

Predicción de niveles de pH urinario en pacientes con recurrencia de litiasis renal utilizando Deep Learning

Itcel-Moncerrat Romero-Salas
División de Ingeniería en
Sistemas Computacionales
Tecnológico de Estudios
Superiores de Ecatepec
Estado de México, México
moncerrat.mebarak@tese.edu.mx

Francisco-Jacob Ávila-Camacho
División de Ingeniería en
Sistemas Computacionales
Tecnológico de Estudios
Superiores de Ecatepec
Estado de México, México
fjacobavila@tese.edu.mx

Adolfo Melendez-Ramirez
División de Ingeniería en
Sistemas Computacionales
Tecnológico de Estudios
Superiores de Ecatepec
Estado de México, México
adolfo_melendez@tese.edu.mx

Juan-Manuel Stein-Carrillo
División de Ingeniería en
Sistemas Computacionales
Tecnológico de Estudios
Superiores de Ecatepec
Estado de México, México
jmsteinc@tese.edu.mx

Abstract—Alterations in the pH level represent an important factor in the formation of kidney stones, urinary pH <5.5 can induce the formation of crystals of uric acid or calcium phosphate, and pH > 6.0 induces the development of calcium oxalate stones. For this reason, keeping a check on the pH levels influences as a preventive way to avoid the development of kidney diseases. In Mexico, few epidemiological studies have been conducted on kidney stones. A national survey carried out by the Mexican Institute of Social Security (IMSS) reported an average prevalence of lithiasis of 2.4 / 10,000 inhabitants. Few patients diagnosed for the first time with stones receive preventive therapy to prevent recurrence (second occurrence). Consequently, it is necessary to have the support of a risk prediction tool for a second episode of kidney stones. Knowing future values of the pH level of a patient diagnosed with the first episode of kidney stones or one diagnosed with recurrence, contributes to optimizing current treatment strategies. In this paper a novel approach and a prototype are proposed to predict the future pH levels for patients to help people as well as physicians to create a good treatment to prevent consequences on time. After evaluating the proposed approach, a prediction level of 99.99% were reached with a loss of 0.0013.

Keywords—urinary pH, neural networks, LSTM, kidney stone

I. INTRODUCCIÓN

La litiasis renal es una patología frecuente que padecen entre el 5 y el 12% de la población en los países industrializados antes de los 70 años de edad [1]. Las potenciales secuelas generan nefrolitiasis, la cual es considerada una infección con factor de riesgo para la enfermedad renal crónica [2]. Los niveles de pH urinario proporcionan información relevante para médicos que buscan determinar si los tratamientos y las medidas que se han tomado son satisfactorias en el tratamiento de los pacientes, cuando los niveles de pH indican lo contrario, deberán realizarse ajustes para mantener al paciente en buen estado de salud y lo más alejado posible de los altos costos hospitalarios que la enfermedad genera [3].

La orina está formada por varias sustancias que normalmente se encuentran en estado de equilibrio, coadyuvando a que sean aprovechadas y absorbidas por el

organismo y este a su vez, ayuda a que puedan ser eliminadas fácilmente, a través de las vías urinarias [4].

Los problemas se originan cuando se rompe ese equilibrio debido a la modificación de la concentración de las sustancias que la componen, lo anterior da lugar a la formación de cristales [5].

Uno de los factores que se encuentra más relacionado con la formación de piedras en el riñón, es el nivel de pH urinario ya que el cambio influye en la solubilidad y cristalización de los distintos componentes presentes en la orina. Cuando estos cristales se quedan atascados en el tejido renal y aumentan de tamaño, entonces se habla de cálculos renales [6].

Existen cinco grandes grupos de cálculos renales: [5], [6]

- Ácido úrico: formados por un exceso de proteínas en la orina y una acidez urinaria inferior a pH 5,5.
- Fosfato cálcico: formados principalmente por una alta concentración de calcio en la orina y una orina generalmente alcalina con valores de pH superiores a 6,2.
- Oxalato cálcico: compuestos por calcio y oxalato, su aparición depende de una formación cristalina previa, comúnmente ácido úrico o fosfato cálcico. Las litiasis más frecuentes (80%) son las cálcicas, mayoritariamente de oxalato cálcico, pero hasta el 40% son mixtas (oxalato y fosfato cálcico) [7].
- Estruvita: formados por fosfato, calcio y magnesio y son relacionados con la presencia de bacterias en una infección urinaria, y su nivel de pH es > 6.5 [8].
- Cistina: formados por un exceso de cistina en la orina, se recomienda mantenerlo en niveles alcalinos por encima de pH 7,5 [9].

