

# Optimization of the Containment Levels for the Reopening of Mexico City due to COVID-19

Luis Miralles-Pechuán, Hiram Ponce, *Member, IEEE*, and Lourdes Martínez-Villaseñor, *Member, IEEE*

**Abstract**—One of the main problems that governments face in a pandemic is preserving the public health of the country whilst reducing the negative effects on the economy. In tackling the COVID-19 pandemic, there is an implicit trade-off between the economy and the reduction in the number of cases and deaths by the virus. If governmental restrictions to combat the pandemic are very strong, the economy could be seriously damaged. Conversely, if restrictions are very mild to minimize economic losses, it would be very difficult to stop the spread of the virus. It is necessary to find an optimization model to support government decisions balancing the impacts of COVID-19 in health and economic aspects. In this paper, we propose a methodology to find out the optimal number of days per contingency phase, in such a way that public health is prioritized and the damage to the economic impact is reduced. Then, our methodology is applied to one of the most densely populated areas in the world, Mexico City. Our methodology uses an SEIR (Susceptible-Exposed-Infected-Removed) model to simulate the evolution of the pandemic, and it can be implemented utilizing either a genetic algorithm or a Deep Q-Learning algorithm. For the experiments, we propose two scenarios in which the number of days for each phase is predicted within a 120-day period. The first experiment guarantees that the number of beds is not exceeded, considering the economic impact less relevant. By contrast, the second experiment reduces the number of days in which beds are exceeded as long as the economic losses are not higher than 20 %, prioritizing the economy. According to the experiments, the implementation based on genetic algorithms has a higher performance.

**Index Terms**—COVID-19, coronavirus, reinforcement learning, deep q-learning, genetic algorithms, model simulation

## I. INTRODUCCIÓN

La enfermedad del COVID-19 inició en diciembre de 2019 en Wuhan, China y se expandió rápidamente por todo el mundo. La Organización Mundial de la Salud (OMS) declaró esta enfermedad como pandemia el 11 de marzo de 2020 [1]. El 30 de mayo de 2020, se confirmaron un total de 5.9 millones de casos en 188 países y territorios y al menos 365,000 muertos [2]. Desde el inicio de la pandemia, los diferentes gobiernos han estado tomando acciones para contrarrestar los efectos del COVID-19. Con base a los resultados se puede concluir que hay factores que facilitan un mejor manejo de la pandemia como, por ejemplo, la veracidad de la información, las medidas gubernamentales de prevención, la cantidad de pruebas que se realizan y la empatía con la que se afronta la enfermedad [3].

Actualmente, la situación en la que se encuentran los países es muy diversa. Algunos países han conseguido controlar el

coronavirus, reduciendo en gran medida el número de casos confirmados, otros países están cercanos a una disminución de los casos y otros países están todavía en fases críticas en las que los casos de la enfermedad siguen incrementando [4]. Los países que han conseguido reducir el virus han probado que las medidas de distanciamiento social favorecen el aplanamiento de la curva de contagios anderson2020will. Anderson et al. [5] muestran cómo el comportamiento personal y las acciones del gobierno que prohíben reuniones masivas y de rastreo de contacto de los infectados son cruciales en el manejo del COVID-19.

La toma de decisiones de medidas de aislamiento no es una tarea sencilla dado el grave impacto económico que supone el distanciamiento social. Por ello, encontrar las mejores acciones en el momento adecuado es crucial para minimizar el número de muertes y el reducir el impacto económico de la pandemia [6]. Es importante también prevenir que no se sobrepase la capacidad de atención en los hospitales, sobre todo de los pacientes graves, y permitir un regreso a la normalidad gradual para evitar rebrotes que afecten tanto a la salud como a la economía.

Los efectos del COVID-19 varían de acuerdo con las características de cada población. Influyen, entre otros, el tamaño y la densidad de la población, las características étnicas que supongan factores de riesgo, las características del sistema de salud (ej. disponibilidad de unidades de cuidado intensivo) y el grado de movilidad de la población actual.

Como se muestra en la Fig. 1, en la Ciudad de México (CDMX), los primeros casos de COVID-19 aparecieron el 27 de febrero de 2020 y no fue hasta el 23 de marzo cuando el Consejo de Salubridad General reconoce la epidemia en México y establece medidas de prevención para controlarla [7]. En la CDMX, se han registrado el mayor número de casos confirmados del país [8].

Por todo lo anterior, es necesario ofrecer una ayuda en la toma de decisiones que tenga en cuenta cómo se ha comportado realmente la enfermedad en la CDMX y qué consecuencias tendrán dichas decisiones en las actividades primarias, secundarias y terciarias en dicha ciudad como lo proponen Nicola et al. [9]. Nicola et al. [9] presenta un resumen de los efectos socio-economicos derivados de las diferentes decisiones gubernamentales y sugiere una planeación a mediano y largo plazo balanceada tomando en cuenta estos efectos. Para poder estimar el impacto de las intervenciones gubernamentales y proponer soluciones es necesario modelar tanto el desarrollo de la enfermedad como el impacto económico además del modelo de optimización. Este es el problema que nos ocupa en este trabajo.

En este artículo se propone una metodología para combatir

L. Miralles-Pechuán is with CeADAR, University College Dublin. D04 Dublin 4, Dublin, Ireland. E-mail: luis.miralles@ucd.ie

H. Ponce and L. Martínez-Villaseñor are with Universidad Panamericana. Facultad de Ingeniería. Augusto Rodin 498, México, Ciudad de México, 03920, México. E-mail: hponce@up.edu.mx and lmartine@up.edu.mx

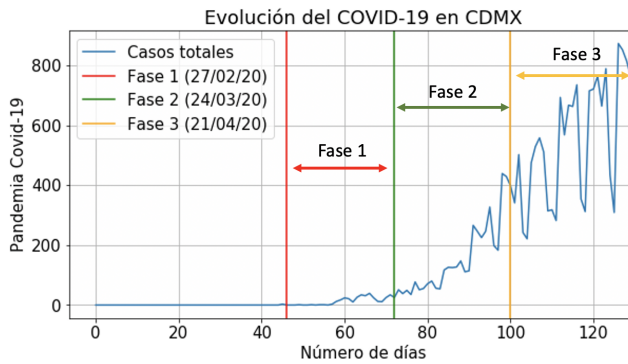


Fig. 1. Evolución del número de casos detectados en la CDMX en cada una de las fases de contingencia.

el COVID-19 que intenta conciliar la economía con la salud pública. El objetivo del estudio es encontrar el número de días óptimo por fases de contingencia en la CDMX de tal manera que se priorice la salud pública y se disminuya el impacto económico. Con la finalidad de analizar las fases de contingencia que el gobierno puede aplicar a la CDMX se proponen: (A) un modelo del comportamiento del virus, (B) un modelo del impacto económico y (C) un método de optimización de la planificación de fases. Para la optimización de las fases de contingencia se utilizaron algoritmos genéticos y aprendizaje por refuerzo (Deep Q-learning). Y se adoptaron las acciones gubernamentales definidas en el Plan gradual hacia la Nueva Normalidad propuestas por el gobierno de la CDMX [10].

