Tang, L., & Liu, L. (2017). Effects of jointing and booting low temperature stresses on grain yield and yield components in wheat. *Agricultural and Forest Meteorology*, 243, 33-42.
 16. Jones, A. W., & Phillips, A. (2016). Historic Food Production Shocks: Quantifying the Extremes. *Sustainability*, 8(5), 427.
 17. Lv, H., Lei, T., Huang, X. L., & Zhang, Y. K. (2015). Application of an Improved Grey Neural Network in Grain Yield Prediction.
 18. Mansourian, S., Darbandi, E. I., Mohassel, M. H. R., Rastgoo, M., & Kanouni, H. (2017). Comparison of artificial neural networks and logistic regression as potential methods for predicting weed populations on dryland chickpea and Winter wheat fields of Kurdistan province, Iran. *Crop Protection*, 93, 43-51.
 19. Massawe, F., Mayes, S., & Cheng, A. (2016). Crop diversity: an unexploited treasure trove for food security. *Trends in plant science*, 21(5), 365-368.
 20. OECD/FAO (2017), *Perspectivas Agrícolas 2017-2026*. OCDE-FAO. Disponible en http://www.agri-outlook.org/OECD-FAO_Outlook_flyer_ES_2017.pdf
 21. Pimentel, A. J. B., Rocha, J. R. D. A. S., Souza, M. A. D., Ribeiro, G., Silva, C. R., & Oliveira, I. C. M. (2015). Characterization of heat tolerance in wheat cultivars and effects on production components. *Revista Ceres*, 62(2), 191-198.
 22. Rawson, H. M. Macpherson, G., (2001). Trigo regado: Manejo del cultivo. Food & Agriculture Org. <http://www.fao.org/docrep/006/x8234s/x8234s00.htm#Contents>
 23. Reeves, T. G., Thomas, G., & Ramsay, G. (2016). Ahorrar para crecer en la práctica: maíz, arroz, trigo. Guía para la producción sostenible de cereales.
 24. Reynolds, M. P., Quilligan, E., Aggarwal, P. K., Bansal, K. C., Cavalieri, A. J., Chapman, S. C. & Jagadish, K. S. (2016). An integrated approach to maintaining cereal productivity under climate change. *Global Food Security*, 8, 9-18.
 25. Sanad, M. N., Campbell, K. G., & Gill, K. S. (2016). Developmental program impacts phenological plasticity of spring wheat under drought. *Botanical Studies*, 57(1), 35.
 26. Sapkota, T. B., Jat, M. L., Aryal, J. P., Jat, R. K., & Khatri-Chhetri, A. (2015). Climate change adaptation, greenhouse gas mitigation and economic profitability of conservation agriculture: Some examples from cereal systems of Indo-Gangetic Plains. *Journal of Integrative Agriculture*, 14(8), 1524-1533.
 27. Serrano, M. M. (2015). Cambio Climático y la Gran Transformación del Siglo XXI: Hacia un Futuro Sostenible. *Derecho & Sociedad*, (35), 146-151.
 28. Singh MK, Singh BR (2015) Observation and temperature changes: warming of the climate system and future global warming in 21st century. *J PhysSci*. doi:10.18090/samriddhi.v5i2.1531
 29. Tesfaye, K., Gbegbelegbe, S., Cairns, J. E., Shiferaw, B., Prasanna, B. M., Sonder, K. & Robertson, R. (2015). Maize systems under climate change in sub-Saharan Africa: Potential impacts on production and food security. *International Journal of Climate Change Strategies and Management*, 7(3), 247-271
 30. Torres, I. (2017). La crisis alimentaria Mundial: causas y perspectivas para su entendimiento. *World Food Crisis: Causes and Prospects for their Understanding*. *Razón y Palabra*, 20(3_94), 602-621.
 31. Tripathi, R. C., Kalyani, V. K., Ram, L. C., Jha, S. K. (2015). Prediction of Wheat Yield from Pond Ash Amended Field by Artificial Neural Networks. *Journal of Hazardous, Toxic, and Radioactive Waste* 19 4, 04015001.
 32. United Nations Conference on Trade and Development (UNCTAD). (2015). *Commodities and Development Report 2015*. Smallholder Farmers and Sustainable Commodity Development.
 33. Yegnaranarayana, B. (2009). Artificial neural networks. PHI Learning Pvt. Ltd.
 34. Zhao, C., Liu, B., Piao, S., Wang, X., Lobell, D. B., Huang, Y., & Durand, J. L. (2017). Temperature increase reduces global yields of major crops in four independent estimates. *Proceedings of the National Academy of Sciences*, 201701762.
 35. Zheng, Z., Cai, H., Yu, L., & Hoogenboom, G. (2017). Application of the CSM-CERES-Wheat Model for Yield Prediction and Planting Date Evaluation at Guanzhong Plain in Northwest China. *Agronomy Journal*, 109(1), 204-217.

This page is intentionally left blank

