

# Death prediction model based on supervised artificial learning.

Huarote Zegarra Raúl Eduardo<sup>1</sup>, Vega Luján Yensi<sup>2</sup>, Romero Valencia Mónica Patricia<sup>3</sup>, Castañeda Hilario Aradiel<sup>4</sup>, Flores Masías Edward José<sup>3</sup>, Larios Franco Alfredo Cesar<sup>1</sup>, Jhonatan Isaac Vargas Huaman<sup>5</sup>

<sup>1</sup>Universidad Nacional Tecnológica de Lima Sur, Perú, rhuarote@untels.edu.pe, alarios@untels.edu.pe

<sup>2</sup>Universidad Nacional de Trujillo, Perú, yensi.vega@gmail.com

<sup>3</sup>Universidad Nacional Federico Villarreal, Perú, mromerova@unfv.edu.pe, eflores@unfv.edu.pe

<sup>4</sup>Universidad Nacional del Callao, Perú, aradiel2006@gmail.com

<sup>5</sup>Universidad Privada del Norte, Perú, jhonatan.vargas@upn.edu.pe

*Abstract– This research aims to cover a need to predict the behavior of the number of deaths in a country that has ended quarantine due to Covid-19. To achieve this, a backpropagation neural network was used as a prediction tool. Taking a public database the country Denmark's death data from Covid-19, with the data accumulated in the range of March 16, 2020 to May 10, 2020 being the inputs for the neural network, managing to predict for May 11, 2020 a cumulative of 209 deaths, implying a forecast of 2 deaths of error according to those that have actually been published of accumulated of 210 deaths. This result represents 98.8% effectiveness.*

*Keywords– Backpropagation, decesses, pandemic, quarantine, neural network, covid-19.*

Digital Object Identifier (DOI):

<http://dx.doi.org/10.18687/LACCEI2021.1.1.358>

ISBN: 978-958-52071-8-9 ISSN: 2414-6390

# Modelo de predicción de decesos basado en aprendizaje artificial supervisado

## Death prediction model based on supervised artificial learning.

Huarote Zegarra Raúl Eduardo<sup>1</sup>, Vega Luján Yensi<sup>2</sup>, Romero Valencia Mónica Patricia<sup>3</sup>, Castañeda Hilario Aradiel<sup>4</sup>, Flores Masías Edward José<sup>3</sup>, Larios Franco Alfredo Cesar<sup>1</sup>, Jhonatan Isaac Vargas Huaman<sup>5</sup>

<sup>1</sup>Universidad Nacional Tecnológica de Lima Sur, Perú, rhuarote@untels.edu.pe, alarios@untels.edu.pe

<sup>2</sup>Universidad Nacional de Trujillo, Perú, yensi.vega@gmail.com

<sup>3</sup>Universidad Nacional Federico Villarreal, Perú, mromerova@unfv.edu.pe, eflores@unfv.edu.pe

<sup>4</sup>Universidad Nacional del Callao, Perú, aradiel2006@gmail.com

<sup>5</sup>Universidad Privada del Norte, Perú, jhonatan.vargas@upn.edu.pe

**Abstract**– This research aims to cover a need to predict the behavior of the number of deaths in a country that has ended quarantine due to Covid-19. To achieve this, a backpropagation neural network was used as a prediction tool. Taking a public database the country Denmark's death data from Covid-19, with the data accumulated in the range of March 16, 2020 to May 10, 2020 being the inputs for the neural network, managing to predict for May 11, 2020 a cumulative of 209 deaths, implying a forecast of 2 deaths of error according to those that have actually been published of accumulated of 210 deaths. This result represents 98.8% effectiveness.

**Keywords**– Backpropagation, decesses, pandemic, quarantine, neural network, covid-19.

**Resumen** - La presente investigación pretende cubrir una necesidad de predecir el comportamiento del número de decesos de un país que ha terminado la cuarentena por Covid-19. Para lograr esto se usó una red neuronal backpropagation como herramienta de predicción. Tomando una base de datos pública los datos de decesos del país Dinamarca por Covid-19, siendo los datos acumulados en el rango de 16 de marzo del 2020 al 10 de mayo del 2020 las entrada para la red neuronal, logrando predecir para el 11 de mayo 2020 un acumulado de 209 decesos, implicando un pronóstico de 2 decesos de error según los que realmente han sido publicados de acumulado de 210 decesos. Este resultado representa 98.8% de efectividad.

