




TICAPPS en el territorio: cuatro casos de investigación y vinculación

Investigaciones y desarrollos en el marco del Programa de Tecnologías de la Información y la Comunicación (TIC) en Aplicaciones de Interés Social (TICAPPS), UNAJ, período 2017-2024



Compiladora
María Joselevich



OBRAS
COLECTIVAS
SOBRE RESULTADOS/
AVANCES DE
INVESTIGACIÓN

TICAPPS en el territorio: cuatro casos de investigación y vinculación

Investigaciones y desarrollos en el marco del Programa de Tecnologías de la Información y la Comunicación (TIC) en Aplicaciones de Interés Social (TICAPPS), UNAJ, periodo 2017-2024

TICAPPS en el territorio: cuatro casos de investigación y vinculación

Investigaciones y desarrollos en el marco del Programa de Tecnologías de la Información y la Comunicación (TIC) en Aplicaciones de Interés Social (TICAPPS), UNAJ, período 2017-2024

Compiladora

María Joselevich

Autores

Christian Botta

Matías Busum

Marcelo Cappelletti

Facundo Chazarreta

Jésica Guzmán

María Joselevich

Diego Miguel Montezanti

Martín Morales

Lucas Olivera

Lucía Osés

Jorge R. Osio

Martín Páez

Braian Pezet

Laureano Sabatier

Mauro Salina

Juan Eduardo Salvatore

Jorge Segovia



TICAPPS en el territorio : investigaciones y desarrollos en el marco del programa de tecnologías de la información y la comunicación TIC en aplicaciones de interés social : TICAPPS / María Joselevich ... [et al.] ; Compilación de María Joselevich. - 1a ed. - Florencio Varela : Universidad Nacional Arturo Jauretche, 2025.

Libro digital, PDF - (Obras colectivas sobre resultados / avances de investigación / Narodowski, Patricio; 9)

Archivo Digital: descarga y online
ISBN 978-631-91005-2-5

1. Tecnología de los Medios de Comunicación. 2. Tecnología de la Información.
3. Medio Ambiente. I. Joselevich, María II. Joselevich, María, comp.
CDD 004.5

Secretaría de
Investigación y
Vinculación Tecnológica

Dirección de
Gestión de la
Investigación

Universidad Nacional
ARTURO JAURETCHE

Rector: Dr. Arnaldo Medina

Vicerrector: Ing. Miguel Binstock

Secretaría de Investigación y Vinculación Tecnológica: Dr. Patricio Narodowski

Dirección de Gestión de la Investigación: Mg. Dolores Chiappe

1ª edición, abril de 2025

© 2025, UNAJ

Av. Calchaquí 6200 (CP1888)

Florencio Varela Buenos Aires, Argentina

Tel: +54 11 4275-6100

editorial@unaj.edu.ar

www.editorial.unaj.edu.ar

Este libro fue seleccionado, con referato externo, en la Convocatoria de Obras Colectivas 2023, realizada por la UNAJ.

Queda hecho el depósito que marca la Ley 11.723



Esta obra está bajo una Licencia Creative Commons Argentina.
Atribución-NoComercial-SinDerivadas 2.5 Argentina (CC BY-NC-ND 2.5 AR)
<https://creativecommons.org/licenses/by-nc-nd/2.5/ar/>

Agradecimientos	9
Capítulo 1. Introducción	11
Capítulo 2. Tecnologías de IoT para la solución de problemas en el medio productivo y el cuidado del medio ambiente	
Jorge R. Osio, Diego Miguel Montezanti, Mauro Salina, Juan Eduardo Salvatore, Matías Busum, Facundo Chazarreta y Martín Paez.....	19
Capítulo 3. Tecnologías de aprendizaje automático para la solución de problemas en el medio productivo y el cuidado del medio ambiente	
Jorge R. Osio, Diego Miguel Montezanti, Mauro Salina; Juan Eduardo Salvatore, Lucía Oses, Braian Pezet y Martín Paez.....	37
Capítulo 4. Optimización de sistemas basados en energía solar mediante algoritmos de aprendizaje automático	
Marcelo Cappelletti, Lucas Olivera, Christian Botta, Jéscica Guzmán y Martín Morales	63
Capítulo 5. El modelo TPACK en la UNAJ: la integración de objetos virtuales de aprendizaje en las prácticas de enseñanza y su relación con el desarrollo TPACK de los docentes	
María Joselevich, Laureano Sabatier y Jorge Segovia.....	103
Capítulo 6. Conclusiones generales	149
Autores	153

Agradecimientos

Los autores de este material agradecemos a la Universidad Nacional Arturo Jauretche, al Consejo Nacional de Investigaciones Científicas y Técnicas y al Ministerio de Ciencia y Tecnología e Innovación de la Nación Argentina por el financiamiento que otorgaron para que los proyectos aquí mencionados pudieran ser implementados.

Agradecemos al Instituto de Ingeniería y Agronomía, a su Director Ing. Miguel Binstock por brindar el lugar de trabajo y las facilidades para la realización de estas investigaciones. Al personal docente y nodocente, especialmente Esteban Pucheta, por acompañarnos en la tarea diaria y su dedicación al trabajo, siempre con la mejor disposición. Agradecemos también a Marcos Ravaschino por la lectura atenta de este material.

Parte de este trabajo fue realizado en el marco de becas para estudiantes otorgadas por la Universidad Nacional Arturo Jauretche, el Consejo Interuniversitario Nacional y por la Comisión de Investigaciones Científicas de la Provincia de Buenos Aires.

Las actividades referidas en este libro no hubieran sido posibles sin el enriquecedor trabajo en equipo con el que funciona el Programa TICAPPS. Queremos resaltar especialmente los aportes

de las y los estudiantes que, tanto como parte de las líneas de investigación como desde las aulas, son parte fundamental del trabajo de este grupo. No sólo alimentan y estimulan el trabajo aportando nuevas ideas, sino que, además, contribuyen a que las propuestas tengan una fuerte articulación con el territorio de la UNAJ, acompañando la idea de alta integración territorial de esta universidad.

Capítulo 1

Introducción

El presente libro expone algunos resultados obtenidos por las investigaciones y desarrollos del Programa “Tecnologías de la Información y la Comunicación (TIC) en Aplicaciones de Interés Social” (TICAPPS, Res CS 64/17).

El Programa TICAPPS surgió en el año 2017 en el Instituto de Ingeniería y Agronomía (IlyA) de la Universidad Nacional Arturo Jauretche (UNAJ) como respuesta a las necesidades de desarrollo e investigación en el área de las TIC que presentaban los sectores del área de influencia de la universidad. El cual es dirigido por el Dr. Ing. Martín Morales.

La UNAJ es una institución con alta integración territorial. Localizada en el partido de Florencio Varela, sus propuestas buscan tener un impacto directo en los partidos del Consorcio de Municipios del Conurbano Sur, conformado por Almirante Brown, Berazategui, Avellaneda, Lanús, Lomas de Zamora y Quilmes. El análisis de las necesidades de las entidades y actores relevantes de la región ha mostrado necesidades en áreas como TIC, energía, salud, producción, medio ambiente y educación. Este programa busca abordar estas vacancias investigando desde una universidad pública nacional y vinculando el conocimiento

generado con la sociedad en la cual se encuentra arraigado. Sus objetivos son:

- Fortalecer las actividades de investigación y vinculación en el área de las TIC que contribuyan a remediar las problemáticas existentes dentro del territorio de influencia de la UNAJ en las áreas de medio ambiente, salud, medio productivo y educación.

- Establecer acuerdos concretos con los sectores productivos y de servicios, organizaciones sociales, municipios, cooperativas, universidades, y otros actores para articular y vincular a éstos los resultados de las investigaciones desarrolladas, las cuales presentan un alto impacto tecnológico y social.

- Promover la creación de conocimiento teórico y aplicado, el desarrollo de instrumentos que puedan aplicarse en materias de grado y posgrado, y la formación en investigación en temas relacionados con las líneas de investigación incluidas en el Programa o nuevas líneas derivadas de éstas.

Para cumplir con los objetivos anteriores, el TICAPPS propone un abordaje integral que se despliega a través de proyectos de investigación y vinculación en los cuales se estudian, desarrollan y utilizan sistemas informáticos basados en tecnologías de información y comunicación novedosas. Para llevar a cabo estas tareas, el programa cuenta con un equipo interdisciplinario que incluye docentes, graduados recientes y estudiantes avanzados de la UNAJ.

Las Tecnologías de la Información y la Comunicación (TIC) abarcan todas aquellas herramientas que permitan el tratamiento, transmisión y difusión de información, siendo estas generalmente electrónicas. Su estudio abarca temas como los algoritmos y lenguajes de programación, ingeniería de software, base de datos, calidad de software, arquitectura de computadoras, comunicaciones, sistemas operativos, redes de datos, seguridad de la información, robótica, Internet de las Cosas (IoT), visión artificial, inteligencia artificial, ciencia de datos, cómputo de altas prestaciones (HPC), *cloud computing*, realidad virtual, realidad aumentada y visualización 3D, simulación computacional, herramientas y modelos de enseñanza con TIC y bioinformática.

El avance en la integración de circuitos electrónicos, la mejora en los medios de transmisión y la reducción de costos tecnológicos han generado un impacto transversal en todas las áreas de la sociedad, por lo que, en la actualidad, las TIC son esenciales para el desarrollo de cualquier país o región.

Este libro, que compila algunos de los hallazgos y resultados del programa TICAPPS, busca mostrar experiencias en las cuales la investigación y la aplicación de las TIC pueden ofrecer soluciones innovadoras y efectivas a problemáticas relevantes en diversas áreas, fortaleciendo así el desarrollo socio-productivo del territorio de influencia de la UNAJ y las necesidades de la misma universidad.

El presente material está compuesto por seis capítulos. En este primer capítulo, presentamos el programa TICAPPS que da

marco a las investigaciones que se relatan en los cuatro capítulos siguientes.

Los capítulos 2 y 3 corresponden al trabajo de la línea de investigación de “Determinación de eficiencia en sistemas con arquitecturas multiprocesador en aplicaciones de transmisión y procesamiento de datos”. En ellos se describen los avances realizados en la utilización de Internet de las Cosas (IoT) como herramienta fundamental para proveer soluciones a problemáticas de interés social, como lo son el cuidado del medio ambiente y la innovación en el sector productivo, focalizando la investigación en las técnicas de visión por computadora y aprendizaje automático. Entre los temas de investigación que se desarrollarán se incluye el diseño e implementación de técnicas de visión por computadora con el objeto de agregar funcionalidades a un robot móvil, de manera de proveer autonomía a su desplazamiento. También se incluye la implementación de técnicas de visión por computadora para la clasificación de residuos reciclables mediante algoritmos de aprendizaje automático. Esta línea de estudio ha sido financiada por los proyectos de investigación UNAJ INVESTIGA 2020 (80020200300027UJ y 80020200100030UJ) bajo la Dirección del Mg. Ing. Jorge R. Osio y del Dr. Ing. Martín Morales, respectivamente, y por el proyecto de vinculación UNAJ VINCULA 2022 bajo la Dirección del Dr. Ing. Marcelo Cappelletti y la Codirección del Mg. Ing. Jorge R. Osio. El Capítulo 2 muestra la utilización de las tecnologías de Internet de las Cosas (IoT) para el desarrollo de una red de sensores en aplicaciones de domótica y el monitoreo y seguimiento de

cultivos. El Capítulo 3 relata el diseño e implementación de técnicas de visión por computadora que, mediante algoritmos de aprendizaje automático, facilitan la autonomía de desplazamiento de un robot móvil para la clasificación de residuos reciclables.

El Capítulo 4 presenta resultados obtenidos por la línea de investigación de Sistemas Tecnológicos Basados en Herramientas y Aplicaciones Informáticas para la Eficiencia Energética y la Salud Ósea. El aumento del consumo energético promueve el uso de nuevas tecnologías basadas en recursos renovables para generar electricidad en detrimento de los combustibles fósiles (carbón, petróleo, gas natural), lo cual a su vez contribuye a reducir las emisiones de dióxido de carbono a la atmósfera y proteger nuestro medio ambiente. La energía solar fotovoltaica constituye una de las opciones más prometedoras, dado que se presenta como una fuente limpia y renovable de electricidad con bajo impacto ambiental, disponibilidad en el sitio de consumo y sostenibilidad. Sin embargo, existen ciertas dificultades para integrar esta energía a la red eléctrica. Las razones son principalmente la variabilidad e impredecibilidad de la luz solar, y la importante inversión inicial requerida para la instalación de plantas de generación basadas en conversión fotovoltaica.

En este capítulo se describen los avances realizados en la utilización de herramientas de aprendizaje automático (*machine learning*) aplicados en el área de las energías renovables, principalmente de la energía solar, a fin de encontrar y proponer nuevas soluciones o mejoras a las principales problemáticas actuales existentes en dicha área. Entre los temas de investigación

que se desarrollarán, se incluye la optimización de la respuesta de sistemas fotovoltaicos (SFV) bajo diversas condiciones de cielo. Esta línea de investigación apunta a reducir los costos asociados a la producción energética para que estos emprendimientos resulten competitivos y puedan ser aplicables a nivel local y regional, tanto para actividades domésticas como industriales. Esta línea de estudio ha sido financiada por los proyectos de investigación UNAJ INVESTIGA 2020 (80020200300012UJ y 80020200100030UJ) bajo la Dirección del Dr. Ing. Marcelo Cappelletti y del Dr. Ing. Martín Morales, respectivamente, y por el proyecto de investigación PIP CONICET 2021-2023 (112-202001-01460CO) bajo la Dirección del Dr. Ing. Marcelo Cappelletti.

El Programa TICAPPS busca atender necesidades de sectores diversos relacionados con la universidad. En relación a las necesidades propias de la UNAJ, una de las que requiere atención es la adquisición de las y los docentes de habilidades para trabajar en sus clases con recursos de las nuevas tecnologías.

El Capítulo 5 de este libro presenta una investigación realizada por el equipo de la línea de Herramientas TIC para el Diseño de Estrategias Didácticas. Allí se describen los avances en la construcción de información acerca de la percepción que tienen los docentes de UNAJ respecto a sus propios conocimientos en el campo de la enseñanza auxiliada con TIC. Como toda práctica de enseñanza, el uso e integración de recursos educativos en el nivel superior está mediado por el imaginario y las concepciones pedagógicas de los docentes. Cuando se trata de recursos

educativos que incluyen desarrollos de las tecnologías de la información y la comunicación, su incorporación requiere de las y los docentes ciertos saberes que consideramos enmarcados en el modelo TPACK. A partir de la información recabada en esta investigación, se analizan las áreas de vacancia para sugerir ofertas de formación y acompañamiento que fortalezcan sus habilidades TPACK. Esta línea de estudio ha sido financiada por el proyecto de investigación UNAJ INVESTIGA 2020 (80020200300028UJ) bajo la Dirección de la Dra. María Joselevich.

El Capítulo 6 propone un cierre de este trabajo y se refiere a los desafíos que el programa tiene por delante.

Capítulo 2

Tecnologías de IoT para la solución de problemas en el medio productivo y el cuidado del medio ambiente

Jorge R. Osio, Diego Miguel Montezanti, Mauro Salina, Juan Eduardo Salvatore, Mañas Busum, Facundo Chazarreta y Martín Paez

2.1 Introducción

En este capítulo se describen los avances realizados en la utilización de Internet de las Cosas (IoT) como herramienta fundamental para proveer soluciones a problemáticas de interés social, como lo es el cuidado del medio ambiente y la innovación en el sector productivo. En relación a las aplicaciones de IoT para el cuidado del medioambiente, se continúa con el desarrollo de una red de sensores en aplicaciones de domótica y el monitoreo y seguimiento de cultivos.

2.1.1. Servidor de Internet de las Cosas y aplicaciones en monitoreo de cultivo y domótica

El concepto de Internet de las Cosas ha adquirido gran relevancia en los últimos años, debido a la posibilidad que ofrece de

interconectar objetos entre sí y la conectividad a internet que provee a las redes de objetos.

En la última década se han incrementado notablemente las tecnologías que permiten la gestión eficiente de sensores y dispositivos de HW (hardware) en aplicaciones IoT, especialmente en aplicaciones industriales lo que se conoce como industria 4.0. En particular es interesante proveer un diseño personalizado para poder ofrecer soluciones a medidas en función de la necesidad del usuario y permite explorar e innovar en nuevas características sobre la plataforma.

El diseño de la plataforma de aplicaciones con servicios de Internet de las Cosas se basa en tres aspectos principales:

- La selección de tecnologías y protocolos estandarizados para asegurar compatibilidad con la mayoría de las tecnologías y sistemas de IoT actuales.
- La evaluación de las prestaciones de cada tecnología en base a la taxonomía de las diferentes arquitecturas.
- Otro de los aspectos evaluados es el uso de herramientas de software libre que provean la posibilidad de agregar nuevas características.

Para el diseño de la plataforma se seleccionaron herramientas para cubrir los siguientes aspectos de un sistema IoT:

- Implementación de administración de dispositivos.

- Implementación de almacenamiento.
- Protocolo de aplicación.

La arquitectura implementada es una Arquitectura Orientada a Servicios (SOA), de tipo publicador suscriptor. Esta selección se fundamenta en que los dispositivos finales típicamente son de clases C1-C3 (con frecuencia de procesamiento entre 16 y 980Mhz y tamaño de datos de 8 a 32 bits), lo que significa que no tienen gran poder de cómputo para llevar adelante aplicaciones complejas de forma eficiente. Esta característica lleva a una separación de la funcionalidad (servicios) y la coordinación de estos (orquestración).

Respecto al protocolo de aplicación adoptado para la capa de aplicación, se utilizó el Message Queuing Telemetry Transport (MQTT) que es un protocolo ligero y simple para el estilo de arquitectura de publicación/suscripción con comunicación indirecta.

Actualmente, en el grupo se están investigando y desarrollando tecnologías de la industria 4.0 orientadas al cuidado del medioambiente y problemática de interés social directamente ligadas al medio socio productivo (especialmente pequeños productores agrícolas e industriales de la zona de influencia). Todas estas líneas de investigación demandan la incorporación de las nuevas tecnologías para recabar grandes cantidades de datos en tiempo real. Además, se debe destacar que la plataforma se complementa con aplicaciones de HW previamente desarrolladas para cubrir las necesidades mencionadas (Mardegan, Osio, Salina

y Cappelletti, 2022) y (Lo, Fain, Osio, Cappelletti y Arórztegui, 2020).

Con el diseño de la plataforma se pretende poder gestionar los datos provenientes de diferentes dispositivos, de manera que puedan ser almacenados en una base de datos, pero también que puedan ser visualizados por el usuario final. Además, dicha plataforma permitirá realizar el control de dispositivos y de los datos desde que son enviados por el nodo, hasta que son procesados y almacenados en el servidor.

En la plataforma se implementó un bróker MQTT configurado específicamente con tópicos para la medición de parámetros de interés, (como por ejemplo temperatura y humedad), que se envían a través de dispositivos de hardware y son almacenados en una base de datos creada por el grupo de IoT e Inteligencia Artificial del Instituto, cumpliendo de esta manera con los requerimientos necesarios para la posterior gestión de la información. Finalmente, estos datos pueden ser accedidos por los clientes (suscriptores) y a su vez ser visualizados en una dashboard (pizarra) personalizada.

Para las pruebas de funcionamiento y la determinación de la respuesta del sistema en tiempo real se realizó una aplicación de automatización en invernaderos, apuntando a mejorar la eficiencia a la hora de utilizar recursos como agua y energía al independizarlos del factor humano (Mardegan, Osio, Salina y Cappelletti, 2022) y (Busum Fradera, Chazarreta, Osio, Salvatore, 2022). Para lograr que este sistema funcione de manera eficaz, primero se debe obtener una lectura de valores ambientales

(humedad de suelo, humedad y temperatura), a través de dispositivos electrónicos, los cuales enviarán los mismos mediante “WiFi” hacia el servidor.

Aunque los sistemas IoT son más que conocidos, su implementación y desarrollo no ha sido completamente explotada en determinados sectores. IoT aplicado a cultivos bajo cubierta es un área en la que la evolución tecnológica nunca ha sido una prioridad, entre los factores que han postergado la investigación en esta área se tiene la falta de capacitación y falta de soporte e interacción con los productores para determinar cuáles son las principales problemáticas que se deben resolver. Para este tipo de ambientes se dispone de un conjunto de protocolos de comunicación e interfaces como GSM/GPRS, Wifi, bluetooth y RF LoRA (a 433Mhz) que requieren un sistema de procesamiento basado en Arquitecturas de Sistemas Embebidos como las desarrolladas en (Mardegan, Osio, Salina y Cappelletti, 2022). Las investigaciones realizadas mediante IoT se podrían aplicar en el monitoreo de cultivos, obtención de información relevante para la toma de decisiones, automatizar el riego, protección de heladas, fertilización e iluminación artificial, entre otras (Mardegan, Osio, Salina y Cappelletti, 2022) y (Busum Fradera, Chazarreta, Osio, Salvatore, 2022).

Estos sistemas son de gran interés, principalmente por ser de uso común en los sectores agrícolas, donde se aplicaron las investigaciones realizadas conjuntamente con el proyecto “Estudio de sistemas inteligentes para optimizar el aprovechamiento de la radiación solar en la actividad

agroindustrial del territorio de la UNAJ” dirigido por el Dr. Marcelo Cappeletti.

2.2 Metodología implementada

2.2.1. Servidor de Internet de las Cosas y aplicaciones en monitoreo de cultivo y domótica

En relación con la línea de investigación sobre tecnologías de IoT, se realizó el diseño e implementación de una plataforma para proveer servicios de IoT, que permite gestionar peticiones de clientes, y almacenar datos recibidos de dispositivos y sensores de manera eficiente. De esta manera, se contribuye con la obtención de datos que quedarán disponibles para el posterior procesamiento ya sea para la toma de decisiones o la predicción mediante técnicas de aprendizaje automático. Por otro lado, se incluyeron herramientas para ayudar a la gestión eficiente durante la interacción con el sistema, tales como un servidor web open source con una aplicación de dashboard llamada grafana, el bróker EMQX y una base de datos (necesarios para vincular los dispositivos de hardware con el servidor IoT). Finalmente, se incluyeron dispositivos reales que permitieron evaluar las prestaciones de la plataforma, proporcionando muy buenos resultados durante las pruebas de funcionamiento.

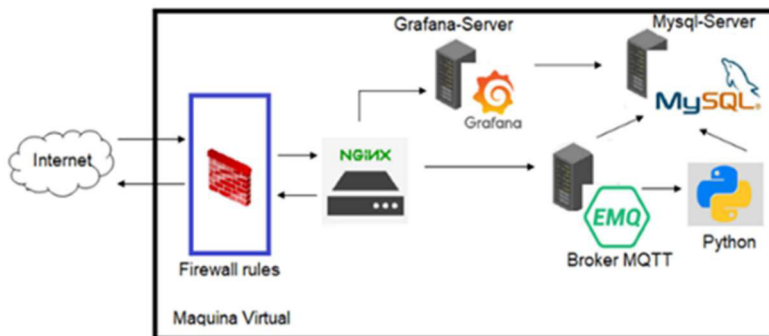


Figura 1. Diagrama en bloques del servidor. Extraída de (Busum Fradera, Chazarreta, Osio, Salvatore, 2022).

Por otro lado, se está desarrollando una red inalámbrica de sensores IoT para el monitoreo de parámetros en cultivos basada en el protocolo LoRa.