Los cálculos de fosfato, cálcico, oxalato cálcico los más frecuentes y predominan en los menores de 60 años [8]. Se ha producido un aumento progresivo en la prevalencia de litiasis durante las últimas 4 décadas siendo los países industrializados

los más afectados [10]. Para evitar su primera formación o que vuelvan a aparecer, como es el caso de la recurrencia, se recomienda llevar un control muy estricto del pH urinario y para mantenerlo en un nivel óptimo de seguridad, los niveles ideales del pH de la orina deben estar en un rango entre 5,5 y 6,2 [11], [12].

Es importante monitorear y controlar el pH urinario para prevenir y tratar la litiasis renal de acuerdo con las necesidades de cada paciente [13].

En [14] se han presentado investigaciones que apuntan a una tasa de recurrencias que se sitúa entre el 26 % y el 53% a los 10 años y a lo largo de la vida entre el 60 y el 80%, [7] otras investigaciones realizadas en 2016 determinan que el porcentaje será en del 11% durante los primeros dos años, 20% a los cinco años y 31% a los 10 años [14].

La Organización Mundial de la Salud (OMS) y la Unión Internacional de Telecomunicaciones (UIT) tienen un objetivo común: adaptar las últimas tecnologías de la información y de la comunicación (TIC) para aplicarlas a la salud en beneficio de los ciudadanos, con efectos cuantificables [15]. Ya que las TIC juegan un papel muy importante en la seguridad del paciente suponiendo una reducción de los errores médicos, evitando morbilidades asociadas a tratamientos no adecuados, y mejorando la asistencia mediante una medicina basada en la evidencia (MBE) [16].

Una de las principales motivaciones para la aplicación de las tecnologías de la información por las organizaciones sanitarias, públicas y privadas, se encuentra en la mejora de la eficiencia en la gestión, así como en la automatización de los procesos de diagnóstico y el control de los avances en la recuperación y mejora de los pacientes [17].

Las TIC son como un árbol del cual se desprenden diferentes ramas y de una de ellas florece la Inteligencia artificial y esta a su vez está compuesta por ramas adicionales. Dentro de una de ellas se ubican las redes neuronales artificiales que son modelos computacionales conformados por un grupo interconectado de nodos los cuales representan cada neurona artificial encargada de ejecutar operaciones y la red en su totalidad simula la estructura de un cerebro biológico [18].

Las redes neuronales recurrentes, LSTM Long Short Term Memory, se utilizan principalmente para el análisis y predicción de series temporales [19]. En este sentido, se propone crear una solución, con redes neuronales recurrentes, que en base a los niveles históricos del nivel de pH en la orina para pacientes con litiasis recurrente, se puedan predecir valores futuros para obtener un panorama para que el médico pueda anticipar estrategias tanto en el tratamiento farmacológico, como en la dieta alimenticia de sus pacientes.

A partir del momento en que el médico conoce valores futuros de nivel de pH, puede recurrir a tratamientos alternativos que incluyan complementos alimenticios que favorezcan un adecuado equilibrio ácido-base de la orina asegurando así, un diagnóstico completo basado en necesidades específicas.

Por lo tanto, al conocer valores específicos de manera anticipada, con su correspondiente atención adecuada se vuelve factible contribuir a la disminución de la tasa de recurrencia.

Para implementar la solución propuesta, se desarrolló un prototipo para medición de pH urinario y un modelo de predicción basado en redes neuronales recurrentes, el cual se describe en las siguientes secciones.

II. PROPUESTA DE SOLUCIÓN

A. Recolección de muestras

El método utilizado para la recolección de muestras fue la recogida de muestras por micción espontánea limpia.

