

Plataformas tecnológicas inteligentes al alcance de la agricultura a pequeña escala

Smart farming platforms in the reach of small farmers

Juan Felipe Restrepo-Arias ^a & John W. Branch-Bedoya ^b

^a Escuela de Ciencias Aplicadas e Ingeniería, Universidad EAFIT, Medellín Colombia. jfrestrepa@unal.edu.co

^b Universidad Nacional de Colombia, Sede Medellín, Facultad de Minas, Medellín, Colombia. jwbranch@unal.edu.co

1 Introducción

Las tecnologías de la Industria 4.0 y en especial la evolución del IoT son una oportunidad para solucionar diferentes problemas en el sector agrícola (Khanna & Kaur, 2019). A diferencia de los sectores industriales, el enfoque heurístico todavía domina en la agricultura para la solución de problemas (Lu, 2017), y muchas de sus actividades de monitoreo requieren de una inspección visual para poder entregar diagnósticos acertados (Tian et al., 2020). Estas inspecciones están a cargo de productores, técnicos e ingenieros que necesitan desplazarse a sitios apartados y muchas veces de difícil acceso, por lo que la asistencia técnica puede verse limitada.

Uno de los principales beneficios desde el punto de vista técnico que ofrece el IoT en la agricultura, es poder acceder a datos que se encuentran en sitios remotos en cuestión de segundos, así como a diferentes ubicaciones en muy corto tiempo, lo que hace posible una asistencia técnica más oportuna y eficiente, muchas veces necesaria en cuestiones que no dan espera como, por ejemplo, la identificación rápida de plagas o enfermedades (Khanna & Kaur, 2019). Así mismo, la colección de grandes cantidades de datos, conocidos como Big Data, permiten aplicar herramientas del campo de la analítica para anticiparse a posibles problemas, lo que a su vez se traduce en ahorro de costos y tiempo, y puede hacer más competitivos tanto a pequeños como grandes productores agrícolas (Elijah et al., 2018; Kamilaris et al., 2017; Pham & Stack, 2018).

Por otro lado, existen retos aún no resueltos en la implementación de plataformas de IoT para la agricultura. En la última década la mayoría de las soluciones de IoT en entornos rurales, se han enfocado en la captura de datos

principalmente climáticos y de condiciones del suelo, provenientes de sensores analógicos y digitales (Terence & Purushothaman, 2020). Si bien, esto es importante debido al avance que se ha dado a la agricultura, aún falta camino por recorrer en la integración de sensores visuales (cámaras), que permitan potencializar aún más el uso de las plataformas de IoT, como ya se viene dando en otros dominios (Campobello & Segreto, 2019; Feng et al., 2019; Lee & Kim, 2018; Liu et al., 2018). Esto redundaría también en beneficios para la agroindustria en general, que vería como la administración de empresas del sector, tendría más información confiable para la toma de decisiones, no solamente en las actividades de campo, sino, por ejemplo, en el manejo adecuado de inventarios, gestión del personal, prevención de fraudes, minimización de los desperdicios y, sobre todo, minimización del impacto ambiental (Elijah et al., 2018).

2 Problemática actual

Una de las principales limitantes para la adopción del IoT en ambientes rurales es la falta de conectividad, debido a la escasez de redes celulares en áreas remotas (Ji et al., 2019). Existen tecnologías alternativas a este tipo de redes, las cuales son conocidas como LPWAN (*Low Power Wide Area Network*) que tienen un bajo consumo de energía (las baterías de los dispositivos pueden durar hasta diez años) y un alcance entre los 10 y los 40 km en áreas abiertas (Islam et al., 2020). Sin embargo, esta tecnología tiene un limitado ancho de banda, que puede variar entre 100 bps a 50 kbps, lo que restringe la cantidad de datos que se transmiten (Islam et al., 2020; Mekki et al., 2018). Las tecnologías de comunicación más representativas de la familia LPWAN son: LoRa (*Long Range*), LoRaWAN (*Long Range Wide Area Network*) y

Sigfox (*Sigfox S.A.*) (Carlsson et al., 2018; Islam et al., 2020; Mekki et al., 2018).