En cuanto a las soluciones tecnológicas para el monitoreo y control de cultivos, se requiere de la disponibilidad de datos tanto del clima como del suelo, la iluminación y el agua. El desarrollo del sistema informático consiste en un algoritmo de software con soporte para diferentes aplicaciones que, en base a la información proporcionada por un conjunto de sensores, emite mensajes de alertas a los usuarios y es capaz de automatizar acciones. En primera instancia el sistema consiste en una red local LoRa que se conecta al servidor mediante un gateway implementado con un kit esp32. Para que la propuesta sea aplicable en cualquier lugar, en una segunda etapa se propone la utilización de una interfaz GPRS/3G/4G que permite transmitir información mediante las antenas celulares proveyendo un largo alcance en las comunicaciones. El diseño del sistema local a utilizar en huertas a

campo abierto y bajo cubierta, está formado por nodos (basados en tecnologías de microcontroladores ATmega328), al cual se conectan los sensores y el dispositivo de comunicación LoRa. El nodo central (gateway) del sistema se compone del bloque procesamiento formado por el kit Heltec (basado en un esp32 con conectividad wifi y LoRa) y los sensores (de humedad, humedad del suelo, temperatura, iluminación, movimiento y barrera infrarroja), actuadores (para el encendido de la luminaria y riego). El sistema es escalable y puede contener nodos simples que contienen solo sensores y se comunican con el Gateway mediante el protocolo LoRa de largo alcance.

La aplicación en domótica tiene como objetivo determinar la eficiencia energética del sistema independizando el consumo del factor humano, para esto simplemente se deben automatizar acciones como por ejemplo el simple encendido y apagado de la luz, así como de otros dispositivos (Busum Fradera, Chazarreta, Osio, 2021). En el sistema de eficiencia energética se detecta presencia en la sala mediante la barrera infrarroja y el sensor de movimiento. El uso de la barrera se hace indispensable, debido a que el sensor de movimiento puede detectar fuentes de calor que no necesariamente son personas, es por eso que para asegurar presencia se detecta el ingreso de individuos mediante la barrera. Como no hay forma de diferenciar si la persona egresa o ingresa, para mantener la luz encendida se debe detectar movimiento en un lapso máximo de 3 minutos. La información relevante se almacena en el servidor mediante la interfaz wifi. Para esto se debe enviar una secuencia de comandos al módulo wifi que posibilite transmitir el paquete de datos de los sensores al servidor. Si se

produce algún error en la secuencia se deberá iniciar la misma desde el principio. El reenvío de comandos se puede realizar tres veces, si a la tercera vez no hay respuesta del módulo wifi, se produce un TIMEOUT. Actualmente, el sistema se encuentra relevando datos de intensidad de luz, presencia y tiempo de encendido de la iluminación de forma automática.

2.3 Resultados

2.3.1. Servidor de Internet de las Cosas y aplicaciones en monitoreo de cultivo y domótica

Luego de instaladas y configuradas las herramientas del servidor IoT se comenzó con las pruebas de funcionamiento. Para la comunicación entre dispositivos y broker se utilizó el protocolo MQTT, (protocolo estándar para IoT), para esto el servidor dispone de soporte completo para MQTT V3.1, V3.2.2 y v5.0 integrando en los mismos los mensajes y niveles de servicios QoS 0, QoS 1 y QoS 2. Para el acceso a los datos los usuarios ingresan al sistema mediante autenticación, la cual se realiza mediante el plugin `emqx_auth_mysql` de EMQX. Este plugin permite gestionar la autenticación de los usuarios que requieren conectarse al broker por medio de una base de datos SQL. Dentro de la base de datos, se almacena el par usuario-contraseña. Para incrementar la seguridad, la contraseña se almacena utilizando la función de hash SHA256 y un salt arbitrario. Una vez realizado este proceso de autenticación el usuario podrá ingresar al dashboard como se observa en la Figura 2.

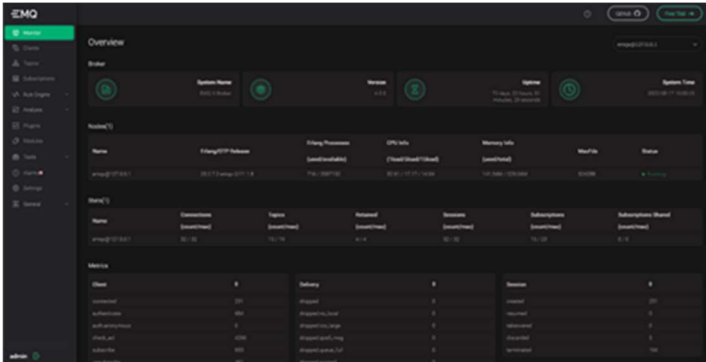


Figura 2. Dashboard proporcionada por el broker emqx. Extraída de (Busum Fradera, Chazarreta, Osio, Salvatore, 2022).

Para conectarse al bróker EMQX, los dispositivos también deben autenticarse mediante usuario y contraseña, evitando que se conecten a la plataforma dispositivos indeseados o malintencionados. De la misma manera, se utilizó el mencionado para limitar la publicación y suscripción de los usuarios a los tópicos. Esto se implementa mediante una tabla ACL (lista de control de acceso), que se almacena en la base de datos MySQL, el bróker define cuáles clientes MQTT pueden publicar y/o suscribirse en cada tópico. El usuario puede acceder a una dashboard previamente configurada para visualizar los datos sensados, la ubicación del sistema y realizar el control de riego (ver Figura 3).

Entre los resultados obtenidos, se debe destacar que las prestaciones logradas son excelentes, teniendo en cuenta que por lo general se miden fenómenos físicos con variaciones lentas. En ese sentido se realizaron pruebas de funcionamiento a intervalos de tiempo de entre 500ms y 1s (Busum Fradera, Chazarreta, Osio,

Salvatore, 2022) y (Chazarreta, et al, 2022). Obteniendo muy buenos resultados sin pérdida de datos. Para medir la latencia del sistema se utilizó un módulo RTC (reloj de tiempo real), en donde se fijó una marca de tiempo, comparando esto con lo indicado por la temporización del servidor, en donde los valores obtenidos siempre fueron inferiores a 1 segundo. Respecto a la latencia, tomando la marca de tiempo del dispositivo esp32 (gateway) al momento de enviar el dato y la marca de tiempo del servidor al momento de recibir el dato, en el peor caso la latencia medida fue del orden de un segundo, lo que es más que aceptable teniendo en cuenta la característica mencionada de los parámetros que se relevan habitualmente. En comparación con algunas plataformas comerciales como por ejemplo thingspeak, se pudo constatar que, para similares exigencias, se verificaron situaciones como pérdida de datos, o recepción de información con latencias de 15 segundos o más, por lo que hay muchas plataformas disponibles, pero muy pocas proveen buena calidad de servicio.

En el sistema de monitoreo y control del cultivo, se implementó un sistema de telemetría mediante la interfaz wifi con el kit basado en esp32, que permite supervisar el estado del cultivo (humedad del suelo, iluminación, humedad ambiente y temperatura), emitir alarmas por sobre temperatura e incendio y accionar el riego automático, lo que fue probado con un prototipo y se obtuvieron excelentes resultados. Durante las pruebas se manifestaron varios inconvenientes provenientes del alcance de la señal wifi, que limita la ubicación del gateway a cierta distancia máxima del router (15 metros) (Mardegan, Osio, Salina y Cappelletti, 2022). Estos inconvenientes impiden que se consiga una buena tasa de

transferencia con la plataforma de acceso remoto (dashboard) más la posible pérdida de datos. Entre las soluciones se propone el reenvío de los datos cuando no se recibe confirmación y el agregado de una antena externa como reemplazo de la antena integrada al circuito. Además, se implementó una dashboard en el servidor IoT que permite visualizar los parámetros en tiempo real (ver Figura 3).

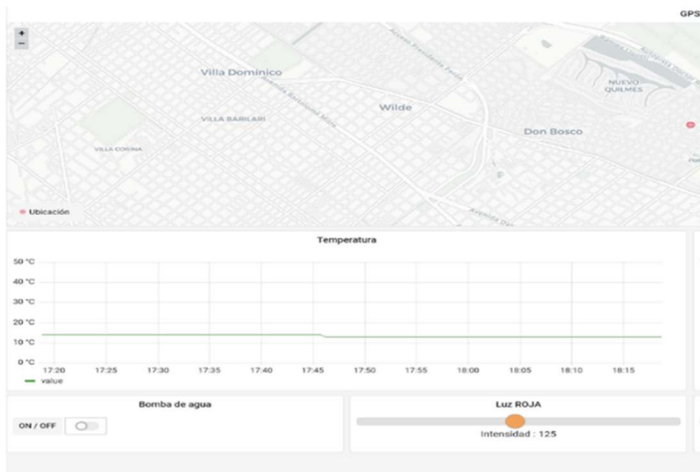


Figura 3. Implementaciones de dashboard para el sistema de monitoreo y control de cultivos. Extraída de (Busum Fradera, Chazarreta, Osio, Salvatore, 2022).

En la implementación del sistema domótico, para determinar la eficiencia fue necesario medir el consumo en la misma sala durante un periodo de tiempo considerable con y sin el uso del sistema, para luego determinar el ahorro real de energía. Los tiempos de medición fueron de 30 días con el objeto de medir el consumo en la misma época del año. En la Figura 4 se muestra el

consumo medido durante 24 hs con y sin sistema de control, esta información es relevante para determinar el ahorro de energía que se puede lograr con el sistema propuesto en distintos tipos de salas/habitaciones (Busum Fradera, Chazarreta, Osio, 2021).

Durante el desarrollo del proyecto surgieron varios problemas con la utilización del módulo Wifi ESP8266. En un principio, para lograr la comunicación entre el módulo Wifi y el microcontrolador de Arduino, se utilizó la librería “SoftwareSerial” que usa software para replicar la funcionalidad del RX, TX en otros pines digitales diferentes a los del módulo UART (que fue usado para test). Esta librería resultó ser bastante inestable debido a la gran cantidad de errores detectados durante la comunicación con el módulo wifi. Debido a esto se decidió optar por la migración del sistema a un NODEMCU, que permite programar directamente el microcontrolador (esp8266) que integra el módulo wifi, sin la necesidad de utilizar un microcontrolador de arduino mediante comandos AT. De esta forma, el NODEMCU envía la información medida por los sensores al servidor para mantener un registro y en caso de error reintentar enviarlos un número determinado de veces. Durante las pruebas también se detectó que el sensor de movimiento emite falsas señales de detección si se encuentra muy próximo a la lámpara, ya que detecta como un movimiento el cambio de temperatura emitido por la luz. Por lo que se debió ubicar el sensor contrapuesto con la ubicación de la lámpara.

Las pruebas realizadas permitieron verificar el correcto funcionamiento del sistema, encendiendo la iluminación sólo

cuando la luz natural es insuficiente y si se detecta presencia en la sala mediante la barrera infrarroja y el sensor de movimiento. La última etapa consistió en medir el consumo en un ambiente determinado durante un periodo de tiempo considerable, con y sin el uso del sistema desarrollado. Esto permitió obtener información relevante del funcionamiento del sistema para corroborar que el mismo contribuye al ahorro del consumo energético (Busum Fradera, Chazarreta, Osio, 2021).




Figura 4. Medición de consumo (línea roja sin control - línea azul con sistema de control). Extraída de (Lo, Fain, Osio, Cappeletti y Arórztegui, 2020).

La cantidad de energía eléctrica ahorrada se puede calcular al realizar la resta entre ambas curvas de consumo a lo largo de los días (ver Figura 5).

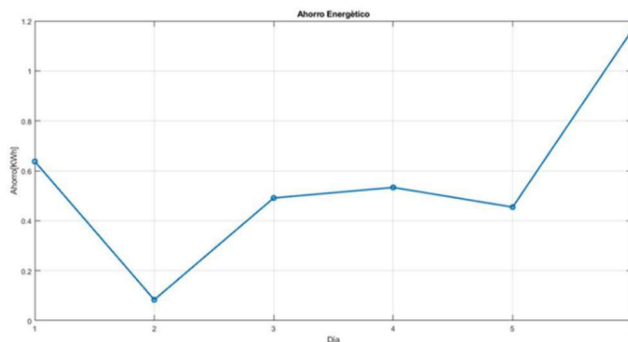


Figura 5. Gráfico de ahorro en el consumo. Extraída de (Lo, Fain, Osio, Cappeletti y Arórztegui, 2020).

2.4 Conclusiones

2.4.1. Servidor IoT y sus aplicaciones:

En primer lugar, se cumplió el objetivo principal de implementar una plataforma IoT completa cubriendo aspectos de seguridad como el acceso por autenticación. Además, se logró un funcionamiento eficiente y confiable, debido a que tiene una velocidad de respuesta mucho mayor que otras plataformas y hay muy poca variación de la latencia entre muestras.

Las plataformas de IoT resultan muy útiles cuando se cuenta con una base de datos que permita el almacenamiento de la información a lo largo del tiempo, ya que de esta manera se pueden obtener importantes cantidades de información para el entrenamiento de algún modelo de aprendizaje automático que permita optimizar el uso de los recursos y posibilite la toma de decisiones en pos de lograr una alta eficiencia minimizando las pérdidas.

Respecto a los beneficios proporcionados durante la utilización de la plataforma en el control de invernaderos. Se independizó el riego y el consumo del factor humano, se pudieron detectar picos de temperatura de forma automática generando alertas que permiten al usuario tomar acciones para mejorar la circulación de aire y evitar temperaturas extremas en ambientes cerrados. En definitiva, se posibilitó el acceso a la información de forma remota y la automatización del sistema, proporcionando las ventajas que proveen las tecnologías de la Industria 4.0.

Como tareas a futuro, se pretende incorporar en el servidor IoT una amplia variedad de aplicaciones relacionadas con la calidad del agua en arroyos, la calidad del aire en ambientes cerrados y medir el desempeño del sistema con la utilización de un mayor porcentaje de sus recursos.

2.4.2. Eficiencia energética

Los sensores utilizados entregan señales digitales y analógicas en un determinado rango, éstos fueron acondicionados para ser utilizados por el sistema y almacenados en la base de datos. Con respecto al sensor de iluminación, éste debe ser calibrado en función del lugar donde se instale el sistema, se determinó que es importante realizar una calibración en el lugar de la instalación.

Con el uso de las librerías que provee el microcontrolador, se facilitó el desarrollo del firmware del sistema de control, logrando muy buenos resultados en las pruebas de funcionamiento.

La utilización de una base de datos disponible en la nube, provee al sistema de respaldo e integridad de la información recabada, que podrá usarse para conocer los hábitos del usuario, para tener una referencia del histórico del consumo y conocer el ahorro de energía que se logró a lo largo del tiempo.

Finalmente, en función de las pruebas de funcionamiento realizadas, se concluye que se logró un sistema robusto capaz de determinar presencia en la sala independientemente del sensor de movimiento. Esto evita que se active el sistema innecesariamente y permite optimizar el consumo en función de los hábitos del usuario.

El sistema implementado realiza un gran aporte en cuanto a la eficiencia energética, ya que el modelo reduce el consumo energético notablemente gracias a sus mecanismos de control.

Bibliografía

Busum Fradera, M., Chazarreta, F., & Osio, J. (2021). Sistema domótico para el control de parámetros ambientales y de seguridad. En Congreso Nacional de Ingeniería Informática/Sistemas de Información (Nº 9). Mendoza, Argentina.

Busum Fradera, M., Chazarreta, F., Osio, J., & Salvatore, J. (2022). Diseño de una plataforma para servicios IoT con aplicaciones en el sector productivo. En Congreso Argentino de Sistemas Embebidos.

Chazarreta, F., Busum Fradera, M., Osio, J. R., Salvatore, J. E., & Morales, D. M. (2022). Diseño de una plataforma de servicios IoT para aplicaciones de interés social. En Congreso Nacional de Ingeniería Informática/Sistemas de Información (N° 10). Concepción del Uruguay, Entre Ríos, Argentina.

Lo, E., Fain, F., Osio, J. R., Cappelletti, M., & Aróztegui, W. (2020). Aprendizaje automático aplicado a variables ambientales. En Congreso de Ingeniería Informática y Sistemas de Información (N° 12, pp. 95-102).

Mardegan, M., Osio, J., & Cappelletti, M. (2022). Sistema embebido escalable para el monitoreo de parámetros en invernaderos mediante IoT. En Congreso Argentino de Sistemas Embebidos. La Plata, Buenos Aires, Argentina.

Capítulo 3

Tecnologías de aprendizaje automático para la solución de problemas en el medio productivo y el cuidado del medio ambiente

Jorge R. Osio, Diego Miguel Montezanti, Mauro Salina; Juan Eduardo Salvatore, Lucía Oses, Braian Pezet y Martín Paez

En este capítulo se describen los avances realizados en la implementación de técnicas de visión por computadora y aprendizaje automático en aplicaciones de interés social. Entre los temas de investigación que se desarrollarán, se incluye el diseño e implementación de técnicas de visión por computadora con el objeto de agregar funcionalidades a un robot móvil, de manera de proveer autonomía a su desplazamiento. En esta línea, también se implementaron técnicas de visión por computadora para la clasificación de residuos reciclables mediante algoritmos de aprendizaje automático.

3.1 Introducción

3.1.1. Visión por computadora aplicada a robótica y detección de objetos reciclables

3.1.1.1. Robótica:

Cuando se habla de un robot lo primero que se piensa es en un objeto metálico con extremidades que imitan la forma física humana. Muchas veces emitiendo sonidos denominados *tech* y con un movimiento algo tosco que intenta imitar al ser humano. Indudablemente hoy en día esa visión de robot cada vez va quedando más atrás cuando se observan todo tipo de robots que son capaces de moverse a grandes velocidades, abrir puertas, realizar saltos y movimientos de parkour, aspirar todas las habitaciones de del hogar y hasta de explorar la superficie de distintos planetas del sistema solar, entre otras.

Una de las aplicaciones que más investigación demanda es la implementación de un sistema de guiado de un robot móvil mediante visión artificial. En este caso, el robot móvil consta de una Raspberry Pi 3, un ordenador de placa simple (*SBC* por sus siglas en inglés), conectada a una cámara web y una estructura vehicular, (cuatro ruedas con sus respectivos motores), que posibilita su movimiento hacia cualquier dirección (izquierda, derecha, reversa y hacia delante) (Osio, et al, 2021) y (Osio, et al, 2022). A través de la cámara es que entra en juego la visión por computadora y se convierte en los ojos del robot dándole toda la información correspondiente para que se pueda guiar en un entorno determinado, persiguiendo un objetivo móvil. Esto lo logra mediante el procesamiento de imágenes, el cual le permite

detectar y seguir la posición de determinados objetos en las imágenes. Posteriormente, se envían los datos al SBC para que dirija las ruedas en pos de conseguir un objetivo predeterminado. También es posible que se encuentre con un obstáculo en su camino que le impida tomar una decisión en base a su capacidad, ya sea directamente un objeto que le obstruya el trayecto o la falta de señalización de la carretera que lo guía. En los casos que no le sea posible planificar la próxima acción a realizar, se utilizará el sistema de monitoreo y control remoto del robot para indicarle las acciones a llevar a cabo con el fin de que pueda volver a funcionar de forma autónoma (Doti, 2021).

3.1.1.2. Detección de Objetos:

La protección del medio ambiente y la importancia del reciclaje son temas de gran relevancia en la sociedad actual. El reciclaje es fundamental para reutilizar elementos u objetos desechados, los cuales, de otra manera, terminarían como desechos y contribuirían al aumento de la formación de basura y al daño ambiental permanente. En nuestro país, la producción de basura es alarmante, con una tonelada de basura producida cada dos segundos y una gran parte de ella termina en rellenos sanitarios que están al borde del colapso. La basura doméstica es uno de los principales desechos y está compuesta principalmente por papel, plásticos, vidrio, metales y pilas. Es esencial realizar la separación en origen para minimizar la generación de residuos y la contaminación. Sin embargo, en nuestro país, solo el 24% de la población se esfuerza por separar los residuos, lo que se debe en gran parte al esfuerzo que se requiere para clasificarlos y separarlos. Por esta razón, en este trabajo se propone desarrollar

un sistema de visión por computadora que permita detectar y clasificar objetos reciclables para minimizar la cantidad de residuos que se generan diariamente.

Para llevar a cabo la propuesta, se utilizó la Inteligencia Artificial (IA), que ha tenido un avance significativo en la última década en áreas como la detección de objetos y la clasificación de imágenes. Esto se debe, en gran parte, a las nuevas técnicas de Aprendizaje Automático (Machine Learning) y Aprendizaje Profundo (Deep Learning), así como a las innovaciones en el manejo de Big Data y el aumento en la capacidad de cómputo mediante el uso de diferentes tecnologías, como la computación en la nube o el uso de GPU.

El Machine Learning es un subcampo de la IA que utiliza diferentes algoritmos para recolectar datos y realizar un aprendizaje para luego hacer una predicción o sugerencia sobre algo. El desafío reside en construir un modelado automático de una función matemática en la que se parte de una entrada y se obtiene una salida. Por otro lado, el Deep Learning es un subcampo del Machine Learning que utiliza redes neuronales artificiales compuestas por varios niveles jerárquicos para realizar procesos de aprendizaje automático. Cada nivel aprende patrones cada vez más complejos, generando información más sofisticada.

El reconocimiento de objetos en forma artificial brinda una aproximación a la capacidad del sentido de la vista humana, de manera tal que un sistema es capaz de conocer por sí solo su entorno e interactuar con él, según la información recolectada, tal y como lo hace el cerebro humano. El Deep Learning estructura

los algoritmos en capas, para crear una red neuronal artificial, que puede aprender y tomar decisiones por sí misma. Estas redes neuronales identifican patrones y clasifican diferentes tipos de información. Las diferentes capas de las redes neuronales sirven como filtro, yendo desde los elementos más generales a los más sutiles, aumentando la probabilidad de detectar y generar un resultado correcto. Por tanto, cuando un sistema de Deep Learning tiene que reconocer un objeto, lo compara con aquellos que ya conoce.

Los sistemas de Visión Artificial en los procesos tecnológicos y dentro de estos los procesos de producción pueden realizar tareas de manera más efectivas y adecuadas que la visión humana, tal es el caso de los siguientes aspectos:

- Dentro del espectro electromagnético la visión humana solamente capta un pequeño rango de frecuencias y amplitudes: “rango de luz visible”, los sistemas de visión artificial pueden captar todo el espectro, es decir, además del rango de luz visible puede captar ondas de radio, de televisión, microondas, infrarrojos, ultravioletas, rayos X, rayos gamma y rayos cósmicos.

- La velocidad de respuesta de la visión humana es de 0,06 segundos, mientras que en las cámaras de estado sólido es de 0,00001 segundos y este tiempo se va reduciendo según se mejora la electrónica de estos sistemas.

- A diferencia de los sistemas artificiales, la visión humana se cansa, se ve afectada por las emociones y es poco consistente por la fatiga y las distracciones, en cambio la visión artificial mantiene

su nivel de rendimiento constante a lo largo de su vida útil. Es ideal en trabajos repetitivos y monótonos.

- El ser humano puede discernir entre 10 o 20 niveles de gris, los sistemas de visión artificial tienen una definición muy superior.

- La visión humana tiene muy poca precisión y para obtener información cuantitativa necesita apoyarse en instrumentos de medida, los sistemas de visión artificial tienen gran precisión en la medición, dependiendo solamente de la resolución espacial de los componentes del sistema.

- Los sistemas de visión artificial pueden trabajar en entornos muy peligrosos, con residuos radiactivos, químicos, biológicos, ruido, polución, temperaturas muy altas y bajas.

El uso de la visión artificial crece rápidamente gracias al descubrimiento de las ventajas que tiene para las industrias, entre ellas:

- Procesa de una manera más simple y rápida: permite a los clientes y a las industrias chequear los productos. Además, les da acceso a sus productos.