La organización del artículo es como sigue. La Sección II presenta una breve revisión de trabajos en los que se analizan las intervenciones gubernamentales de diferentes partes del mundo como Italia, China y Nueva York. La Sección III incluye los fundamentos del modelo epidemiológico y el plan de reapertura de la CDMX. En la Sección IV se describe metodología propuesta usando un modelo epidemiológico, un modelo económico y los modelos de optimización. En la Sección V se describen los experimentos implementados en el trabajo. La Sección VI presenta los resultados y una discusión sobre estos. Finalmente, en la Sección VII se muestran las conclusiones del trabajo.

## II. TRABAJO RELACIONADO

Los investigadores han tratado de estimar el impacto de las intervenciones gubernamentales en diferentes partes del mundo. A continuación, se presenta una breve revisión de los trabajos relacionados que analizan y/o optimizan las medidas de intervención.

Fang et al. [11] simula la dinámica de propagación de la enfermedad por coronavirus y el impacto de las diferentes medidas de control en China. Para ello, adoptaron el modelo de susceptibles-expuestos-infectados-recuperados (SEIR) para la estimación de la dinámica y la potencial propagación basado en los datos de China hasta el 29 de febrero 2020 para calcular el número efectivo reproductivo ( $R$ ). Posteriormente, establecieron la relación entre los valores de  $R$  y la efectividad

de las estrictas medidas de control por parte del gobierno chino.

En Italia, otro de los países con más casos de COVID-19, Giordano et al. [12] propusieron un nuevo modelo para predecir el curso de la epidemia para ayudar a crear una estrategia efectiva de control. En su investigación tomaron como base el modelo de ocho etapas de infección: susceptible ( $S$ ), infectado ( $I$ ), diagnosticado ( $D$ ), enfermo ( $A$ ), reconocido ( $R$ ), amenazado ( $T$ ), sanado ( $H$ ) y extinto ( $E$ ), llamado SIDARTHE. Este modelo busca principalmente diferenciar los infectados entre los diagnosticados y no diagnosticados. El estudio muestra la necesidad de medidas restrictivas para controlar la enfermedad.

En el informe [13], Flaxman et al. diseñaron un modelo jerárquico bayesiano para intentar inferir el impacto de las intervenciones implementadas en once países europeos. Se enfocaron sobre todo en medir el factor de reproducción y sus cambios a raíz de las intervenciones. La proporción de la población infectada hasta el 30 de marzo resultó más alta en España seguida por Italia y menor en Alemania y Noruega.

Hoertel et al. [14] realizaron un modelo de microsimulación con base en un agente estocástico para evaluar el potencial impacto de las medidas gubernamentales en la epidemia de COVID-19 en Nueva York. En dicho modelo, tomaron en cuenta afectar ciertos factores (como la duración de la cuarentena, el levantamiento de restricciones durante la cuarentena, el monitoreo de la cuarentena y una hipotética introducción de tratamiento contra el COVID-19) en la incidencia acumulada de casos, la mortalidad y la ocupación de camas en terapia intensiva.

Mena et al. [15] presentan un tipo de modelo tipo Kermack-McKendrick para evaluar la eficiencia de la declaración de emergencia sanitaria para contener la propagación del COVID-19 en la CDMX tomando en cuenta la escasez e incertidumbre de los datos. Su modelo provee proyecciones basadas en casos confirmados que sitúan la máxima incidencia de casos a finales de mayo y principios de junio de 2020.

En estos trabajos [11], [12], [13], [14], [15] se analizan y evalúan el impacto de las medidas de los diferentes gobiernos en el desarrollo de la epidemia; sin embargo, no estudian el impacto económico que conllevan dichas medidas.

Yang et al. [16] realizan un estudio que define un modelo matemático llamado SEMCR que extiende el tradicional modelo SEIR añadiendo una relación entre los expuestos y los recuperados. El modelo fue evaluado con datos de casos confirmados diarios de Wuhan y Londres y compararon las estrategias para controlar la enfermedad entre ambos países. En Londres tomaron intervenciones híbridas para la supresión y mitigación del virus para conciliar el total de infectados con la pérdida económica.

Khadilkar et al. [17] propusieron una medida cuantitativa para calcular el impacto de decisiones como el aislamiento y liberación teniendo en cuenta la salud pública y la economía. Utilizaron datos públicos de la pandemia en India, aprendieron políticas con un algoritmo de aprendizaje por refuerzo en el contexto de COVID-19 que incluye costos asociados con la salud y la economía.

A la fecha hay muy pocos trabajos como el de Yang et al. [16], y Khadilkar et al. [17] que propongan modelos que traten de balancear los impactos de las decisiones de intervención tanto en la salud como en la economía. En la metodología propuesta de este trabajo, se busca optimizar las acciones gubernamentales en las siguientes fases de contingencia de la nueva normalidad, incluyendo el estudio del impacto de la enfermedad y de la economía.

### III. FUNDAMENTOS

A continuación, se incluyen los fundamentos sobre el modelo epidemiológico a utilizar en el presente trabajo, así como el plan de reapertura considerado por el gobierno de la CDMX.

#### A. Modelos Epidemiológicos

Los modelos matemáticos para enfermedades infecciosas permiten entender y controlar la propagación de un virus en una población. Estos modelos utilizan una serie de variables tales como el periodo de incubación, el promedio de días de infección y la tasa de contacto, empleando un sistema de ecuaciones diferenciales que representa el comportamiento de la epidemia en una población [18], [19]. Este modelo es conocido como SIR [18] y divide la población en tres categorías: Susceptible (S) que representa individuos sanos, Infectados (I) que representa a los individuos que transmiten la enfermedad y Recuperado (R) que son aquellos individuos que se han recuperado o muerto por la enfermedad.

