



Anexo 1. Formato de protocolo de investigación

1. Datos generales del proyecto

- **Título de proyecto:** Análisis de variables ambientales y técnicas de machine learning aplicadas a problemas ecológicos.
- **Etapas/Etapa única:** etapa única
- **Fecha inicio:** 1 de febrero de 2023
- **Fecha fin:** 1 de febrero de 2024
- **LGAC de INFOTEC en la que incide el proyecto:**

Núm.	LGAC (Línea General y Aplicación del Conocimiento)	Marcar con X
1	La SIC y la apropiación social de las TIC	
2	Las TIC y la gestión de la información y el conocimiento	
3	Ciberseguridad y delitos informáticos	
4	Protección de datos digitales	
5	Regulación de las TIC	
6	Diseño y desarrollo de sistemas embebidos inteligentes para aplicaciones industriales, biomédicas e internet de las cosas	X
7	Regulación y política pública de las telecomunicaciones	
8	Analítica de datos e información	X
9	Combinatoria, modelado y análisis de algoritmos	
10	Inteligencia computacional en la Ciencia de Datos	
11	Analítica de grandes cúmulos de información	X

- **Palabras clave:**
análisis de datos, aprendizaje automático.



2. Descripción del proyecto:

- **Resumen** (ejecutivo):

El análisis de datos y el aprendizaje automático se han convertido en herramientas cada vez más importantes para estudiar y comprender los problemas ecológicos. En los años anteriores se han identificado 3 problemas ecológicos que se han tomado como casos de estudio en los que la aplicación de estas técnicas deriva en importantes aportaciones, tanto en el ámbito académico como en el impacto social a corto plazo. Estos casos de estudio son:

1. Red de estaciones de monitorización de variables climáticas y polinizadores regionales.
2. La dispersión de contaminantes en ciudades.
3. La caracterización y predicción del comportamiento regional del viento.

En los últimos años la predicción meteorológica ha pasado de ser una simple observación para basarse en la tecnología, ciencia y las matemáticas avanzadas para predecir el tiempo con precisión. Parte fundamental de esta práctica es el conocimiento de las condiciones meteorológicas, debido a su contribución a un mejor control de la cosecha, la aparición de plagas, los días de siembra y la necesidad de riego. En contraste, la instrumentación, instalación y el mantenimiento necesarios resulta costoso en términos económicos; en particular, para las personas que consideran tener un huerto de menor tamaño, cuya afectación para el proceso de siembra y cosecha de los alimentos radica en el desconocimiento de las condiciones en las que se encuentra el huerto y los pronósticos del clima, los cuales no siempre se adecúan a ciertas regiones ni toman en cuenta microclimas. En el caso de los animales polinizadores, el análisis de datos y el aprendizaje automático pueden utilizarse para identificar las especies de polinizadores de una zona y cartografiar las áreas más importantes para el ecosistema. Estos modelos también tienen el potencial de predecir la dinámica de las poblaciones de polinizadores; por ejemplo, los movimientos y tasas de supervivencia, así como para evaluar su posible impacto en el rendimiento de los cultivos.



**Dirección Adjunta de Innovación y Conocimiento
Gerencia de Innovación
Subgerencia de Innovación Gubernamental**

El análisis de datos y el aprendizaje automático también pueden utilizarse para estudiar la dispersión de contaminantes en una zona. La recopilación de datos sobre la topografía local, la vegetación y las condiciones meteorológicas, pueden utilizarse para predecir el comportamiento de los contaminantes en el medio ambiente. Esto puede ser de utilidad para evaluar los riesgos potenciales para la salud y el medio ambiente que causan los contaminantes.

Por último, el análisis de datos y el aprendizaje automático pueden utilizarse para estudiar el comportamiento regional del viento; por ejemplo, mediante el análisis de datos históricos sobre el viento, se pueden utilizar modelos de aprendizaje automático para predecir futuros patrones de viento y evaluar las posibles repercusiones de la energía eólica. Esto puede aportar elementos para la toma de decisiones, informadas sobre dónde y cómo construir parques eólicos que produzcan la mayor cantidad de energía.

Antecedentes:

A continuación se da un contexto breve de los antecedentes de cada caso de estudio mencionado.