- Fiabilidad: las computadoras y las cámaras no tienen el factor humano del cansancio. La eficiencia suele ser la misma, no depende de factores externos como pueden ser bajas por enfermedad o errores humanos por agotamiento.

- **Precisión:** esta tecnología asegura una mejor precisión en el producto final.
- **Una amplia gama de usos:** se puede ver el mismo sistema informático en varios campos y actividades diferentes (fábricas con seguimiento de almacenes y envío de suministros, y en la industria médica a través de imágenes escaneadas, entre otras múltiples opciones).
- **La reducción de los costes:** el tiempo y la tasa de error se reducen en el proceso.

Mediante técnicas de aprendizaje profundo se desarrolló una aplicación de software encargada de realizar la búsqueda de objetos en imágenes a partir de una clasificación de las mismas en tiempo real, mediante la cual se detecta la presencia de determinados objetos en dicha imagen (objetos reciclables y objetos defectuosos) (Salina, et al, 2022) y (Pezet, Osés, Salina, Osio y Cappelletti, 2023). El desarrollo se enfoca específicamente en el uso de redes neuronales convolucionales, las cuales han demostrado ser las más eficientes en el área del procesamiento de imágenes. Específicamente, el software permite realizar la tarea de detección de objetos reciclables en imágenes y video (Salina, et al, 2022) y (Pezet, Osés, Salina, Osio y Cappelletti, 2023).

3.2 Metodología implementada

3.2.1. Visión por computadora aplicada a robótica y detección de objetos reciclables.

3.2.1.1. Robótica:

Se ha desarrollado un robot móvil que funciona a batería (power bank) y cuyo sistema de control se basa en una minicomputadora Raspberry PI con cámara integrada y un driver de control de motores (ver Figura 6). En ella se implementó un software en lenguaje Python que, mediante técnicas de procesamiento de imágenes, aplicadas a las imágenes obtenidas de la cámara, detecta las líneas que delimitan los laterales de un carril de circulación y obtiene el área ROI en tiempo real posibilitando que el robot se mantenga en el centro del carril a medida que avanza. Para esto desde la Raspberry Pi se actúa sobre los servos que mueven las ruedas, corrigiendo la desviación del centro del carril en todo momento. De esta manera se provee autonomía a un robot móvil en un entorno determinado. Adicionalmente, se implementó el control a distancia de este, para casos en donde el algoritmo no funciona (por ejemplo, cuando el carril no dispone de las líneas de referencia).




Figura 6. Diagrama en bloques para el control del robot. Extraída de (Doti, 2021).

3.2.1.2. Detección de objetos:

Respecto a las técnicas de IA, se han desarrollado diferentes modelos de aprendizaje automático aplicados al procesamiento de imágenes para la detección y clasificación de objetos reciclables (con aplicación en la separación automática de residuos), y objetos defectuosos (con aplicación en la calidad de la producción industrial). En todos estos casos, se utilizaron redes neuronales convolucionales, en las cuales las primeras capas detectan características básicas de las imágenes, las siguientes capas buscan combinar los patrones de detección de esas características para conseguir formas más simples y además se puede sumar conocimiento a partir de otros patrones como la posición o la iluminación. Finalmente, en las últimas capas se puede hacer coincidir la imagen con todos los patrones descubiertos, para conseguir una predicción final considerando la suma de todos

ellos. Además, se realizaron diferentes ajustes, pruebas y modificaciones para obtener la arquitectura de red optimizada con la que se lograron hasta el momento los mejores resultados con mínimos errores. Para esto se realizaron entrenamientos variando la cantidad de épocas, la función de activación, la tasa de aprendizaje, el número de filtros (Kernels) de las capas convolucionales y el tamaño de la ventana (pool size) de las capas de Max-Pooling, entre otros. Los datos de entrada para llevar a cabo el entrenamiento y testeo de los modelos son grandes cantidades de imágenes de objetos reciclables, defectuosos, no reciclables de acuerdo con la aplicación correspondiente.

Para evaluar y comparar el desempeño de los diferentes modelos de clasificación analizados se utilizó una matriz de confusión, la cual es una herramienta sumamente útil que permite visualizar la calidad de los modelos a partir de un conteo de los aciertos y errores de cada una de las clases en la clasificación. Luego se utilizaron diferentes métricas tales como exactitud, precisión, sensibilidad o la raíz cuadrática del error cuadrático medio, entre otros.

Todos los modelos bajo análisis fueron implementados utilizando como lenguaje de programación Python, apoyándose en el Framework de backend Tensor Flow y la librería de alto nivel Keras.

3.3 Resultados

3.3.1. Visión por computadora aplicada a robótica y detección de objetos reciclables.

3.3.1.1. Robótica

Luego de implementar los algoritmos de procesamiento de imágenes del proyecto usando más de 1500 líneas de código escritas en Python y teniendo ensamblado el robot de la forma deseada para conseguir la versión final del prototipo, se realizaron las pruebas finales. Para ello se armó una pista en la que el robot pueda desenvolverse de forma autónoma detectando las líneas laterales mediante la cámara y obstáculos mediante el sensor de ultrasonido.

Para la realización de las pruebas se posicionó el robot al inicio de la pista y se ejecutó la aplicación de forma remota a través del VNC. Además, se ejecutaron los programas `videoStreamRaspberry.py` y `movementControllerRaspberry.py` para enviar el video en vivo a través el puerto 8000 y para controlar el robot mediante instrucciones por el puerto 5500, respectivamente. A su vez en la PC se ejecutó el archivo `pcClientProcessor.py` que se encarga de recibir el video en crudo, procesarlo y enviarle las instrucciones al robot (Doti, 2021).



Figura 7. Video en vivo procesado, con la información pertinente en pantalla. Extraída de (Doti, 2021).

Como se puede apreciar en la Figura 7 el robot es capaz de seguir las líneas de carril amarillas para guiarse en el circuito (emulando un carril). Se puede ver el área verde pintada que indica la superficie detectada del carril, como así también en la esquina superior izquierda de la pantalla los datos que se obtuvieron del procesamiento de las imágenes, los radios calculados en base a las líneas del carril y el desplazamiento del centro que tiene actualmente el robot (en la imagen se observa un desvío de 1 centímetro hacia la izquierda. Con esta información el robot intentará corregir la desviación maniobrando hacia el lado opuesto, este es el funcionamiento básico para guiar al robot en el circuito.

Luego de ser ejecutado en reiteradas oportunidades, para evaluar su comportamiento se apreció que aproximadamente en un 60% de las pruebas realizadas cuando debía atravesar las curvas más pronunciadas, el robot no lograba direccionarse a tiempo y se desviaba de la pista. Lo que provocaba que el mismo entre en un ciclo de direcciones erróneas, ya que al estar fuera de la pista se dejan de detectar las líneas laterales. Luego de estudiar en detalle este comportamiento, se determinó que el principal inconveniente se da mientras el robot está ejecutando una instrucción que interpretó pero no llega a reaccionar a tiempo para la próxima instrucción, en ese lapso de tiempo se desvía de la pista y pierde la referencia.

Las posibles soluciones al problema detectado son:

- Reducir la velocidad del robot cuando se detecta una desviación superior a un delta de desplazamiento para llegar a procesar las imágenes en tiempo y forma mientras se atraviesa la curva.
- Combinar el uso de detección de carriles mediante procesamiento de imágenes con el uso de un sensor seguidor de línea (esto requiere más procesamiento, pero evita que el robot se aleje de la línea de referencia).
- Como tercera opción, cuando la desviación supera cierto umbral, en lugar de aplicar un algoritmo de detección de líneas se recomienda aplicar el de detección de círculos o figuras elípticas (esta sería la mejor solución, debido a que permite que el robot se adapte más rápidamente a las características del camino).

3.3.1.2. Detección de objetos

Durante todo el proyecto se desarrollaron alrededor de 40 modelos de redes neuronales convolucionales. Los primeros 25 modelos se entrenaron desde cero, mientras que los últimos 15 modelos utilizaron transfer learning con redes pre-entrenadas.

El entrenamiento de los modelos duró aproximadamente dos meses de horas máquina, con un tiempo promedio de entrenamiento de 12 horas para los modelos más simples y 48 horas para los modelos más complejos, resultando en un promedio general de 30 horas por modelo propuesto, utilizando el hardware mencionado previamente.

Durante el desarrollo de los primeros modelos, se identificó el overfitting (sobreajuste) como uno de los principales problemas, con buenos resultados para el set de entrenamiento y malos para el set de validación. Para mejorar estos resultados, se probaron pequeñas variaciones en los hiperparámetros de la red y la profundidad de los modelos. Además, se implementaron técnicas como data augmentation, early stopping y dropout para reducir el sobreajuste del modelo. Se utilizaron tres funciones "callbacks": "EarlyStopping", "ModelCheckpoint" y "ReduceLROnPlateau" para monitorear y modificar los hiperparámetros durante el entrenamiento.

Se aplicó la técnica de dropout que varió entre un 25% y un 40% de las neuronas de la capa completamente conectada del modelo, variando el porcentaje de neuronas al que se le aplicaba, lo que

permitió evitar que el modelo memorice un resultado (Salina, et al, 2022).

Estas modificaciones permitieron una mejora considerable en el porcentaje de acierto de los modelos propuestos, con valores superiores al 70% para el set de datos dividido en las seis clases antes mencionadas. Luego, se utilizaron modelos pre-entrenados, logrando resultados superiores al 80% para el mismo set de datos.

Se presentan a continuación las matrices de confusión obtenidas de los 2 mejores modelos implementados, en la Figura 8-A se presenta la matriz de confusión correspondiente al modelo binario con entrenamiento desde cero, y en la Figura 8-B la matriz del modelo con transfer learning. Así mismo, en la Figura 9-A se representa la matriz de confusión correspondiente al modelo multiclase con entrenamiento desde cero, y en la Figura 9-B la matriz del modelo con transfer learning (Salina, et al, 2022) y (Pezet, Osés, Salina, Osio y Cappelletti, 2023).

A) Matriz de confusión – Training from scratch B) Matriz de confusión – Transfer Learning

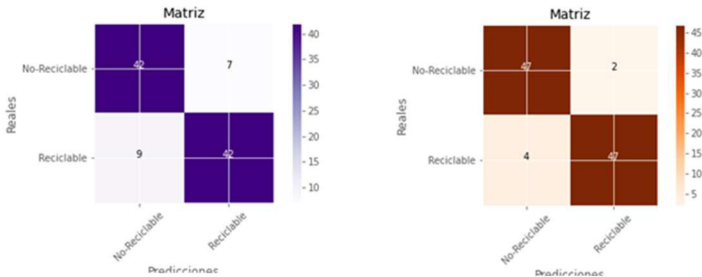


Figura 8. Matrices de confusión modelos binarios. Extraída de (Salina, et al, 2022).

A) Matriz de confusión – Training from scratch B) Matriz de confusión – Transfer Learning

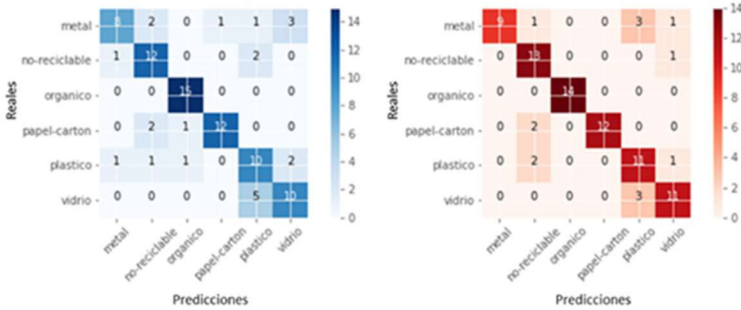


Figura 9. Matrices de confusión modelos multiclase. Extraída de (Salina, et al, 2022).

A continuación, se presentan las métricas obtenidas (tabla 1) para cada uno de los casos, siempre evaluando los modelos que presentaron un mejor resultado.

Para el modelo binario entrenado desde cero: F1 \approx 0,83 Accuracy \approx 0,84	Modelo binario con aprendizaje por transferencia: F1 \approx 0,93 Accuracy \approx 0,94
Modelo de 6 clases entrenado desde cero: Accuracy \approx 0,744 La métrica F1-score se calculó para cada una de las clases, se muestra a continuación como ejemplo el cálculo para la clase “Vidrio” y “Orgánico” F1-vidrio \approx 0,66 (clase desbalanceada respecto al resto) F1-organico \approx 0,937 (clase con buen balance)	Modelos de 6 clases con transfer learning: Accuracy \approx 0,833 La métrica F1-score se calculó para cada una de las clases, se muestra a continuación como ejemplo el cálculo para la clase “Metal” y “Orgánico” F1-metal \approx 0,78 (clase desbalanceada respecto al resto) F1-organico = 1 (clase con buen balance)

Tabla 1 - Métricas obtenidas para los mejores modelos.

En la siguiente figura (Figura 10) se presentan algunas métricas obtenidas durante el entrenamiento del modelo de 6 clases utilizando YOLO.




Figura 10. Métricas del entrenamiento durante las primeras 50 épocas. Extraída de (Salina, et al, 2022).

En las siguientes imágenes (Figura 11 y 12) se muestra el proceso de etiquetado de las imágenes utilizadas para armar el dataset con el que se implementaron los modelos de redes neuronales convolucionales (Pezet, Osés, Salina, Osio y Cappelletti, 2023).

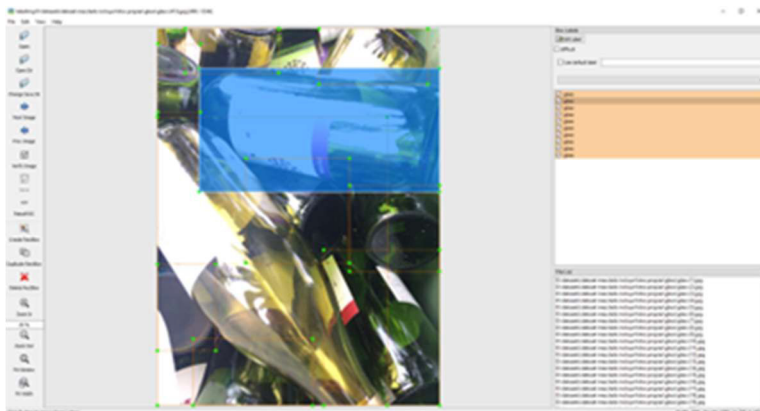


Figura 11. Etiquetado de imagen que contiene vidrio. Extraída de (Pezet, Osés, Salina, Osio y Cappelletti, 2023).



Figura 12. Etiquetado de imagen que contiene metal. Extraída de (Pezet, Osés, Salina, Osio y Cappelletti, 2023).

Estos modelos que obtuvieron los mejores resultados fueron probados en una minicomputadora Raspberry Pi 3B + con el módulo Pi-Cam en donde se implementó el prototipo de una aplicación para realizar la detección de objetos en tiempo real, en

las siguientes figuras se presentan a modo de ejemplo algunos capturas de los videos de prueba. (Figura 13 y 14).

Como tareas a futuro se pretende realizar pruebas intensivas del modelo en sistemas de cómputo de bajas prestaciones, para determinar su aplicabilidad en sistemas de bajo consumo.

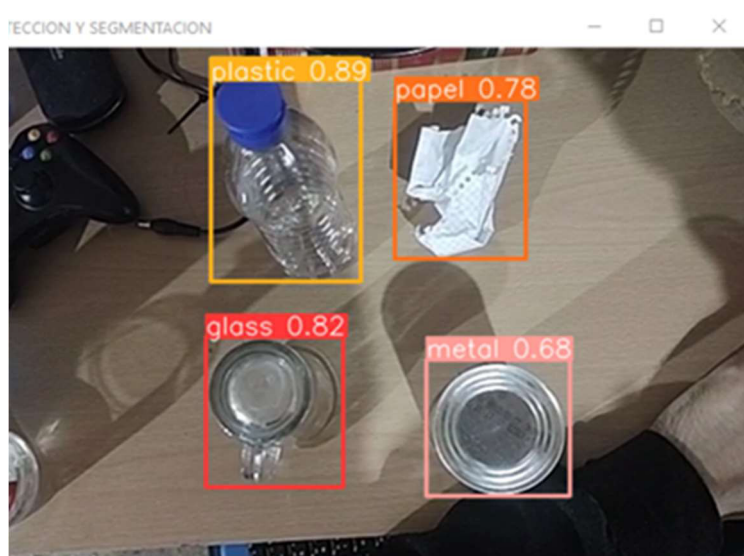


Figura 13. Captura ejemplo de clasificación 1. Extraída de (Pezet, Osés, Salina, Osio y Cappelletti, 2023).

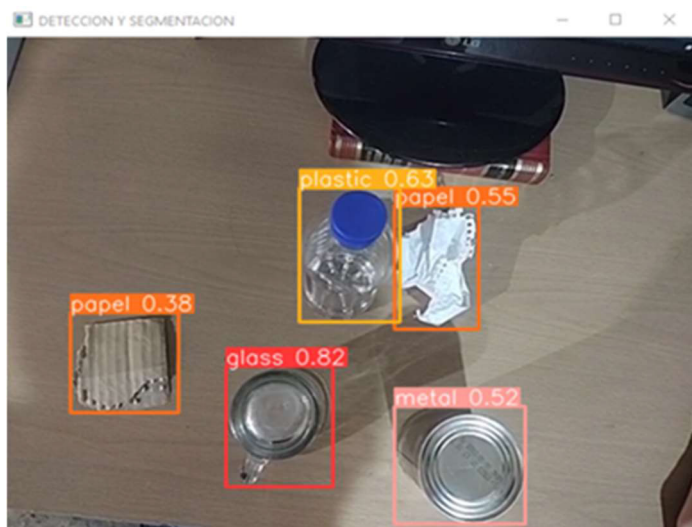


Figura 14. Captura ejemplo de clasificación 2. Extraída de (Pezet, Osés, Salina, Osio y Cappelletti, 2023).

El software desarrollado se encuentra actualmente en la etapa de prueba y validación de los primeros resultados obtenidos, los cuales pueden considerarse como muy satisfactorios. Principalmente ha sido satisfactoria la implementación en sistemas embebidos como en el caso de la raspberry Pi posibilitando la implementación de un sistema de bajo consumo y portable.

3.4 Conclusiones

3.4.1. *Visión por computadora aplicada a robótica y detección de objetos reciclables*

3.4.1.1. *Robótica*

Analizado el inconveniente en profundidad con el manejo del robot se analizaron distintas posibles soluciones. En un principio lo que se realizó fue un ajuste en las variables de guiado del mismo, es decir, se manipularon variables como:

- El ángulo de giro: si el robot no gira con tanta fuerza o amplitud se reduce la desviación promedio del mismo. Ya que de esta forma el dispositivo no realiza movimientos tan bruscos para corregir su dirección que lo suelen dejar desviado del camino, sino que los hace de una forma mucho más controlada.

- Máximo de desplazamiento: se determinó que como máximo el robot puede estar desplazado 10 centímetros hacia la derecha o la izquierda ya que el ancho del carril es pequeño en comparación al del dispositivo y, dentro de ese rango de 20 cm, se lo considera centrado dado que no puede caber entero en la carretera.

- Velocidad: se redujo la velocidad de las ruedas del motor prácticamente al mínimo para que el dispositivo pueda guiarse de una forma mucho más controlada y pausada, dándole el mayor tiempo posible para terminar de ejecutar la instrucción actual y darle lugar a la siguiente.

Al momento de volver a ejecutar el programa se pudieron notar algunas mejoras al atravesar las curvas de la pista, pero el robot

seguía teniendo inconvenientes para mantenerse dentro de la carretera, seguía desviándose del trayecto ideal de una forma no determinista y al azar. Es decir, no había un patrón predeterminado en el cual ciertas acciones siempre daban con el mismo resultado o trayecto de desviación.

Ante esta nueva situación se comenzó a investigar mejores formas de controlar y dirigir el robot para planificar las mejoras futuras del proyecto actual. Se pudo hallar una muy interesante basada en la aplicación de técnicas de control PID, que consiste en un mecanismo de retroalimentación de bucle de control que calcula la diferencia entre un punto de ajuste deseado y la salida real de un proceso, y usa ese resultado para aplicar una corrección al proceso.

Implementando y manipulando las variables del controlador PID se puede mejorar ampliamente el manejo del robot ya que es un mecanismo de control que constantemente se está retroalimentando con la salida actual y comparando con una referencia, lo que permite determinar el error y por ende el grado de ajuste necesario para lograr corregir su trayecto para mantenerse dentro del carril.

3.4.1.2. Detección de objetos

Durante el desarrollo e implementación del sistema de detección de objetos se estudiaron algunas técnicas de Machine Learning aplicadas a la clasificación de imágenes y particularmente se buscó colaborar con el cuidado del medio ambiente utilizando la inteligencia artificial aplicada a la clasificación de objetos reciclables.

De por sí la implementación del sistema se encuentra atada a la complejidad de los altos requerimientos de una red neuronal convolucional, pero de todas formas, se logró implementar una red funcional que supera los objetivos planteados durante las primeras etapas de diseño. Se ha elegido Deep Learning (DL) para llevar a cabo este trabajo debido a la alta capacidad que presenta para el análisis de imágenes. Sin embargo, al programar algoritmos de DL, específicamente redes neuronales convolucionales, se presentaron algunas dificultades. Es muy importante y complejo determinar los parámetros e hiperparámetros que mejor se adecuen al modelo propuesto impactando directamente en el resultado final. Este ajuste “fine tuning” muchas veces se considera un arte y no una ciencia para los que se inician en el campo del DL, debido a que se requiere cierta experiencia e intuición para encontrar los valores óptimos. En este caso, la investigación ha jugado un papel fundamental, además se debe tener en cuenta que los parámetros e hiperparámetros se deben especificar antes de iniciar el proceso de entrenamiento. Otro aspecto que se debe tener en cuenta es la profundidad y la cantidad de capas de los modelos propuestos.

Por otro lado, la correcta elección y confección del set de datos que se utilizará para entrenar los modelos es vital para llegar a los resultados deseados. La red debe conocer de igual manera todos los elementos o clases que se quieren predecir o clasificar, por lo que, las distintas clases deben estar correctamente balanceadas, contener ejemplos representativos y, además, contar con la mayor cantidad posible de datos para lograr buenas soluciones, aunque esto se traduce en un mayor tiempo de entrenamiento. A lo largo

del diseño del sistema se comprobó que las redes neuronales convolucionales presentan excelentes resultados en el campo de la “computer vision”, aunque uno de los inconvenientes encontrados ha sido el tiempo, ya que, a medida que los modelos se hacen más complejos crecen los tiempos de entrenamiento, llegando en el caso de este trabajo a un promedio de 36 horas para el entrenamiento de cada uno de los modelos propuestos.

Se debe tener en cuenta también que trabajar con CNN y grandes conjuntos de datos implica un alto costo computacional, por lo tanto, es muy importante contar con equipos que presenten altas prestaciones e incluso contar con GPUs (unidades de procesamiento gráfico).

En referencia a los resultados obtenidos para el conjunto de datos de prueba se puede decir que fueron satisfactorios, estos superaron las expectativas propuestas al inicio del trabajo. Además, todas las pruebas realizadas sirven como base para planificar mejoras a realizarse en el nuevo proyecto.

Bibliografía

Busum Fradera, M., Chazarreta, F., & Osio, J. (2021). Sistema domótico para el control de parámetros ambientales y de seguridad. En Congreso Nacional de Ingeniería Informática/Sistemas de Información (Nº 9). Mendoza, Argentina.