Debido a esto, la mayoría de las plataformas IoT de AI, se limitan a la captura de datos muy livianos y relativamente fáciles de transmitir, como los provenientes de sensores analógicos o digitales que miden variables espacio-temporales (temperatura, velocidad del viento, humedad del suelo, humedad relativa, etc.), (Codeluppi et al., 2020). Esto limita la posibilidad de transferir datos más pesados, desde el punto de vista computacional, como imágenes digitales y videos (Islam et al., 2020).

Por otro lado, los desarrollos de soluciones basadas en visión artificial para agricultura vienen en aumento en los últimos años como, por ejemplo, detección de plagas y enfermedades (Pathan & Chakole, 2019; Zhong et al., 2018), identificación de malezas (Sa et al., 2018), conteo de frutos y de árboles (Apolo-Apolo et al., 2020; De Luna et al., 2020; Koc-San et al., 2018), detección de estados fenológicos (Yalcin, 2018), entre otras aplicaciones, a través de imágenes digitales capturadas con diferentes dispositivos como UAVs (Unmanned Aerial Vehicles), teléfonos móviles o cámaras de dispositivos IoT.

Desafortunadamente, al tratar de integrar estas soluciones de visión artificial, a las plataformas IoT, se generan cuellos de botella, debido a las condiciones limitadas de las tecnologías de transmisión o hardware usadas en algunos entornos, lo cual genera errores en los datos transmitidos, alta latencia, altos consumos de energía y en algunos casos la interrupción de las transmisiones por completo (Jankowski et al., 2020). En la literatura, se plantean dos (2) desafíos que permanecen abiertos en la comunidad científica y tecnológica que realiza investigación y desarrollo en las posibles soluciones en dominios similares al rural (Jankowski et al., 2020):

1. Minimizar la cantidad de cálculos locales en los dispositivos IoT, sin perder eficacia en los procesos.
2. Diseñar esquemas de transmisión más robustos para estos entornos, con limitantes en las comunicaciones.

3 Solución propuesta

Este trabajo de investigación tuvo como objetivo principal aportar en la solución de este tipo de problemas, al proponer un método de clasificación de imágenes integrado a una plataforma de agricultura inteligente, que busca reducir el costo computacional del proceso de clasificación de imágenes digitales, aplicado en un contexto rural con dispositivos que tienen limitaciones en su capacidad de cómputo local.

Lo primero fue seleccionar una arquitectura de referencia. Esta arquitectura se basó en el uso de la tecnología de comunicación LoRa (Long Range), especialmente creada para trabajar en contextos con limitaciones de conectividad y energía. Luego se seleccionó el caso de aplicación de la clasificación de enfermedades en plantas, por ser uno de los que más impacto tiene en la economía y productividad de los agricultores, para lo cual se generó un conjunto de datos de imágenes digitales, basado en el conjunto de datos (dataset) PlantVillage, uno de los más usados en investigaciones de este tipo. Posteriormente, con base en los resultados que otros investigadores han obtenido en el entrenamiento de

algoritmos de Inteligencia Artificial con el conjunto de datos seleccionado, se hizo una preselección de métodos basados en redes neuronales convolucionales que combinan dos características: (1) un desempeño con exactitud en la clasificación por encima del 90 % y (2) un número de parámetros de entrenamiento menor de cinco millones. El método seleccionado fue MobileNet, con los siguientes resultados de desempeño: exactitud (Accuracy) del 96,31 %, precisión (Precision) del 95,55 %, sensibilidad (Recall) del 95,93 %, F1—score del 95,72 %, con 3.762.056 de parámetros y un tamaño de 28,7 MB. Finalmente, el método seleccionado fue evaluado en tres escenarios de reducción de su arquitectura, para conocer su robustez al tener que adaptarse a condiciones con limitadas capacidades de cómputo. Para la evaluación se implementó una plataforma de agricultura inteligente en condiciones reales de trabajo, en dos (2) unidades productivas de cultivo de tomate bajo invernadero, obteniendo métricas por encima del 90 % en todos los casos.