1. Red de estaciones de monitorización de variables climáticas y polinizadores regionales.

La polinización es un proceso importante para el mundo y los sistemas de producción agrícola, debido a que muchos cultivos dependen de la polinización para el mantenimiento de la viabilidad y la diversidad genética de las plantas. Existen diversos tipos de insectos polinizadores; más aún, se conoce que la polinización de las abejas es fundamental, porque aumenta el tamaño del fruto, la producción de semillas y las tasas de germinación; por lo tanto, generan una polinización suficiente que aumenta la aptitud de la planta. De lo anterior, es importante monitorear los parámetros ambientales que pueden afectar la calidad de los cultivos. Actualmente, existen sistemas de monitoreo basados en diferentes técnicas de inteligencia artificial que ayudan a conocer las condiciones ambientales de los cultivos. Por lo tanto, los datos que se generan pueden ser analizados y, por consiguiente, generan respuestas eficientes, tales como, el aumento de la calidad, productividad o una mejora en la economía en general. Los jardines inteligentes se basan en un modelo de desarrollo sustentable que buscan generar una mayor calidad en la producción agrícola y se basan en la agricultura de precisión.



**Dirección Adjunta de Innovación y Conocimiento
Gerencia de Innovación
Subgerencia de Innovación Gubernamental**

Se cuenta con un desarrollo tecnológico previo al dispositivo IoT, denominado “Maraca IoT”, cuyo nivel de madurez tecnológica alcanza el valor 4 (se adjunta el reporte técnico correspondiente), junto con otro prototipo llamado “Monpo”, con el cual colaboro con la Dra. Tania Ramírez, adscrita al Centrogeo.

2. Dispersión de contaminantes en ciudades.

El uso de la inteligencia artificial para estudiar la calidad del aire y la dispersión de contaminantes en las ciudades es una tendencia en rápido crecimiento en el campo de las ciencias ambientales. Utilizando datos de código abierto procedentes de fuentes, como imágenes por satélite, sensores móviles y otros dispositivos conectados, la IA puede emplearse para desarrollar modelos predictivos que permitan evaluar la calidad del aire en las ciudades y detectar focos de contaminación. Esto puede ayudar a identificar las zonas con altos niveles de contaminación atmosférica y permitir la toma de decisiones informadas en términos de salud pública, planificación urbana y protección del medio ambiente.

El uso de estos métodos tiene el potencial de detectar de manera precoz la contaminación atmosférica, permitiendo a los ciudadanos tomar medidas preventivas como el uso de mascarillas o el cierre de ventanas. Además, la IA puede utilizarse para crear mapas de contaminación que ayuden a fundamentar las decisiones de planificación urbana, inclusive la ubicación de espacios verdes y la implantación de fuentes de energía limpias.

El comportamiento del viento en una región es un sistema complejo que depende de múltiples variables, la mayoría de ellas son desconocidas o difíciles de cuantificar. El diseño de modelos de caracterización de sistemas eólicos en regiones específicas es un problema a numerosas escalas. La información de la velocidad y dirección del viento obtenida de los anemómetros en las estaciones meteorológicas representan los datos que más información proporcionan en los modelos actuales; sin embargo, existen más variables que pueden tener correlación con los fenómenos meteorológicos, como lo son la humedad relativa y la presión atmosférica.



**Dirección Adjunta de Innovación y Conocimiento
Gerencia de Innovación
Subgerencia de Innovación Gubernamental**

Actualmente, se realiza el trabajo con la colaboración del alumno de doctorado Rodrigo Domínguez en nuevos métodos de análisis de los datos ambientales, así como nuevas visualizaciones. El software desarrollado hasta el momento se encuentra alojado en el repositorio de Github, cuya liga electrónica de acceso es https://github.com/ruy2311/predictor_ZMVM.