**Palabras clave**-- Backpropagation, decesos, pandemia, cuarentena, red neuronal, covid-19.

### I. INTRODUCCIÓN

Desde que 31 de diciembre del 2019 [1] informa un conjunto de casos de neumonía en la ciudad de Wuhan (provincia de Hubei, China) determinan que es por un virus. El 30 de enero del 2020 [2] cataloga al COVID-19 formalmente como pandemia por obviamente por los alarmantes niveles de propagación de la enfermedad, por la gravedad en casos infectados y por la inacción de las autoridades involucradas a la protección de la salud. Para [3] el COVID-19 representa riesgos para la salud, es clave tomar medidas de protección para reducir la probabilidad de que las personas se infecten y así mitigar la propagación de nuevas enfermedades por el coronavirus. Los

países podrán tomar sus propias decisiones y adoptar comportamientos positivos para protegerse de enfermedades como COVID-19. En este sentido la presente investigación pretende apoyar en la predicción de la cantidad de decesos por cada país por medio de dos modelos de predicción como es la correlación de datos y usando las redes neuronales artificiales, ya que la información adecuada y oportuna es el primer recurso que permite a la población tomar mejores decisiones para cuidar su salud.

Múltiples investigaciones se han suscitado frente a esta pandemia y en una variedad de campos como la ingeniería, la biología, la alimentación y la medicina, así como el tratamiento de datos estadísticos para evaluar cómo se va comportando índice de contagio en los diferentes países, tal como [4] ha identificado entre otros detalles la tasa de mortalidad en 9 países, resaltando a China como país con alta tasa de mortalidad a pesar de ser el país con menor caso de contagios diarios. También [5] encontró la cantidad de muertes por el coronavirus en exceso referente a su publicación de diferentes países del continente europeo y asiático. También [6] creó el método Algoritmo basado en información del paciente PIBA (Patient Information Based Algorithm) para estimar la tasa de mortalidad y predecir en tiempo real el número de muertes en la población coreana, y que se puede usar para medir eficientemente otras enfermedades infecciosas y que se puede construir en base a información conocida de pacientes tempranamente reportados en diferentes países. También [7] ha hecho un análisis de propagación y predicción del COVID-19 encontrando los valores de los parámetros para un modelo de transmisión del virus logrando establecer 8 días en promedio de tiempo de incubación del virus, tiempo promedio desde la incubación hasta la cura del paciente en 21 días y la tasa de mortalidad en la provincia de Hubei de 4.5%. Así también el modelo propuesto en esta investigación para predecir la mortalidad de un determinado país está basado en redes neuronales artificiales a partir de una base de datos pública.

Por tanto, sabiendo los diferentes ámbitos de aplicación del comportamiento de los decesos por el COVID-19, es un aporte

importante mostrar un modelo de predicción para tener un cierto grado de certeza al momento de tomar una decisión.

## II. PREDICCIÓN

Existe una variada perspectiva acerca de la predicción, ya que la toma de decisiones está inmersa en diferentes áreas de aplicación. Tomando como referencia a [8] también se han utilizado en pronósticos de precios y en la disponibilidad de insumos futuros, tal como se muestra en la Fig 2. En la investigación de [9] usa las redes neuronales artificiales para predecir la lealtad de pasajeros de aerolíneas dando como resultado una certeza de 89% de precisión. Así [10] usó una red neuronal para predecir el momento de aducción de la rodilla en pacientes con osteoartritis usando punto de referencias anatómicas que se pueden obtener a partir del análisis de video 2d, considerando con una precisión de 85%. Así también [11] logró predecir los precios de las acciones en función de las actividades de los comerciantes informados utilizando redes neuronales profundas, logrando que el modelo de un 74% de efectividad. También [12] predice la congestión de tráfico de redes en chip con redes neuronales artificiales con una precisión promedio de 88,28 – 96,25. En otra investigación [13] desarrolla una red neuronal para predecir el desempeño de los proyectos en construcción en Siria, logrando una precisión de 96,1%.