4 Lugar de implementación

Las unidades productivas piloto están ubicadas en la vereda San José de la Montaña, corregimiento de San Cristóbal, municipio de Medellín, a una altura de 2200 msnm (Fig. 1).

Para el estudio se seleccionaron dos productores de hortalizas que tienen invernaderos, instalados desde el año 2020. Estos invernaderos son tipo semi-arco, cada uno de 300 m². El invernadero no.1 de 15m de ancho x 20m de longitud, y el invernadero no.2 de 10m de ancho x 30m de longitud, con sistema de riego por goteo, cortinas para ventilación de acción manual y 6m de altura máxima. Los cultivos principales son tomate, cebolla y cilantro, estos cultivos se alternan de acuerdo con la programación de los productores y la época del año.

Arquitectura de la plataforma de agricultura inteligente implementada.

La plataforma prototipo para la implementación del método de clasificación de imágenes seleccionado se construyó con base en la arquitectura de referencia LoRaFARM (Codeluppi et al., 2020). A continuación, la Fig. 2, muestra el esquema general de la arquitectura implementada.



Figura 1. Ubicación del sitio seleccionado para la implementación
 Nota. Panorámica general de la zona de estudio: 1: Invernadero No.1; 2: Invernadero No.2; N-A: Nodo tipo A; N-B: Nodo tipo B; M-E: Estación meteorológica. Coordenadas: 6°17'42.68" N 75°39'25.99" O
 Fuente: elaboración propia.