Cabe señalar que se ha publicado el artículo con respecto al tema :

1. Minutti-Martinez, C., Arellano-Vázquez, M., & Zamora-Machado, M. (2021, October). A Hybrid Model for the Prediction of Air Pollutants Concentration, Based on Statistical and Machine Learning Techniques. In *Mexican International Conference on Artificial Intelligence* (pp. 252-264). Springer, Cham. https://link.springer.com/chapter/10.1007/978-3-030-89820-5_21

3. Caracterización y predicción del comportamiento regional del viento.

La investigación sobre la caracterización regional del viento mediante el aprendizaje automático es un área de investigación reciente y de rápido crecimiento con un gran potencial para mejorar la generación de energía eólica. Las técnicas de aprendizaje automático permiten analizar grandes conjuntos de datos para identificar patrones y correlaciones en la velocidad y dirección del viento, así como otras características importantes del viento, lo que ofrece a los generadores de energía eólica más información sobre las mejores ubicaciones para las turbinas.

Se ha demostrado que el uso del aprendizaje automático mejora la precisión de las predicciones de velocidad y dirección del viento, lo que conduce a una generación de energía eólica más eficiente. Además, el análisis de conjuntos de datos complejos puede aportar información valiosa sobre las características de determinadas regiones, como los cambios estacionales en la velocidad y dirección del viento o el efecto del terreno en los patrones de viento.

Se desarrolló un trabajo previo para automatizar la detección de los vientos de Santana en la región de la Rumorsosa en BC, los resultados obtenidos de este estudio dan la pauta para aplicar el mismo método a otras regiones geográficas. El comportamiento del viento depende la ubicación geográfica y de las condiciones



**Dirección Adjunta de Innovación y Conocimiento
Gerencia de Innovación
Subgerencia de Innovación Gubernamental**

del terreno, por lo tanto, aplicar este estudio a otra región requiere de un estudio previo de la zona, y en particular, es de interés aplicar este método a la región central del país, como lo es la Ciudad de México.

Desde el año 2018 se cuenta con el software Windc11A, que se encuentra bajo licencia de código abierto en la plataforma github (para más información, referirse a la liga electrónica <https://github.com/estudiovientos/saw>).

A pesar de que esta versión no contaba con una interfaz amigable, se utilizó para el análisis de campos eólicos, como la rumorosa 1.

En este año, desde el mes de enero se realizó una mejora del código que incluyó una mejora del aspecto y un manual de usuario, esto con el apoyo de un becario de la universidad politécnica de Aguascalientes (Fernando Huerta), esta versión se encuentra públicamente disponible para su consulta mediante la liga electrónica <https://github.com/estudiovientos/saw/tree/Versi%C3%B3n-2> .

En relación a este tema, se han publicado dos artículos:

1. El artículo Magali, A. V., Marlene, Z. M., Robles, M., & Jaramillo, O. A. (2020, September). Favorable wind states in wind energy production at La Rumorosa I wind farm. In *Journal of Physics: Conference Series* (Vol. 1618, No. 6, p. 062071). IOP Publishing. DOI <https://doi.org/10.1088/1742-6596/1618/6/062071> . En este artículo soy primera autora.
2. El artículo Arellano-Vázquez, M., Minutti-Martinez, C., & Zamora-Machado, M. (2020, October). Automated Characterization and Prediction of Wind Conditions Using Gaussian Mixtures. In *Mexican International Conference on Artificial Intelligence* (pp. 158-168). Springer, Cham. https://link.springer.com/chapter/10.1007/978-3-030-60884-2_12 . En este artículo son primera autora.

• **Justificación:**

1. Red de estaciones de monitorización de variables climáticas y polinizadores regionales.

El registro de datos meteorológicos a nivel regional, además de dar la posibilidad de monitorizar en tiempo real las condiciones atmosféricas y del terreno, permitiría a



**Dirección Adjunta de Innovación y Conocimiento
Gerencia de Innovación
Subgerencia de Innovación Gubernamental**

múltiples instancias de investigación, realizar diferentes análisis de series de tiempo para variables ambientales, utilizando métodos estadísticos, y adicionalmente, la cantidad de datos generados por las estaciones propuestas hace factible el uso de técnicas de inteligencia artificial, las cuales requieren grandes volúmenes de datos, generando resultados que brinden información de valor tanto para agricultores locales como para la población, en general, y con ello mejorar el aprovechamiento de los recursos naturales, como el hídrico y adicionalmente promover mayor investigación utilizando este tipo de datos. Además, estos datos contribuyen al análisis para la preservación de los polinizadores.

