

IoT-Based CO₂ Monitoring and Forecasting System to Prevent Transmission of COVID-19

M. J. Marquez-Zepeda* I. Santos-Ruiz* E. J. Pérez-Pérez*
H. R. Hernández-De León*

* *Tecnológico Nacional de México, I.T. Tuxtla Gutiérrez,
TURIX-Dynamics Diagnosis and Control Group, Carretera
Panamericana km 1080 S/N, Tuxtla Gutiérrez 29050, México;
M21271145@tuxtla.tecnm.mx, ildeberto.dr@tuxtla.tecnm.mx,
esvandejesus@gmail.com, hector.hl@tuxtla.tecnm.mx*

Abstract: This paper presents the development of low-cost CO₂ remote monitoring devices based on NDIR sensors, and the design of a Nonlinear Autoregressive Neural Network (NAR) that forecasts the indoor CO₂ concentration in the short and medium term to avoid risks of SARS-CoV-2 contagion due to the accumulation of poor quality air previously breathed by other people. Different configurations of the NAR were analyzed, varying the number of layers, the number of neurons per layer and the number of input delays. The best network configurations predicted changes in CO₂ concentration in an academic office up to a four-hour horizon with an RMS error around 30 ppm.

Keywords: CO₂; Air Quality; IoT; Remote Monitoring; Forecasting; NDIR Sensor; COVID-19.

1. INTRODUCCIÓN

En la pandemia de COVID-19 causada por el virus SARS-CoV-2 es importante evitar las altas concentraciones de aerosoles (partículas microscópicas exhaladas al hablar o respirar) debido a que son la principal fuente de contagio, como ha sido comprobado en diversos experimentos (Kutter et al., 2021) y publicado por la CDC (2021), la OMS (2020), entre otros organismos sanitarios. Existe evidencia científica de que el SARS-CoV-2 se transmite mediante aerosoles que contienen virus viables exhalados por personas infectadas (Enriquez Jimenez and Pratt Archilla, 2021). El problema se acentúa cuando personas se reúnen en espacios cerrados mal ventilados, pues el riesgo de contagio aumenta con el tiempo y con el número de personas, debido a que el incremento en la concentración de aerosoles ocasiona que aumente la carga viral en el aire (Moreno Grau et al., 2020). Esta situación se presenta en las aulas durante las clases presenciales, donde carecen de las condiciones óptimas para evitar los contagios y mantener una concentración moderada del CO₂. Para ello, es importante monitorear continuamente la concentración de CO₂, además de predecir o pronosticar

cómo evolucionará dicha concentración en un horizonte de tiempo, lo que permite estimar en cuánto tiempo en una determinada sala se alcanzarán niveles de CO₂ que representen un riesgo alto.

El aire limpio que respiramos “al aire libre”, sin contaminación, contiene alrededor de 400 partes por millón (ppm) de CO₂. En la literatura se reportan entre 412 ppm y 420 ppm como nivel de referencia mínimo, según diversas fuentes (Lahrz et al., 2008). Un aire con esta concentración de CO₂ se considera que no ha sido respirado recientemente. Las concentraciones de CO₂ por encima del nivel de referencia indican que el aire ya ha sido parcialmente respirado por alguien, en las proporciones que se indican en la Tabla 1. Por ejemplo, se estima que alrededor de 1.5% del aire ya ha sido previamente respirado por alguien cuando la concentración de CO₂ alcanza 1000 ppm. Por ello, arriba de 1000 ppm existe un alto riesgo de contagiarse de SARS-CoV-2, aunque incluso el CO₂ representa por sí mismo un riesgo sanitario dada su toxicidad (Zemitis et al., 2021; Peng and Jimenez, 2021).

Para evaluar la calidad del aire se debe seleccionar el sensor adecuado. Los sensores NDIR (siglas en inglés de “infrarrojo no dispersivo”) resultan adecuados para medir la concentración de CO₂, ya que las moléculas de este gas son propensas a la absorción de la luz infrarroja. Ya se han realizado evaluaciones sobre los sensores NDIR como opción de bajo costo para la medición de CO₂. Una de estas se realizó en un entorno de laboratorio,

* Esta investigación se desarrolló en el Tecnológico Nacional de México campus Tuxtla Gutiérrez. El trabajo de M. J. Marquez-Zepeda es financiado por el Programa de Becas para Estudios de Posgrado del CONACYT.