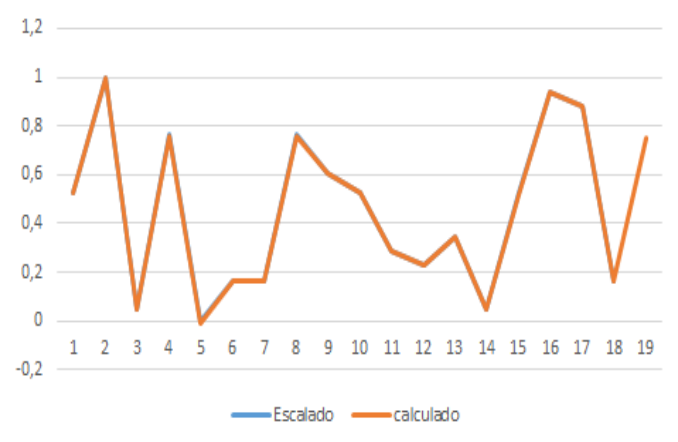


Fig. 1 Ejemplo de predicción de series de tiempo (semanas) de ventas.

## II. COMPORTAMIENTO

Según [14] los sistemas dinámicos que aparecen en la biología, la economía, la física, etc., pueden ser modelados por sistemas de ecuaciones diferenciales. Si  $x$  es el vector de estado del sistema dinámico, su evolución temporal queda descrita por un sistema de ecuaciones diferenciales de la forma como se muestra en la ecuación (1):

$$\dot{x} = f(x, t) \dots\dots\dots(1)$$

Donde:  $f: D \subset R^n \times R \rightarrow R^n$

De acuerdo a estos modelos  $x$  representa el vector de estados del sistema, el cual la dinámica del sistema hace variar en el tiempo, dentro de un espacio euclidiano  $n$ -dimensional que constituye el espacio de estados del sistema dinámico.

## III. DECESOS POR COVID-19

Según [15] proporciona la cantidad de decesos por el COVID-19, siendo el que hasta hoy 10 de mayo del 2020 el que más decesos tiene es Estados Unidos de Norteamérica con 78794, seguido de Reino Unido con 31587 decesos, Italia con 30395 decesos, España con 26478 decesos, Francia con 26310 decesos, Brasil con 10627 decesos. También considerando los países que padecieron el COVID-19 y que ahora reportan mínimo casos de deceso y por tanto han decidido levantar la cuarentena, tales como Republica Checa, Dinamarca, Noruega y Austria, y su estadística de mortalidad desde el 16 de abril del 2020 hasta el 10 de mayo del 2020 se muestra en la siguiente Fig. 2.

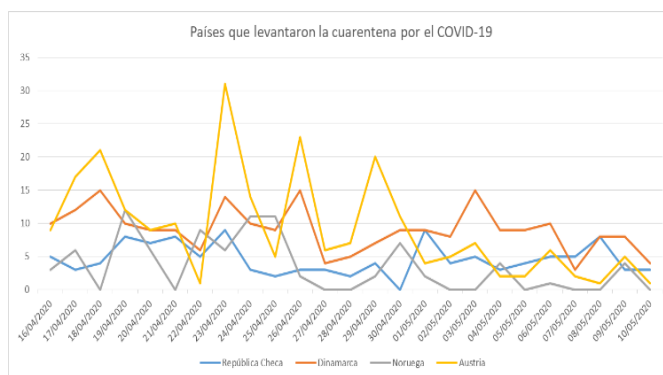


Fig. 2 Datos para la predicción de series de tiempo (por día) de decesos.[8].

Con lo dicho hasta aquí podemos comprender que la aplicación presentada es recomendable y provechosa.

## IV. INTELIGENCIA ARTIFICIAL

Según [16] afirma que la inteligencia artificial puede definirse como “el medio por el cual las computadoras, los robots y otros dispositivos realizan tareas que normalmente requieren de inteligencia humana”, para [17] “es el estudio de cómo lograr que las computadoras realicen tareas que, por el momento, los humanos hacen mejor”, también para [18] “es la rama de la ciencia de la computación que se ocupa de la automatización de la conducta inteligente”, por otro lado [19] es “el medio por el cual las computadoras, los robots y otros dispositivos realizan tareas que normalmente requieren de la inteligencia humana”. También [20] menciona que, “si bien es imposible pronosticar con precisión lo que se puede esperar de esta disciplina en el futuro, es evidente que las computadoras

que posean una inteligencia a nivel humano o superior, tendrán repercusiones importantes en la vida diaria, así como en el devenir de la civilización”.