Posteriormente, se propuso el modelo SEIR [20] que incorpora una nueva categoría llamada Expuesto (E). Dicha categoría representa a los individuos que han contraído la enfermedad, pero aún no pueden transmitirla. El modelo SEIR simplifica el comportamiento de la enfermedad mediante (1), donde  $N$  representa el número de individuos de la población, asumiendo que no hay cambios demográficos.

$$N = S + E + I + R \quad (1)$$

En un inicio, la mayoría de los individuos de la población forman parte del grupo  $S$  y dicho grupo va disminuyendo en el tiempo conforme a (2), donde  $\beta$  representa la tasa de contacto del número promedio de individuos que entran en contacto con el grupo  $I$ .

$$\frac{dS}{dt} = -\beta SI \quad (2)$$

Posteriormente, el grupo  $E$  crece mientras que los individuos del grupo  $S$  se van contagiando y se reduce cuando el periodo de incubación finaliza como se expresa en (3), donde  $\alpha$  representa el inverso del promedio del periodo de incubación en días.

$$\frac{dE}{dt} = \beta SI - \alpha E \quad (3)$$

Tal como se muestra en (4), el grupo  $I$  crece mientras el periodo de incubación de  $E$  finaliza. Y disminuye mientras el inverso del tiempo de infección promedio en días,  $\gamma$ , termina.

$$\frac{dI}{dt} = \alpha E - \gamma I \quad (4)$$

En la ecuación (5), se expresa el periodo de recuperación del grupo  $I$ . No se considera posible una nueva infección de los individuos ya recuperados, por lo que al final la mayoría de la población terminará en el grupo  $R$ .

$$\frac{dR}{dt} = \gamma I \quad (5)$$

#### B. Plan de Reapertura de la CDMX

Con la finalidad de reabrir después de la contingencia por COVID-19, el gobierno de la CDMX define las siguientes fases, según el plan [10], como:

- *Fase 0* – Es la fase menos restrictiva del plan de contingencia. Las actividades económicas se encuentran disponibles con medidas de distanciamiento social e higiene, las oficinas de gobierno se encuentran abiertas, regreso de la educación presencial, y espacios públicos abiertos.
- *Fase 1* – Medidas restrictivas que implican actividades económicas al 60% de su ocupación habitual, algunas oficinas de gobierno presenciales y otras en línea, educación a distancia, espacios públicos al 60% de ocupación, y personas vulnerables sin aislamiento pero con seguridad sanitaria prioritaria.
- *Fase 2* – Implica actividades económicas al 30% de su ocupación habitual, actividades de gobierno en línea con atención urgente presencial, educación a distancia, ocupación de espacios públicos al 30% de su capacidad con condiciones estrictas de sanidad, y personas vulnerables en aislamiento.
- *Fase 3* – Es la fase más restrictiva del plan de contingencia. Esta fase implica actividades primarias esenciales, actividades de gobierno en línea, educación a distancia, ocupación de espacios públicos al 30% de su capacidad con restricciones, personas vulnerables en aislamiento y seguimiento epidemiológico activo.

### IV. METODOLOGÍA PROPUESTA

En esta investigación, se propone la siguiente metodología con la finalidad de estudiar la mejor secuencia de acciones gubernamentales (fases) aplicables a la CDMX, la cual incluye: (A) un modelo de la enfermedad, (B) un modelo del impacto económico y (C) un método de optimización de la secuenciación de acciones. En la Fig. 2 se muestra la metodología propuesta. Primero, se adopta el modelo SEIR para la enfermedad COVID-19 en CDMX, en donde los valores de  $\alpha$  (inverso del periodo de incubación) y  $\gamma$  (inverso del tiempo de infección) se ajustan con base en datos reales provistos por el gobierno de México [8]. El valor de  $\beta$  (tasa de contacto con infectados) es ajustado para cada una de las fases a partir del modelo económico propuesto basado en el producto interno bruto del país. Por otra parte, las políticas de acción (fases) se optimizan mediante un método de optimización, tomando el modelo SEIR como parte de la función objetivo. En este trabajo se utilizan el método de algoritmos genéticos y otro basado en aprendizaje por refuerzo deep Q-learning (DQL) para encontrar la mejor secuencia de

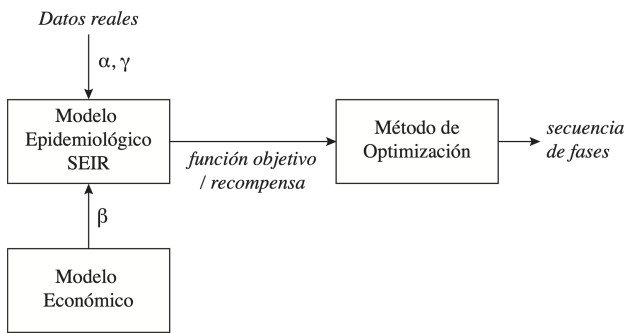


Fig. 2. Metodología propuesta en la optimización de las políticas de acción (fases) en la CDMX. El modelo SEIR se ajusta mediante datos reales ( $\alpha, \gamma$ ) y el modelo económico en cada una de las fases ( $\beta$ ). El modelo SEIR se utiliza como parte de la función objetivo en el método de optimización (AG y DQL) que obtiene el número de días de cada fase en un horizonte de 120 días.

fases. Al final, se obtienen los días de duración de cada fase en un horizonte de 120 días (cuatro meses). A continuación, se detalla la metodología propuesta en el presente trabajo.

#### A. Modelo Epidemiológico de COVID-19

Se propone el uso del modelo SEIR para simular el comportamiento de la epidemia de COVID-19 en la CDMX. Con base en investigaciones anteriores [21], se proponen los valores  $\alpha = 0.1923$  y  $\gamma = 0.0686$  que se utilizaron para crear un modelo con los datos reales de la ciudad facilitados por la página oficial del gobierno de México [8].

Debido a que el valor  $\beta$  depende de las acciones gubernamentales impuestas, este valor cambiará dependiendo de las fases (ver Sección B). Cuanta más interacción haya entre las personas, y cuantas menos restricciones se apliquen, mayor será su valor. Ciertas medidas como el distanciamiento social, el lavado de manos, el uso de mascarillas y el confinamiento pueden reducir su valor en gran medida; lo cual se conjuga con la teoría de inmunidad de rebaño [22]. Dicha inmunidad implica que cuando un gran número de individuos en la población es inmune, el virus va perdiendo capacidad de propagación hasta que la tasa de contagio es menor que uno y desaparece. Esta teoría puede conllevar un elevado número de defunciones; pero tiene un menor impacto negativo en la economía [22]. Por ejemplo, en la Fig. 3 se muestra la evolución de los individuos infectados en cada una de las fases durante un periodo de 180 días. Se puede apreciar que, cuanto más restrictiva es la fase, menor es el contagio.