Autor correspondiente: ildeberto.dr@tuxtla.tecnm.mx

Tabla 1. Relación entre la concentración de CO_2 y la fracción de aire respirado[†]

Concentración de CO_2	Porcentaje de aire respirado
400 ppm	0 %
600 ppm	0.5 %
700 ppm	0.7 %
800 ppm	1.0 %
1000 ppm	1.5 %
2000 ppm	4.0 %
3000 ppm	6.5 %
4000 ppm	9.0 %

[†] Basado en las recomendaciones IDAEA-CSIC-LIFTEC.

demostrando que, sin ninguna calibración o corrección, los sensores NDIR alcanzan errores RMS entre 5 ppm y 21 ppm comparados con un sensor de precisión (Martin and Bari N. Turpie, 2017). En ese trabajo hallaron que una vez calibrados los sensores NDIR alcanzaban una exactitud de medición cercana a la del sensor de precisión, demostrando ser una opción de buena calidad y bajo costo para aplicaciones en análisis de calidad del aire. Por lo tanto, se justifica el uso de estos sensores para su implementación en sistemas de monitoreo de CO_2 .

Es posible gestionar y analizar las mediciones de CO_2 por diversos métodos. Típicamente, como complemento a los sistemas de monitoreo, se desarrollan aplicaciones de diagnóstico/pronóstico donde los datos son procesados mediante programas especializados (e.g., MATLAB) o servicios de cómputo en la nube, como ThingSpeak, Microsoft Azure y Amazon Web Services, entre otros (Tripathi et al., 2021). El cómputo en la nube ofrece servicios de almacenamiento y análisis de datos para efectuar pronósticos sobre diversas variables físicas mediante técnicas de inteligencia computacional, como las redes neuronales. En (Robin et al., 2021) se evaluaron las redes neuronales convolucionales para monitorear la calidad del aire; por otra parte, Altikat et al. (2020) también utilizó redes neuronales para predecir el paso de CO_2 del suelo a la atmósfera. Recientemente, Kapoor et al. (2022) diseñaron un sistema de monitoreo piloto para CO_2 usando redes neuronales y máquinas de vectores soporte. Sin embargo, la investigación en este campo sigue abierta y aún existen áreas de oportunidad para mejorar los sistemas de monitoreo y pronóstico de CO_2 .

En las secciones subsecuentes se describirá un sistema de monitoreo y predicción de la concentración de CO_2 conformado por módulos sensores/transmisores, denominados “estaciones de monitoreo”, las cuales se conectan inalámbricamente. Las mediciones se almacenan en la nube y son utilizadas como entradas de una red neuronal autorregresiva para estimar los niveles futuros de CO_2 a partir de mediciones previas. Estas estaciones de monitoreo se han instalado en aulas, oficinas y laboratorios del TecNM en Tuxtla Gutiérrez. Con las mediciones de los sensores se generaron datasets para entrenar la red neuronal, con la cual se logró predecir satisfactoriamente

la concentración de CO_2 por periodos de hasta cuatro horas.

En la aplicación que se presenta a continuación se utilizan redes neuronales recurrentes como modelos predictivos para estimar variables del ámbito sanitario. Específicamente, se describe un prototipo que recolecta muestras de una serie de tiempo con concentraciones de CO_2 y una red neuronal que pronostica sus instancias futuras. Entre los retos computacionales al trabajar con las redes neuronales se abordan la selección de la arquitectura y su configuración para obtener el mejor desempeño. El propósito de la aplicación desarrollada es coadyuvar en la planeación de las actividades presenciales en espacios cerrados y prevenir contagios durante la pandemia de COVID-19.

2. METODOLOGÍA

2.1 Medición de la concentración de CO_2

Para medir la concentración de CO_2 en el aire se utiliza un sensor NDIR, el cual es bastante preciso y fácil de calibrar. Este sensor consiste de un tubo, un filtro óptico, un emisor y un detector de infrarrojos (IR), como se muestra en la Figura 1. El emisor produce ondas de luz IR que viajan a través del tubo que contiene la muestra de aire. Las ondas IR se mueven hacia el filtro óptico frente al detector. El detector mide la cantidad de luz IR que pasa a través del filtro.




Figura 1. Sensor de CO_2 NDIR.