A. Modelo de red neuronal artificial backpropagation para la predicción de decesos por la pandemia Covid-19

Según [21] las redes neuronales procesan información basadas en las redes neuronales biológicas capaces de resolver funciones no lineales que corresponden a sistemas cuyo comportamiento puede ser complejo y frecuentemente impredecibles, generalmente difíciles (o imposibles) de modelar. También [22] menciona que para aplicar el modelo de redes neuronales artificiales (RNA) se necesita un conjunto de datos de entrada, estos se dividen para: entrenamiento, validación y prueba. También [23] menciona que son sistemas ideados como abstracciones de las estructuras neurobiológicas (cerebros) encontradas en la naturaleza y tienen la característica de ser sistemas desordenados capaces de guardar información. Modelo de red neuronal backpropagation para la predicción del comportamiento de decesos en países por el COVID-19, considerando que para la presente investigación se ha considerado el país de Noruega por que la cantidad de decesos pro día a la fecha se tiene 0.

El modelo para la predicción del comportamiento de decesos en países por el COVID-19 está dado por la estructura de la red neuronal backpropagation de 1 capas de entrada con 2 neuronas (adicionalmente la 1 bía), 2 capas ocultas con 25 neuronas para la capa de entrada a la primera capa oculta, 24 neuronas para la primera capa oculta a la segunda capa oculta y una neurona para la capa de salida.

Si se desea saber un sólo valor pronosticado, necesariamente debe tener una neurona de salida, puesto que debe aprender un valor pronosticado de una serien de tiempo t. Donde el valor de  $t_{n-2}$  representa el valor en un determinado tiempo (anterior al  $t_{n-1}$ ), y el valor de t representa el valor respecto al tiempo actual. El modelo a presentar se muestra en la Fig 3.

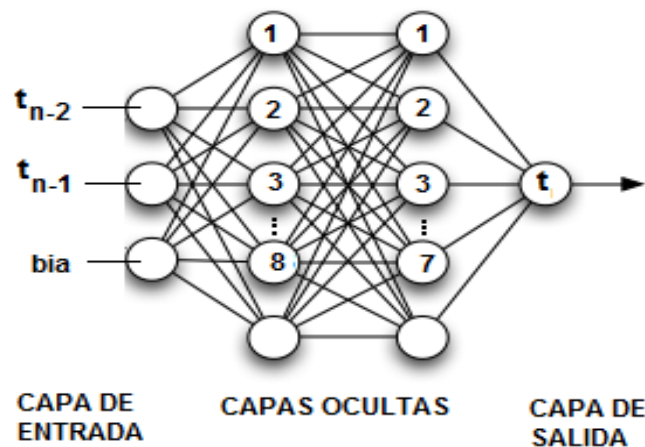


Fig. 3 Modelo de la red neuronal propuesta backpropagation para la predicción.

Escalado de valores de cantidad de decesos acumulados a un rango de [0 a 1] aplicando la ecuación que se muestra en la Tabla I, esto para poder tener la proporción en valores que se pueda ingresar como patrones de entrada para la red neuronal artificial.

TABLA I  
TABLA DE ECUACIONES PARA REALIZAR EL ESCALADO Y EL PROCESO INVERSO.

Ecuación	Detalle	Observación
$r = \frac{Y - Min}{Max - Min}$	r: valor escalado Y: valor a escalar,	Necesario para escalar en el rango de 0 a 1
$Y = r(Max - Min) + Min$	Min: Valor mínimo del conjunto de datos Max: máximo del conjunto de datos.	Necesario para regresar la proporción original en función de r

Donde se muestra converge los resultados aprendido, para ello usa la función sigmoidea, esto para que el proceso de aprendizaje sea suave.