#### B. Modelo del Impacto Económico en CDMX

Con la finalidad de modelar el impacto económico de las fases de contingencia por efecto de las fases de contingencia, se propone utilizar el porcentaje económico de la CDMX al producto interno bruto (PIB) del país.

El PIB es una magnitud macroeconómica que mide el valor de todos los bienes, servicios, e inversiones producidos en un territorio definido durante un periodo de tiempo. En México, el PIB considera las aportaciones de las actividades primarias (aquellas que satisfacen una necesidad empleando recursos naturales), secundarias (aquellas que transforman los productos

primarios en manufacturas) y terciarias (aquellas que brindan servicios y que son indispensables para la realización de las otras actividades), más los impuestos [23]. La Tabla I muestra los valores del PIB en el primer trimestre de 2020 y el aporte proporcional de cada rubro,  $p_a$ , basado en el PIB anual de 2018 [24].

Con base en las actividades específicas de cada rubro del PIB y basado en las fases de contingencia estipuladas por la CDMX, se proponen los siguientes porcentajes,  $p_c$ , de impacto negativo al PIB en la ciudad por concepto: 0% por actividades primarias; 75% por actividades secundarias tomando en cuenta las actividades 2.a, 2.c y 2.d (Tabla I) y 53.33% por actividades terciarias tomando las actividades 3.a, 3.b., 3.g, 3.h, 3.j, 3.l, 3.m, 3.o (Tabla I). Dicho porcentaje corresponde a la proporción de actividades afectadas de manera uniforme en cada concepto. En este estudio, se consideraron que todas las demás actividades no tienen impacto sobre las fases.

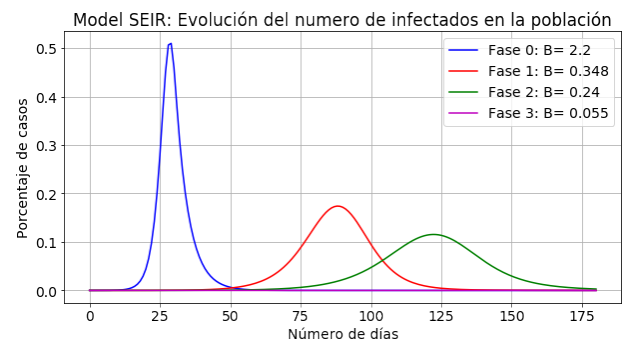


Fig. 3. Evolución para cada una de las fases en una población de 8.9 millones de personas con 200 infectados iniciales para cada una de las fases durante 180 días. En cada fase, el valor  $\beta$  cambia, lo cual impacta en el número de infectados en la población.

TABLA I  
PIB EN EL PRIMER TRIMESTRE DE 2020 EN MÉXICO,  
PRESENTADO POR CONCEPTO DE ACTIVIDAD ECONÓMICA  
[23], [24]

Concepto	Actividad	Aporte (%)
Primarias	1.a Agricultura, cría, pesca, caza	3.34
	2.a Minería	
Secundarias	2.b Energía eléctrica	28.49
	2.c Construcción	
	2.d Industrias manufactureras	
	3.a Comercio al por mayor	
Terciarias	3.b Comercio al por menor	63.78
	3.c Transportes, correo, almacenamiento	
	3.d Información en medios masivos	
	3.e Servicios financieros	
	3.f Servicios inmobiliarios	
	3.g Servicios profesionales y técnicos	
	3.h Corporativos	
	3.i Apoyo a residuos y desechos	
	3.j Educación	
	3.k Salud y asistencia social	
	3.l Cultura, deportes, recreación	
	3.m Hotelería, alimentos, bebidas	
	3.n Otros servicios, no gubernamentales	
	3.o Actividades gubernamentales	
Impuestos		4.39

Con base en las fases de contingencia definidas en el plan de CDMX [10], se proponen los valores de permisibilidad,  $p_p$ , de cada concepto por fase aplicada: 100 % en *Fase 0*, 60 % en *Fase 1*, 40 % en *Fase 2* y 30 % en *Fase 3*. Para la *Fase 2*, el gobierno de la CDMX estipula un umbral del 30 % [10]; sin embargo, como es menos restrictiva que la *Fase 3*, se fijó un valor de 40 %.

Finalmente, se obtiene un valor de impacto económico,  $I_E$ , por fase mediante (6), donde  $A_P$  es la afectación en actividades primarias,  $A_S$  la afectación en actividades secundarias y  $A_T$  la afectación en actividades terciarias. La afectación por actividad  $A_i$  se calcula como (7) donde  $i$  se refiere al concepto.

$$I_E = A_P + A_S + A_T \quad (6)$$

$$A_i = p_{c,i} \times p_{a,i} \times (1 - p_{p,i}) \quad (7)$$

Los valores finales,  $I_E$ , considerados en este modelo de impacto económico son: 0 % para la *Fase 0*, 22 % para la *Fase 1*, 33 % para la *Fase 2* y 39 % para la *Fase 3*.

Por otra parte, para calcular el valor de  $\beta$  en cada fase, se analizaron los datos obtenidos de la página oficial del gobierno de México, específicamente para la CDMX. Con la finalidad de obtener los valores  $\beta$ , se utilizó el modelo SEIR, y se fueron variando los valores hasta encontrar un comportamiento similar a los datos reales. Los valores de  $\beta$  obtenidos se muestran en la Tabla II. Estos valores son muy similares a los de otras investigaciones [21]. El valor de  $\beta$  en circunstancias normales se tomó de algunos estudios de propagación del coronavirus [25].

### C. Formulación del Problema de Optimización

En este trabajo se plantea el uso de un algoritmo genético (AG) y de un método de aprendizaje por refuerzo llamado deep Q-learning (DQL). El método AG ha sido ampliamente usado en la literatura para resolver múltiples problemas de optimización. Por otro lado, este problema se asemeja mucho a una cadena de Márkov donde los estados podrían representarse como el número de infectados en los últimos treinta días y las acciones como la fase asociada con cada día, tal y como se propone al usar DQL.