Busum Fradera, M., Chazarreta, F., Osio, J., & Salvatore, J. (2022). Diseño de una plataforma para servicios IoT con aplicaciones en el sector productivo. En Congreso Argentino de Sistemas Embebidos.

Chazarreta, F., Busum Fradera, M., Osio, J. R., Salvatore, J. E., & Morales, D. M. (2022). Diseño de una plataforma de servicios IoT para aplicaciones de interés social. En Congreso Nacional de Ingeniería Informática/Sistemas de Información (Nº 10). Concepción del Uruguay, Entre Ríos, Argentina.

Doti, S. A. (2021). Sistema de guiado de un robot móvil mediante visión artificial (Directores: Osio, J., & Salvatore, J.). Repositorio digital – biblioteca UNAJ. <https://biblio.unaj.edu.ar/cgi-bin/koha/opac-detail.pl?biblionumber=7498>

Lo, E., Fain, F., Osio, J. R., Cappelletti, M., & Aróztegui, W. (2020). Aprendizaje automático aplicado a variables ambientales. En Congreso de Ingeniería Informática y Sistemas de Información (Nº 12, pp. 95-102).

Mardegan, M., Osio, J., & Cappelletti, M. (2022). Sistema embebido escalable para el monitoreo de parámetros en invernaderos mediante IoT. En Congreso Argentino de Sistemas Embebidos. La Plata, Buenos Aires, Argentina.

Osio, J., Salvatore, J., Salina, M., Montezanti, D., Denon, N., Doti, S., Olivera, L., Botta, C., Busum Fradera, M., Chazarreta, F., Cappelletti, M., Encinas, D., & Morales, M. (2022). Tecnologías de Smart IoT y aprendizaje automático para la solución de

problemas en el medio productivo. En *Workshop de Investigadores en Ciencias de la Computación* (Nº 24). Mendoza, Argentina.

Osio, J., Salvatore, J., Salina, M., Montezanti, D., Denon, N., Doti, S., Olivera, L., Busum Fradera, M., Alonso, D., Cappelletti, M., Encinas, D., & Morales, M. (2021). Tecnologías de IoT y aprendizaje automático para la solución de problemas en el medio productivo y el cuidado del medioambiente. En *Workshop de Investigadores en Ciencias de la Computación* (Nº 23). La Rioja, Argentina.

Pezet, B., Osés, L., Salina, M. D., Osio, J. R., & Cappelletti, M. (2023). Aprendizaje automático aplicado al procesamiento de imágenes para la clasificación de objetos reciclables. En *JAIIO (Simposio Argentino de Inteligencia Artificial)* (Nº 52, vol. 9, Cap. 2, pp. 95-107).

Salina, M. D., Osio, J. R., Cappelletti, M., & Morales, M. (2021). Aprendizaje automático aplicado al procesamiento de imágenes para la clasificación de objetos reciclables. En *Congreso Argentino de Ciencias de la Computación* (Nº 27, pp. 31-40).

Capítulo 4

Optimización de sistemas basados en energía solar mediante algoritmos de aprendizaje automático

Marcelo Cappelletti, Lucas Olivera, Christian Botta, Jérica Guzmán y Martín Morales

El objetivo general al cual apuntó esta línea de investigación es la generación de conocimiento en el área de las energías renovables, principalmente energía solar, a fin de encontrar y proponer nuevas soluciones o mejoras a algunas de las problemáticas existentes en dicha área. El gran potencial de energía solar disponible se presenta como una fuente limpia y renovable de electricidad con bajo impacto ambiental, disponibilidad en el sitio de consumo y sostenibilidad, tendiente a sustituir las fuentes de energía no renovables (carbón, petróleo, gas natural) y reducir las emisiones de dióxido de carbono a la atmósfera, con el propósito de proteger nuestro medio ambiente. Adicionalmente, el proyecto fomentó la formación de recursos humanos quienes pudieron adquirir experiencia en esta área de estudio. Específicamente, la investigación se enfocó en el desarrollo de modelos basados en algoritmos de aprendizaje automático y de aprendizaje profundo para la clasificación del cielo y la estimación de la radiación solar

horaria bajo diferente cobertura de nubes, en pos de promover el uso de energías alternativas en el territorio de la UNAJ.

4.1 Introducción

La vasta disponibilidad de energía solar representa una oportunidad significativa para producir electricidad de manera limpia y renovable, con un impacto ambiental mínimo. Esta fuente de energía no solo está fácilmente accesible en el lugar de consumo, sino que también es sostenible a largo plazo. Su potencial radica en la capacidad de reemplazar gradualmente las fuentes de energía no renovables, como el carbón, el petróleo y el gas natural, lo que conlleva a una reducción sustancial de las emisiones de dióxido de carbono (CO₂) en la atmósfera, contribuyendo así a la preservación de nuestro medio ambiente.

Como consecuencia de lo anteriormente mencionado, existe en los últimos años un fuerte incentivo para el estudio de sistemas fotovoltaicos (SFV), los cuales convierten la radiación solar en energía eléctrica, con un reducido costo operativo y bajos niveles de contaminación (Taretto, 2015).

En la actualidad, los sistemas fotovoltaicos (SFV) emergen como una de las opciones más prometedoras para la generación de energía eléctrica de manera limpia y eficiente. Su creciente adopción se observa tanto en aplicaciones terrestres, abarcando desde entornos domésticos hasta industriales, como en misiones espaciales.

En particular, la investigación llevada a cabo se enfocó sobre dos líneas de estudio diferentes. Por un lado, la clasificación del cielo a partir del uso de imágenes mediante aprendizaje profundo. Y, por otro lado, la estimación de la radiación solar a través de aprendizaje automático.

Ambas líneas de investigación se encuentran en el marco del Programa TICAPPS (Tecnologías de la Información y la Comunicación (TIC) en Aplicaciones de Interés Social) del Instituto de Ingeniería y Agronomía de la UNAJ. El Programa TICAPPS tiene como objetivo general el de fortalecer la actividad de investigación y vinculación en el área de las TIC que contribuyan a remediar las problemáticas existentes dentro del territorio de la UNAJ en las áreas de medio ambiente, salud, medio productivo y educación.

4.2 Radiación solar

El conocimiento exacto de la radiación solar en un lugar y momento específicos es esencial para optimizar el diseño de sistemas como los paneles solares para la generación de electricidad y los colectores solares para calentar fluidos. Además, la radiación solar desempeña un papel crucial en la arquitectura y la agricultura. Por ejemplo, en esta última, afecta directamente el rendimiento y el desarrollo de los cultivos, y su escasez o exceso puede causar daños irreparables.

El desafío radica en la falta de datos experimentales de radiación solar en áreas de interés y en la fuerte variabilidad de esta radiación debido a factores geográficos y climáticos locales. La

cobertura de nubes también influye, causando fluctuaciones en la energía solar recibida. Esta variabilidad dificulta la predicción precisa de la producción de energía eléctrica por parte de los sistemas fotovoltaicos (SFV), lo que los hace menos predecibles que los combustibles fósiles.

Para abordar este problema, es crucial tener un conocimiento preciso de la radiación solar en tiempo real en ubicaciones específicas. Esto permitiría evaluar la producción potencial de energía eléctrica y desarrollar estrategias para maximizar la eficiencia de los SFV. Aunque los piranómetros y pirheliómetros pueden medir la radiación solar, son costosos y requieren calibración y mantenimiento regular. Por lo tanto, se suelen emplear modelos teóricos para estimar la radiación solar (Pandey y Katiyar, 2013).

Existen diversas técnicas y modelos para estimar la radiación solar, como la ecuación de Ångström–Prescott y sus modificaciones, modelos lineales, polinómicos, exponenciales y logarítmicos (Assi, Jama y Al-Shamisi, 2012), las técnicas geoestadísticas (Leal, Tiba y Piacentini, 2009), las técnicas estocásticas (Kaplanis y Kaplani, 2010) y las técnicas basadas en imágenes satelitales (Polo Martínez, 2010).

Sin embargo, muchos de estos modelos se centran en datos mensuales o diarios (Erdinc y Uzunoglu, 2012), mientras que para un diseño óptimo de SFV, es preferible tener datos horarios. Los sistemas diseñados con base de datos de radiación solar horaria suelen ser más confiables. Sin embargo, todos estos modelos

pueden verse afectados por la incertidumbre debido a la cobertura de nubes.

Dada esta complejidad, hay un interés creciente en utilizar técnicas de aprendizaje automático para estimar la radiación solar con mayor precisión y eficiencia computacional. Gracias al avance tecnológico, estas técnicas ofrecen una alternativa prometedora para mejorar la precisión de las estimaciones de radiación solar con un menor costo y mayor velocidad de convergencia (Pang, Niu y O'Neill, 2020; Çoban y Onar, 2020; Neelamegam y Amirtham, 2016; Khatib y Elmenreich, 2015).

4.3 Aprendizaje Automático y Aprendizaje Profundo

El Aprendizaje Automático (Machine Learning) es un subcampo de la Inteligencia Artificial y se caracteriza por la capacidad de los algoritmos de aprender de su entorno a través de conjuntos de datos durante la etapa de entrenamiento (Jordan y Mitchell, 2015; Harrington, 2012). Esta "capacidad de aprendizaje" implica la habilidad de identificar patrones en grandes volúmenes de datos y utilizarlos para tomar decisiones o predecir futuros comportamientos. Así, se posibilita la resolución de problemas de manera intuitiva y automatizada, sin necesidad de una programación previa del mecanismo de elección. En términos prácticos, esto se traduce en la formulación de una función matemática que toma una entrada y produce una salida, lo que plantea el desafío de construir un modelo automático de esta función.

Las técnicas de Aprendizaje Automático están logrando resultados que anteriormente no eran alcanzables mediante métodos tradicionales. No obstante, no existe una técnica única óptima para todos los problemas. Cada caso debe evaluarse individualmente y, en función de los requisitos del problema, se debe seleccionar la técnica más apropiada.

Este estudio se centrará en los algoritmos de aprendizaje supervisado, en los cuales los modelos se entrenan utilizando un conjunto de datos en el que la respuesta correcta es conocida.

Por su parte, el Aprendizaje Profundo (Deep Learning) se sitúa dentro del campo del Aprendizaje Automático y se esfuerza por emular el proceso de aprendizaje humano, utilizando redes neuronales con diversas características que se aplican a problemas complejos.

Inspirándose en la idea del Perceptrón Multicapa (MLP: Multi-Layer Perceptron), que consta de una capa de entrada para recibir estímulos externos, una capa de salida que proporciona la respuesta de la red, y una o más capas intermedias llamadas capas ocultas, en los últimos años han surgido nuevas arquitecturas de redes neuronales que comprenden varios niveles jerárquicos (Chollet, 2017; Goodfellow, Bengio y Courville, 2016). En el nivel inicial, la red aprende patrones simples, y esta información se transmite al siguiente nivel de la jerarquía. Este segundo nivel combina la información del primero con nuevos patrones aprendidos, generando información más compleja, que se pasa a un tercer nivel, y así sucesivamente.

Dentro del Aprendizaje Profundo, se destacan dos técnicas principales: las Redes Neuronales Profundas (DNN: Deep Neural Networks), que son arquitecturas neuronales densas, y las Redes Neuronales Convolucionales (CNN: Convolutional Neural Networks), que son arquitecturas convolucionales conectadas a una capa de salida densa.

Las DNN adoptan la estructura del MLP, con una capa oculta que puede contener dos o más capas, incluso alcanzando cientos o miles de capas ocultas. Esta técnica es extremadamente versátil, ya que puede procesar texto, imágenes pequeñas y datos numéricos. Sin embargo, cuanto mayor sea el número de capas ocultas, más aumenta la complejidad computacional, lo que requiere equipos de alto rendimiento.

Por otro lado, las CNN conectan las neuronas de una capa solo con un subgrupo de ellas, lo que reduce el número de neuronas y el coste computacional. Estas redes convolucionan características aprendidas con los datos de entrada y emplean capas convolucionales 2D, lo que las hace idóneas para procesar datos bidimensionales como imágenes. Son ampliamente utilizadas para tareas de clasificación de objetos, dividiendo y modelando la información en partes más pequeñas en las primeras capas, y combinando esta información en las capas más profundas para obtener predicciones más precisas.

En el ámbito del reconocimiento de imágenes, las CNN son fundamentales pero su entrenamiento puede ser costoso en términos de datos y tiempo. Por ello, se ha popularizado una técnica conocida como sintonía fina (Fine-tuning). Consiste en

tomar una red pre-entrenada y ajustar sus pesos mediante un entrenamiento adicional con nuevos datos específicos del problema que se desea resolver. Esto permite adaptar gradualmente las características previamente aprendidas a los nuevos datos, logrando mejoras significativas en el rendimiento. En los últimos años, han surgido diversas redes neuronales pre-entrenadas con conjuntos de imágenes de propósito general, lo que resulta invaluable para tareas como la clasificación de imágenes. Estas redes, como MobileNet v2, han sido entrenadas con conjuntos de datos extensos y diversificados, lo que permite capturar una amplia gama de características visuales. Utilizar una red pre-entrenada como MobileNet v2 no solo ahorra tiempo de entrenamiento y cómputo, sino que también facilita la búsqueda de hiperparámetros óptimos y aborda el desafío de la escasez de datos. MobileNet v2, en particular, destaca por su diseño compacto y su eficiencia en el reconocimiento de formas y objetos en imágenes, ofreciendo un rendimiento excepcional tanto en términos de precisión como de velocidad de procesamiento en tiempo real.

El Aprendizaje Profundo está ganando terreno en aplicaciones como el procesamiento de imágenes, reconocimiento de voz, categorización de videos, entre otros. Su capacidad para aprender y procesar datos complejos lo convierte en una herramienta poderosa en diversos campos de la inteligencia artificial.

4.4 Metodología de trabajo

La metodología empleada en este estudio se divide en cinco etapas fundamentales:

- **Recolección de datos:** Se inicia con la búsqueda y recopilación de datos esenciales para la investigación. Estos datos pueden ser obtenidos de diversas fuentes, como sensores, páginas web o bases de datos públicas.
- **Tratamiento y procesamiento de datos:** Una vez recopilados, los datos son sometidos a un proceso de tratamiento para maximizar su utilidad. Esto implica diversas tareas como la reducción de la dimensionalidad, la normalización, la detección y manejo de valores atípicos, así como análisis estadísticos y gráficos. Además, se aborda la gestión de datos faltantes.
- **Entrenamiento del modelo:** En esta fase, se elige un modelo de Aprendizaje Automático o Profundo y se le suministran los datos procesados. El modelo es entrenado para identificar patrones dentro del conjunto de datos, lo que le permite realizar predicciones sobre nuevos datos que se integren al sistema.
- **Evaluación del modelo:** Se lleva a cabo una fase de prueba exhaustiva para evaluar el desempeño del modelo seleccionado. Esto se realiza mediante métricas que proporcionan información sobre la precisión y la exactitud del modelo en relación con los datos de prueba.
- **Visualización e interpretación de resultados:** Finalmente, se procede a representar de manera clara e intuitiva los resultados obtenidos durante el estudio. Esto facilita una interpretación efectiva de los hallazgos, permitiendo extraer el conocimiento adquirido de manera comprensible y significativa.

En este trabajo se han desarrollado modelos tanto de clasificación como de regresión, utilizando técnicas de aprendizaje automático y aprendizaje profundo supervisado, los cuales se entrenan utilizando conjuntos de datos con respuestas conocidas.

En el caso de la clasificación del cielo a partir del uso de imágenes mediante aprendizaje profundo, se trabajó con imágenes del cielo para diseñar y analizar modelos que categorizan diferentes tipos de nubes. Estos modelos clasifican las imágenes en categorías como "cielo despejado", "cielo parcialmente nublado" o "cielo totalmente nublado". La recopilación de imágenes del cielo incluyó diferentes tipos de nubes, y el conjunto total de imágenes se dividió en tres conjuntos distintos: entrenamiento, validación y evaluación de modelos.

Para llevar a cabo la clasificación de nubes, se entrenaron diversos modelos de aprendizaje profundo, particularmente CNN. Los rendimientos de cada modelo se evaluaron y compararon utilizando parámetros estadísticos para seleccionar el que minimizara el error. La evaluación del desempeño de los modelos de clasificación se realizó utilizando una matriz de confusión, una herramienta valiosa que permite visualizar la calidad de los modelos mediante el recuento de aciertos y errores en la clasificación de cada clase.

Basándose en los resultados de la matriz de confusión, se utilizaron diversas métricas, como la exactitud, precisión, recall y F1_score, para evaluar el desempeño de los modelos de clasificación desarrollados. Estas métricas proporcionan una comprensión detallada del rendimiento de los modelos y ayudan

a identificar áreas de mejora. Las ecuaciones (1)-(4) son utilizadas para calcular estas métricas, respectivamente (Arisholm, Briand y Johannessen, 2010):

$$\text{Exactitud} = \frac{(TP + TN)}{(TP + TN + FP + FN)} \quad (1)$$

$$\text{Precisión} = \frac{TP}{(TP + FP)} \quad (2)$$

$$\text{Recall} = \frac{TP}{(TP + FN)} \quad (3)$$

$$F1_score = 2 \cdot \frac{\text{Precisión} \cdot \text{Recall}}{(\text{Precisión} + \text{Recall})} \quad (4)$$

TP, TN, FP y FN representan los casos de verdaderos positivos, verdaderos negativos, falsos positivos y falsos negativos, respectivamente.

La exactitud, como métrica, evalúa el porcentaje de predicciones correctas realizadas por el modelo. La precisión, por su parte, indica qué tan cerca está una predicción del valor verdadero. La métrica recall (sensibilidad) representa la proporción de verdaderos positivos respecto al total de casos positivos, lo que revela la capacidad del modelo para identificar correctamente los

casos positivos. En contraste, el F1_score combina las medidas de precisión y recall en un solo valor, proporcionando una evaluación conjunta del rendimiento del modelo en términos de precisión y exhaustividad.

Por otro lado, se empleó la función de pérdida (loss function) conocida como entropía cruzada categórica (categorical cross entropy), diseñada específicamente para medir la discrepancia entre dos distribuciones de probabilidad. Esta función se utiliza en tareas de clasificación multiclase, donde cada ejemplo puede pertenecer a una de varias categorías posibles, y el objetivo del modelo es asignar correctamente cada ejemplo a su categoría correspondiente. La entropía cruzada categórica es fundamental en la optimización del modelo para maximizar la precisión de las clasificaciones en este tipo de problemas.

Por su parte, para la estimación de la radiación solar a través de aprendizaje automático se han desarrollado y analizado modelos de regresión para estimar la radiación solar horaria, utilizando datos históricos de diversas magnitudes meteorológicas, como la temperatura media, humedad relativa, velocidad del viento, presión atmosférica y radiación solar global. Estos datos provienen de la estación meteorológica propia ubicada en el predio de la UNAJ (<https://www.unaj.edu.ar/estacion-meteorologica-para-el-desarrollo-territorial/>). Además de estos parámetros, se considera el índice de claridad, definido como la relación entre la radiación solar global medida en la superficie terrestre y la radiación solar extraterrestre. Este índice refleja la claridad de la atmósfera en un momento dado y es sensible a la

presencia de nubosidad y contaminación atmosférica. Es una herramienta ampliamente utilizada para caracterizar las diferentes condiciones del cielo en un lugar específico (Okogbue, Adedokun y Holmgren, 2009). La radiación solar extraterrestre sobre un plano horizontal cada media hora se puede calcular mediante ecuaciones que requieren como parámetros el número de día del año, la latitud, la longitud y la hora oficial (Grossi Gallegos, 2004).

En los modelos de regresión, se busca establecer la relación entre una variable dependiente y una o más variables explicativas o independientes. Estos modelos arrojan un valor numérico como resultado, dentro de un conjunto infinito de posibilidades. Una vez más, los datos se dividen en tres conjuntos distintos para entrenamiento, validación y evaluación de los modelos. Posteriormente, se entrenaron diversos modelos de estimación de la radiación solar horaria utilizando técnicas de aprendizaje automático, específicamente redes neuronales artificiales (RNA). Para evaluar y comparar el desempeño de cada modelo, se utilizaron métricas como el coeficiente de determinación (R^2), el error absoluto medio (MAE, Mean Absolute Error) y la raíz cuadrada del error cuadrático medio (RMSE, Root Mean Square Error) en base a las ecuaciones (5)-(7). Estas métricas proporcionan una evaluación cuantitativa del rendimiento de los modelos y permiten identificar cuál es el más adecuado para las necesidades específicas del problema.

$$R^2 = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2} \quad (5)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (6)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (7)$$

4.5 Resultados

4.5.1. Clasificación del cielo a partir del uso de imágenes mediante aprendizaje profundo

La radiación solar desempeña un papel crucial en diversas aplicaciones, como el diseño de sistemas basados en energía solar y el desarrollo de cultivos. Sin embargo, la disponibilidad de datos experimentales de radiación solar en ubicaciones específicas y el equipamiento para su medición no siempre están garantizados. Además, la presencia de nubes puede interferir y causar fluctuaciones en la cantidad de energía solar recibida. Por lo tanto, conocer la presencia de nubes en un campo solar es fundamental para optimizar el aprovechamiento de la radiación solar en sistemas energéticos que dependen de ella.

En esta línea de trabajo, se realizó un análisis para clasificar tres condiciones diferentes del cielo (despejado, parcialmente nublado y totalmente nublado) utilizando imágenes y redes neuronales basadas en aprendizaje profundo. Se evaluaron y compararon los desempeños de modelos basados en redes neuronales profundas (DNN), redes neuronales convolucionales (CNN) y redes neuronales convolucionales pre-entrenadas (MobileNet v2). El

modelo con el mejor rendimiento se podría integrar en un sistema de monitoreo de la cobertura de nubes en tiempo real, con el fin de optimizar el uso de la radiación solar en aplicaciones que dependen de la energía solar, como los sistemas fotovoltaicos.

Las imágenes utilizadas se obtuvieron de un repositorio público en la plataforma Kaggle (<https://www.kaggle.com>), que reúne a colaboradores de todo el mundo dedicados a la ciencia de datos. Específicamente, se seleccionó el conjunto de datos "Cloud Classification", del cual se extrajeron 1500 imágenes de diversas condiciones del cielo. Estas imágenes originalmente estaban clasificadas en seis grupos diferentes: "Cielo despejado", "Nubes estampadas", "Nubes oscuras gruesas", "Nubes blancas gruesas", "Nubes blancas delgadas" y "Nubes de velo", pero para este trabajo se agruparon en las categorías de "Cielo despejado", "Parcialmente nublado" y "Totalmente nublado". Se dispuso de 500 imágenes para cada categoría, asegurando así un conjunto de datos balanceado. Las imágenes obtenidas originalmente tenían un tamaño de 150 x 150 píxeles. Para asegurar la uniformidad del tamaño y facilitar el procesamiento con MobileNet, se aplicó un re-escalado a 255 x 255 píxeles. De esta manera, todas las imágenes se normalizaron a una medida estándar, lo que permitió un análisis más eficiente y preciso con el modelo de MobileNet. La Figura 1 muestra un conjunto de imágenes de ejemplo del dataset utilizado.




Figura 1. Imágenes utilizadas para el entrenamiento clasificadas en tres categorías. (Elaboración propia).

De las 1500 imágenes seleccionadas en total, se destinaron 1200 imágenes para el entrenamiento de los modelos, mientras que el resto se reservó para la validación. La distribución de estas imágenes garantizó una adecuada representación del conjunto de datos tanto en la fase de entrenamiento como en la de validación, lo que ayudó a obtener modelos robustos y generalizables.

La Figura 2 presenta de manera detallada las arquitecturas utilizadas en este estudio, ofreciendo una visión clara de las estructuras y componentes clave de los modelos empleados.