La estrategia para lograr la predicción de valores donde implica la cantidad de decesos, para el proceso de aprendizaje de predicción del deceso, va en función del tiempo, donde  $t_{n-4}$  y  $t_{n-3}$  va a generar  $t_{n-2}$ ,  $t_{n-3}$  y  $t_{n-2}$  va a genera  $t_{n-1}$ ,  $t_{n-2}$  y  $t_{n-1}$  va a generar t, considerando estos antecedentes se puede pronosticar el valor de '?' donde representa  $t_{n+1}$ . Por tanto, para cada valor de va a representar los patrones de entrada y una salida respectiva. Tal como se muestra en la Fig 4:

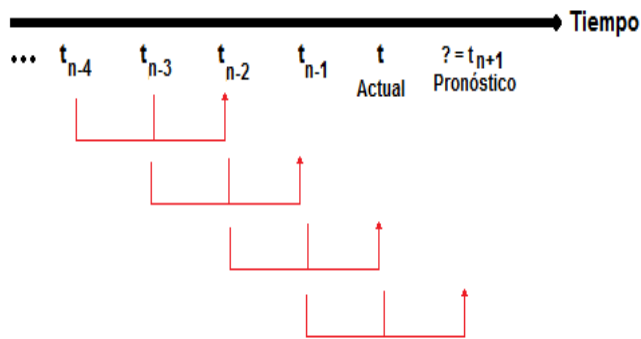


Fig. 4 Línea de tiempo para la obtención de datos.

V. DATOS HISTÓRICOS PARA EL APRENDIZAJE

La fuente obtenida para realizar el proceso de aprendizaje se basa en países que han padecido el COVID-19 y la curva de contagios ha sido baja que las autoridades de estos países han decidido terminar la cuarentena y continuar con las actividades, con mayor grado de vigilancia, según [15] los datos de decesos

por cada país se muestran en la tabla II, el cual se ha tomado el país de Dinamarca.

TABLE II  
DATOS DE DECESOS POR PAÍS QUE TERMINARON LA CUARENTENA HACE 25 DÍAS.

DECESOS POR COVID EN DINAMARCA				
T	Fecha	Por Día	Acumulado	Valor Escalado
t	10/05/2020	0	206	1
t-1	09/05/2020	4	206	1
t-2	08/05/2020	0	202	0,951807229
t-3	07/05/2020	0	202	0,951807229
t-4	06/05/2020	1	202	0,951807229
t-5	05/05/2020	0	201	0,939759036
t-6	04/05/2020	4	201	0,939759036
t-7	03/05/2020	0	197	0,891566265
t-8	02/05/2020	0	197	0,891566265
t-9	01/05/2020	2	197	0,891566265
t-10	30/04/2020	7	195	0,86746988
t-11	29/04/2020	2	188	0,78313253
t-12	28/04/2020	0	186	0,759036145
t-13	27/04/2020	0	186	0,759036145
t-14	26/04/2020	2	186	0,759036145
t-15	25/04/2020	11	184	0,734939759

t-16	24/04/2020	11	173	0,602409639
t-17	23/04/2020	6	162	0,469879518
t-18	22/04/2020	9	156	0,397590361
t-19	21/04/2020	0	147	0,289156627
t-20	20/04/2020	6	147	0,289156627
t-21	19/04/2020	12	141	0,21686747
t-22	18/04/2020	0	129	0,072289157
t-23	17/04/2020	6	129	0,072289157
t-24	16/04/2020	3	123	0

## VI. ANÁLISIS DE DATOS

En función de los datos obtenidos de la Tabla II se va a realizar el análisis considerando la predicción por la red neuronal backpropagation.

Cabe resaltar que se hizo la pruebas dando resultados alentadores, de los 25 valores originales (lo que representa del día 16 de abril del 2020 al 10 de mayo del 2020) donde es representado en posiciones, pronosticado para t+1 obteniendo los resultados de la Tabla III, donde el valor pronosticado para t+1 está dado por 1,018920403 que representa en 207,570393 (obtenido por realizar el proceso inverso del escalado  $y=r(\text{Max-Min})+\text{Min}$ ) de posición.

TABLE III  
PRUEBAS REALIZADAS A LOS VALORES QUE SON PARTE DE ENTRENAMIENTO CON SU VALOR PROPORCIONAL.