Para esto, se formuló un problema de optimización mono-objetivo buscando maximizar la función objetivo  $f$  en (8), donde  $T$  es el número total de días,  $I_{E_d}$  es el impacto económico en el día  $d$ ,  $P_d$  es la penalización en el día  $d$  dado por (9) y  $PIB_{diario}$  es el PIB diario. En el caso de la penalización,  $infectados_d$  es el número de infectados obtenidos por el modelo SEIR con valor  $\beta$  referente al día

$d$ ,  $h$  es el porcentaje de pacientes infectados que requieren hospitalización y  $N_{camas}$  es el número de camas disponibles.

$$f = \sum_{d=1}^T [(1 - I_{E_d}) \cdot PIB_{diario} - P_d] \quad (8)$$

$$P_d = \begin{cases} 1 \times 10^9 & infectados_d \times h > N_{camas} \\ 0 & \text{otro} \end{cases} \quad (9)$$

Para el método del AG, se define un individuo *ind* compuesto de cuatro números reales aleatorios  $ind = \{a, b, c, d\}$ . Dichos números se dividen entre la suma de estos para representar el porcentaje de días de forma que la suma de dichos porcentajes dan como resultado la unidad. Cada porcentaje corresponde a cada una de las fases; desde la *Fase 0* hasta la *Fase 3*.

La decodificación del individuo corresponde a una cadena de tamaño  $T$ , que representa el número de días en el periodo  $T$ . Cada elemento de la cadena es el número de fase que le corresponde. Por ejemplo, si se tienen  $a = 0.3$ ,  $b = 0.1$ ,  $c = 0.4$ ,  $d = 0.2$ , esto generará una cadena de tamaño  $T$  donde habrá  $(0.3 \times T)$  elementos cero (*Fase 0*), seguidos de  $(0.1 \times T)$  elementos uno (*Fase 1*), seguidos de  $(0.4 \times T)$  elementos dos (*Fase 2*) y de  $(0.2 \times T)$  elementos tres (*Fase 3*).

El mejor individuo es aquel que consigue obtener la aptitud más alta. La aptitud se calcula como el sumatorio de recompensas durante los  $T$  días de la pandemia. El Algoritmo 1 resume el proceso del cálculo de la aptitud para el AG basado en la función objetivo (8).

### Algoritmo 1 Cálculo de la aptitud para un individuo.

```

1: procedure LA APTITUD REPRESENTA EL SUMATORIO DE RECOMPEN-
   SAS PARA LOS PRÓXIMOS  $T$  DÍAS
2:    $rec\_tot \leftarrow 0$  ▷ Representa a las recompensas totales.
3:    $\alpha \leftarrow 0.1923$  ▷ Inverso del promedio del periodo de incubación.
4:    $\gamma \leftarrow 0.0686$  ▷ Inverso del promedio de tiempo de infectar el virus.
5:   for  $d = 1$  to  $T$  do ▷ Para cada día de los  $T$  que tiene el individuo
6:      $fase \leftarrow ind[d]$ 
7:     if  $fase = 0$  then
8:        $recompensa \leftarrow (1 - I_{E_0}) * PIB_{diario}$ 
9:        $\beta \leftarrow \beta_0$ 
10:    end if
11:    if  $fase = 1$  then
12:       $recompensa \leftarrow (1 - I_{E_1}) * PIB_{diario}$ 
13:       $\beta \leftarrow \beta_1$ 
14:    end if
15:    if  $fase = 2$  then
16:       $recompensa \leftarrow (1 - I_{E_2}) * PIB_{diario}$ 
17:       $\beta \leftarrow \beta_2$ 
18:    end if
19:    if  $fase = 3$  then
20:       $recompensa \leftarrow (1 - I_{E_3}) * PIB_{diario}$ 
21:       $\beta \leftarrow \beta_3$ 
22:    end if
23:    if  $(infectados \times h) > N_{camas}$  then
24:       $recompensa \leftarrow -1 \times 10^9$  ▷ Penalización
25:    end if
26:     $infectados \leftarrow SEIR(\alpha, \beta, \gamma)$  ▷ Calcula el número de
   infectados del siguiente día.
27:     $rec\_tot = recompensa + rec\_tot$ 
28:  end for
29:  return  $rec\_tot$ 
30: end procedure

```

TABLA II  
VALORES DE  $\beta$  CALCULADOS PARA CADA FASE.

Fase	$\beta$
<i>Fase 0</i>	2.200
<i>Fase 1</i>	0.348
<i>Fase 2</i>	0.240
<i>Fase 3</i>	0.055

Para el caso del DQL, el problema se plantea como un proceso de Márkov, donde cada situación de la evolución del

virus representa un estado,  $S = \{s_0, \dots, s_n\}$  donde  $S$  es el número de infectados en los últimos treinta días y cada fase es una de las posibles acciones  $A = \{a_0, \dots, a_m\}$ , que llevan al agente de un estado a otro  $A(s, s')$ , obteniendo una recompensa  $R$ . La solución del problema puede verse como encontrar la política óptima  $Q^*(s, a)$ , que permita obtener el mayor número de recompensas acumuladas desde el estado inicial hasta el final. Y la secuencia de acciones representa las fases para cada día. En este caso, las recompensas son los ingresos económicos estimados y las penalizaciones se obtienen cuando se supera el número de camas.

Para aproximar el valor  $Q(s, a)$  se utiliza una red neuronal (detalles de implementación en Sección V). La red neuronal tiene como entradas los diferentes estados y una acción, y como salida, la recompensa asociada con cada acción para cada estado. La red neuronal evita tener que almacenar todas las posibles acciones en cada estado. Lo cual, implicaría una enorme cantidad de memoria.

## V. EXPERIMENTACIÓN

Para el análisis del impacto de las acciones gubernamentales en la CDMX por COVID-19, se presentan dos experimentos utilizando la metodología propuesta.

Los experimentos han sido diseñados para predecir los periodos de cada fase durante  $T = 120$  días a partir del 1 de junio de 2020. Tal y como se explicó anteriormente, los métodos de optimización buscan optimizar el número de días para cada una de las fases. Para el modelo epidemiológico de COVID-19 en la CDMX se usaron como parámetros  $\alpha = 0.1923$  y  $\gamma = 0.0686$ , así como los valores de  $\beta$  presentados en la Tabla II, para una población de  $N = 8,918,653$  de habitantes en la CDMX. Para el modelo del impacto económico por COVID-19 en la CDMX se utilizaron los valores de afectación  $I_E$  con 0%, 22%, 33% y 39% para las *Fase 0*, *Fase 1*, *Fase 2* y *Fase 3*, respectivamente. El valor  $PIB_{diario}$  utilizado fue de 3,348 millones de dólares por día [24].

El primer experimento se configuró con la prioridad de no sobrepasar el número de camas disponibles en la CDMX, fijado en un valor de  $N_{camas} = 1.5$  por cada mil habitantes. Para dicho fin se aplicó una penalización en las soluciones evaluadas de  $1 \times 10^9$  por cada día que se sobrepasa el límite de camas. Se estimó que un  $h = 5\%$  de pacientes los infectados requieren hospitalización. Este experimento no limitó el efecto negativo en el impacto económico.