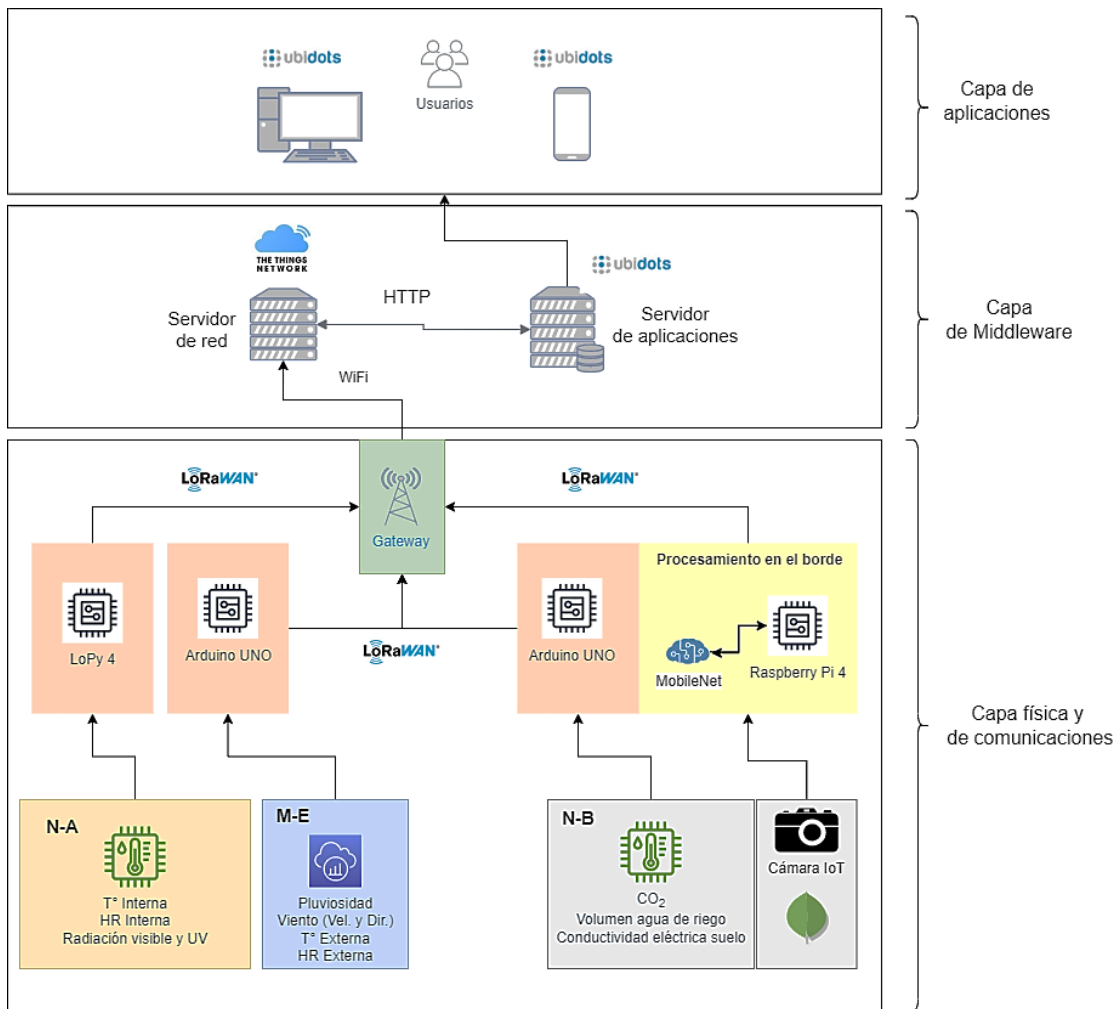


Figura 2. Arquitectura de la plataforma de Agricultura Inteligente implementada
Fuente: elaboración propia.

I. Descripción del proceso de clasificación de imágenes en la Plataforma

La implementación del método de clasificación de imágenes, empleando técnicas de Inteligencia Artificial a una plataforma de agricultura inteligente, propuesto en este trabajo se implementó en los nodos tipo B (N-B) y tiene de tres etapas que se describen en la Fig. 3.

- I. Pre-procesamiento de las imágenes.
- II. Clasificación.
- III. Envío de datos y almacenamiento en la Nube.

I. Pre-procesamiento de las imágenes. El preprocesamiento de las imágenes se llevó a cabo en tres subetapas: (1) la captura de las imágenes, que se realizó con un módulo independiente creado para tal fin como se muestra en la Fig. 4. (2) Segmentación, en la cual mediante un algoritmo de clasificación Bayesiana se retira el color del fondo. Y (3) el recorte de la imagen donde se seleccionan solamente los segmentos en los que la hoja ocupa un 80% de píxeles o más.

II. Clasificación. En esta etapa los recortes con el 80% o más de píxeles pertenecientes a la hoja pasan por la red neuronal MobileNet y son clasificados de acuerdo con el entrenamiento de la red. La clase que es almacenada es la que presenta un mayor porcentaje de probabilidad según el algoritmo de clasificación, y por lo menos uno de los recortes que presente la enfermedad es suficiente para almacenar los datos como pertenecientes a una de las enfermedades. Esto debido a que algunos recortes pueden quedar con tejido sano y ser clasificados en la clase Health.

III. Envío de datos y almacenamiento en la Nube. Luego de ser clasificada la imagen, la aplicación creada para la integración envía el dato directamente desde el microprocesador RaspberryPi al Gateway y este a su vez la envía al servidor donde es almacenado. Es importante aclarar que no se envían imágenes a través de la red y los recortes son eliminados cada cierto periodo de tiempo que puede ser programado de acuerdo con el volumen de imágenes que se puedan obtener. Esto es importante porque se debe cuidar que la memoria del microprocesador no se consuma con el almacenamiento de imágenes.