T	Fecha	Acumulado Real	Valor Escalado	Valor obtenido	Escalado Inverso (predecido)	Error de aprendizaje
t+1	11/05/2020	210		1,018920403	207,570393	2,429607
t	10/05/2020	206	1	1,013514527	207,121706	-1,1217058
t-1	09/05/2020	206	1	1,010947443	206,908638	-0,9086377
t-2	08/05/2020	202	0,951807229	1,010947443	206,908638	-4,9086377
t-3	07/05/2020	202	0,951807229	1,009420956	206,781939	-4,7819393
t-4	06/05/2020	202	0,951807229	1,008739216	206,725355	-4,7253549
t-5	05/05/2020	201	0,939759036	1,002087586	206,17327	-5,1732697
t-6	04/05/2020	201	0,939759036	0,998926418	205,910893	-4,9108927
t-7	03/05/2020	197	0,891566265	0,998926418	205,910893	-8,9108927
t-8	02/05/2020	197	0,891566265	0,995109964	205,594127	-8,594127
t-9	01/05/2020	197	0,891566265	0,977716937	204,150506	-7,1505058
t-10	30/04/2020	195	0,86746988	0,964229461	203,031045	-8,0310453
t-11	29/04/2020	188	0,78313253	0,961689487	202,820227	-14,820227
t-12	28/04/2020	186	0,759036145	0,961689487	202,820227	-16,820227
t-13	27/04/2020	186	0,759036145	0,955633396	202,317572	-16,317572
t-14	26/04/2020	186	0,759036145	0,911460053	198,651184	-12,651184
t-15	25/04/2020	184	0,734939759	0,824276824	191,414976	-7,4149764
t-16	24/04/2020	173	0,602409639	0,739884832	184,410441	-11,410441
t-17	23/04/2020	162	0,469879518	0,621726339	174,603286	-12,603286
t-18	22/04/2020	156	0,397590361	0,574821972	170,710224	-14,710224
t-19	21/04/2020	147	0,289156627	0,496660266	164,222802	-17,222802
t-20	20/04/2020	147	0,289156627	0,276472721	145,947236	1,05276418

Digital Object Identifier: (only for full papers, inserted by LACCEI).  
ISSN, ISBN: (to be inserted by LACCEI).  
DO NOT REMOVE

t-21	19/04/2020	141	0,21686747	0,189905358	138,762145	2,23785529
t-22	18/04/2020	129	0,072289157	0,088576896	130,351882	-1,3518824
t-23	17/04/2020	129	0,072289157	0,143289157	134,893	-5,893
t-24	16/04/2020	123	0	0	123	0

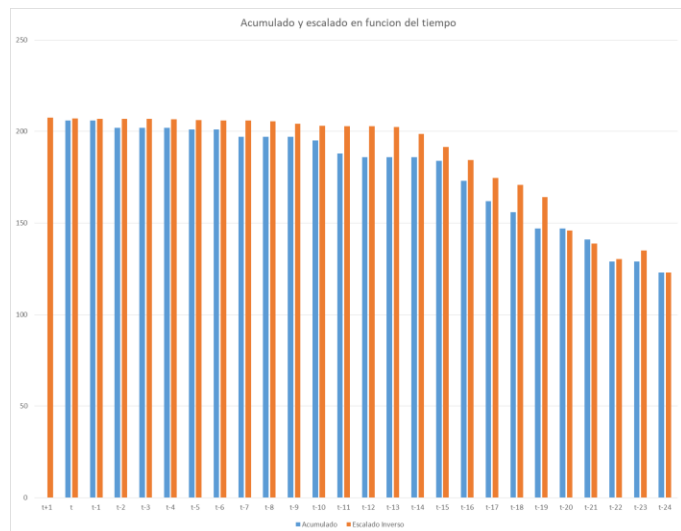


Fig. 5 Comportamiento del caso real y el predicho

En la Fig. 5, muestra los datos respecto a la tabla III, donde recorre en función del tiempo t-24 hasta t+1, considerando que t-24 es el primer caso que se va a realizar el aprendizaje, y t+1, es el caso predicho, ya que la información que se cuenta esta dado por los datos en el tiempo de t-24 hasta t, por tanto el recorrido en función del tiempo el valor acumulado que no es más el valor real de decesos en el país de Dinamarca, y el escalado inverso es el valor de resultado de aprendizaje. Por tanto se aprecia en la Fig. 6 el error de la comparativa del caso real y el aprendido, donde el valor error máximo es 15 por defecto y el valor mínimo es 1 por exceso.