Dentro de los diferentes tipos de recolección de orina este método tiene el porcentaje de preferencia de un 80% debido a que es una técnica fácil, barata, no invasora y eficiente [20]. Aunado a lo anterior, se tomaron en cuenta los lineamientos para la toma, manejo y envío de muestras de un paciente femenino para diagnóstico a la Red nacional de laboratorios de salud pública [21], [22].

Se recolectaron las muestras durante un mes para un paciente de sexo femenino realizando las mediciones de pH urinario con el prototipo de medición y posteriormente se contrastaron con un siguiente mes de muestras. El registro de mediciones se conservó durante el mes para realizar las predicciones para el siguiente día y la siguiente semana, todo ello se validó durante el mes adicional.

B. Diseño del Prototipo de medición

Para la construcción del prototipo se utilizó un electrodo sensor de pH con su interfaz PH2.0 para conexión con Arduino, el cual tiene una precisión de 0.1pH.




Fig. 1 Cableado de conexión del Arduino y el electrodo sensor de pH

La salida del electrodo sensor de pH es en voltios, por lo que se utilizó la placa Arduino para el procesamiento de las señales analógicas, la siguiente imagen muestra una tabla con la relación del voltaje con el nivel del pH.

Voltaje (mV)	Valor pH	Voltaje (mV)	Valor pH
414.12	0.00	-414.12	14.00
354.96	1.00	-354.96	13.00
295.80	2.00	-295.80	12.00
236.64	3.00	-236.64	11.00
177.48	4.00	-177.48	10.00
118.32	5.00	-118.32	9.00
59.16	6.00	-59.16	8.00
0.00	7.00	0.00	7.00

Fig. 2 Relación del voltaje del electrodo y el valor del pH

El electrodo fue sumergido durante un minuto en la muestra de orina fresca para obtener el valor del nivel del pH. El total de datos obtenidos por muestra fue de 68 durante el minuto de registro.

C. Calibración del electrodo

La calibración del sensor es importante y se fue considerada como mantenimiento rutinario, se llevó a cabo usando soluciones tampón de calibración (buffers) con valores cercanos al del proceso y a la temperatura establecida que indica cada solución de acuerdo con lo que establece la guía de calibración del sensor [23].

En esta investigación, se utilizaron soluciones buffer 4.0 y 6.68 a una temperatura de 25°C.

Los valores leídos durante todas las mediciones se fueron almacenando en un archivo de texto separado por comas tipo CSV para su posterior entrenamiento del modelo de predicción y en donde se registró también la fecha de cada muestra.

III. MODELO DE PREDICCIÓN BASADO EN REDES NEURONALES RECURSIVAS

El modelo principal se creó con una red neuronal recurrente con arquitectura LSTM, (Long-Short Term Memory) para evitar el estancamiento a la hora de realizar el análisis y predicción de series temporales. Tomando de esta forma una secuencia de entrada para generar una secuencia de salida.

A. Arquitectura de la red LSTM

La figura 3, muestra el diagrama de la red LSTM con 4 capas (cajas amarillas) y de operaciones puntuales (cajas verdes) especialmente la suma de vectores.




Fig. 3 Arquitectura de la red LSTM

Cada línea lleva un vector completo, desde la salida de un nodo hasta las entradas de otros. El éxito de las redes LSTM,

está en el estado de las celdas (C_t), (línea roja). El estado recorre todo el diagrama con interacciones lineales menores y tiene la facultad de eliminar o agregar información al estado de la celda y es regulado por estructuras llamadas puertas cuya función es dejar fluir la información.