En cuanto a la arquitectura de las redes neuronales profundas (DNN), se seleccionó el optimizador ADAM (Adaptive Moment Estimation), el cual calcula una combinación lineal entre el gradiente y el incremento anterior, y se eligieron las funciones de

activación ReLU y Softmax. El optimizador es el algoritmo que permite ajustar los pesos de la red, mientras que la función de activación transfiere los valores entre neurona y neurona, permitiendo eliminar la linealidad de las redes neuronales. La función de activación ReLU se define como $\text{MAX}(0, X)$, lo que implica que cualquier valor de X menor a 0 se transforma en 0, mientras que los valores de X mayores a 0 se mantienen sin cambios. En esencia, esta función se comporta de manera lineal cuando X es mayor que 0. En contraste, la función de activación Softmax asigna probabilidades decimales a cada clase en un problema de múltiples clases, garantizando que la suma de estas probabilidades sea siempre igual a 1. Esta restricción adicional acelera la convergencia del entrenamiento en comparación con otros enfoques. Finalmente, la capa Flatten tiene como principal función la de transformar los datos de entrada, que pueden ser matrices de imágenes de dimensiones $N \times M$, en un vector unidimensional. Por ejemplo, si la entrada es una matriz de 6×6 , la capa Flatten produce un arreglo de salida de 12×1 elementos. De este modo, esta capa prepara los datos para ser procesados por capas posteriores de la red neuronal.

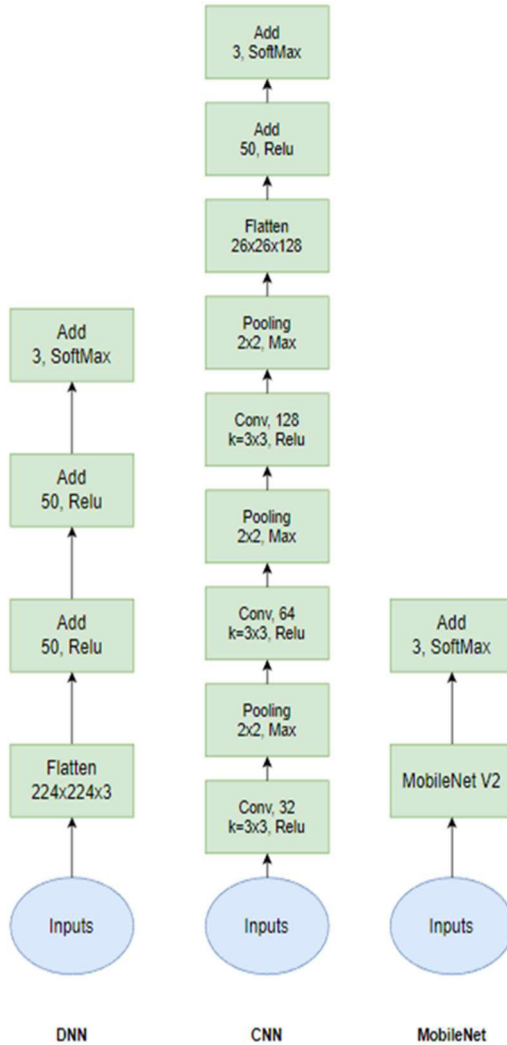


Figura 2. Arquitectura de las tres redes neuronales utilizadas en este estudio. (Elaboraci n propia).

Con respecto a la arquitectura de las redes neuronales convolucionales (CNN), se puede observar en la Figura 2 que, las últimas capas de la misma, presentan una arquitectura muy similar a la que se describió para la red DNN. Adicionalmente, la arquitectura de las redes CNN presentan capas de convolución y de pooling de manera intercalada. Las capas de convolución representan el núcleo esencial de una CNN. La convolución se ejecuta sobre los datos de entrada mediante un filtro de convolución, también conocido como Kernel, con el objetivo de generar un nuevo mapa de características (Feature Map). Este proceso implica la multiplicación de matrices elemento por elemento y la suma del resultado, lo que produce una matriz convolucional que captura las características fundamentales de la imagen de entrada. En este estudio, se optó por un Kernel de tamaño 3x3 para las capas de convolución, con pasos (strides) predeterminados en (1,1). Por otro lado, la capa de pooling se utiliza para extraer los datos más relevantes de un mapa de características. En este estudio, se empleó la capa de Max Pooling, que destaca por seleccionar el valor máximo dentro de una región específica del mapa de características. Esta estrategia posibilita reducir la cantidad de parámetros, lo que resulta en una disminución en el tiempo requerido para el entrenamiento y contribuye a mitigar el sobreajuste del modelo.

Finalmente, como tercer modelo de red neuronal fue utilizada la arquitectura de las redes neuronales convolucionales pre-entrenadas (MobileNet v2) como capa de entrada, seguida de la inclusión de la capa de salida de las arquitecturas previamente mencionadas.

A continuación, se llevó a cabo la etapa de entrenamiento de los tres modelos analizados, en donde cada modelo fue entrenado con 50 iteraciones (epoch). En la Figura 3 se muestran los resultados de la exactitud (Accuracy) y la función de pérdida (Loss) en función del número de iteraciones, para los modelos DNN, CNN y MobileNet v2 entrenados.

Para el modelo DNN, se observa en la Figura 3 (a) cierta disparidad entre los conjuntos de datos de entrenamiento y prueba. La exactitud aumenta progresivamente con cada época, alcanzando un valor máximo de 0,92 para el conjunto de datos de entrenamiento (DNN_Train) y de 0,88 para el conjunto de datos de prueba (DNN_Test). Esta discrepancia entre ambos conjuntos se mantiene a lo largo de todo el periodo de entrenamiento. Para la pérdida, la Figura 3 (b) muestra una disminución gradual de los valores con el avance de cada época, manteniendo una variación en los resultados de cada conjunto.

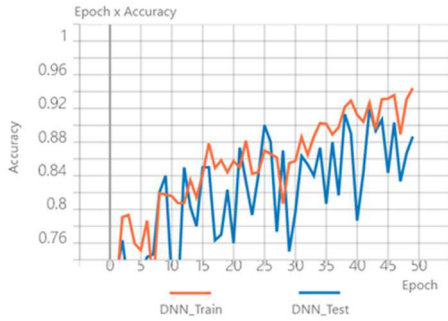
En cuanto a la arquitectura convolucional CNN, en la Figura 3 (c) se puede observar los resultados de la exactitud durante el entrenamiento, el cual aumenta inicialmente de manera exponencial hasta alcanzar valores máximos de aproximadamente 0,96 para ambos conjuntos de entrenamiento (CNN_Train) y prueba (CNN_Test) después de la época N°5. Posteriormente, ambos conjuntos se mantienen prácticamente constantes hasta la última época, con valores cercanos entre sí y pequeñas disparidades. En lo que respecta a la pérdida (Figura 3 (d)), se observa que los valores de cada conjunto descienden abruptamente hasta la época N°10, donde se mantienen con

alguna variación hasta el final del entrenamiento. Es importante señalar que el conjunto de entrenamiento (CNN_Train) alcanza valores más cercanos a 0 que el conjunto de prueba (CNN_Test).

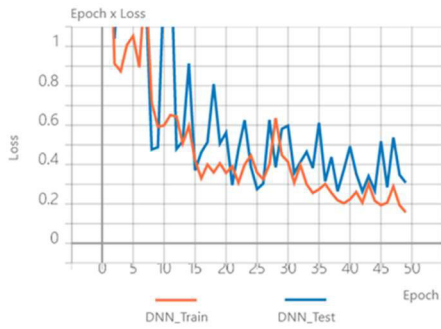
Para el último modelo considerado, con la arquitectura CNN MobileNet, los resultados del entrenamiento para la exactitud y la pérdida se muestran en las Figuras 3 (e) y (f), respectivamente. En particular, en la Figura 3 (e) se observa un crecimiento exponencial en la exactitud de ambos conjuntos, de entrenamiento (CNN2_Train) y prueba (CNN2_Test), hasta la época N°10, seguido por un comportamiento constante con valores cercanos a 1 hasta el final del entrenamiento. Por otro lado, en la Figura 3 (f), se evidencia que la pérdida desciende hasta la época N°10 en ambos conjuntos, para luego mantenerse constante hasta la última época, alcanzando valores cercanos a 0.

Una vez finalizada la etapa de entrenamiento de los modelos, se procedió a su validación utilizando un conjunto de 300 nuevas imágenes (aproximadamente 100 imágenes por cada categoría) que nunca antes habían sido vistas por los modelos. La Figura 4 muestra los resultados obtenidos mediante matrices de confusión de dimensiones 3x3 para los modelos DNN, CNN y CNN MobileNet. En estas matrices, las clases Cielo_D, Cielo_PN y Cielo_TN representan las tres diferentes condiciones del cielo: despejado, parcialmente nublado y totalmente nublado, respectivamente.


a)



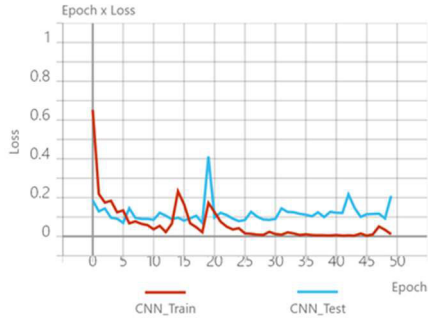
b)



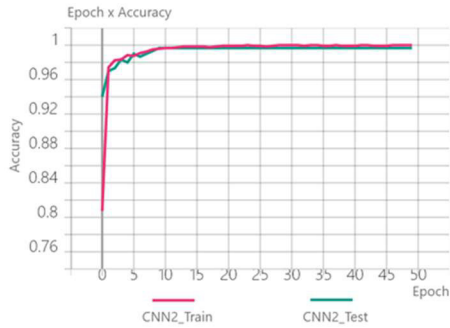
c)



d)



e)



d)

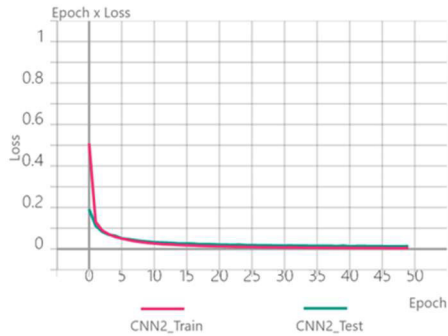


Figura 3. Comparación de la exactitud y la función de pérdida por época de entrenamiento para los modelos: (a-b) DNN, (c-d) CNN y (e-f) CNN MobileNet. (Elaboración propia).

		Predicciones		
		Cielo_D	Cielo_PN	Cielo_TN
Reales	Cielo_D	75	23	4
	Cielo_PN	3	92	4
	Cielo_TN	0	0	99

		Predicciones		
		Cielo_D	Cielo_PN	Cielo_TN
Reales	Cielo_D	94	4	4
	Cielo_PN	0	96	3
	Cielo_TN	0	0	99

		Predicciones		
		Cielo_D	Cielo_PN	Cielo_TN
Reales	Cielo_D	102	0	0
	Cielo_PN	0	98	1
	Cielo_TN	0	0	99

Figura 4. Matriz de confusión para los modelos: (a) DNN, (b) CNN y (c) CNN MobileNet. (Elaboración propia).

Tabla 1. Métricas calculadas para el modelo DNN.

Clase	Exactitud	Precisión	Recall	F1_score
Cielo_D	0,90	0,96	0,74	0,83
Cielo_PN	0,90	0,80	0,93	0,86
Cielo_TN	0,97	0,93	1,00	0,96

Tabla 2. Métricas calculadas para el modelo CNN.

Clase	Exactitud	Precisión	Recall	F1_score
Cielo_D	0,97	1,00	0,92	0,96
Cielo_PN	0,98'	0,96	0,97	0,96
Cielo_TN	0,98	0,93	1,00	0,97

Tabla 3. Métricas calculadas para el modelo CNN MobileNet.

Clase	Exactitud	Precisión	Recall	F1_score
Cielo_D	1,00	1,00	1,00	1,00
Cielo_PN	1,00	1,00	0,99	0,99
Cielo_TN	1,00	0,99	1,00	0,99

Los resultados obtenidos revelan que ambos modelos de redes convolucionales (CNN y MobileNet) muestran un mejor rendimiento en comparación con las redes convencionales (DNN) para el problema bajo estudio.

En cuanto a los modelos DNN y CNN, se observa que la métrica de recall para la categoría de cielo despejado fue la más baja, con un 74% y 92%, respectivamente. Esto indica que ambos modelos de clasificación muestran una sensibilidad limitada, es decir, no logran detectar muchos casos positivos de esta categoría. Esta dificultad puede atribuirse a la identificación errónea de áreas muy brillantes alrededor del sol como nubes, lo que resultó en una sobreestimación de la cobertura de nubes.

Con el fin de mejorar el rendimiento de los modelos, se realizó un análisis adicional utilizando la técnica conocida como "Aumento de Datos" (Data Augmentation) para expandir los conjuntos de datos. Esta técnica permite aumentar significativamente la cantidad de imágenes disponibles aplicando pequeñas modificaciones, lo que ayuda a prevenir el sobreajuste y mejorar la capacidad de generalización del modelo. El Aumento de Datos implica la aplicación de transformaciones geométricas simples y aleatorias a las imágenes originales, como traslaciones, rotaciones, zoom, giros verticales y horizontales, cambios de escala, entre otros. De esta manera, se amplió el conjunto de datos a un total de 3000 muestras, que fueron utilizadas para un nuevo análisis (2700 imágenes para entrenamiento y 300 para validación).

Una vez más, se llevó a cabo el entrenamiento supervisado con un total de 50 iteraciones. La Figura 5 presenta los resultados

obtenidos durante esta fase de entrenamiento, específicamente en términos de exactitud, en relación con el número de iteraciones, para las arquitecturas correspondientes a los modelos DNN, CNN y CNN MobileNet (referida como CNN2).

Por un lado, se destaca que el modelo denso (DNN) muestra una mejora en comparación con la versión anteriormente entrenada sin el uso de aumento de datos. Se observa una mayor coherencia entre sus conjuntos de entrenamiento y prueba, con valores que fluctúan en rangos cercanos entre sí. Por otro lado, en lo que respecta a los modelos convolucionales (CNN y MobileNet), sus comportamientos son análogos al caso sin el aumento de datos, aunque las curvas de los conjuntos parecen alcanzar los límites de aprendizaje con mayor rapidez. Además, se aprecia que el modelo MobileNet exhibe la mayor estabilidad entre todos los modelos analizados.

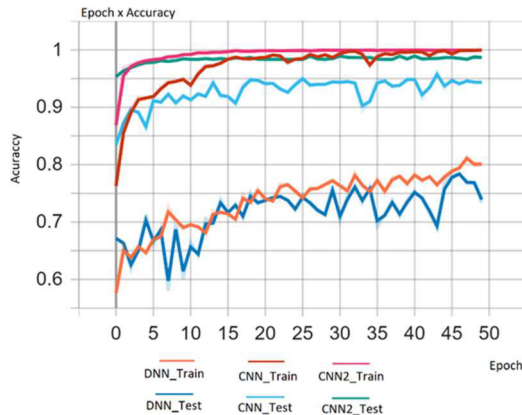


Figura 5. Comparación de la exactitud por época de entrenamiento para los modelos DNN, CNN y CNN MobileNet utilizando la técnica de Aumento de Datos. (Elaboración propia).

La Figura 6 muestra las nuevas matrices de confusión obtenidas durante la etapa de validación para los modelos DNN, CNN y CNN MobileNet, respectivamente, con la técnica de aumento de datos.

		Predicciones		
		Cielo_D	Cielo_PN	Cielo_TN
Reales	Cielo_D	85	14	3
	Cielo_PN	19	67	13
	Cielo_TN	0	0	99

		Predicciones		
		Cielo_D	Cielo_PN	Cielo_TN
Reales	Cielo_D	102	0	0
	Cielo_PN	0	98	1
	Cielo_TN	0	0	99

		Predicciones		
		Cielo_D	Cielo_PN	Cielo_TN
Reales	Cielo_D	102	0	0
	Cielo_PN	0	99	0
	Cielo_TN	0	0	99

Figura 6. Matriz de confusión utilizando la técnica de Aumento de Datos para los modelos: (a) DNN, (b) CNN y (c) CNN MobileNet. (Elaboración propia).

Las métricas de desempeño calculadas para cada modelo se presentan en las Tablas 4-6, evidenciando las mejoras significativas, especialmente en los modelos basados en redes convolucionales (CNN y MobileNet). Así, el empleo de capas de convolución y Max Pooling propicia la proposición de modelos con un rendimiento superior en el procesamiento de imágenes en comparación con los enfoques tradicionales. Es importante resaltar que la arquitectura MobileNet demostró un desempeño numérico óptimo en todas las métricas evaluadas.

Tabla 4. Métricas calculadas para el modelo DNN utilizando la técnica de Aumento de Datos.

Clase	Exactitud	Precisión	Recall	F1_score
Cielo_D	0,88	0,82	0,83	0,83
Cielo_PN	0,85	0,83	0,68	0,74
Cielo_TN	0,95	0,86	1,00	0,93

Tabla 5. Métricas calculadas para el modelo CNN utilizando la técnica de Aumento de Datos.

Clase	Exactitud	Precisión	Recall	F1_score
Cielo_D	1,00	1,00	1,00	1,00
Cielo_PN	1,00'	1,00	0,99	0,99
Cielo_TN	1,00	0,99	1,00	0,99

Tabla 6. Métricas calculadas para el modelo MobileNet utilizando la técnica de Aumento de Datos.

Clase	Exactitud	Precisión	Recall	F1_score
Cielo_D	1,00	1,00	1,00	1,00
Cielo_PN	1,00	1,00	1,00	1,00
Cielo_TN	1,00	1,00	1,00	1,00

4.5.2. Estimación de la radiación solar a través de aprendizaje automático

Esta investigación se centra en el desarrollo y evaluación del rendimiento de diversos modelos de regresión para estimar la radiación solar horaria en el territorio de la UNAJ, utilizando datos históricos de variables meteorológicas clave, como temperatura media, humedad relativa, velocidad del viento, presión atmosférica y radiación solar global. Además, se incorporó el índice de claridad, que representa la relación entre la radiación solar global medida en la superficie terrestre y la radiación solar extraterrestre. Para este propósito, se emplearon algoritmos de aprendizaje automático basados en redes neuronales artificiales (RNA), implementados a través de un software desarrollado en Python.

Los datos meteorológicos se obtuvieron de una estación meteorológica automática ubicada en el campus de la UNAJ. Desde su instalación en diciembre de 2017, esta estación ha registrado mediciones cada 30 minutos, incluyendo la

temperatura ambiente, la humedad relativa, la velocidad del viento, la presión atmosférica y la radiación solar global. Los datos utilizados en este estudio abarcan el período de diciembre de 2017 a marzo de 2023. Para el entrenamiento y la evaluación de los modelos, se limitó el análisis a las horas comprendidas entre las 8:00 y las 18:00, dado que la irradiancia solar fuera de este rango horario es insignificante.

Un dataset de 40,156 muestras se emplearon para entrenar y evaluar los modelos RNA. Específicamente, el 80% de estos datos se destinaron al entrenamiento, mientras que el 20% restante se reservó para las pruebas. En cuanto al índice de claridad Kt, se consideró la siguiente clasificación:

- $Kt > 0.6$: condición de cielo despejado o soleado
- $0.4 < Kt < 0.6$: condición de cielo parcialmente nublado
- $Kt < 0.4$: condición de cielo nublado

Teniendo en cuenta el índice de claridad Kt, el conjunto de datos total se divide en 16,284 muestras para Kt superior a 0,6; 10,003 muestras para Kt mayor a 0,4 y menor a 0,6; y 13,869 muestras para el caso restante. Se utilizó el método de Optimización Bayesiana (OB) para optimizar los hiperparámetros de los modelos. Este es un esquema de optimización que utiliza modelos bayesianos basados en procesos gaussianos para predecir buenos parámetros de ajuste. Además, se utilizó la técnica de validación cruzada quintuple para evaluar la capacidad de generalización de los modelos.

Para construir los modelos RNA, el método OB se aplicó en los siguientes rangos de valores de hiperparámetros:

- número de capas ocultas: [1]
- número de neuronas ocultas: [100-1000]
- función de activación: [tanh-relu]
- valor inicial de la tasa de aprendizaje: [0,001-0,1]

Para entrenar y testear los modelos, el conjunto de datos de entrada incluye información del tiempo (hora del día y número de mes del año) y parámetros meteorológicos, como la temperatura del aire, la humedad relativa y la presión atmosférica.

El mejor rendimiento para cada hiperparámetro en el modelo RNA se obtuvo para:



- número de capas ocultas = 1
- número de neuronas ocultas = 1000
- función de activación = tanh
- valor inicial de la tasa de aprendizaje = 0,01

A continuación, se llevó a cabo el análisis para tres modelos diferentes, M1 a M3, para estimar la radiación solar en diferentes condiciones del cielo. En la Tabla 7 se muestran las variables que se consideraron para cada modelo, donde Mes, Hora, Temp., Hum. y Presión, son el número de mes del año, la hora del día, la temperatura del aire, la humedad relativa y la presión atmosférica, respectivamente.

Tabla 7. Modelos propuestos para la estimación de la radiación solar bajo diferentes condiciones de cielo.

Modelos	Datos totales	Condición de cielo despejado ($K_t > 0.6$)	Condición de cielo parcialmente nublado ($0.4 < K_t < 0.6$)	Mes, Hora, Temp., Hum., Presión.
M1	X			X
M2		X		X
M3			X	X

La Figura 7 muestra los diagramas de dispersión de los valores observados y estimados de radiación solar para los modelos con diferentes entradas (M1 a M3).






Figura 7. Gráficos de dispersión entre los valores de radiación solar observados y estimados para los modelos M1 a M3 utilizando RNA. (Elaboración propia)

El desempeño de los modelos M1 a M3 en términos de los valores de R^2 , MAE y RMSE se presenta en la Tabla 8.

Tabla 8. Valores de las métricas para los modelos M1 a M3.

	M1	M2	M3
R^2	0,86	0,97	0,91
RMSE (W/m^2)	106,49	34,79	44,74
MAE (W/m^2)	73,93	23,91	34,41

En la Tabla 8 y la Figura 22 se puede observar una mejora considerable en el rendimiento de los modelos M2 y M3 en comparación con el modelo M1 cuando se utiliza el índice de claridad. Así, los valores RMSE se reducen significativamente de 106,49 W/m^2 a 34,79 W/m^2 y a 44,74 W/m^2 , para condiciones de cielo soleado y cielo parcialmente nublado, respectivamente. En particular, el modelo para condición de cielo soleado (M2) presenta un mejor rendimiento que el modelo para condición de cielo parcialmente nublado (M3) debido a la mayor variabilidad

de la radiación solar global durante la condición de cielo parcialmente nublado.

4.6 Conclusiones:

Este estudio se enfocó, por un lado, en el desarrollo y comparación de tres arquitecturas de redes neuronales profundas para clasificar las condiciones del cielo, con el propósito de identificar la arquitectura más fiable para este tipo de análisis y su idoneidad en el procesamiento de imágenes. Específicamente, se evaluaron y compararon el rendimiento de una red neuronal profunda (DNN), una red neuronal convolucional (CNN) y una CNN pre-entrenada (MobileNet v2) utilizando imágenes representativas de tres condiciones del cielo: despejado, parcialmente nublado y totalmente nublado. Los resultados revelaron que las arquitecturas convolucionales (CNN y MobileNet) son las más adecuadas para realizar con precisión el monitoreo de la cobertura de nubes, minimizando los errores. Además, se observó una mejora significativa en el rendimiento de estas redes convolucionales al aplicar la técnica de aumento de datos, lo que permitió duplicar la cantidad de imágenes disponibles inicialmente. Asimismo, la estrategia de sintonía fina aplicada para aprovechar la red pre-entrenada MobileNet demostró un excelente desempeño en las métricas de clasificación, además de ofrecer ahorros notables en recursos computacionales y tiempo de procesamiento. Esta arquitectura se centra en adaptar las características específicas de los conjuntos de datos propuestos, congelando los pesos de las capas internas del modelo y ajustando la salida según el objetivo de predicción. Los hallazgos de este estudio son particularmente relevantes para sistemas que

dependen de la energía solar, ya que los modelos de predicción de radiación solar basados en el índice de claridad podrán beneficiarse de estos resultados para tomar decisiones más precisas.