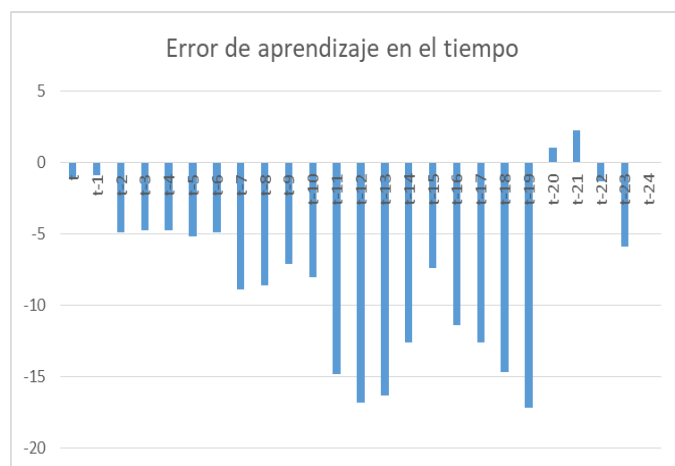


Fig. 6 Error en el aprendizaje en función del tiempo

## VI. CONCLUSIONES

Para la predicción usando red neuronal artificial backpropagation, el pronóstico de los decesos en el país de Noruega, fueron alentadores en el sentido de similaridad con la realidad, considerando los datos históricos de los decesos anteriores a la fecha 11/05/2020, y en dicha fecha ha dado como resultado la cantidad de decesos predichos de 207.57 (208 personas), el cual implica un error frente a la realidad de 2,429607 (2 personas) lo que representa el 98.8% de certeza, con similares resultados de certeza de predicción en las investigaciones de [9], [10] y [12] teniendo a favor 89%, 85% y 88.25% respectivamente, esto se refleja como resultado comparativo del valor real con el predicho basado en redes neuronales artificiales.

## AGRADECIMIENTO

Agradecimiento a todos los participantes de la presente investigación, con el fin de cubrir una necesidad de predecir sucesos basado en inteligencia artificial, específicamente en la red neuronal artificial backpropagation y poder tomar mejores decisiones.

## REFERENCES

- [1] Organización Mundial de la Salud. (2020, May 10). "Neumonía de causa desconocida - China". [Online]. Available: <https://www.who.int/csr/don/05-january-2020-pneumonia-of-unknown-cause-china/es/>.
- [2] Organización Mundial de la Salud. (2020, May 10). "La OMS caracteriza a COVID-19 como una pandemia". [Online]. Available: [https://www.paho.org/hq/index.php?option=com\\_content&view=article&id=15756:who-characterizes-covid-19-as-a-pandemic&Itemid=1926&lang=es](https://www.paho.org/hq/index.php?option=com_content&view=article&id=15756:who-characterizes-covid-19-as-a-pandemic&Itemid=1926&lang=es)
- [3] Organización Panamericana de la Salud. (2020, May 10). "COVID-19: Materiales de comunicación" [Online]. Available: <https://www.paho.org/es/covid-19-materiales-comunicacion>.
- [4] L. Chic-cheng, W. Cheng-Li, H. Shun-Chung, K. Wen-Chien and H. Po-Ren. "Global epidemiology of coronavirus disease 2019 (COVID-19): disease incidence, daily cumulative index, mortality, and their association with country healthcare resources and economic status" Taiwan, 2020.
- [5] The Economist. (2020, April 28). "Tracking covid-19 excess deaths across countries". [Online]. Available: <https://www.economist.com/graphic-detail/2020/04/16/tracking-covid-19-excess-deaths-across-countries?fsrc=scn%2Ftw%2Fte%2Fb1%2Fed%2Fcovid19datatrackingovid19excessdeathsacrosscountriesgraphicdetail&fbclid=IwAR2EeHtM0o4k8kSVA9nqTdkI9TuwdEUUnQpXLHBOwnKHUipg5PjZK1hmnGLE>
- [6] W. Lishi, L. Jing, G. Sumin, X. Ning, Y. Lan, C. Yanhong, W. Sara, C. Scott, G. Carolyn, G. Tianshu, J. Jiafu, G. Weikuan and S. Dianjun. "Real-time estimation and prediction of mortality caused by COVID-19