Las técnicas de aprendizaje automático encierran un gran potencial para monitorizar a los polinizadores en los sistemas agrícolas. Los polinizadores, como las abejas y las mariposas, son vitales para la salud de los cultivos, y entender cómo se mueven e interactúan con las plantas es esencial para mantener un sistema agrícola sano. Por ejemplo, el aprendizaje automático puede ayudar a los agricultores a identificar las zonas donde los polinizadores son más activos y a determinar qué plantas son las más atractivas para los polinizadores. Esto puede ayudar a los agricultores a optimizar su rotación de cultivos para garantizar que sus plantas se polinizan adecuadamente. Además, el aprendizaje automático puede ayudar a identificar áreas en las que el uso de pesticidas puede estar afectando a las poblaciones de polinizadores, y ayudar a los agricultores a tomar medidas para reducir su impacto sobre los polinizadores.

El aprendizaje automático también puede ayudar a los agricultores a identificar cuándo está disminuyendo su población de polinizadores y a tomar medidas para garantizar que sus polinizadores se mantengan sanos. Mediante el seguimiento y la comprensión de los movimientos de los polinizadores, los agricultores pueden identificar cuándo su población de polinizadores está en peligro y tomar medidas para solucionarlo. Esto puede incluir proporcionar fuentes de alimento adicionales, crear hábitats favorables a los polinizadores o utilizar técnicas alternativas de gestión de plagas.

2. La dispersión de contaminantes en ciudades.

En ciudades mexicanas densamente pobladas (como la Ciudad de México, Monterrey y Guadalajara), además de su población, su geografía y topografía han



**Dirección Adjunta de Innovación y Conocimiento
Gerencia de Innovación
Subgerencia de Innovación Gubernamental**

provocado un aumento de la contaminación atmosférica. En particular, la Ciudad de México es una de las ciudades más contaminadas del mundo. La contaminación del aire en Ciudad de México se ha relacionado con una amplia gama de problemas de salud, desde asma hasta enfermedades respiratorias. Con el fin de mejorar la calidad del aire en Ciudad de México y reducir los riesgos para la salud asociados a la contaminación atmosférica, la ciudad ha puesto en marcha diversas estrategias para reducir las emisiones, pero la calidad del aire sigue siendo mala.

Afortunadamente, las técnicas de aprendizaje automático ofrecen una nueva forma de abordar este complejo problema. Mediante el uso de algoritmos para identificar patrones en los datos de calidad del aire, el aprendizaje automático tiene el potencial de identificar las fuentes de contaminación atmosférica, predecir cuándo los niveles de contaminación serán máximos y sugerir intervenciones para reducir las emisiones. Por ejemplo, el aprendizaje automático puede utilizarse para analizar patrones de tráfico e identificar las horas del día o las zonas de la ciudad donde las emisiones relacionadas con el tráfico son más altas, lo que permite a las autoridades centrarse en estas zonas y reducir las emisiones.

Al reducir la contaminación del aire, la Ciudad de México puede mejorar la salud de sus ciudadanos y reducir la carga financiera de los problemas de salud relacionados con la contaminación del aire.

El uso de la IA en la investigación de la calidad del aire tiene un impacto social directo. Al facilitar a los ciudadanos el acceso a datos sobre la calidad del aire, la IA puede capacitar a las personas para tomar decisiones más informadas sobre su salud y su entorno. Además, mediante el seguimiento de la contaminación atmosférica en las ciudades, la IA puede ayudar a identificar áreas preocupantes, que pueden abordarse con una mejor planificación urbana y legislación medioambiental.

3. La caracterización y predicción del comportamiento regional del viento.

Además de mejorar la generación de energía eólica, la investigación sobre la caracterización regional del viento mediante el aprendizaje automático también tiene aplicaciones potenciales en otros ámbitos, como la predicción meteorológica y la integración de las energías renovables. Las técnicas de aprendizaje automático



**Dirección Adjunta de Innovación y Conocimiento
Gerencia de Innovación
Subgerencia de Innovación Gubernamental**

pueden utilizarse para identificar patrones en los datos eólicos que sirvan para mejorar las previsiones y para modelizar los efectos de la energía eólica en la red eléctrica general.