Y, por otro lado, la investigación se centró en el desarrollo y evaluación de diversos modelos de regresión para estimar la radiación solar horaria en el territorio de la UNAJ, empleando técnicas de aprendizaje automático, específicamente redes neuronales artificiales (RNA). Se utilizaron para ello datos históricos de variables meteorológicas clave, como temperatura media, humedad relativa, velocidad del viento, presión atmosférica y radiación solar global. Además, se consideró el índice de claridad, que indica la transparencia atmosférica y es sensible a la presencia de nubes y contaminación. Los resultados revelaron una fuerte dependencia del desempeño de los modelos respecto al tipo de cielo. Se observó una mejora significativa en los modelos que solo consideraban datos de cielo despejado (modelo M2) y parcialmente nublado (modelo M3), en comparación con aquellos que incorporaban el conjunto completo de datos (modelo M1). La inclusión del índice de claridad permitió reducir notablemente el error medio cuadrático de $106,49 \text{ W/m}^2$ a $34,79 \text{ W/m}^2$ y a $44,74 \text{ W/m}^2$ para condiciones de cielo soleado y cielo parcialmente nublado, respectivamente. Específicamente, el modelo M2 mostró un rendimiento superior al M3 debido a la mayor variabilidad de la radiación solar global durante condiciones parcialmente nubladas. Los modelos M2 y M3 brindan la capacidad de estimar la radiación solar en ausencia de información fiable, lo que resulta beneficioso para diversas

aplicaciones, como la evaluación y dimensionamiento de proyectos fotovoltaicos, la restauración de conjuntos de datos de radiación solar en caso de interrupciones del sistema de monitoreo, o su implementación en sistemas de seguimiento del punto de máxima potencia en sistemas fotovoltaicos.

Bibliografía

Arisholm, E, Briand, L, Johannessen, E. “A systematic and comprehensive investigation of methods to build and evaluate fault prediction models”. *Journal of Systems and Software*. Vol. 83(1). (2010). pp. 2–17

Assi, A., Jama, M., Al-Shamisi, M. “Prediction of Global Solar Radiation in Abu Dhabi”. *Int. Scholarly Research Network ISRN Renewable Energy*. Vol. 2012, Article ID 328237, 10 pages, (2012). DOI: doi.org/10.5402/2012/328237

Chollet, F. “Deep Learning with Python”. First edition. Manning Publications. (2017).

Çoban, V., Onar, S.. In: Kahraman C. et al., “Intelligent and Fuzzy Techniques in Big Data Analytics and Decision Making”. *INFUS 2019. Advances in Intelligent Systems and Computing*, vol 1029. Springer, (2020).

Erdinc, O., Uzunoglu, M. “Optimum design of hybrid renewable energy systems: overview of different approaches”. *Renewable and Sustainable Energy Reviews*. Vol. 16, no. 3. pp. 1412–1425, (2012). DOI: doi.org/10.1016/j.rser.2011.11.011

Goodfellow, I, Bengio, Y, Courville, A. “Deep Learning”. MIT Press. (2016).

Grossi Gallegos, H. “Notas sobre Radiación Solar”. Universidad Nacional de Lujan – Departamentos de Ciencias Básicas. (2004).

Harrington, P. “Machine Learning in Action”. Manning Publications Co. (2012).

Jordan, M, Mitchell, T. “Machine learning: Trends, perspectives, and prospects”. *Science*. Vol. 349, Issue 6245. (2015). pp. 255-260.

Kaplanis, S., Kaplani, E. “Stochastic prediction of hourly global solar radiation for Patra, Greece”. *Applied Energy*. Vol. 87, pp. 3748– 3758, (2010). DOI: doi.org/10.1016/j.apenergy.2010.06.006

Khatib, T., Elmenreich, W. “A Model for Hourly Solar Radiation Data Generation from Daily Solar Radiation Data Using a Generalized Regression Artificial Neural Network”. *International Journal of Photoenergy*. Vol. 2015 Article ID 968024, 13 pages, (2015). DOI: doi.org/10.1155/2015/968024

Leal, S., Tiba, C., Piacentini, R. “Modelos estadísticos para determinação da irradiação solar UV diária no estado de Pernambuco”. *Avances en Energías Renovables y Medio Ambiente*, Vol. 13, pp. 11.41–11.47, (2009).

Neelamegam, P., Amirtham, V. “Prediction of solar radiation for solar systems by using ANN models with different back propagation algorithms”. *Journal of Applied Research and Technology* Vol. 14. 206–214, (2016). DOI: doi.org/10.1016/j.jart.2016.05.001

Okogbue, E., Adedokun, J., Holmgren, B. “Hourly and daily clearness index and diffuse fraction at a tropical station, Ile-Ife, Nigeria”. *Int. Journal of Climatology*. Vol. 29, pp.1035–1047, (2009). DOI: doi.org/10.1002/joc.1849

Pandey, C., Katiyar, K. “Solar Radiation: Models and Measurement Techniques”. *Journal of Energy*. Vol. 2013, Article ID 305207, 8 pages, (2013). DOI: doi.org/10.1155/2013/305207

Pang, Z., Niu, F., O Neill, Z. “Solar radiation prediction using recurrent neural network and artificial neural network: A case study with comparisons”. *Renewable Energy*. Vol. 156. 279–289, (2020). DOI: doi.org/10.1016/j.renene.2020.04.042

Polo Martínez, J. “Optimización de modelos de estimación de la radiación solar a partir de imágenes de satélite”. Tesis Doctoral. Universidad Complutense de Madrid, (2010).

Taretto, K. “Celdas Solares, Teoría, Ensayo y Diseño”. Ed. Nueva Librería. Ed. 1º. (2015).

Capítulo 5

El modelo TPACK en la UNAJ: la integración de objetos virtuales de aprendizaje en las prácticas de enseñanza y su relación con el desarrollo TPACK de los docentes

María Joselevich, Laureano Sabatier y Jorge Segovia

En este capítulo se describen avances en la indagación de aspectos en los cuales los docentes de UNAJ requieren apoyo para la inclusión de tecnología en sus propuestas de clase, a través de una experiencia llevada a cabo entre los años 2021 y 2024.

Se trabajó tomando como marco el modelo TPACK (Conocimiento Tecnológico y Pedagógico del Contenido, por sus siglas en inglés, Mishra y Koehler, 2006). Este modelo analiza los saberes docentes organizándolos según las dimensiones pedagógica, tecnológica y de contenido disciplinar, y define el área de intersección entre ellos. Según estos autores, una enseñanza donde se incorporan efectivamente estos aspectos es aquella en la cual se los trabaja de forma amalgamada.

Se realizó una encuesta sobre acerca de la autopercepción de docentes en temas relacionados con las dimensiones definidas en

el modelo. El análisis multifactorial de los ítems de la encuesta mostró la existencia de correlación entre varios de ellos permitiendo la postulación de cuatro constructos. Estos constructos son coherentes con las dimensiones postuladas en el marco teórico y respaldan la idea de que el modelo TPACK es aplicable para el análisis de las propuestas de aula de los docentes de UNAJ y justifica el realizar las recomendaciones de ofrecer a las y los docentes cursos que aborden en forma articulada al menos estas tres dimensiones, subrayando la necesidad de un abordaje holístico de la formación docente.

5.1 Introducción

Tanto en el mundo privado como en el ámbito público ha habido un enorme crecimiento del acceso tanto a información como a herramientas novedosas para su procesamiento. Esto hace que sea necesario analizar su impacto en las distintas actividades particulares.

En lo relacionado a las actividades educativas, y en particular a la educación superior, el proceso de tecnologización ha embebido tanto los procedimientos administrativos como los objetos de estudio y enseñanza. Estamos de acuerdo con Mariana Maggio (2012: 21), cuando dice que la enseñanza debe llevar a las y los estudiantes a ámbitos cercanos a lo que serán los sitios de desarrollo de su profesión, con lo que las ofertas educativas deberían contemplar el uso de tecnologías en distintos sentidos, tanto administrativos como de enseñanza.

Dado que todo lo relacionado a las prácticas de enseñanza está mediado por el imaginario y las concepciones pedagógicas de los equipos docentes, resulta fundamental identificar estas concepciones para poder diseñar estrategias para acompañar la incorporación adecuada de nuevas tecnologías en las prácticas áulicas.

En el caso de la incorporación y utilización de recursos educativos que incluyen desarrollos de las tecnologías de la información y la comunicación, su incorporación requiere de los docentes ciertos saberes que, según nuestro punto de vista, están enmarcados en el modelo TPACK.

El TPACK se construye sobre el concepto de Conocimiento Pedagógico del Contenido (CPC), acuñado por Shulman (2005): “esa especial amalgama entre materia y pedagogía que constituye una esfera exclusiva de los maestros, su propia forma especial de comprensión profesional”. El CPC representa el área de intersección entre un contenido a enseñar y una didáctica asociada, por la que determinados temas y problemas se organizan, representan y adaptan a los diversos intereses y capacidades de los estudiantes y se exponen para su enseñanza.

En vías de integrar genuinamente la tecnología en la enseñanza, Mishra y Koehler propusieron extender el concepto de CPC y formularon el modelo TPACK, el cual –tomando en cuenta la esencia compleja, multifacética y situada del conocimiento del profesor– define los conocimientos necesarios para utilizar la tecnología en un entorno educativo determinado, de manera que sean contextualmente auténticos y pedagógicamente adecuados.

Los tres componentes principales del modelo son: el conocimiento pedagógico (PK), el tecnológico (TK) y el disciplinar (DK). El TPACK se construye en la intersección de estos tres campos, teniendo además en cuenta que el TPACK, así como el CPC, responde a áreas particulares en contextos específicos.




Figura 1. Modelo TPACK adaptado y reproducido con permiso de sus autores, © 2012 tpack.org

De lo anterior surge que no alcanza con que los docentes sean expertos en alguno o algunos de los componentes del TPACK. Para que un docente se encuentre capacitado para la incorporación de algún recurso en particular, no es suficiente con la comprensión y percepción de estos tres componentes básicos

en forma aislada, sino que deben considerarse en interacción. Es la posibilidad de reunirlos, con la especificidad de cada situación de enseñanza, la que hace que la propuesta de enseñanza acompañe a los estudiantes a la construcción de aprendizajes significativos.

Cox y Graham (2009) se preguntan cómo llegan los profesores a adquirir ese conocimiento TPACK. Según estos autores los profesores adquieren primero un conocimiento relacionado con lo tecnológico del contenido y más tarde el TPACK se desarrolla cuando movilizan su conocimiento en un entorno pedagógico. Otra vía, añaden, sería obtener un conocimiento general sobre los usos de la tecnología en aula, un conocimiento tecnopedagógico, antes de que pueda centrarse específicamente en el uso que le puede dar en una materia específica. En todo caso, el proceso de adquisición no está claro y son necesarios más estudios empíricos para comprenderlo mejor (Cejas León, Navío Gámez y Barroso Osuna, 2016).

El trabajo que se presenta en este capítulo comenzó a desarrollarse en el año 2020. En ese momento, la emergencia sanitaria producto de la pandemia por COVID-19 obligó a las universidades a migrar intempestivamente sus propuestas de enseñanza hacia una modalidad virtual con trabajo a distancia, funcionando desde entonces en una modalidad de Enseñanza Remota de Emergencia (ERE).

En este marco, muchas de las materias incorporaron recursos de las TIC a sus propuestas de enseñanza, más por la urgencia de suplir materiales utilizados en sus clases presenciales que por

decisiones de enseñanza tomadas a partir de análisis pedagógicos realizados por los equipos docentes. Sin embargo, la selección de esos recursos es fundamentalmente un acto pedagógico que demanda a los docentes el uso de habilidades que, en muchos casos, están en proceso de construcción. En relación a esto, consideramos deseable que se busque lo que Mariana Maggio llama una “inclusión genuina”, refiriéndose a un proceso de integración de TIC de orden epistemológico que “reconoce el complejo entramado de la tecnología en la construcción del conocimiento en modos específicos por campo disciplinar y emula ese entramado en el plano de la práctica de la enseñanza” (Maggio, 2012: 21). De esta forma, los desarrollos tecnológicos forman parte integral de las propuestas pedagógicas en lugar de ocupar el lugar subsidiario de la superficie.

Diversos autores sugieren desde hace tiempo que la incorporación de las TIC en la enseñanza vino para quedarse. Dussel y col. (2020), por ejemplo, vislumbraron un escenario en el que muchas propuestas de enseñanza se desarrollan en formatos bimodales. Actualmente, la mayoría de las universidades del mundo desarrollan sus propuestas, al menos en parte, en este tipo de escenarios.

Tomando en cuenta el concepto de inclusión genuina que expusimos más arriba, consideramos que la experiencia adquirida en la cuarentena por el COVID-19, que llevó a la incursión forzada de recursos de las TIC en la enseñanza, se debe aprovechar para la incorporación de nuevas estrategias pedagógicas que contemplen el uso potente de recursos tecnológicos. Lo anterior

implica que sería deseable que los docentes alcanzaran un alto nivel de conocimientos relacionados con el TPACK y sería un próximo paso que permitiría mejorar y ampliar los horizontes didácticos de cada materia de la universidad.

Sin embargo, varias investigaciones plantean dificultades de los docentes universitarios para apropiarse del marco TPACK. Flores y col. (2018) han relevado trabajos que muestran la existencia de grandes influencias del campo disciplinar del docente en el ejercicio de su enseñanza. Por ejemplo, los docentes de ciencias físico-naturales suelen desarrollar una docencia centrada en los contenidos, mientras que los de ciencias sociales y humanas, una más centrada en el alumno. Por otro lado, las prácticas con foco en el docente suelen realizarse con usos tecnológicos que demandan menos capacidades mientras que las que requieren el desarrollo de capacidades tecnológicas más complejas se vinculan a enfoques constructivistas.

Otros investigadores destacan la influencia de las creencias de los docentes sobre la utilización de las tecnologías en el aula, las cuales están muy asentadas en torno al enseñar y aprender con TIC, y se relacionan con las decisiones que adoptan y acciones que realizan previamente, durante y luego de sus prácticas educativas. Flores identifica como “un elemento clave que facilita o dificulta la implicación de un docente en un proyecto de innovación con tecnologías, es la compatibilidad entre sus creencias pedagógicas y la tecnología. Estas y otras indagaciones pusieron al descubierto que los docentes más reflexivos y conscientes de sus propias creencias pedagógicas, generalmente, son más adaptativos y

flexibles. Así, la implementación con éxito de tecnologías en el aula es más probable que se produzca cuando los profesores reflexionan acerca de su enseñanza y de los objetivos que persiguen.” (Flores, 2018)

En base a esto, suponemos que docentes con mayor conocimiento de su nivel de desarrollo y amalgamamiento en sus competencias TPACK podrán enriquecer genuinamente sus prácticas pedagógicas incluyendo recursos tecnológicos para acompañar a los estudiantes a construir aprendizajes más significativos.

Por otro lado, la disponibilidad de nuevas herramientas didácticas invita a las y los docentes a enriquecer e innovar en sus prácticas pedagógicas, incursionando en distintas modalidades de enseñanza que estimulan la construcción de entornos de aprendizaje más significativos para los estudiantes y que refuercen en los docentes el rol de orientador de los aprendizajes.

En base a lo anterior nos propusimos el objetivo de estudiar los aspectos en los cuales los docentes de UNAJ requieren apoyo para desarrollar sus competencias para la inclusión de tecnología en sus propuestas didácticas tendiente a hacer un uso que resulte en aprendizajes más significativos de sus estudiantes. Para esto, decidimos relevar el nivel TPACK autopercebido de un grupo de docentes de UNAJ.

5.2 Metodología

5.2.1 Primer cuestionario

En los trabajos publicados referidos al diagnóstico de la adopción genuina del modelo TPACK, se han ensayado varios instrumentos (Gewerc, Pernas y Varela, 2013; Mouza, Karchmer-Klein, et al., 2014). Entre ellos, el más empleado es el cuestionario (Schmidt et al., 2009; Schmidt et al., 2020). En la primera etapa de esta investigación, se confeccionó y puso a punto una herramienta de toma de datos traducida y adaptada de los trabajos de Schmidt (2009) y Burgoyne (2010).

Para validar el instrumento de medición y ajustarlo al contexto de UNAJ, se realizó un primer muestreo con trece docentes seleccionados por el equipo de investigadores, en base a experiencias previas de trabajo con ellas y ellos. Se los eligió con la consideración de que tengan un nivel TPACK medio o alto, buscando evitar en esta primera instancia algún efecto causado por la dificultad para comprender u operar cuestionarios digitales.

El cuestionario se armó como un formulario digital y se envió por correo electrónico a los encuestados, quienes respondieron voluntariamente. El tiempo requerido para responder fue aproximadamente de 40 minutos por persona. Si bien el cuestionario se definió como anónimo, quedó a criterio de cada docente el registrar o no sus datos personales.

El instrumento construido contuvo 16 preguntas con las cuales se buscó determinar el nivel autopercebido de cada docente en los siete aspectos del modelo TPACK: 3 preguntas sobre el

conocimiento tecnológico (CT), 2 sobre el conocimiento del contenido (CC), 1 sobre el conocimiento pedagógico (CP), 1 sobre el conocimiento pedagógico del contenido (CPC), 3 sobre el conocimiento tecnológico del contenido (CTC), 1 sobre el conocimiento tecnológico y pedagógico (CTP), 1 sobre el conocimiento pedagógico y tecnológico del contenido (CTPC). Los participantes respondieron a cada pregunta usando la siguiente escala Likert de cinco niveles, donde 1 correspondía a “muy en desacuerdo” (MD), 2 a “en desacuerdo” (D), 3 a “ni de acuerdo ni en desacuerdo” (N), 4 a “de acuerdo” (A), y 5 a “muy de acuerdo” (MA).

Luego de las preguntas anteriores se incorporaron otras tres adicionales, con las que se buscó indagar sobre el contexto en el que los encuestados dan clases, su formación docente y el tipo de asistencia o acompañamiento tecnológicos a los que les gustaría acceder para mejorar sus propuestas de clase.

Finalmente, se solicitó a los encuestados indicar en una escala en cuál nivel se ubicaban en cuanto al uso de tecnologías educativas en sus clases.

Este cuestionario se cargó en un ormulario de Google y se aplicó a los trece docentes voluntarios de UNAJ.

5.2.2 Segundo cuestionario

A partir del análisis de los resultados del primer cuestionario y de los comentarios y sugerencias de los encuestados, se procedió a optimizar el instrumento para luego aplicarlo a un número mayor

de docentes. La consulta se realizó enviando por mensaje electrónico un enlace a la aplicación Jotform. Esta plataforma, además de ofrecer al usuario mayor interacción con el formulario, ofrece distintas posibilidades de visualización de datos.

El instrumento empleado finalmente constó de 11 secciones que contenían preguntas de respuesta única con escala Likert y/o de selección múltiple. La tabla 1 resume el contenido y número de ítems en cada sección.

Tabla 1. Composición de la segunda encuesta aplicada

Título de sección	Contenido	Nº de ítems
General	Edad, instituto de pertenencia, antigüedad, máximo título alcanzado y formación docente.	6
CT	Conocimiento tecnológico	13
CC	Conocimiento del contenido	4
CP	Conocimiento pedagógico	7
CPC	Conocimiento pedagógico del contenido	3
CTC	Conocimiento tecnológico del contenido	4
CTP	Conocimiento tecnológico pedagógico	8
TPACK	Conocimiento tecnopedagógico del contenido.	3
Formación	Experiencia durante la formación académica referida al uso pedagógico de la tecnología.	3
Contexto	Conocimiento sobre la accesibilidad que tienen las y los estudiantes a la tecnología.	4
Cierre	Opinión sobre el tipo de asistencia que considera útil para mejorar el uso de la tecnología en el aula.	3

Muestra

La nueva muestra fue construida a partir de un muestreo no probabilístico, utilizando la técnica de participación voluntaria, para realizar después un análisis de tipo factorial (Trigueros & De Aldecoa, 2021).

Se convocó al cuerpo docente de varias materias de la UNAJ, contactando coordinadores de materias y con docentes aislados. El muestreo se realizó por saturación teórica y el total de respuestas obtenidas ascendió a 52 (cincuenta y dos).

Técnicas de Análisis

El análisis de las frecuencias obtenidas según el nivel de acuerdo para cada afirmación propuesta no permite construir la estructura de las representaciones de los participantes. Por ello, resulta necesario reagruparlos en dimensiones más generales para su comprensión que se espera, como hipótesis, que se agrupen de igual forma que como plantea Schmidt et al. (2009). De este modo, el contenido de las afirmaciones fue reagrupado en 4 dimensiones teóricas diferenciadas.

- Autopercepción del conocimiento del contenido (A-CC): Refiere al dominio que tiene la/el docente sobre el contenido que enseña, incluyendo conceptos y habilidades, propias de su campo disciplinar. Se utilizaron 4 indicadores.
- Autopercepción del conocimiento tecnológico (A-CT): Implica el conocimiento que se tiene respecto al uso de distintas

tecnologías, desde las más rudimentarias (lápiz y papel) hasta las más avanzadas (software, internet). Se utilizaron 3 indicadores.

- Autopercepción del conocimiento pedagógico (A-CP): Incluye el conocimiento sobre las teorías y los métodos y procedimientos de enseñanza, tales como la planificación, el diseño y la evaluación. Se utilizaron 4 indicadores.

- Autopercepción del conocimiento tecnológico pedagógico del contenido (A-TPACK): refiere al saber necesario para utilizar las tecnologías de forma pedagógicamente efectiva para enseñar un contenido específico. Se utilizaron 3 indicadores.

Los datos de esta encuesta se analizaron en forma exhaustiva trabajando con el software Factor Analysis (versión 12.03), realizando un análisis factorial de reducción de dimensiones, agrupando cada factor mediante los argumentos teóricos que definen el CC, CP, CT y TPACK, con un análisis de fiabilidad del instrumento completo y cálculo del alfa ordinal para cada factor y de la varianza explicada. De ahí se obtuvieron los constructos A-CC, A-CP, A-CT y A-TPACK.

5.3 Resultados

5.3.1 Primer cuestionario

El primer cuestionario se utilizó para realizar una consulta preliminar, cuyos resultados nos permitieron rediseñar y mejorar el instrumento.

Algunas de las impresiones resultantes de las respuestas obtenidas sugieren que las y los docentes encuestados parecen sentir más seguridad en cuanto al conocimiento disciplinar del contenido. Sin embargo, en cuanto al conocimiento tecnológico reconocen tener un manejo “aceptable”, “satisfactorio”, y que en muchos casos requieren de asistencia para poder resolver algunas situaciones particulares.

Teniendo en cuenta que para acceder a cargos docentes es requerimiento la formación de grado disciplinar pero no la formación en tecnología y/o pedagogía, estos resultados parecieran ser coherentes con lo esperado para el promedio de la población docente encuestada.

Las y los docentes encuestados aportaron comentarios acerca del instrumento que fueron utilizados para mejorarlo y construir una nueva encuesta, como se verá en el apartado siguiente.