El segundo experimento se configuró para dar mayor importancia a la reducción del impacto económico negativo, imponiendo la restricción de que el impacto económico fuera menor o igual al 20% de reducción; por lo que se dejó de recompensar a la solución candidata cuando tuviera una reducción de la economía mayor al 20% del impacto económico. El mismo valor de penalización se utiliza si se rebasa el número de camas disponibles por día.

Para realizar los experimentos, se implementó un algoritmo genético (AG) con los siguientes parámetros: el número de generaciones es 1000, el tamaño de la población es 100, el número de padres es 100 y solamente muta un gen cada vez. La selección del padre es por torneo, la operación cruce es



Fig. 4. Experimento 1: Desempeño de los métodos de optimización basado en el sumatorio del número de recompensas acumuladas durante los 120 días.

uniforme, la mutación es aleatoria. El mejor padre de cada generación pasa directamente a la siguiente, y el tamaño del cromosoma es fijo en cuatro donde cada número representa el porcentaje de días de para cada una de las fases. Esta configuración está recomendada en algunas publicaciones [26].


Para la configuración del algoritmo de RL se usó una ventana de 30 elementos que representa el porcentaje de infectados por día. Se implementó una red neuronal artificial y se implementó el algoritmo típico de aprendizaje Deep Q-Learning (DQL). El agente se entrenó con 1000 episodios y cada diez episodios, se hacía un test con el modelo para medir su rendimiento. La tasa de decaimiento fue de 0.99 y el valor de exploración mínimo de 2%. La red neuronal está compuesta por cuatro capas con 64, 128, 128 y 8 nodos respectivamente, con un optimizador de tipo Adam y una función de pérdida de error cuadrático medio geométrico.

## VI. RESULTADOS Y DISCUSIÓN


En esta sección se muestran los resultados obtenidos en los experimentos descritos anteriormente con la finalidad de encontrar la secuencia de fases que permita reducir tanto el número de infectados por COVID-19 como el impacto económico negativo en la CDMX.

La Fig. 4 muestra el desempeño promedio del resultado de 50 ejecuciones independientes para los dos métodos de optimización empleados en el experimento 1. Para el método AG se obtuvo un valor de aptitud de  $270,846.39 \pm 216.01$ , mientras que para el DQL se obtuvo un valor total de recompensas de  $227,621.48 \pm 63,425.28$ . Para realizar las ejecuciones con las condiciones establecidas, el método AG necesitó 65.31 segundos y el método DQL 156.48 segundos. Con base en esta información, se considera que el método AG tiene un mejor desempeño que el DQL debido a su mayor precisión y menor variabilidad en la solución, así como a su ejecución 1.39 veces más rápida en tiempo. Es importante señalar que el valor de aptitud y la recompensa evalúan el rendimiento de las soluciones tanto para AG como para DQL, pero cada uno desde su propia óptica.

La Fig. 5 muestra la evolución del número de personas que requieren hospitalización por COVID-19 utilizando el modelo SEIR y la mejor solución de optimización realizada por los métodos AG y DQL. Como puede observarse en ambas gráficas de la Fig. 5, el total de infectados que requieren




(a) Resultado por AG.




(b) Resultado por DQL.

Fig. 5. Experimento 1: Evolución del número de infectados que necesitan camas (rojo) basados en las fases planificadas por cada método.



(a) Resultado por AG.



(b) Resultado por DQL.

Fig. 6. Experimento 1: Impacto de las fases en la economía. Cuanto más restrictiva es la fase (fase 3 es la más restrictiva), mayor es el impacto negativo sobre la economía. En línea roja las fases de confinamiento y en línea azul la evolución económica.

hospitalización se mantiene por debajo del número de camas disponibles durante el periodo de simulación. También se puede ver que el número de personas expuestas a la enfermedad incrementa a medida que las fases de contingencia son menos restrictivas.

En la Fig. 6 se muestra el resultado de las fases obtenido con la mejor solución en cada uno de los métodos de optimización. En el primer caso, el método AG calculó la secuencia de fases como: 77 días en *Fase 3*, 41 días en *Fase 1* y 2 días en *Fase 0*. En el caso del método DQL la mejor secuencia tiene: 85 días en *Fase 3* y 35 días en *Fase 1*. Por otra parte, la Fig. 6 también representa la variación del impacto económico en porcentaje. Se puede observar que conforme las fases se vuelven menos restrictivas, la economía tiene un impacto negativo menor, mostrando una tendencia de mejoría con el paso del tiempo. En el caso del método AG muestra una recuperación económica mayor que la del método DQL.

En términos del experimento 2, la Fig. 7 muestra el desempeño promedio de los métodos de optimización. Como puede observarse, el método AG obtuvo un desempeño con un promedio de  $317, 254.51 \pm 115.77$ , mientras que el método DQL no logró encontrar una solución de calidad en ninguna de las 50 iteraciones realizadas durante el tiempo máximo de ejecución. Al método AG le tomó 45.39 segundos, en promedio, encontrar una solución óptima.

La Fig. 8 muestra la simulación del modelo SEIR con las fases obtenidas con la mejor solución del método AG. Como puede apreciarse, el número de infectados crece ligeramente y sobrepasa el número de camas; pero posteriormente se estabiliza. En contraste con la Fig. 9 donde se observa que las fases tienen la siguiente secuencia: 39 días en *Fase 3*, 2 días en *Fase 2*, 37 días en *Fase 1* y 42 días en *Fase 0*. Como puede observarse, las fases son de menor duración, lo cual implica que la recuperación económica también es más rápida.

En la Fig. 10, se muestra el modelo SEIR de la enfermedad utilizando el plan de contingencia anunciado por la CDMX. Como se observa, el número de infectados tarda más en recuperarse en comparación con las fases obtenidas por los métodos de optimización. La Tabla III compara los resultados de ambos experimentos y el plan oficial de la CDMX. Como puede observarse, el experimento 1 muestra un aumento en el impacto económico cercano al plan oficial; mientras que el experimento 2 muestra uno menor (20%).

En comparación con los artículos encontrados que consideran el impacto en la salud y en la economía textcolorredse puede decir lo siguiente. En Khadilkar et al. [17], los autores utilizan un método de optimización de aprendizaje reforzado en el que modelan los costos por cada semana de confinamiento, para el distrito promedio, con el mismo costo económico durante todas las fases simuladas. En cambio, en este trabajo se considera una afectación económica diferente para cada fase a partir de datos oficiales de México. Por otra parte, Yang et al. [16] mencionan las afectaciones económicas, pero realmente no incluyen un modelo económico para calcular la afectación derivada de la aplicación de medidas de restricción en las poblaciones de Wuhan y Londres.