- **Objetivo general:**

Aplicar métodos de análisis de datos y machine learning a los siguientes tres problemas ecológicos:

1. Red de estaciones de monitorización de variables climáticas y polinizadores regionales.
2. La dispersión de contaminantes en ciudades.
3. La caracterización y predicción del comportamiento regional del viento.

- **Objetivos específicos:**

1. Hacer una versión mejorada de la estación meteorológica Maraca IoT y de MonPo.
2. Hacer una versión mejorada de MonPo.
3. Recopilar imágenes de polinizadores regionales.
4. Creación de una base de datos climática regional.
5. Hacer una plataforma de visualización de datos en tiempo real.
6. Realizar análisis de información histórica para la búsqueda de patrones climáticos.

- **Meta:**

- Incrementar el TRL al nivel 5 de los desarrollos tecnológicos Maraca IoT y Monpo.
- Desarrollo de la investigación de caracterización regional del viento en la península de Baja California.
- El estudio regional del viento en la ciudad de Monterrey, NL.

- **Metodología:**

La metodología seguida para el caso de estudio uno se detalla en los reportes técnicos anexos.



**Dirección Adjunta de Innovación y Conocimiento
Gerencia de Innovación
Subgerencia de Innovación Gubernamental**

En el caso del análisis del viento se han usado en las publicaciones anteriores el software WindCIIA que se base en la aplicación del Mixture Gaussian Model. Para la siguiente etapa del proyecto se explorarán otros métodos de procesamiento, como lo son las redes neuronales.

- **Beneficios esperados:**

1. Red de estaciones de monitorización de variables climáticas y polinizadores regionales.

El estado de Aguascalientes tiene un corto periodo de lluvias por lo que es deseable optimizar el consumo de agua de riego en los cultivos. Es así que, al contar con una base de datos regional alimentada por los datos de varias estaciones meteorológicas de tamaño reducido y bajo costo, será posible visualizar los datos en tiempo real para ser usados en la toma de decisiones a corto plazo (por ejemplo, la periodicidad de riego), determinar las mejores condiciones ambientales para los cultivos (por medio del análisis de series temporales).

De igual forma, se espera que la disponibilidad de estos datos para el público y a otras instituciones de investigación, promoverá nuevos proyectos de investigación donde se utilicen como base o apoyo a estos.

El sector agrícola puede beneficiarse enormemente del uso del aprendizaje automático para vigilar a los polinizadores. Los datos precisos sobre las poblaciones de polinizadores pueden utilizarse para tomar decisiones informadas sobre la gestión de plagas y la producción de cultivos, ayudando a maximizar los rendimientos y minimizando el uso de pesticidas. Además, el aprendizaje automático puede ayudar a identificar los polinizadores más eficientes para cultivos específicos, lo que permite a los agricultores tomar decisiones sobre qué especies apoyar y gestionar. Los datos precisos sobre las poblaciones de polinizadores pueden utilizarse para informar las políticas públicas y garantizar que la conservación de los polinizadores siga siendo una prioridad.



**Dirección Adjunta de Innovación y Conocimiento
Gerencia de Innovación
Subgerencia de Innovación Gubernamental**

Es importante destacar que también el impacto es la formación de recursos humanos de alta calidad, mediante la presencia de población juvenil en el área STEM, incentivando vocaciones científicas, mediante la investigación y desarrollo tecnológico aplicado a problemáticas prioritarias.

2. La dispersión de contaminantes en ciudades.

El uso de técnicas de aprendizaje automático para controlar y predecir la calidad del aire puede tener un enorme impacto positivo en la sociedad y la salud pública. Al predecir la calidad del aire, las personas pueden evitar exponerse a niveles potencialmente nocivos de contaminación, reduciendo su riesgo de desarrollar problemas respiratorios u otras afecciones asociadas a la mala calidad del aire.

Además, el aprendizaje automático podría ayudar a identificar las fuentes de contaminación atmosférica, lo que permitiría a los gobiernos tomar medidas para reducir la cantidad de contaminantes liberados a la atmósfera. Al comprender de dónde procede la contaminación, los gobiernos pueden centrarse en fuentes específicas y aplicar normativas para reducir la cantidad de contaminantes liberados. Al predecir la calidad del aire en tiempo real, las personas pueden tomar medidas para protegerse de niveles peligrosos de contaminación atmosférica.