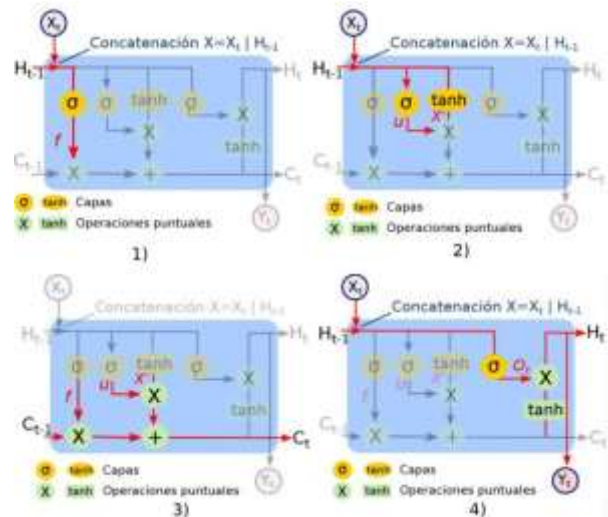


Fig. 4 1) Forget layer, 2) capa de puerta de enlace y valores candidatos, 3) nueva celda y 4) salida y la nueva salida

LSTM, se compone de 3 puertas y se componen de una capa de red neuronal llamada sigmoide (σ) y una operación puntual de multiplicación (líneas verdes del diagrama).

Las LSTM constan de cuatro etapas, como se muestra en la figura 4.

En la etapa 1, se elige la información que arroja el estado de la celda mediante una capa sigmoide llamada "Forget gate layer" (f).

La concatenación X de h_{t-1} y la entrada X_t genera una salida (0-1) para cada valor en el estado de la celda C_{t-1} , donde 1 indica "mantenerlo por completo" y -1 "deshacerlo por completo".

La expresión que define lo anterior es:

$$f = \sigma(X \cdot W_f + b_f) \quad (1)$$

En la etapa 2, se definen en dos partes los datos nuevos que se almacenará en el estado de la celda. La primera es una puerta de entrada (capa sigmoide (u)) encargada de seleccionar qué valores se actualizan y la segunda, es la capa tanh, que crea un vector de nuevos valores candidatos (X') los cuales pueden adherirse al estado.

La expresión que define lo anterior es:

$$u = \sigma(X \cdot W_u + b_u) \quad (2)$$

$$X' = \tanh(X \cdot W_c + b_c) \quad (3)$$

En la etapa 3, se actualiza el estado de la celda anterior C_{t-1} . Para renovarlo a una nueva celda, se realiza con las etapas anteriores multiplicando f con el estado anterior C_{t-1} y sumándolo con la multiplicación de u con la concatenación X^* .

$$C_t = f \cdot C_{t-1} + u \cdot X^* \quad (4)$$

Por último, la etapa 4 decide lo que se generará como salida, está basada en el estado de la celda, pero será una nueva versión de salida filtrada H_t (nuevo estado oculto). Para lograrlo se ejecuta una capa sigmoide que decide la parte del estado de la celda que se generará como salida (O_t), después se pone el estado de la celda C_t a través de \tanh , para que los valores sean entre -1 y 1, y multiplicarlo por O_t . [24], [25].

$$O_t = \sigma(X \cdot W_c + b_c) \quad (5)$$

$$H_t = O_t * \tanh(C_t) \quad (6)$$

B. Diseño de la red LSTM utilizando Keras

El dataset, contiene el registro histórico de los datos del nivel de pH de la primera a la cuarta semana del mes de mayo 2020, y cada registro contiene 5 campos:

- 1) *semana*: semana a la que pertenece.
- 2) *día*: día al que pertenece con un rango de 1 a 7.
- 3) *highest*: el valor más alto obtenido durante la medición del electrodo en la orina durante un minuto.
- 4) *lowest*: el valor más bajo obtenido durante la medición del electrodo en la orina durante un minuto.
- 5) *fecha*: fecha de la medición

Para esta investigación se utilizó por registro el valor más alto obtenido durante cada muestra.

Para comprobar la red neuronal artificial LSTM se empleó la técnica de validación cruzada. Consiste en fraccionar los datos de la muestra, en este caso en dos subconjuntos:

- Entrenar la red con un 80% del total para que la red aprenda a predecir los valores máximos de pH futuros.
- Validación de los datos: 20% del total de los datos.

La ventaja de la validación cruzada es que utiliza todos los datos con que se cuenta en la prueba de entrenamiento y el error es independiente de los datos seleccionados en cada modelo [26].

Para asegurar que los datos están normalizados (con un rango de 0-1) se utilizó la librería Scikit Learn, y después de realizar el entrenamiento, se realizó una transformación inversa sobre el conjunto de los datos de predicción para obtener valores en la escala real.