La banda de radiación del emisor coincide con la banda de absorción del CO_2 , la cual se ubica alrededor de los 4.26 μm . El espectro de absorción es único, por lo que sirve como firma o huella digital para identificar la molécula de CO_2 .

A medida que la luz IR avanza por el tubo, las moléculas del gas CO_2 absorben la banda característica de 4.26 μm mientras dejan pasar otras longitudes de onda. En el extremo del detector, la luz restante incide en un filtro óptico que absorbe todas las longitudes de onda de la luz, excepto la longitud de onda absorbida por las moléculas de CO_2 en el tubo que contiene la muestra de aire.

Finalmente, el detector recibe la cantidad restante de luz IR que no fue absorbida por las moléculas de CO_2 o por el filtro óptico. Para calcular la concentración de CO_2 se

mide la diferencia entre la cantidad de luz IR radiada por el emisor y la cantidad de luz IR recibida por el detector. Dado que esta diferencia es el resultado de la absorción de la luz por las moléculas de CO₂ en el tubo, es directamente proporcional al número de moléculas de CO₂ en la muestra de aire.

En la estación de monitoreo donde el sensor está embebido se toman en cuenta algunos aspectos para que las mediciones sean lo más exactas posibles, una de ellas es el tiempo de precalentamiento que dura aproximadamente 60 segundos; durante este tiempo los datos no son confiables y no se registran. Además, el sensor debe ser calibrado mediante un proceso que toma como referencia la concentración más baja registrada al aire libre durante un periodo de tiempo. Para comprobar el funcionamiento correcto y la exactitud de cada sensor NDIR, se comparan sus lecturas con un medidor de CO₂ de precisión para validar la calibración.

Las concentraciones de CO₂ registradas por el sensor varían en función de dónde se coloque dentro del espacio monitoreado; para una lectura confiable, considerando la influencia de la ventilación, los sensores se colocan al menos a 120 cm del suelo, a 60 cm de los flujos de aire (ventanas), y a 2 m de las personas dentro de la habitación, según sugieren estudios previos (Nusseck Manfred, 2021).

2.2 Estaciones de monitoreo

Las estaciones de monitoreo captan las mediciones de los sensores para transmitirlos en una red IoT donde convergen las las mediciones de todas las aulas u oficinas monitoreadas. Cada estación se compone de los siguientes elementos:

- Un módulo microcontrolador ESP32, con conexiones inalámbricas WiFi, Bluetooth y LoRa; también permite conexiones cableadas mediante protocolos I2C, UART y SPI.
- Un sensor NDIR modelo MH-Z19D con interfaz serie tipo UART; su rango de detección va de 400 ppm a 10 000 ppm, con un error máximo de 50 ppm.
- Conexión a una red IoT por WiFi o LoRa (radiofrecuencia de largo alcance), dependiendo de la conectividad inalámbrica disponible en cada estación.

El microcontrolador captura los valores detectados por el sensor NDIR y envía los datos en forma inalámbrica para su registro y procesamiento en la nube. El diagrama eléctrico del sistema se muestra en la Figura 2, donde se especifican las conexiones del microcontrolador con el sensor y los indicadores visuales/sonoros utilizados como alarma cuando la concentración de CO₂ sobrepasa los valores seguros.

Para resguardar el sensor y los circuitos, se utiliza un gabinete plástico que contiene todos los componentes de la estación de monitoreo. Considerando la importancia del flujo de aire dentro del gabinete, para asegurar el buen

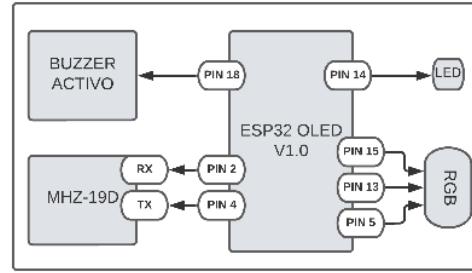


Figura 2. Conexiones en la estación de monitoreo.

funcionamiento del sensor NDIR, se perforaron veinte orificios de 7 mm en cada pared del gabinete, como se muestra en la Figura 3.



Figura 3. Estación de monitoreo.