- with patient information based algorithm”, Science of The Total Environment, Volume 727, 20 July 2020, 138394.
- [7] L. Lixiang, Y. Zihang, D. Zhongkai, M. Cui, H. Jimgze, M. Haotian, W. Deyu, C. Guanhua, Z. Jiakuan, P. haipeng and S. Yiming. “Propagation analysis and prediction of the COVID-19”. Infectious Disease Modelling, Volume 5, 2020, Pages 282-292.
- [8] Michel, L. &. (2013). Comparison of Statistical Models for Analyzing Wheat Yield Time Series. Estados Unidos: PLoS ONE.
- [9] Balgopal Singh, “Predicting airline passengers’ loyalty using artificial neural network theory”, Journal of Air Transport Management, Volume 94, 2021, 102080, ISSN 0969-6997, <https://doi.org/10.1016/j.jairtraman.2021.102080>.
- [10] M.A. Boswell, S.D. Uhlrich, L. Kidziński, K. Thomas, J.A. Kolesar, G.E. Gold, G.S. Beaupre, S.L. Delp, "A neural network to predict the knee adduction moment in patients with osteoarthritis using anatomical landmarks obtainable from 2D video analysis", Osteoarthritis and Cartilage, Volume 29, Issue 3, 2021, Pages 346-356, ISSN 1063-584, <https://doi.org/10.1016/j.joca.2020.12.017>.
- [11] Haejung Na, Soonho Kim, "Predicting stock prices based on informed traders’ activities using deep neural networks", Economics Letters, Volume 204, 2021, 109917, ISSN 0165-1765, <https://doi.org/10.1016/j.econlet.2021.109917>.
- [12] Aqib Javed, Jim Harkin, Liam McDaid, Junxiu Liu, "Predicting Networks-on-Chip traffic congestion with Spiking Neural Networks", Journal of Parallel and Distributed Computing, Volume 154, 2021, Pages 82-93, ISSN 0743-7315, <https://doi.org/10.1016/j.jpdc.2021.03.013>.
- [13] Rana Maya, Bassam Hassan, Ammar Hassan, "Develop an artificial neural network (ANN) model to predict construction projects performance in Syria", Journal of King Saud University - Engineering Sciences, 2021, ISSN 1018-3639, <https://doi.org/10.1016/j.jksues.2021.05.002>.
- [14] Sachin S. Thakur, M. S.-O. (2017). *Stably engineered nanobubbles and ultrasound - An effective platform for enhanced macromolecular delivery to representative cells of the retina*. Union Europea: Alfred S Lewin, Editor.
- [15] European Centre for Disease Prevention and Control. (2020, May 10). “Download today’s data on the geographic distribution of COVID-19 cases worldwide”. [Online]. Available: <https://www.ecdc.europa.eu/en/publications-data/download-todays-data-geographic-distribution-covid-19-cases-worldwide>
- [16] Gómez, R., La inteligencia Artificial ¿Hacia dónde nos lleva? ¿Cómo lo vez?, México, UNAM, 2013.
- [17] Elaine Rich y Knight Kevin. Inteligencia Artificial. Segunda Edición. McGraw Hill: México, 1994.
- [18] Luger, G., Stubblefield W., Artificial Intelligence: Structures and Strategies for Complex Problem Solving, BC, 1993.
- [19] G. H. Renato, “La inteligencia artificial. ¿Hacia dónde nos lleva? ¿Cómo ves?” México: UNAM, 2013.
- [20] P. P. Cruz, “Inteligencia artificial con aplicaciones a la ingeniería”, México: Alfaomega Grupo Editores S.A. de C.V., México, 2010.
- [21] Rivas-Asanza, Wilmer & Mazon-Olivo, Bertha & Mejia, Fernando. (2018). Capítulo 1: Generalidades de las redes neuronales artificiales.
- [22] Cervantes Osornio, R., Arteaga Ramírez, R., Vázquez Peña, M. A., & Ojeda Bustamante, W. (2016). *Red neuronal artificial backpropagation versus modelos empíricos*. Mexico: Mexicana de Ciencias Agrícolas
- [23] WayBacjk Machine. (15 de 08 de 2016). Obtenido de [http://info.fisica.uson.mx/amulfo.castellanos/archivos\\_html/quesonredneu.htm](http://info.fisica.uson.mx/amulfo.castellanos/archivos_html/quesonredneu.htm)