Fig. 7. Experimento 2: Desempeño de los métodos de optimización. Se puede ver que el método basado en RL no es capaz de encontrar soluciones satisfactorias para este problema.




Fig. 8. Experimento 2: Impacto de las fases, según la mejor solución obtenida con los AG, en el número de camas. Hay que recordar que inf (en rojo), representa solo el grupo de infectados que necesitan hospitalización, no el número de infectados totales.

## VII. CONCLUSIONES

En este artículo se ha mostrado cómo optimizar las acciones que un gobierno puede definir para combatir una pandemia. Para ello se propone un modelo de la enfermedad, un modelo del impacto económico y dos métodos de optimización de la secuenciación de acciones; la cual se ha aplicado a la Ciudad de México. La metodología utiliza el modelo SEIR para representar la propagación del virus COVID-19 y una serie de algoritmos de optimización (AG y DQL) para encontrar las acciones óptimas según las preferencias del gobierno. En el primer experimento, se pretendió salvaguardar la salud pública garantizando que el número de camas en los hospitales nunca se excediera. En el segundo, se prioriza la economía realizando un modelo que garantice que ésta no se merme por más de un 20%. Al querer garantizar la salud pública se tienen pérdidas económicas del 32.55% del PIB y cuando se ponen restricciones económicas, gran parte de la población

TABLA III  
COMPARACIÓN DEL NÚMERO DE DÍAS POR FASE EN CADA ESCENARIO.

Fase	Experimento 1	Experimento 2	Plan oficial
Fase 3	77	39	30
Fase 2	0	2	44
Fase 1	41	37	44
Fase 0	2	42	2
Aptitud/Recompensa	271,021	317,375	277,867
Reducción económica	32.6 %	20.0 %	30.0 %




Fig. 9. Experimento 2: Impacto de las fases, según la mejor solución obtenida con los AG, en la economía. Cuanto menos restrictiva es la fase, menor es el impacto negativo sobre la economía. En línea roja las fases de confinamiento y en línea azul la evolución económica.

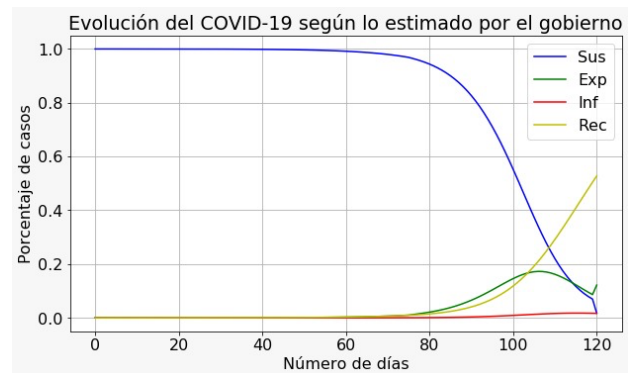


Fig. 10. Impacto de las fases a partir del plan de acción que contempla realizar la Ciudad de México. Se puede ver que a partir del día 100, el número de infectados que necesitan cama sufre un gran aumento. Así como el número de expuestos y recuperados. [10].

se enferma. Los experimentos muestran que el AG muestra mejores soluciones, pero esto se debe a que se han modificado de forma que todas las soluciones generadas cumplen con la condición de cadenas ordenadas de las fases.

La metodología propuesta puede aplicarse a cualquier ciudad o país, pero se necesita hacer un estudio en profundidad de cómo cada fase afecta a la economía y a la transmisión de contagio; además de tomar en cuenta los objetivos que los gobiernos quieran cumplir (como en los escenarios de los dos experimentos presentados). Algunos factores como la mejora de los tratamientos médicos, la concienciación ciudadana, la menor agresividad del virus tras sucesivas mutaciones, o la mejor transmisión por subida de temperaturas y humedad, son factores que podrían disminuir la letalidad del virus y que se podrían considerar en futuras investigaciones. El algoritmo DQL no funcionó bien en el segundo experimento debido al gran número de requisitos impuestos para alcanzar las acciones óptimas. Sería interesante una investigación más profunda en cómo modelar el problema para alcanzar mejores soluciones.

## REFERENCIAS

- [1] T. G. Sarah Boseley, "Who declares coronavirus pandemic," 2020, en línea; Consultado 30 May 2020. [Online]. Available: <https://www.theguardian.com/world/2020/mar/11/who-declares-coronavirus-pandemic>