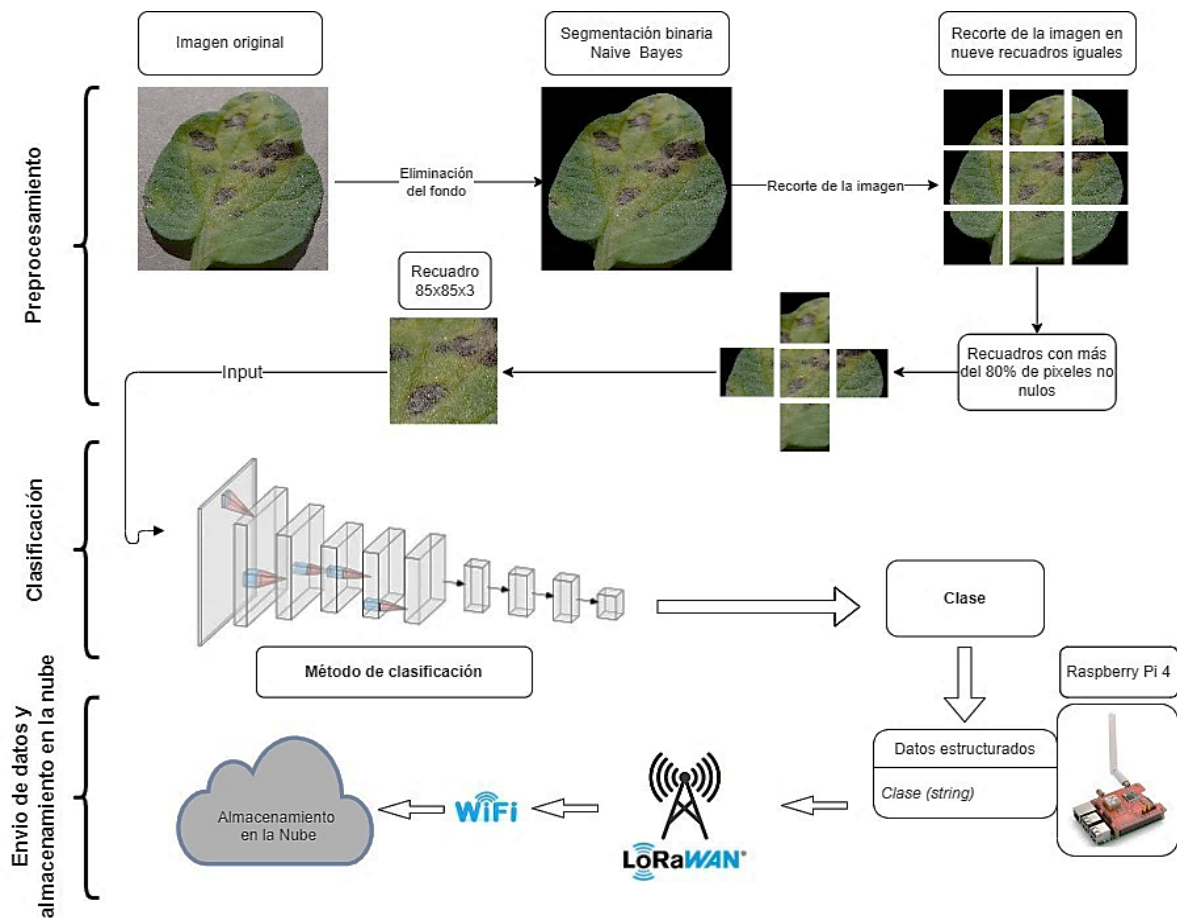


Figura 3. Esquema general del proceso de clasificación de imágenes en la plataforma IoT
Fuente: elaboración propia.




Figura 4. Módulo para la captura de imágenes
Fuente: elaboración propia.

1 Conclusiones y trabajo futuro

Con este trabajo y las oportunidades de servicios de acceso libre, como las plataformas de IoT con

disponibilidad de servidores y de integraciones de software gratuito, se puede afirmar que es posible integrar a pequeños agricultores con limitaciones de conectividad que deseen ser parte de la transformación digital por la que

atraviesa la actividad agropecuaria en todo el mundo. Las oportunidades de gestión que se encuentran al ser parte de esta transformación son muy diversas e impulsan a los agricultores tradicionales a cambiar sus métodos para ser más eficientes y competitivos.