3. La caracterización y predicción del comportamiento regional del viento.

Recientemente, las tendencias de investigación en la caracterización regional del viento mediante el aprendizaje automático han recibido una atención considerable debido a su potencial para reducir el coste y la complejidad de la generación de energía eólica y las energías renovables. Se han desarrollado algoritmos de aprendizaje automático, como la aplicación de modelos como de Gaussian Mixture Model o métodos no supervisados como las redes neuronales artificiales, para predecir con exactitud las velocidades y direcciones del viento en una región determinada. La precisión de estos algoritmos mejora con más datos, lo que convierte al aprendizaje automático en una herramienta atractiva para la generación de energía eólica.

Con predicciones más precisas, las comunidades pueden planificar y gestionar mejor sus fuentes de energía, lo que redundará en una mayor sostenibilidad y una



**Dirección Adjunta de Innovación y Conocimiento
Gerencia de Innovación
Subgerencia de Innovación Gubernamental**

mejora de la calidad de vida de quienes viven en la zona. Además, el aprendizaje automático puede ayudar a identificar las zonas en las que los aerogeneradores pueden ubicarse de forma más eficiente, reduciendo la necesidad de infraestructuras a gran escala y sus impactos ambientales asociados.

- **Resultados esperados (productos entregables):**
Una nueva versión de los desarrollos tecnológicos MonPo y Maraca. Artículos en congreso o revista internacional.

3. Cronograma de actividades

Etapa 1/Etapa única:				
#	Actividad	Resultado esperado (producto entregable)	Fecha inicio (dd/mm/aaaa)	Fecha fin (dd/mm/aaaa)
1	Solicitud de los datos de las estaciones meteorológicas de conagua de los años 2021 y 2022 de la Ciudad de México y zona conurbada.	Actualización de la base de datos regional del viento de la Ciudad de México	01/02/2023	01/04/2023
2	Solicitud de los datos de las estaciones meteorológicas de conagua de los años 2017-2022 de la ciudad de Monterrey, NL y zona conurbada.	Creación de base de datos para la ciudad de Monterrey.	01/03/2023	01/05/2023
3	Mejora de la estación meteorológica Maraca IoT	Liberación de la versión 2 de Maraca	01/02/2023	01/02/2024
4	Análisis de los datos de viento de Baja California	Publicación de artículo en revista arbitrada o congreso internacional.	01/02/2023	01/02/2024
5	Método de predicción de dispersión de contaminantes en la Ciudad de México	Publicación de artículo en revista arbitrada o congreso internacional.	01/02/2023	01/02/2024

4. Referencias



**Dirección Adjunta de Innovación y Conocimiento
Gerencia de Innovación
Subgerencia de Innovación Gubernamental**

- Saleh H Awami, Youssef H Shakmak, and Rabeh A Mohammed. A novel approach for forecasting average temperature using artificial neural networks (applied to benghazi city's weather). In Proceedings of the 6th International Conference on Engineering & MIS 2020, pages 1–10, 2020.
- Constantinos Marios Angelopoulos, Sotiris Nikolettseas, and Georgios Constantinos Theofanopoulos. A smart system for garden watering using wireless sensor networks. In Proceedings of the 9th ACM international symposium on Mobility management and wireless access, pages 167–170, 2011.
- Birgit Penzenstadler, Jason Plojo, Marinela Sanchez, Ruben Marin, Lam Tran, and Jayden Khakurel. The diy resilient smart garden kit. In Proceedings of the Workshop on Computing within Limits (LIMITS), Calgary, AB, Canada, pages 6–7, 2018.
- Cristina Botías and Francisco Sánchez-Bayo. Papel de los plaguicidas en la pérdida de polinizadores. *Revista Ecosistemas*, 27(2):34–41, 2018.
- The Food and Agriculture Organization (FAO). Es hora de apreciar la labor de los polinizadores.
- The Food and Agriculture Organization (FAO). Los polinizadores: su biodiversidad poco apreciada, pero importante para la alimentación y la agricultura.
- Omar Jehovani López Orozco, Miguel González Mendoza, Juan Manuel Olvera Santoyo, and Ariel Lucien García Gamboa. Modelo de datos para el monitoreo de variables agro-climatológicas de huertos urbanos utilizando internet de las cosas y cómputo en la nube. *Research in Computing Science*, 147:239–248, 2018.
- Marta García García, Leonardo Alberto Ríos Osorio, and Javier Álvarez del Castillo. La polinización en los sistemas de producción agrícola: revisión sistemática de la literatura. *Idesia (Arica)*, 34(3):53–68, 2016.
- Alexander Chautá-Mellizo, Stuart A Campbell, Maria Argenis Bonilla, Jennifer S Thaler, and Katja Poveda. Effects of natural and artificial pollination on fruit and offspring quality. *Basic and Applied Ecology*, 13(6):524–532, 2012.
- Ciprian-Radu Rad, Olimpiu Hancu, Ioana-Alexandra Takacs, and Gheorghe Olteanu. Smart monitoring of potato crop: a cyber-physical system architecture model in the field of precision agriculture. *Agriculture and Agricultural Science Procedia*, 6:73–79, 2015.