Las estaciones de monitoreo conforman una red IoT gestionada por ThingSpeak, el cual es un servicio de Cloud Computing administrado por MathWorks. Los datos se almacenan en la nube, desde donde pueden ser actualizados y visualizados mediante la API de ThingSpeak, permitiendo su visualización en computadoras o dispositivos móviles conectados a internet. En la captura de pantalla de la Figura 4 se muestra la interfaz remota de una de las estaciones. El periodo de muestreo del sensor es de un segundo, aunque la actualización de los datos en la nube se hace cada 15 segundos debido a las limitaciones en el ancho de banda y en el espacio de almacenamiento disponible; la latencia en la comunicación es de aproximadamente un segundo, lo que resulta suficiente considerando la frecuencia de actualización de los datos y la dinámica lenta en el espacio monitoreado, pues no existen cambios bruscos en la concentración de CO₂.



Figura 4. Interfaz de monitoreo en ThingSpeak.

2.3 Pronóstico de la concentración de CO₂

El pronóstico de la concentración de CO₂ se realiza utilizando una red neuronal autorregresiva (NAR, por

sus siglas en inglés), la cual es entrenada para estimar los niveles futuros de CO₂ a partir de un determinado número de mediciones previas. Con las concentraciones de CO₂ registradas por las estaciones, se crean series de tiempo para cada aula u oficina monitoreada, las cuales se utilizan para estimar las futuras concentraciones de CO₂ con base en las mediciones más recientes.




Figura 5. Arquitectura neuronal autorregresiva.

Se utilizó una arquitectura de red neuronal autorregresiva no lineal (NAR), bosquejada en la Figura 5, la cual ha demostrado buenos resultados en la predicción con series de tiempo (Aguilar et al., 2020). En esta arquitectura, la salida $y(t)$ (en este caso, la concentración de CO₂ en ppm) se obtiene a partir de sus M muestras más recientes, las cuales se asumen conocidas, adoptando la siguiente relación funcional:

$$y(t) = f(y(t-1), y(t-2), \dots, y(t-M)). \quad (1)$$

La expresión (1) puede ser implementada mediante configuraciones neuronales con diferentes números de capas ocultas y diferentes números de neuronas por capa. Al configurar la red, también debe especificarse el número M de retardos que se usarán en la primera capa de neuronas, el cual se tomó como 100 en este trabajo. Para el aprendizaje (training) de la red neuronal, los datos se dividen en 70% para entrenamiento y 30% para validación. La red se entrenó con el historial de mediciones de tres días muestreadas cada 5 minutos. Adicionalmente, se muestreó un intervalo de tiempo posterior al entrenamiento para evaluar (testing) el desempeño de la red.

Para entrenar la red se utiliza el algoritmo de Levenberg-Marquardt (método de mínimos cuadrados amortiguado), estableciendo un número máximo de 1 000 épocas con un gradiente mínimo de 1×10^{-7} .

Una vez entrenada, el desempeño de la red (i.e., su capacidad de predicción) se mide con la Raíz del Error Cuadrático Medio (RMSE, por sus siglas en inglés):

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

donde y_i es la salida real, \hat{y}_i es el valor pronosticado, y N es el número de muestras en el horizonte de predicción. Para evaluar el desempeño de la red, solo se sustituyen en (2) los nuevos y_i destinados para prueba, es decir, las muestras que no se usaron para entrenamiento.

3. RESULTADOS

En la Figura 6 se muestra un registro del monitoreo remoto correspondiente a una estación, indicando la fecha-hora y la concentración de CO₂. Se trata de un espacio con tasa de ventilación baja, debido a que las puertas y ventanas se mantenían mayormente cerradas con una media de 8 personas durante el día. El nivel de seguridad de 1000 ppm fue superado en diferentes periodos alcanzando niveles mayores que 1500 ppm.

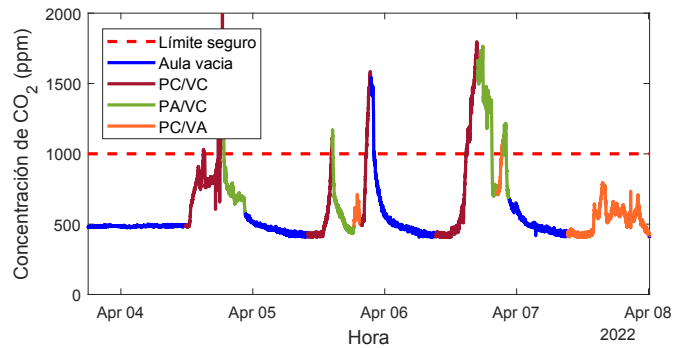


Figura 6. Registro de CO₂ en un aula.