La propuesta planteada en este trabajo constituye un primer paso en la implementación de una plataforma de agricultura inteligente para pequeños productores. Los resultados obtenidos muestran el éxito de la implementación, sin embargo, hay tareas que se pueden desarrollar para trabajos futuros:

1. Análisis de eficiencia de la vida útil de las baterías, dado que son baterías de litio y pueden tener unos ciclos de vida reducidos, por lo que se propone plantear protocolos de ahorro de energía.
2. Análisis de compatibilidad y facilidad de conectividad, puesto que se trabaja con dispositivos de distintas marcas y manufacturas, por lo que se puede ver bastante afectada la conectividad entre ellos.
3. Análisis de aspectos socioculturales y del entorno, como pueden ser barreras geográficas, culturales y socioeconómicas, las cuales pueden ser abordadas desde distintos contextos, en estudios posteriores.
4. Indicadores de beneficios para el agricultor. En estudios posteriores se debe medir el impacto del uso de estas tecnologías en la productividad de los cultivos y en la mejora de la calidad de vida de los campesinos.

Referencias

- [1] Apolo-Apolo, O.E., Martínez-Guanter, J., Egea, G., Raja, P., and Pérez-Ruiz, M., Deep learning techniques for estimation of the yield and size of citrus fruits using a UAV. *European Journal of Agronomy*, 115, art. 126030, 2020. DOI: <https://doi.org/10.1016/j.eja.2020.126030>
- [2] Campobello, G., and Segreto, A., A low complexity image compression algorithm for IoT multimedia applications, 2019, 27th European Signal Processing Conference (EUSIPCO), A Coruna, Spain, 2019, pp. 1-5. DOI: <https://doi.org/10.23919/EUSIPCO.2019.8902678>
- [3] Carlsson, A., Kuzminykh, I., Franksson, R., and Liljegren, Measuring a LoRa network: performance, possibilities and limitations. In: Galinina, O., Andreev, S., Balandin, S., and Koucheryavy, Y., (eds). *Internet of things, smart spaces, and next generation networks and systems. NEW2AN ruSMART 2018. Lecture Notes in Computer Science*, vol 11118. Springer, Cham. 2018. DOI: https://doi.org/10.1007/978-3-030-01168-0_11
- [4] Codeluppi, G., Cilfone, A., Davoli, L., and Ferrari, G., LoraFarM: a LoRaWAN-based smart farming modular IoT architecture. *Sensors (Switzerland)*, 20(7), art. 2028, 2020. DOI: <https://doi.org/10.3390/s20072028>
- [5] De Luna, R.G.R.G., Dadios, E.P.E.P., Bandala, A.A.A.A., and Vicerra, R.R.P.R.R.P., Tomato growth stage monitoring for smart farm using deep transfer learning with machine learning-based maturity grading. *Agrivita*, 42(1), pp. 24–36. 2020. DOI: <https://doi.org/10.17503/agrivita.v42i1.2499>
- [6] Elijah, O., Rahman, T.A., Orikumhi, I., Leow, C.Y., and Hindia, M.N., An overview of Internet of Things (IoT) and data analytics in agriculture: benefits and challenges. *IEEE Internet of Things Journal*, 5(5), pp. 3758–3773, 2018. DOI: <https://doi.org/10.1109/JIOT.2018.2844296>
- [7] Feng, W., Ju, W., Li, A., Bao, W., and Zhang, J., High-Efficiency progressive transmission and automatic recognition of wildlife monitoring images with WISNs. *IEEE Access*, 7, pp. 161412–161423, 2019. DOI: <https://doi.org/10.1109/ACCESS.2019.2951596>
- [8] Islam, N., Ray, B., and Pasandideh, F., IoT based smart farming: are the LPWAN technologies suitable for remote communication? *Proceedings - 2020 IEEE International Conference on Smart Internet of Things, SmartIoT 2020*, pp. 270–276, 2020. DOI: <https://doi.org/10.1109/SmartIoT49966.2020.00048>
- [9] Jankowski, M., Gündüz, D., and Mikolajczyk, K., Deep joint transmission-recognition for power-constrained IoT devices. *ArXiv*, pp. 1–10, 2020.