**Dirección Adjunta de Innovación y Conocimiento
Gerencia de Innovación
Subgerencia de Innovación Gubernamental**

- Izzatdin Abdul Aziz, Mohd Jimmy Ismail, Nazleeni Samiha Haron, and Mazlina Mehat. Remote monitoring using sensor in greenhouse agriculture. In 2008 International Symposium on Information Technology, volume 4, pages 1–8. IEEE, 2008.
- Kirtan Jha, Aalap Doshi, Poojan Patel, and Manan Shah. A comprehensive review on automation in agriculture using artificial intelligence. *Artificial Intelligence in Agriculture*, 2019.
- Bartomeus, I., Dicks, L.V.: The need for coordinated transdisciplinary research infrastructures for pollinator conservation and crop pollination resilience. *Environmental Research Letters* 14(4), 045017 (2019).
- Carneiro, T., Da Nobrega, R.V.M., Nepomuceno, T., Bian, G.B., De Albuquerque, V.H.C., Reboucas Filho, P.P.: Performance analysis of google colab as a tool for accelerating deep learning applications. *IEEE Access* 6, 61677–61685 (2018)
- Chollet, F., et al.: Keras. <https://keras.io> (2015)
- FAO: La reducción de la población de abejas es una amenaza para la seguridad alimentaria y la nutrición, <http://www.fao.org/news/story/es/item/1194963/icode/>, [Online; accessed March, 2021]
- Iyer, V., Nandakumar, R., Wang, A., Fuller, S.B., Gollakota, S.: Living iot: A flying wireless platform on live insects. In: *The 25th Annual International Conference on Mobile Computing and Networking*. pp. 1–15 (2019)
- Kearns, C.A., Inouye, D.W., Waser, N.M.: Endangered mutualisms: the conservation of plant-pollinator interactions. *Annual review of ecology and systematics* 29(1), 83–112 (1998) Kulyukin, V., Mukherjee, S., Amlathe, P.: Toward audio beehive monitoring: Deep learning vs. standard machine learning in classifying beehive audio samples. *Applied Sciences* 8(9), 1573 (2018)
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., Duchesnay, E.: Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research* 12, 2825–2830 (2011)
- Simonyan, K., Zisserman, A.: Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556* (2014)



**GOBIERNO DE
MÉXICO**



CONACYT
Consejo Nacional de Ciencia y Tecnología



**Dirección Adjunta de Innovación y Conocimiento
Gerencia de Innovación
Subgerencia de Innovación Gubernamental**

- Zhong, Y., Gao, J., Lei, Q., Zhou, Y.: A vision-based counting and recognition system for flying insects in intelligent agriculture. Sensors 18(5), 1489 (2018)

ATENTAMENTE

DRA. MAGALI ARELLANO VÁZQUEZ

PROFESORA INVESTIGADORA INGENIERA TECNÓLOGA TITULAR "A" ITA

C.c.p. Mtro. Carlos Josué Lavandeira Portillo, Director Adjunto de Innovación y Conocimiento. Presente.