Para facilitar su análisis, la serie de tiempo en la Figura 6 se ha rotulado con las siguientes marcas: PC, puerta cerrada; PA, puerta abierta; VC, ventana cerrada; VA, ventana abierta. La gráfica evidencia la importancia de la ventilación: con la puerta abierta no se sobrepasan los niveles seguros de CO₂, y con la ventana abierta el espacio se satura de CO₂ más lentamente.

Para predecir la evolución a corto y mediano plazo en la concentración de CO₂, se probaron diferentes configuraciones de la red NAR, variando el número de retardos, el número de capas, y el número de neuronas por capa. A continuación se presentan dos configuraciones que produjeron buenos resultados. La primera configuración consiste de cuatro capas ocultas, como se muestra en la Figura 7. En cada paso de tiempo se toman como variables de entrada los últimos 100 registros de la concentración de CO₂ en el espacio monitoreado. Se requirieron 39 épocas para entrenar esta configuración de red.




Figura 7. Configuración NAR 12-11-12-8

La Figura 8 muestra que la red NAR 12-11-12-8 consigue una buena capacidad de predicción, dado que su salida

converge a valores muy cercanos a las mediciones de CO₂ en las horas inmediatas siguientes al entrenamiento. Con esta configuración de red se alcanzó un RMSE de 29 ppm en las muestras de prueba.




Figura 8. Desempeño de la red NAR 12-11-12-8.

En la Figura 9 se muestra cómo disminuye el gradiente del error durante el entrenamiento de la red, hasta alcanzar el valor de 9.4948×10^{-11} en la época 39, superando el gradiente mínimo establecido como parámetro de entrenamiento. Esto representa que los pesos en la red neuronal se han ajustado dentro de los límites de error establecidos.




Figura 9. Gradiente en la red NAR 12-11-12-8.

La segunda configuración de red que se utilizó tiene solo tres capas, como se muestra en la Figura 10. Esta configuración utilizó 61 épocas para su entrenamiento.




Figura 10. Configuración NAR 12-9-9.

La Figura 11 muestra que el pronóstico de los niveles de CO₂ con la nueva configuración es menos certero que con la configuración anterior, lo cual puede deberse a la menor complejidad de la red. Para las mismas fechas-horas que la configuración anterior, la nueva configuración (NAR 12-9-9) mostró un mayor error de predicción y también una mayor variabilidad en la salida. Con esta configuración se alcanzó un RMSE de 46 ppm.

Se probaron otras configuraciones de NAR, pero estas presentaban problemas de sub-entrenamiento al reducir




Figura 11. Desempeño de la red NAR 12-9-9.

a una o dos capas, y de sobre-entrenamiento al superar las cinco capas, obteniendo predicciones menos exactas, es decir, mayores RMSE. También se observó que en los pronósticos por periodos largos el error de predicción aumenta significativamente con todas las configuraciones de red NAR que se probaron. Se demostró, al menos experimentalmente, que la arquitectura de red NAR en este problema está limitada a horizontes de predicción no mayores a cuatro horas.

4. CONCLUSIONES

Se presentó un sistema de monitoreo de CO₂ construido con un microcontrolador ESP32 y un sensor NDIR, soportados por una plataforma de IoT. Los dispositivos para monitorear la concentración de CO₂ son herramientas útiles para conocer la calidad del aire y el riesgo de contagio del virus SARS-CoV-2. Si bien el monitoreo en línea es útil en sí mismo por la posibilidad de generar alarmas cuando se sobrepasan los niveles seguros, las estaciones de monitoreo se complementaron con modelos predictivos basados en redes neuronales, para anticipar los niveles futuros de CO₂ y así prevenir situaciones de riesgo en espacios cerrados con poca ventilación.

El pronóstico se basó en las redes neuronales autorregresivas, las cuales fueron entrenadas con mediciones estructuradas como series de tiempo. Tanto la arquitectura/configuración de la red neuronal propuesta como los datos disponibles para entrenarla fueron determinantes para obtener pronósticos certeros. Sin embargo, como trabajo futuro, también se ha considerado probar otras arquitecturas neuronales (e.g., redes NARX y LSTM), para comparar y elegir la que mejor se desempeñe al pronosticar las concentraciones de CO₂. En este trabajo se observó que un parámetro importante para obtener predicciones precisas es la cantidad de retardos (registros de memoria) usados en la primera capa de la red, así como el número de capas ocultas y de neuronas en cada capa, los cuales se determinaron en forma empírica. Por otro lado, se observó una variación importante en las concentraciones de CO₂ respecto de algunas variables exógenas que no fueron consideradas en esta investigación, por ejemplo, la tasa de ventilación, la cantidad de personas en la habitación y el volumen de esta, por lo

que se plantea como una oportunidad de investigación y desarrollo futuro.