- [10] Ji, M., Yoon, J., Choo, J., Jang, M., and Smith, A., LoRa-based visual monitoring scheme for agriculture IoT. *SAS 2019 - 2019 IEEE Sensors Applications Symposium, Conference Proceedings*. 2019. DOI: <https://doi.org/10.1109/SAS.2019.8706100>
- [11] Kamilaris, A., Kartakoullis, A., and Prenafeta-Boldú, F.X., A review on the practice of big data analysis in agriculture. *Computers and Electronics in Agriculture* 143, pp. 23–37, 2017. DOI: <https://doi.org/10.1016/j.compag.2017.09.037>
- [12] Khanna, A., and Kaur, S., Evolution of Internet of Things (IoT) and its significant impact in the field of Precision Agriculture. *Computers and Electronics in Agriculture*, 157(December 2018), pp. 218–231, 2019. DOI: <https://doi.org/10.1016/j.compag.2018.12.039>
- [13] Koc-San, D., Selim, S., Aslan, N., and San, B.T., Automatic citrus tree extraction from UAV images and digital surface models using circular Hough transform. *Computers and Electronics in Agriculture*, 150(February), pp. 289–301, 2018. DOI: <https://doi.org/10.1016/j.compag.2018.05.001>
- [14] Lee, S.W., and Kim, H.Y., An energy-efficient low-memory image compression system for multimedia IoT products. *Eurasip Journal on Image and Video Processing*, 2018(87), 2018. DOI: <https://doi.org/10.1186/s13640-018-0333-3>
- [15] Liu, Z., Liu, T., Wen, W., Jiang, L., Xu, J., Wang, Y., and Quan, G., DeepN-JPEG: A deep neural network favorable JPEG-based image compression framework. *Proceedings - Design Automation Conference, Part F1377(3)*, pp. 1–6, 2018. DOI: <https://doi.org/10.1145/3195970.3196022>
- [16] Lu, Y., Industry 4.0: a survey on technologies, applications and open research issues. *Journal of Industrial Information Integration*, 6, pp. 1–10, 2017. DOI: <https://doi.org/10.1016/j.jii.2017.04.005>
- [17] Mekki, K., Bajic, E., Chaxel, F., and Meyer, F., Overview of cellular LPWAN Technologies for IoT deployment: Sigfox, LoRaWAN, and NB-IoT, in: 2018 IEEE International Conference on Pervasive Computing and Communications Workshops (PerCom Workshops), Athens, Greece, 2018, pp. 197-202. DOI: <https://doi.org/10.1109/PERCOMW.2018.8480255>
- [18] Pathan, T.U., and Chakole, S., Sensor based smart farming and plant diseases monitoring. *International Journal of Engineering and Advanced Technology*, 8(2), pp. 442–446, 2019.
- [19] Pham, X., and Stack, M., How data analytics is transforming agriculture. *Business Horizons*, 61(1), pp. 125–133, 2018. DOI: <https://doi.org/10.1016/j.bushor.2017.09.011>
- [20] Sa, I., Chen, Z., Popovic, M., Khanna, R., Liebisch, F., Nieto, J., and Siegwart, R., WeedNet: dense semantic weed classification using multispectral images and MAV for smart farming. *IEEE Robotics and Automation Letters*, 3(1), pp. 588–595, 2018. DOI: <https://doi.org/10.1109/LRA.2017.2774979>
- [21] Terence, S., and Purushothaman, G., Systematic review of Internet of Things in smart farming. *Transactions on Emerging Telecommunications Technologies*, 31(6), art. 3958, 2020. DOI: <https://doi.org/10.1002/ett.3958>
- [22] Tian, H., Wang, T., Liu, Y., Qiao, X., and Li, Y., Computer vision technology in agricultural automation —A review. *Information Processing in Agriculture*, 7(1), pp. 1–19, 2020. DOI: <https://doi.org/10.1016/j.inpa.2019.09.006>
- [23] Yalcin, H., Phenology recognition using deep learning: DeepPheno. In: 26th IEEE Signal Processing and Communications Applications Conference, SIU 2018, pp. 1–4. DOI: <https://doi.org/10.1109/SIU.2018.8404165>
- [24] Zhong, Y., Gao, J., Lei, Q., and Zhou, Y., A vision-based counting and recognition system for flying insects in intelligent agriculture. *Sensors (Switzerland)*, 18(5), art. 1489, 2018. DOI: <https://doi.org/10.3390/s18051489>