- [2] Aljazeera, "Coronavirus: Which countries have confirmed cases," 2020, en línea; Consultado 30 May 2020. [Online]. Available: <https://www.aljazeera.com/news/2020/01/countries-confirmed-cases-coronavirus-200125070959786.html>
- [3] F. Avivah Wittenberg-Cox, "What do contries with the best coronavirus responses have in common? women leaders," 2020, en línea; Consultado 30 May 2020. [Online]. Available: <https://www.forbes.com/sites/avivahwittenbergcox/2020/04/13/what-do-countries-with-the-best-coronavirus-reponses-have-in-common-women-leaders/#626226c3dec4>
- [4] EndCoronavirus.org, "Some are winning- some are not: Which countries do best in beating covid-19," 2020, en línea; Consultado 30 May 2020. [Online]. Available: <https://www.endcoronavirus.org/countries>
- [5] R. M. Anderson, H. Heesterbeek, D. Klinkenberg, and T. D. Hollingsworth, "How will country-based mitigation measures influence the course of the covid-19 epidemic?" *The Lancet*, vol. 395, no. 10228, pp. 931–934, 2020.
- [6] R. E. Hall, C. I. Jones, and P. J. Klenow, "Trading off consumption and covid-19 deaths," Stanford University Working Paper, Tech. Rep., 2020.
- [7] D. O. d. I. F. Secretaría de Gobernación, "Dof:23/03/2020," 2020, en línea; Consultado 30 May 2020. [Online]. Available: [https://www.dof.gob.mx/nota\\_detalle.php?codigo=5590161&fecha=23/03/2020](https://www.dof.gob.mx/nota_detalle.php?codigo=5590161&fecha=23/03/2020)
- [8] U. N. A. de México, "Covid-19 monitoreo de casos en méxico por estados," 2020, en línea; Consultado 30 May 2020. [Online]. Available: <https://www.arcgis.com/apps/opsdashboard/index.html#/55176cfbbf47463fbc778c5b5e77fea9>
- [9] M. Nicola, Z. Alsaifi, C. Sohrabi, A. Kerwan, A. Al-Jabir, C. Iosifidis, M. Agha, and R. Agha, "The socio-economic implications of the coronavirus and covid-19 pandemic: A review," *International Journal of Surgery*, 2020.
- [10] G. de la Ciudad de México, "Plan gradual hacia la nueva normalidad," 2020, en línea; Consultado 30 May 2020. [Online]. Available: <https://covid19.cdmx.gob.mx/nuevanormalidad>
- [11] Y. Fang, Y. Nie, and M. Penny, "Transmission dynamics of the covid-19 outbreak and effectiveness of government interventions: A data-driven analysis," *Journal of medical virology*, vol. 92, no. 6, pp. 645–659, 2020.
- [12] G. Giordano, F. Blanchini, R. Bruno, P. Colaneri, A. Di Filippo, A. Di Matteo, and M. Colaneri, "Modelling the covid-19 epidemic and implementation of population-wide interventions in italy," *Nature Medicine*, pp. 1–6, 2020.
- [13] S. Flaxman, S. Mishra, A. Gandy, H. Unwin, H. Coupland, T. Mellan, H. Zhu, T. Berah, J. Eaton, P. Perez Guzman *et al.*, "Report 13: Estimating the number of infections and the impact of non-pharmaceutical interventions on covid-19 in 11 european countries," 2020.
- [14] N. Hoertel, M. Blachier, C. Blanco, M. Olsson, M. Massetti, F. Limosin, and H. Leleu, "Facing the covid-19 epidemic in nyc: a stochastic agent-based model of various intervention strategies," *medRxiv*, 2020.
- [15] R. H. Mena, J. X. Velasco-Hernandez, N. B. Mantilla-Beniers, G. A. Carranco-Sapiéns, L. Benet, D. Boyer, and I. P. Castillo, "Using the posterior predictive distribution to analyse epidemic models: Covid-19 in mexico city," *arXiv preprint arXiv:2005.02294*, 2020.
- [16] P. Yang, J. Qi, S. Zhang, X. Wang, G. Bi, Y. Yang, and B. Sheng, "Feasibility study of mitigation and suppression intervention strategies for controlling covid-19 outbreaks in london and wuhan," *medRxiv*, 2020.
- [17] H. Khadilkar, T. Ganu, and D. P. Seetharam, "Optimising lockdown policies for epidemic control using reinforcement learning," *arXiv preprint arXiv:2003.14093*, 2020.
- [18] W. O. Kermack and A. G. McKendrick, "A contribution to the mathematical theory of epidemics," *Proceedings of the royal society of london. Series A, Containing papers of a mathematical and physical character*, vol. 115, no. 772, pp. 700–721, 1927.
- [19] M. Y. Li and J. S. Muldowney, "Global stability for the seir model in epidemiology," *Mathematical biosciences*, vol. 125, no. 2, pp. 155–164, 1995.
- [20] A. d'Onofrio, "Stability properties of pulse vaccination strategy in seir epidemic model," *Mathematical biosciences*, vol. 179, no. 1, pp. 57–72, 2002.
- [21] F. J. A. Canto and E. J. Avila-Vales, "Fitting parameters of seir and sird models of covid-19 pandemic in mexico," 2020.
- [22] K. O. Kwok, F. Lai, W. I. Wei, S. Y. S. Wong, and J. W. Tang, "Herd immunity—estimating the level required to halt the covid-19 epidemics in affected countries," *Journal of Infection*, vol. 80, no. 6, pp. e32–e33, 2020.
- [23] Instituto Nacional de Estadística y Geografía, "Producto interno bruto de méxico durante el primer trimestre de 2020," Instituto Nacional de Estadística y Geografía, Tech. Rep., 2020.
- [24] —, "Producto interno bruto por entidad federativa 2018," Instituto Nacional de Estadística y Geografía, Tech. Rep., 2018.
- [25] A. Mahmud and P. Y. Lim, "Applying the seir model in forecasting the covid-19 trend in malaysia: A preliminary study," *medRxiv*, 2020.
- [26] T. Back, "Selective pressure in evolutionary algorithms: A characterization of selection mechanisms," in *Proceedings of the first IEEE conference on evolutionary computation. IEEE World Congress on Computational Intelligence*. IEEE, 1994, pp. 57–62.



**Luis Miralles He** is currently working a full-time researcher in data analytics for CeADAR (Centre for Applied Data Analytics Research) at University College Dublin (Ireland) in several projects related to Machine Learning. He is a Computer Engineer with a PhD in Machine Learning and a Postdoc in Data Science. He worked as a full-time Professor/Researcher at the Faculty of Engineering at Universidad Panamericana in Mexico City for several years. He has worked on issues related to data science since 2013, and he has published extensively on these topics. At the beginning of his professional career, he was responsible for the technological part of Project Digitum ([digitum.um.es](http://digitum.um.es))—a Java-based digital repository for the management of research documents of the University of Murcia (Spain).



**Hiram Ponce** He is a full-time professor and researcher in the School of Engineering at Universidad Panamericana (Mexico). He graduated in Mechatronics Engineering at Tecnológico de Monterrey (Mexico), obtained a Master in Science Engineering and a Ph.D. in Computer Science in the same university. He is a member of the National System of Researchers rank level 1 of the National Council of Science and Technology (Mexico). He is author of more than 75 international journal and conference publications, 8 book chapters, and 4 books in the area of artificial intelligence and robotics. He is executive board member of the Mexican Society of Artificial Intelligence (Mexico), member of the Technical Committee on Neural Networks in IEEE Computational Intelligence Society, member of the Technical Committee on Robotics and Mechatronics in IFToMM, among other memberships. He was awarded with a Google Research Award for Latin America in 2017. He has served as guest editor in different special issues of reputed journals. He is currently Associate Editor in IEEE Access.



**Lourdes Martínez-Villaseñor** She is a Computer Systems Engineer and a Doctor in Computational Sciences from Tecnológico de Monterrey, Mexico. She is a research professor in the area of artificial intelligence at the Universidad Panamericana and head of the computing area at the Faculty of Engineering. She has the distinction of rank level 1 of the National System of Researchers of National Council of Science and Technology (Conacyt). She is author of more than 35 international journal and conference publications, 3 book chapters, and 5 books in the area of artificial intelligence. She is a member of the board of Mexican Society of Artificial Intelligence. She has been guest editor in different special issues of international journals. Her main research interests are artificial intelligence applied to human activity recognition and user modelling, and ethics for artificial intelligence.