REFERENCIAS

- Aguilar, R.M., Torres, J., and Martín, C. (2020). Red neuronal autorregresiva no lineal con entradas exógenas para la predicción del electroencefalograma fetal. In *XXXVIII Jornadas de Automática: Gijón, 6, 7, y 8 de septiembre de 2017*. Universidade da Coruña. Servizo de Publicacións.
- Altikat, S., Gulbe, A., Kucukerdem, H.K., and Altikat, A. (2020). Applications of artificial neural networks and hybrid models for predicting CO₂ flux from soil to atmosphere. *Int. J. Environ. Sci. Technol. (Tehran)*, 17(12), 4719–4732.
- CDC (2021). Scientific Brief: SARS-CoV-2 Transmission. *Centers for Disease Control and Prevention*.
- Enriquez Jimenez, M. and Pratt Archilla, V. (2021). La Transmisión del SARS-CoV-2 en aerosol y mecanismos de protección. In *Libro Blanco*, 68.
- Kapoor, N.R., Kumar, A., Kumar, A., Kumar, A., Mohammed, M.A., Kumar, K., Kadry, S., and Lim, S. (2022). Machine learning-based CO₂ prediction for office room: A pilot study. *Wireless Communications and Mobile Computing*, 2022.
- Kutter, J.S., de Meulder, D., Bestebroer, T.M., Lexmond, P., Mulders, A., Richard, M., Fouchier, R.A., and Herfst, S. (2021). SARS-CoV and SARS-CoV-2 are transmitted through the air between ferrets over more than one meter distance. *Nature communications*, 12(1), 1–8.
- Lahrz, T., Bischof, W., Sagunski, H., et al. (2008). Gesundheitliche bewertung von kohlendioxid in der innenraumluft. *Bundesgesundheitsblatt, Gesundheitsforschung, Gesundheitsschutz*, 51(11), 1358–69.
- Martin, C.R. and Bari N. Turpie, N.Z. (2017). Evaluation and environmental correction of ambient CO₂ measurements from a low-cost NDIR sensor. *Atmos. Meas. Tech.*, 1–13.
- Moreno Grau, S., Álvarez León, E., García dos Santos Alves, S., Diego Roza, C., Ruiz de Adana, M., Marín Rodríguez, I., Rodríguez-Baño, J., Tomás Carmona, M., Minguillón, M.C., and van der Haar, R. (2020). Evaluación del riesgo de la transmisión de SARS-CoV-2 mediante aerosoles. Medidas de prevención y recomendaciones. Documento Técnico. Ministerio de Sanidad.
- Nusseck Manfred, Richter Bernhard, S.C. (2021). CO₂ measurements in instrumental and vocal closed room settings as a risk reducing measure for a Coronavirus infection. *MedRxiv & bioRxiv*, 2–5.
- OMS (2020). Schools and other educational institutions transmission investigation protocol for coronavirus disease 2019. *World Health Organization*.
- Peng, Z. and Jimenez, J.L. (2021). Exhaled CO₂ as a COVID-19 infection risk proxy for different indoor environments and activities. *Environmental Science & Technology Letters*, 8(5), 392–397.
- Robin, Y., Amann, J., Baur, T., Goodarzi, P., Schultealbert, C., Schneider, T., and Schütze, A. (2021). High-performance VOC quantification for IAQ monitoring using advanced sensor systems and deep learning. *Atmosphere (Basel)*, 12(11), 1487.
- Tripathi, B.S., Gupta, R., and Reddy, S. (2021). Cloud architecture based learning kit platform for education and research—a survey and implementation. In *International Symposium on Ubiquitous Networking*, 172–185. Springer.
- Zemitis, J., Bogdanovics, R., and Bogdanovica, S. (2021). The study of CO₂ concentration in a classroom during the COVID-19 safety measures. In *E3S Web of Conferences*, volume 246, 01004. EDP Sciences.