5.3.2 Segundo cuestionario

5.3.2.1 Instrumento de recolección de datos

En la construcción del segundo instrumento de consulta se utilizó una adaptación del cuestionario utilizado en la primera etapa,

modificando algunas preguntas en función a los resultados del análisis anterior. Esta optimización consistió, por un lado, en la modificación en la redacción de algunas preguntas. Además, se suprimieron los ítems semiabiertos sustituyéndolos por listas de selección múltiple, se reorganizaron las y los docentes según el Instituto en el que dan clase (en lugar del área de especialización profesional), buscando contemplar la naturaleza multidisciplinaria de las carreras que se cursan en UNAJ. Finalmente, se modificó el soporte del instrumento utilizando esta vez la aplicación Jotform, que resultaba más amigable a las y los encuestados.

La encuesta final resultó en un cuestionario estructurado de 11 secciones que se aplicó a 52 docentes, como se describe en el apartado de Metodología.

Se incorporaron en la encuesta 8 ítems en donde se indaga sobre las características de las y los encuestados (máximo título obtenido, edad, pertenencia institucional, formación docente) y sobre qué tipo de asistencia o acompañamiento consideraba cada uno de ellos necesario para mejorar su propuesta tecnológica en el aula. Las respuestas a estas preguntas fueron codificadas.

Se envió por correo electrónico el enlace al cuestionario armado como una encuesta digital. El tiempo requerido para responder fue de aproximadamente 40 minutos por persona. Si bien el cuestionario se definió como anónimo, cada docente podía dejar registrado su nombre y apellido si lo deseaba.

5.3.2.2 Toma y caracterización de la muestra

Como se indicó más arriba, la encuesta se envió por correo electrónico a las y los coordinadores de algunas materias masivas de la universidad que habían aceptado publicarla y a algunos docentes individuales. Se recibieron 52 respuestas de las cuales se incluyeron en el análisis las 44 que habían sido completadas.

Las características de los 44 docentes que respondieron la encuesta en su totalidad se muestran en la siguiente tabla (tabla 4):

Tabla 4: Características de las y los docentes encuestados.
Segunda encuesta

Edad	Menos de 42 años: 15 (34%) Entre 43 y 59 años: 23 (52%) 60 años o más: 6 (14%)
Máximo grado de estudio	Grado: 16 (36%) Especialización: 9 (20%) Maestría: 6 (14%) Doctorado: 13 (30%)
Experiencia docente (antigüedad en cargos de docencia universitaria)	1 a 7 años: 7 (16%) 8 a 15 años: 24 (55%) 16 a 23 años: 9 (20%) más de 23 años: 4 (9%)
Instituto de pertenencia (no se computa la doble pertenencia)	Instituto de Estudios Iniciales: 15 (34%) Instituto de Ingeniería y Agronomía: 12 (27%) Instituto de Ciencias de la Salud: 16 (36%) Instituto de Ciencias Sociales y Administración: 1 (2%)
Experiencia docente en otro nivel de enseñanza	Sí: 24 (55%) No: 20 (45%)

5.3.2.3 Procedimiento de análisis

Como se indicó en el apartado de Metodología, los factores se determinaron haciendo un análisis factorial de reducción de dimensiones con el software Factor Analysis (versión 12.03).

Se siguieron los siguientes criterios:

- Cada indicador fue agrupado mediante el fundamento teórico descripto previamente.
- Se realizó un análisis de fiabilidad del instrumento completo, así como también el cálculo del alfa ordinal para cada factor.
- La varianza explicada resultó superadora del 50%
- Existían al menos tres reactivos por factor

Mediante este procedimiento se obtuvo un material final conformado por las respuestas de 44 encuestados a 15 ítems del cuestionario estructurado con una escala Likert conformada con cinco opciones de respuesta, donde 1 correspondía a “totalmente en desacuerdo” (TD), 2 a “en desacuerdo (D), 3 a “ni de acuerdo ni en desacuerdo” (N), 4 a “de acuerdo” (A) y 5 a “totalmente de acuerdo” (TA).

Los ítems quedaron distribuidos de la siguiente manera: tres para la autopercepción del conocimiento tecnológico (A-CT), cuatro para la del conocimiento del contenido (A-CC), cuatro para la del conocimiento pedagógico (A-CP), y tres ítems para la autopercepción del conocimiento tecnológico pedagógico del contenido (A-TPACK).

El modelo TPACK enfatiza la importancia de que estos tres elementos (CC, CP y CT) interactúen simultáneamente en el proceso de enseñanza y aprendizaje, construyendo una red de interrelaciones. Por eso, se incluyeron en el instrumento original preguntas tendientes a buscar cómo se autoperciben las y los docentes en las dimensiones cruzadas de conocimiento tecnológico del contenido, conocimiento pedagógico del contenido y conocimiento tecnológico pedagógico. Sin embargo, varios de las y los docentes no respondieron esas preguntas, por lo que no se pudo determinar si existía correlación entre los ítems que las representaban.

5.3.2.4 Resultados

Para realizar el análisis, se eliminaron los 8 casos que no respondieron completamente todo el cuestionario, resultando finalmente analizada la información aportada por 44 casos.

Para la prueba de consistencia interna se realizaron los siguientes procedimientos:

- Análisis de fiabilidad alfa ordinal.
- Evaluación de correlación ítem-total.
- La correlación al cuadrado (varianza explicada) con todos los reactivos.
- Eliminación de los reactivos que disminuían el valor de alfa.

Al utilizarse un nivel de medición ordinal tipo Likert, se realizó un análisis factorial policórico.

Posteriormente se eliminaron los ítems en función a los siguientes criterios:

- Que tuvieran cargas factoriales inferiores a 0,4,
- Que se agruparan en un componente teórico distinto al propuesto.
- Que se agrupara en un factor que tuviera menos de tres reactivos.

La solución final mostró la existencia de cuatro factores. La misma explicó el 82,1% de la varianza. Los ítems presentan cargas factoriales superiores a 0,40 dentro de su factor y comunalidades mayores a 0,35.

El instrumento final quedó conformado por 15 reactivos que se presentan en la Tabla 7.

La prueba de esfericidad de Bartlett's fue significativa ($df = 105$; $P = 0,000010$) y el indicador de adecuación del tamaño de muestra Kaiser-Meyer-Olkin fue adecuado (0,720). El alfa de Cronbach del instrumento total resultó ser de 0,897.

Tabla 7: Ponderaciones de factores para el análisis factorial exploratorio del Constructo de Interrelación de Conocimientos Autopercebidos (CICA).

		A-CC	A-CT	A-CP	A-TPACK
Rango		1-5	1-5	1-5	1-5
Media		4,32	3,77	4,2	3,5
Desviación estándar		1,008	0,883	0,632	1,130
Varianza explicada		0,31	0,28	0,15	0,085
Alfa Ordinal		0,960	0,953	0,959	0,980
Reactivo		Carga factorial			
1	Conozco la historia y el desarrollo de teorías importantes en la materia que enseño.	0,917	0,105	0,191	0,133
2	Puedo utilizar una forma de pensar específica de la asignatura que enseño.	0,887	0,199	0,187	0,127
3	Frecuentemente leo publicaciones científicas actualizadas sobre los temas que enseño en el aula.	0,850	0,216	0,170	0,111
4	Tengo suficiente conocimiento sobre mi área de estudio.	0,825	0,103	0,272	0,161
5	En mis clases utilizo tecnología frecuentemente	0,210	0,826	0,307	0,171
6	En mi formación docente he experimentado clases en las que se utilizó tecnología	0,107	0,803	0,029	0,139
7	En la preparación de mis clases utilizo tecnología frecuentemente	0,223	0,776	-	0,407
8	En mi trabajo diario fuera de la docencia utilizo tecnología frecuentemente	0,106	0,736	-	0,253
9	Sé cómo evaluar el desempeño de las y los estudiantes en una clase	0,235	0,189	0,842	-0,032
10	Puedo evaluar el aprendizaje de las y los estudiantes de múltiples formas	0,260	0,130	0,824	-0,036

11	Sé cómo adaptar mi forma de enseñar en función de qué entienden y qué no mis estudiantes	0,049	-0,252	0,770	0,312
12	Puedo utilizar una amplia gama de estrategias de enseñanza diferentes	0,378	-0,053	0,697	0,319
13	Puedo elegir qué tecnología usar para mejorar la enseñanza de determinado contenido	0,083	0,305	0,102	0,876
14	Puedo ayudar y guiar a otros colegas a coordinar el uso de contenido, tecnologías y distintas estrategias pedagógicas	0,143	0,286	0,092	0,776
15	Soy capaz de usar estrategias que combinan contenido, tecnología y diferentes estrategias de enseñanza que aprendí durante mi formación	0,400	0,333	0,219	0,674

Nota. Las cifras en negritas indican las cargas factoriales más altas

Análisis

1. Estructura de las representaciones del Constructo de Interrelación de Conocimientos Autopercebidos (CICA)

La versión final del instrumento, con el conjunto de indicadores seleccionados, permitió determinar cuatro factores. Los ítems que aportan a cada factor obtenido (A-CC, A-CP, A-CT y A-TPACK) muestran una agrupación acorde con el modelo teórico empleado (Mishra, 2006) y nos lleva a postular la surgimiento de una variable que llamamos Constructo de Interrelación de Conocimientos Autopercebidos (CICA).

De este modo, es posible reagrupar las categorías en cada dimensión del siguiente modo:

Tabla 8: Estructura general de las dimensiones construidas a partir de las autopercepciones de las y los docentes y del constructo CICA. Fuente: elaboración propia.

Variable	Dimensión	Categorías incluidas. Juicios respecto a:
Constructo de interrelación de conocimientos autopercebidos (CICA)	A-CC	<ul style="list-style-type: none"> ● Conozco la historia y el desarrollo de teorías importantes en la materia que enseño ● Puedo utilizar una forma de pensar específica de la asignatura que enseño ● Frecuentemente leo publicaciones científicas actualizadas sobre los temas que enseño en el aula ● Tengo suficiente conocimiento sobre mi área de estudio
	A-CT	<ul style="list-style-type: none"> ● En mis clases utilizo tecnología frecuentemente ● En la preparación de mis clases utilizo tecnología frecuentemente ● En mi trabajo diario fuera de la docencia utilizo tecnología frecuentemente
	A-CP	<ul style="list-style-type: none"> ● Sé cómo evaluar el desempeño de las y los estudiantes en una clase ● Puedo utilizar una amplia gama de estrategias de enseñanza diferentes ● Puedo evaluar el aprendizaje de las y los estudiantes de múltiples formas ● Sé cómo adaptar mi forma de enseñar en función de qué entienden y qué no mis estudiantes
	A-TPACK	<ul style="list-style-type: none"> ● Puedo elegir qué tecnología usar para mejorar la enseñanza de determinado contenido

		<ul style="list-style-type: none">● Puedo ayudar y guiar a otros colegas a coordinar el uso de contenido, tecnologías y distintas estrategias pedagógicas● Soy capaz de usar estrategias que combinan contenido, tecnología y diferentes estrategias de enseñanza que aprendí durante mi formación
--	--	---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------

Como se puede observar en la tabla anterior (tabla 8), el análisis de las encuestas mostró entre los ítems una correlación en línea con las agrupaciones propuestas originalmente en función de la teoría TPACK. Así, por ejemplo, los tres primeros ítems de la tabla fueron incluidos para consultar acerca de los conocimientos del contenido (CC) de las y los docentes. Esos tres primeros ítems muestran una correlación entre sí que, en este trabajo, conforma una dimensión que se denomina conocimiento del contenido autopercebido (A-CC).

Contenido y actitudes de las representaciones en cada dimensión

Para determinar el contenido y actitud de las y los docentes respecto a cada dimensión hallada, se presenta el análisis al interior de cada uno de ellas, tomando en cuenta el grado de acuerdo de las y los participantes.

El proceso de baremación se realizó mediante la suma de las puntuaciones obtenidas en cada dimensión y se establecieron 5 puntos de corte a partir del rango determinado. A continuación, se presenta el análisis de cada una de las dimensiones.

Autopercepción de conocimiento tecnológico (A-CT)

El análisis de dimensión de A-CT indica que el 63,6 % de las y los docentes encuestados se autopercibe “de acuerdo” o “totalmente de acuerdo” al responder sobre su conocimiento tecnológico, como se puede ver en el gráfico de abajo.




Gráfico 2: Dimensión de autopercepción de conocimiento tecnológico (A-CT)

El análisis hacia el interior de la dimensión de autopercepción de CT muestra que una gran cantidad de encuestados (81,8 %) considera que emplea tecnología frecuentemente en su trabajo diario fuera de la docencia, lo que sugiere una familiaridad con las herramientas tecnológicas en otros aspectos de su vida profesional. Sin embargo, si bien el 63,7 % reconoce emplear tecnologías en la preparación de las clases, solo un 45,5 % afirma emplearlas durante las mismas. Estas cifras podrían sugerir una integración poco efectiva de la tecnología en los procesos de enseñanza dentro del aula.

Tabla 10: Ítems de autopercepción de conocimiento tecnológico (%)

		En mi trabajo diario fuera de la docencia utilizo tecnología frecuentemente	En mis clases utilizo tecnología frecuentemente	En la preparación de mis clases utilizo tecnología frecuentemente
Válido	TD	0,0	4,5	4,5
	D	6,8	18,2	4,5
	N	11,4	31,8	27,3
	A	43,2	25,0	43,2
	TA	38,6	20,5	20,5
	Total	100,0	100,0	100,0

Autopercepción de conocimiento del contenido (A-CC)

Al analizar la dimensión de autopercepción de CC, se observa que la gran mayoría de las/os encuestadas/os (88,6%) se posiciona en los rangos de "De acuerdo" o "Totalmente de acuerdo", lo que indica una percepción mayoritariamente positiva en cuanto a la suficiencia de su conocimiento del contenido (Gráfico 3).




Gráfico 3: Dimensión de autopercepción de conocimiento del contenido (A-CC)

El análisis de la actitud hacia el interior de la dimensión autopercepción de CC indica que la gran mayoría de las y los docentes, un 91%, se sienten seguros en cuanto a su conocimiento sobre su área de estudio. Esto sugiere que las y los participantes tienen una percepción positiva acerca de su competencia y dominio en el campo académico al que se dedican. Por otro lado, aunque un porcentaje significativo (68%) reporta leer frecuentemente publicaciones científicas actualizadas sobre los temas que enseñan en el aula, no alcanza el mismo nivel de acuerdo que la percepción de conocimiento sobre el área de estudio. Esta diferencia podría indicar que, si bien las y los encuestados confían en su propio conocimiento, pueden haber variaciones en cuanto a la constancia y profundidad de su actualización científica. Sin embargo, resulta alentador que un amplio 91% se sienta capaz de utilizar una forma de pensar específica de la asignatura que enseñan, lo que sugiere una confianza en sus habilidades para utilizar herramientas cognitivas específicas del campo disciplinar. Además, el 73% de las y los

participantes afirma conocer la historia y el desarrollo de teorías importantes en la materia que enseñan, lo que sugiere una comprensión sólida de los fundamentos teóricos y el contexto histórico de su área de estudio.

Tabla 12: Ítems de autopercepción de conocimiento del contenido (%)

	Tengo suficiente conocimiento sobre mi área de estudio.	Frecuentemente leo publicaciones científicas actualizadas sobre los temas que enseño en el aula.	Puedo utilizar una forma de pensar específica de la asignatura que enseño.	Conozco la historia y el desarrollo de teorías importantes en la materia que enseño.
Válido	0,0	6,8	0,0	0,0
T				
D	2,3	2,3	2,3	4,5
N	6,8	22,7	6,8	22,7
A	50,0	29,5	45,5	45,5
TA	40,9	38,6	45,5	27,3
Total	100,0	100,0	100,0	100,0

Autopercepción de conocimiento pedagógico (A-CP)

En relación con la autopercepción de CP, el 88,6 % de las y los docentes encuestados se percibe “de acuerdo” o “totalmente de acuerdo” al responder acerca de su conocimiento pedagógico. Este alto porcentaje sugiere que la gran mayoría de las y los encuestados se sienten seguros en su capacidad para entender y aplicar diversas estrategias de enseñanza en sus prácticas docentes. Esta percepción positiva puede ser indicativa de una sólida

formación profesional, experiencia en el aula y/o un compromiso con el desarrollo continuo en el campo de la educación.




Gráfico 4: Dimensión de autopercepción de conocimiento pedagógico (A-CP)

Los resultados muestran que un considerable 81,8% de las y los encuestados afirma sentirse capaz tanto de evaluar el desempeño de las y los estudiantes en una clase, como de hacerlo de múltiples formas. Esto sugiere que consideran tener una comprensión sólida de los métodos y herramientas de evaluación disponibles para medir el progreso y el logro de las y los alumnos, así como una variedad de enfoques y técnicas de evaluación utilizadas. Además, un notable 86,4% declara saber cómo adaptar su forma de enseñar en función de lo que consideran que entienden y no entienden sus estudiantes, lo que podría reflejar sensibilidad hacia las necesidades individuales del estudiantado. Por otro lado, un porcentaje ligeramente menor (66%) asegura ser capaz de utilizar una amplia gama de estrategias de enseñanza diferentes. Estas diferencias podrían deberse a que algunos docentes pueden sentirse más cómodos utilizando un conjunto limitado de estrategias que consideran eficaces, mientras que otros pueden

estar más abiertos a explorar y experimentar con una amplia variedad de enfoques pedagógicos.

Tabla 14: Ítems de autopercepción de conocimiento pedagógico (%)

		Sé cómo evaluar el desempeño de los estudiantes en una clase	Puedo evaluar el aprendizaje de las y los estudiantes de múltiples formas	Sé cómo adaptar mi forma de enseñar en función de qué entienden y qué no mis estudiantes	Puedo utilizar una amplia gama de estrategias de enseñanza diferentes
Válido	D	0	2,3	2,3	0,0
	N	18,2	15,9	11,4	34,1
	A	47,7	56,8	59,1	45,5
	TA	34,1	25,0	27,3	20,5
	Total	100,0	100,0	100,0	100,0

Autopercepción de Conocimiento tecnológico y pedagógico del contenido (A-TPACK)

El 47,7% de las y los encuestados se percibe “de acuerdo” o “totalmente de acuerdo” al responder acerca de su conocimiento vinculado a la Integración de la tecnología en la enseñanza para un contenido específico.




Gráfico 5: Dimensión de autopercepción de conocimiento pedagógico y tecnológico del contenido (A-TPACK).

Del análisis de las preguntas relacionadas con el TPACK, se ve que un 54,6% de las y los encuestados afirma ser capaz de utilizar estrategias que combinan contenido, tecnología y diferentes estrategias de enseñanza aprendidas durante su formación inicial o continua. Este porcentaje sugiere que sólo una parte de las y los docentes se siente competente en integrar estas tres dimensiones en su práctica educativa, lo que puede reflejar un nivel poco adecuado de formación y experiencia en este ámbito.

Además, el 56,8% de las y los encuestados declara ser capaz de elegir qué tecnología utilizar para mejorar la enseñanza de un contenido específico. Esto parece indicar una cierta habilidad para identificar y seleccionar herramientas tecnológicas apropiadas que puedan potenciar la enseñanza y el aprendizaje en el aula.

Sin embargo, sólo el 43,2% se siente capaz de ayudar y guiar a otros colegas en la coordinación del uso de contenido, tecnologías y diversas estrategias pedagógicas.

Lo anterior parece sugerir que, aunque algunos docentes pueden sentirse cómodas/os con el uso personal de la tecnología y las estrategias pedagógicas, pueden no estar seguros en su capacidad para liderar y colaborar con otros en la implementación de estas prácticas.

Tabla 16: Ítems de autopercepción de conocimiento tecnopedagógico del contenido (TPACK) (%).

	Soy capaz de usar estrategias que combinan contenido, tecnología y diferentes estrategias de enseñanza que aprendí durante mi formación	Puedo elegir qué tecnología usar para mejorar la enseñanza de determinado contenido	Puedo ayudar y guiar a otros colegas a coordinar el uso de contenido, tecnologías y distintas estrategias pedagógicas
Válido TD	4,5	2,3	6,8
D	2,3	11,4	15,9
N	38,6	29,5	34,1
A	36,4	34,1	25,0
TA	18,2	22,7	18,2
Total	100,0	100,0	100,0

Correlaciones

Dado el carácter amalgamado del concepto de TPACK, se intentó establecer si las dimensiones halladas en la muestra obtenida son independientes entre sí.

Para ello, se realizaron un conjunto de correlaciones entre las dimensiones halladas siguiendo los cinco pasos de prueba de hipótesis:

1- Supuestos

Nivel de medición: nominal/ordinal.

Ho: Parámetros independientes.

Hipótesis teórica: “Existe dependencia entre variables”

Hipótesis nula: “Existe independencia de variables”

2- Distribución de muestreo

Distribución χ^2 (Chi cuadrado)

3- Nivel de significación

Nivel de significación de 0,05

4- Cálculo del estadístico de la prueba

El cálculo de los estadísticos de todas las correlaciones se realizó mediante el software SPSS.

5- Decisión.

Cruzamiento entre las variables A-CC, A-CT y A-CP y A-TPACK.

En el caso de las dimensiones A-CT y A-CC, se observa que existe asociación entre las variables. De acuerdo con los resultados de Chi-cuadrado (47,773) y una significación asintótica de 0,000, se rechaza la hipótesis nula.

Para el caso del cruzamiento de las dimensiones A-CT y A-CP, si bien el valor de Chi-cuadrado es 17,562, la significación asintótica de 0,025 permite asumir la existencia de correlación.

Cuando se buscó correlación entre A-CC y A-CP, se encontró un Chi-cuadrada (27,535) con una significación asintótica de 0,001, nuevamente, muestran la existencia de una correlación entre las variables encontradas.

El cruzamiento de las variables A-CC, A-CT, A-CP con A-TPACK mostró los siguientes resultados:

Tabla 17: Cruzamiento de las variables A-CC, A-CT, A-CP con A-TPACK

	Chi-cuadrada	significación asintótica	Intensidad de la relación
A-CT / A-TPACK	44,000	0,000	0,567
A-CP / A-TPACK	16,000	0,039	0,449
A-CC / A-TPACK	34,674	0,004	0,456

En los tres casos se puede verificar la existencia de correlación. Sin embargo, los coeficientes de intensidad de la correlación muestran que, sólo en el caso del cruzamiento entre A-CT y A-TPACK, se puede decir que esa correlación es alta.

La verificación de la existencia de correlación entre las cuatro dimensiones nos lleva a postular el surgimiento de una variable que agrupa todos los ítems. Dado que este constructo incluye los ítems pensados para consultar acerca de la percepción de TPACK, no se trataría del TPACK mismo por lo que lo llamamos Constructo de Interrelación de Conocimientos Autopercebidos (CICA).

Otros hallazgos

Un aspecto más consultado en la encuesta fue el uso que le dan las y los docentes a algunas herramientas tecnológica en clase presencial (ver gráfico 6).

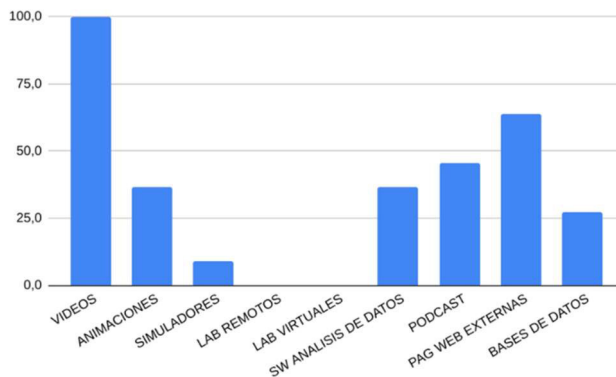


Gráfico 6: Respuestas a la pregunta “¿Utilizo en el aula presencial los recursos listados para facilitar el aprendizaje de algún contenido?”

Cabe destacar que esta fue una de las pocas preguntas que no fueron respondidas por la mayoría de las y los encuestados, por lo que no fue incluida en el análisis completo de la encuesta. Suponemos que esto se debió a que –como se puede ver en las respuestas a las consultas de conocimiento tecnológico– menos de la mitad de las y los docentes utilizan los recursos en el aula. Entre quienes contestaron, todos dijeron utilizar videos en sus clases presenciales y ninguno afirmó utilizar laboratorios remotos ni virtuales, y un porcentaje muy pequeño (sólo 9%) usar simuladores. Se puede observar que los recursos de mayor uso son aquellos con los cuales el estudiantado no interactúa activamente. Si bien esto podría dar alguna idea del nivel de apertura a propuestas de trabajo activo de las y los estudiantes, consideramos que sería conveniente estudiar estos usos en el marco de las propuestas de clase completas para analizar este factor.

Para finalizar la encuesta, se consultó acerca de la asistencia que les gustaría recibir a las y los docentes de parte de la universidad para mejorar su uso de tecnologías educativas en el aula.




Gráfico 7: Respuestas a la pregunta “¿Qué tipo de asistencia considerarás que te sería más útil para mejorar tu uso de tecnologías educativas en el aula?”

A1. Cursos de formación pedagógicos.

A2. Cursos de formación tecnológicos/ de alfabetización digital.

A3. Cursos de formación tecnopedagógica con colegas que trabajan en temas similares a los míos.

A4. Mayor disponibilidad de recursos digitales en la UNAJ.

A5. Acompañamiento en el aula de personas con formación avanzada en tecnología educativa.

Como puede verse en el gráfico 7, la mayor demanda de las y los docentes es por la disponibilidad de recursos tecnológicos, seguida de la formación tecnopedagógica con colegas que trabajen en temas similares a los suyos. Estos resultados difieren ligeramente

de los de la muestra preliminar, en la cual los y las docentes consultados eligieron mayoritariamente la opción A3.

Cabe destacar la poca importancia que le dan los encuestados a los cursos de formación pedagógicos y tecnológicos. Esto parece indicar un reconocimiento de parte de las y los docentes encuestados de la existencia de un campo diferenciado de conocimiento tecnopedagógico situado en el contenido a enseñar, esto es, el TPACK. Es notable también que las y los docentes no solicitan el acompañamiento de expertos en tecnología en el aula.

5.4 Conclusiones

A partir de las encuestas realizadas y del análisis de los resultados obtenidos luego de su aplicación, se lograron construir cuatro dimensiones que consideramos están en relación con los conceptos teóricos: la autopercepción del conocimiento del contenido (A-CC), la autopercepción del conocimiento pedagógico (A-CP), la autopercepción del conocimiento tecnológico (A-CT) y la autopercepción del conocimiento pedagógico y tecnológico del contenido (A-TPACK). Estos constructos fueron entrecruzados mostrando la existencia de una asociación entre las variables, con lo cual se postula el surgimiento de una nueva variable que llamamos Constructo de Interrelación de Conocimientos Autopercibidos (CICA).

Estos resultados respaldan la premisa central del modelo TPACK, que postula que la enseñanza se enriquece cuando las propuestas se construyen en la intersección y la integración sinérgica de estos

tres tipos de conocimiento. Además, demuestran la importancia de considerar no sólo las competencias individuales en cada dimensión, sino también la capacidad de las y los docentes para combinar y aplicar de manera efectiva estos conocimientos en la práctica educativa. Por lo tanto, estos hallazgos subrayan la necesidad de un enfoque holístico en el desarrollo profesional de las y los docentes, que fomente la integración consciente y reflexiva de CP, CC y CT en el diseño y la implementación de experiencias de aprendizaje significativas y efectivas para las y los estudiantes.

Como se mencionó al principio de este capítulo, la investigación que se refiere buscó indagar sobre aspectos en los cuales las y los docentes de UNAJ requieren apoyo para la inclusión de tecnología en sus propuestas pedagógicas tendiente a hacer un uso que resulte en aprendizajes más significativos de sus estudiantes.

En este sentido, el resultado más significativo que se obtuvo fue la información de los niveles de satisfacción que tienen las y los docentes respecto a los tipos de conocimiento sobre los cuales se les consultó.

En relación a esto, un 64% de las y los encuestados se muestra conforme con su conocimiento tecnológico. Si bien parece existir una familiaridad con las herramientas tecnológicas, deducimos que esto se da más en aspectos de la vida profesional que en una integración efectiva de la tecnología en los procesos de enseñanza dentro del aula.

Esto lo vemos en que:

- 82% informa que emplea tecnología frecuentemente en su trabajo diario fuera de la docencia,
- 64% reconoce emplear tecnologías en la preparación de las clases pero solo un
- 46 % afirma emplear herramientas tecnológicas durante las clases.

En relación al conocimiento del contenido, un 89% se posiciona positivamente en cuanto a la suficiencia de su conocimiento. Sin embargo, si bien las y los encuestados confían en su propio conocimiento, pueden haber variaciones en cuanto a la constancia y profundidad de su actualización científica. Además, los resultados sugieren que los y las docentes tienen confianza en sus habilidades para utilizar herramientas cognitivas específicas del campo disciplinar y que tienen una comprensión sólida de los fundamentos teóricos y el contexto histórico de su área de estudio. Las deducciones anteriores se basan en que:

- 91% se siente seguro acerca de sus conocimientos en el área de sus estudios
- 68%, dice leer frecuentemente publicaciones científicas actualizadas sobre los temas que enseñan en el aula
- 91% se siente capaz de utilizar una forma de pensar específica de la asignatura que enseñan

- 73% afirma conocer la historia y el desarrollo de teorías importantes en la materia que enseñan

En relación a su conocimiento pedagógico, las y los docentes también tienen un posicionamiento positivo. Se muestran capaces de entender y aplicar diversas estrategias de enseñanza en sus prácticas docentes lo cual puede hablar de una sólida formación profesional, experiencia en el aula y/o un compromiso con sus prácticas educativas y parecen reflejar sensibilidad hacia las necesidades individuales del estudiantado. Sin embargo, deducimos que algunos docentes son más abiertos que otros a explorar y experimentar con una amplia variedad de enfoques pedagógicos. Esto se deduce de que:

- 82% se considera capaz de evaluar el desempeño de sus estudiantes en clase y de hacerlo de varias formas diferentes.
- 86% dice poder adaptar su forma de enseñar en función de lo que consideran que entienden y no entienden sus estudiantes.
- 66% se sienten capaces de utilizar muchas estrategias de enseñanza diferentes.

Las respuestas respecto a la autopercepción del TPACK son más dispersas que las referidas a los conocimientos por separado. Sólo el 48% refiere un nivel de acuerdo alto o medio alto en relación a este tipo de conocimiento combinado, lo cual parece indicar que sólo una parte de las y los docentes se siente capaz de integrar estas tres dimensiones en su enseñanza. Esto se deduce de que:

- 55% afirma ser capaz de utilizar estrategias que combinan los tres tipos de conocimiento
- 57% responde que se siente capaz de elegir qué tecnología utilizar para enseñar un contenido determinado
- Sólo 43% se siente capaz de acompañar a otros colegas en la coordinación entre los tres tipos de conocimiento (tecnológico, pedagógico y del contenido)

El análisis de la encuesta muestra la existencia de correlaciones entre las variables anteriores. Es decir, se observan correlaciones cruzadas entre las autopercepciones de los conocimientos tecnológico, pedagógico, del contenido a enseñar y los de la dimensión TPACK de las y los docentes de UNAJ encuestados.

Del estudio de las respuestas a los ítems individuales, se ve que las y los docentes muestran mayores niveles de satisfacción respecto a los tipos de conocimientos separados que a las preguntas de la sección TPACK, construidas combinando las dimensiones de conocimiento.

Lo anterior respalda la premisa de que el modelo TPACK es aplicable para las y los docentes de UNAJ y justifica el realizar recomendaciones en las cuales se sugiera ofrecer a las y los docentes cursos que aborden en forma articulada al menos estas tres dimensiones, subrayando la necesidad de un abordaje holístico de la formación docente. Más aún, según los resultados de esta investigación esos cursos de capacitación docente serían mejor recibidos si son impartidos por colegas que trabajen en

temas organizados según el área del conocimiento de las y los docentes que participen.

Bibliografía

Burgoyne, N., Graham, C. R., & Sudweeks, R. (2010). The validation of an instrument measuring TPACK. En D. Gibson & B. Dodge (Eds.), *Proceedings of SITE 2010: Society for Information Technology & Teacher Education International Conference* (pp. 3787–3794). San Diego, CA: Association for the Advancement of Computing in Education (AACE). <https://www.learntechlib.org/p/33971>

Coronado Aguilar, B. L., & Morelos, B. (2019). La formación inicial docente y la enseñanza de las ciencias: Una investigación evaluativa desde el modelo TPACK. Pearson Educación de México, S. A. de C. V.

Flores, F., Ortiz, M., & Buontempo, M. (2018). TPACK: Un modelo para analizar prácticas docentes universitarias. El caso de una docente experta. *REDU. Revista de Docencia Universitaria*, 16(1), 119–136. <https://doi.org/10.4995/redu.2018.8804>

Flores, F., & Ortiz, M. (2019). El modelo TPACK en la praxis docente en la universidad argentina: Conocimientos y prácticas docentes en torno al conocimiento didáctico-tecnológico del contenido (CDTC) en aulas universitarias. *Revista de la Escuela de Ciencias de la Educación*, 15(14), 14–27. ISSN 2362-3349

Harris, J., Grandgenett, N., & Hofer, M. (2012). Testing an instrument using structured interviews to assess experienced teachers' TPA. En Society for Information Technology & Teacher Education International Conference.

Mishra, P., & Koehler, M. (2006). Technological pedagogical content knowledge: A framework for teacher knowledge. *Teachers College Record*, 108(6), 1017–1054.

Morales-Soza, M. (2020). TPACK para integrar efectivamente las TIC en educación: Un modelo teórico para la formación docente. *Revista Electrónica de Conocimientos, Saberes y Prácticas*. <https://doi.org/10.12345/recsp.vi>.

Mouza, C., Karchmer-Klein, R., et al. (2014). Investigating the impact of an integrated approach to the development of preservice teachers' technological pedagogical content knowledge (TPACK). *Computers & Education*, 71, 206–221.

Paidicán Soto, M. (2018). Evaluación de competencias docentes por medio del modelo tecno pedagógico TPACK. *Revista Educativa Internacional*, 1. ISSN 2444-5150. Málaga, España.

Ronau, R. N., Rakes, C. R., & Niess, M. L. (Eds.). (2012). *Educational technology, teacher knowledge, and classroom impact: A research handbook on frameworks and approaches*. IGI Global.

Schmid, M., Brianza, E., & Petko, D. (2020). Developing a short assessment instrument for technological pedagogical content knowledge (TPACK.xs) and comparing the factor structure of an integrative and a transformative model. *Computers & Education*. <https://doi.org/10.1016/j.compedu.2020.103967>

Schmidt, D. A., Baran, E., Thompson, A. D., Mishra, P., Koehler, M. J., & Shin, T. S. (2009). Technological pedagogical content knowledge (TPACK): The development and validation of an assessment instrument for preservice teachers. *Journal of Research on Technology in Education*, 42(2), 123–149.

Torres-Salazar, P. L., & Melamed-Varela, E. (2016). Uso de TPACK como estrategia de transferencia de conocimiento en las universidades. En *Docencia, Ciencia y Tecnología: Un enfoque desde el ser y el hacer*. ISBN: 978-980-6792-93-7.

Trigueros, I. M. G., & De Aldecoa, C. Y. (2021). The digital gender gap in teacher education: The TPACK framework for the 21st century. *European Journal of Investigation in Health, Psychology and Education*, 11(4), 1333–1349. <https://doi.org/10.3390/ejihpe11040097>

Capítulo 6

Conclusiones generales

El presente material consiste en una muestra del trabajo llevado adelante en el Programa TICAPPS entre los años 2017 y 2024. La que sigue es una enumeración no exhaustiva de algunos de los resultados alcanzados por los equipos de trabajo en ese período.

En relación a la línea de implementación de técnicas de visión por computadora y aprendizaje automático en aplicaciones de interés social, se presentan aportes destinados a satisfacer demandas del mundo de la visión por computadora. En este sentido, en el proyecto se viene trabajando en pequeños aportes como la detección de objetos reciclables, el guiado de un robot móvil de forma totalmente autónoma, o el control de un brazo robótico para la separación de objetos reciclables. Todo esto busca contribuir a la implementación de dispositivos totalmente autónomos que automaticen la separación de residuos en origen, la recolección de residuos en lugares públicos, y (a largo plazo) la implementación de un robot explorador que pueda recorrer ambientes totalmente desconocidos. El campo de aplicación de estas tecnologías está experimentando un crecimiento exponencial gracias al avance de las técnicas de inteligencia artificial y las nuevas tecnologías. Se vislumbra por lo tanto como un área prometedora para el trabajo futuro.

Respecto al Internet de las Cosas, es una tecnología que actualmente es utilizable en todo tipo de aplicación que requiera monitoreo, control y acceso remoto. En este sentido se ha implementado un servidor de servicios IoT totalmente personalizado que posibilita la implementación de sistemas OEM (a medida). En el mediano plazo se perfeccionará una serie de aplicaciones, que ya se vienen llevando a cabo, orientadas al cuidado del medioambiente, como el monitoreo de parámetros en arroyos, el monitoreo y seguimiento de cultivos, la calidad de aire en ambientes cerrados y la eficiencia energética. También se están evaluando diferentes medidas de seguridad para evitar la denegación de servicios, el acceso a datos críticos y el robo de información. A largo plazo, se propone realizar investigaciones de aplicaciones basadas en Smart IoT (Internet de las Cosas Inteligentes) implementadas en dispositivos de bajos recursos computacionales.

Por otro lado, en este trabajo se presentan aportes científico-tecnológicos tanto en el área de las energías renovables como el de las herramientas TIC que redundan en métodos y procesos más eficientes de generación de energía eléctrica a partir de recursos energéticos renovables, como la energía solar. Estas contribuciones están relacionadas con la clasificación del cielo a partir del uso de imágenes mediante aprendizaje profundo y con la estimación de la radiación solar bajo diversas condiciones de cielo a través de aprendizaje automático. Ambas temáticas tienen como objetivo el de reducir los costos asociados a la producción energética para que los emprendimientos correspondientes, como los sistemas fotovoltaicos, resulten competitivos y puedan ser

aplicables a nivel local y regional, tanto para actividades domésticas como industriales.

El Programa TICAPPS destina sus propuestas a los actores económicos y productivos del área de influencia de la UNAJ como también a la comunidad educativa de la universidad. La UNAJ evoluciona hacia el fortalecimiento de sus propuestas pedagógicas estimulando cada vez más la inclusión de recursos de las TIC. En este sentido, una área de interés para futuras investigaciones radica en explorar con mayor detalle las contribuciones individuales de cada tipo de conocimiento al conocimiento TPACK. Si bien la investigación que se relata aquí no pudo abordar este aspecto en profundidad, reconocemos la importancia de comprender cómo el conocimiento pedagógico (CP), el conocimiento del contenido específico (CC) y el conocimiento tecnológico (CT) se entrelazan para conformar el marco integral del TPACK. En consecuencia, como investigadoras/es, estamos motivadas/os a profundizar en esta área para examinar cómo cada dimensión de conocimiento impacta en la capacidad general de las/os docentes para integrar de manera efectiva la tecnología en la enseñanza. Explorar estas relaciones aportaría una comprensión más completa de cómo fortalecer la práctica docente.

En base a la experiencia adquirida durante el desarrollo de las líneas de investigación aquí presentadas, es fundamental dar continuidad a los estudios en estos campos a lo largo del tiempo. Esto facilitará la integración de herramientas y análisis innovadores para mejorar el rendimiento óptimo de los diferentes

sistemas analizados. Además, la inclusión de nuevos investigadores en estas líneas resultará crucial. El área de las TIC es innovadora y atractiva, lo que fomenta la participación de estudiantes, graduados o investigadores interesados en estos temas.

Autores

Matías Busum

Ingeniero en Informática del IlyA - UNAJ. Su experiencia de investigación está relacionada con el estudio de herramientas de IoT y visión por computadora.

Christian Botta

Ingénieur en Informática del IlyA - UNAJ. Es docente del IlyA-UNAJ. Es estudiante de doctorado de la UNQ. Su experiencia de investigación está relacionada con el estudio de herramientas de aprendizaje profundo y visión por computadora.

Marcelo A. Cappelletti

Doctor en Ingeniería (UNLP) e Ingeniero en Electrónica (UNLP). Es Profesor Asociado del IlyA-UNAJ. Es Investigador Adjunto CONICET. Es investigador responsable de la línea de estudio “Estrategias y algoritmos de optimización mediante aprendizaje automático aplicadas a sistemas basados en energías renovables” en el marco del Programa de Investigación TICAPPS. Su experiencia de investigación pasada y actual está relacionada con el estudio de dispositivos fotovoltaicos y optoelectrónicos; y el estudio de sistemas reales por medio de técnicas de aprendizaje automático.

Facundo Chazarreta

Ingeniero en Informática del IlyA - UNAJ. Su experiencia de investigación está relacionada con el estudio de herramientas de IoT y visión por computadora.

Jésica V. Guzmán

Ingeniera en Sistemas de la Información de la Universidad Tecnológica Nacional Facultad Regional La Plata (UTN-FRLP). Es docente del IlyA-UNAJ y de la UTN-FRLP. Su experiencia de investigación está relacionada con el uso de herramientas TIC en diferentes aplicaciones.

María Joselevich

Doctora y Licenciada en Ciencias Químicas (FCEyN, UBA). Es Especialista en Educación y Nuevas Tecnologías (FLACSO). Es Profesora Asociada del IlyA-UNAJ y coordinadora del CCC de Licenciatura en Enseñanza de las Ciencias Naturales (IEI, UNAJ). Su área de investigación incluye la incorporación de recursos tecnológicos en la enseñanza y es investigadora responsable de la línea de estudio “Herramientas TIC para el diseño de estrategias educativas” en el marco del Programa de Investigación TICAPPS. Su experiencia de investigación pasada y actual está relacionada con la integración de herramientas tecnológicas en las prácticas de enseñanza.

Diego Miguel Montezanti

Doctor en informática (UNLP) e Ingeniero en Electrónica (UNLP). Es Especialista en Cómputo de Altas Prestaciones y Tecnología (UNLP). Es Coordinador de la materia Sistemas Operativos I de la carrera Ingeniería en Informática del IlyA-UNAJ. Es Co-Director del proyecto de Investigación “Nuevas Tecnologías de IoT y Aprendizaje Automático para la solución de problemas en el medio productivo”. Es Profesor Adjunto del IlyA-UNAJ. Su experiencia de investigación pasada y actual está relacionada con el estudio de sistemas HPC.

Martín Morales

Doctor en Ciencia y Tecnología (UNQ) e Ingeniero en Electrónica (UNLP). Es Especialista en Cómputo de Altas Prestaciones y Tecnología (UNLP). Es Especialista en Docencia Universitaria (UNLP). Es Coordinador de la carrera Ingeniería en Informática del IlyA-UNAJ y Vicedirector del IlyA-UNAJ. Es Profesor Titular del IlyA-UNAJ, Profesor Adjunto en UTN, así como docente de posgrado en la UNQ. Su experiencia de investigación pasada y actual está relacionada con el estudio de herramientas TIC aplicadas en sistemas reales. Es Director del Programa de Investigación TICAPPS.

Lucas M. Olivera

Ingeniero en Informática del IlyA - UNAJ. Es docente del IlyA-UNAJ. Es estudiante de doctorado de la UNQ. Es becario de la Comisión de Investigaciones Científicas de la Provincia de Buenos Aires (CIC-PBA). Su experiencia de investigación está

relacionada con el estudio de herramientas de aprendizaje automático.

Jorge R. Osio

Magister en Ingeniería (UNLP) e Ingeniero en Electrónica (UNLP). Es Profesor Adjunto del IlyA-UNAJ. Es investigador responsable de la línea de estudio “Tecnologías de IoT y Aprendizaje Automático para la solución de problemas en el medio productivo y el cuidado del medio ambiente” en el marco del Programa de Investigación TICAPPS. Su experiencia de investigación pasada y actual está relacionada con el estudio de sistemas digitales, específicamente en el área de la visión artificial e Internet de las Cosas.

Laureano Sabatier

Lic. en Química, Doctor de la Facultad de Ciencias Exactas Área Ciencias Biológicas (UNLP) y Especialista en Enseñanza de las Ciencias Naturales (UDES). Es Profesor Adjunto del IlyA-UNAJ y Titular en la Universidad Provincial de Ezeiza. Es Co-Director del proyecto de Investigación “Inclusión de herramientas de inteligencia artificial para la enseñanza de las ciencias básicas en carreras de ingeniería: una propuesta de investigación -acción en contextos de cambio”.

Mauro D. Salina

Ingeniero en Informática del IlyA - UNAJ. Es docente del IlyA-UNAJ. Es estudiante de doctorado de la UNQ. Su experiencia de investigación está relacionada con el estudio de herramientas de aprendizaje automático.

Juan Salvatore

Ingeniero Electrónico (UNLP) y está especializado en IoT y sistemas embebidos. Es JTP del Instituto de Ingeniería y Agronomía de la UNAJ.

Jorge Segovia

Licenciado en Educación (UNQ) y Profesor en Ciencias Económicas. Participa desde 2017 en proyectos de Investigación dirigidos al análisis de Políticas Públicas en el Nivel Superior y es profesor en los Departamentos de Ciencias Sociales y de Economía (UNQ). Se desempeña en gestión académica en la Dirección General de Posgrado de la UNAJ. Ejerce la docencia desde 2011 en los distintos niveles del Sistema Educativo.

Martín Páez

Estudiante avanzado de Ingeniería Informática del IlyA - UNAJ. Su experiencia de investigación está relacionada con el estudio de herramientas de IoT y visión por computadora.

Lucia Osés

estudiante avanzada de Ingeniería Informática del IlyA - UNAJ.
Su experiencia de investigación está relacionada con el estudio de herramientas de visión por computadora y machine learning.

Braian Pezet

Estudiante avanzado de Ingeniería Informática del IlyA - UNAJ.
Su experiencia de investigación está relacionada con el estudio de herramientas de visión por computadora y machine learning.

Este libro presenta algunos de los resultados del Programa "Tecnologías de la Información y la Comunicación (TIC) en Aplicaciones de Interés Social" (TICAPPS) de la Universidad Nacional Arturo Jauretche (UNAJ).

Desde su creación en 2017, el programa ha desarrollado investigaciones orientadas a resolver problemáticas locales en salud, medio ambiente, educación y producción, en el Conurbano Sur. Mediante la integración de TIC innovadoras como inteligencia artificial, Internet de las Cosas y bioinformática, TICAPPS fortalece los vínculos entre la academia y la sociedad, ofreciendo soluciones tecnológicas de alto impacto.

Esta obra refleja cómo las universidades públicas pueden generar conocimiento transformador y contribuir al desarrollo socio-productivo de su entorno.



OBRAS
COLECTIVAS
SOBRE RESULTADOS/
AVANCES DE
INVESTIGACIÓN

Secretaría de

**Investigación y
Vinculación Tecnológica**

Dirección de

**Gestión de la
Investigación**