Para el entrenamiento se utilizaron bloques de 10 datos consecutivos (timestep = 10) y el valor del dato 11 fue usado como salida, siendo este el valor a predecir por la red LSTM.

Antes de diseñar el modelo de la red, fue necesario ajustar la dimensión del modelo para indicar que cada entrada de datos será un vector de 10 (bloque de datos de entrada) x 1 (salida a predecir, en este caso, el dato 11) .

En esta investigación se diseñó una red LSTM de una capa, con un total de 50 neuronas dentro de la capa oculta.

Para crear el contenedor de la red LSTM se utilizó el módulo Secuencial. Y el módulo `mrsprop` para el entrenamiento.

Se utilizaron lotes de 10 ejemplos (batch_size=10) y se realizó un total de 24 épocas (epochs=24).

El criterio de evaluación de la eficiencia de la red neuronal recurrente fue el Error Cuadrático Medio (ECM).

IV. RESULTADOS

Después de analizar el comportamiento histórico de los niveles de pH a través de una red LSTM y keras, fue posible obtener el valor futuro del nivel de pH del paciente alcanzando el objetivo deseado de esta investigación. Por lo que se puede concluir que es posible realizar predicciones de los niveles de pH urinario con una red LSTM que cumpla con un modelo matemático adecuado. La red se puso a prueba implementando dos casos adicionales.

En el primer caso se evalúa la capacidad del modelo matemático de red LSTM diseñado para realizar la predicción del nivel de pH del paciente del día siguiente. La red se entrenó con un rango de datos del dataset del día 1 al día 27 para realizar la predicción del nivel del pH del día 28.

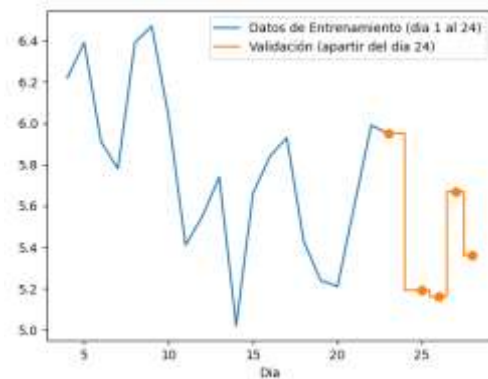


Fig. 5 Gráfica de datos de entrenamiento y validación

La gráfica resultante de la predicción de datos muestra la serie temporal del nivel de pH. La línea roja, corresponde a los valores reales y la línea azul, corresponde a la predicción del modelo de red recurrente. LSTM.

La figura 7, muestra el error cuadrático medio que se obtuvo al entrenar la red neuronal, este fue de 0.0013.

Epoch 24/24

1242/1242 [=====] - 1s

643us/step - loss: 0.0013



Fig. 6 Grafica obtenida de la predicción de datos del día

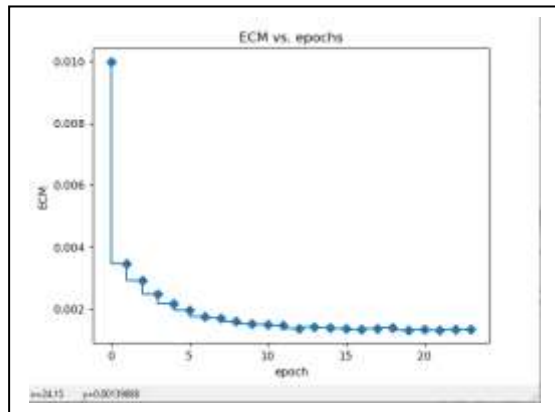


Fig. 7 Se obtuvo un error cuadrático medio del 0.013 al realizar la predicción del día 28.

En el segundo caso, se evalúa la capacidad del modelo matemático de red LSTM diseñado para realizar la predicción del nivel de pH del paciente de la semana siguiente. La red se entrenó con un rango de datos del dataset de la semana 1 a la semana 3 para realizar la predicción del nivel del pH de la semana 4.




Fig. 8 Grafico de datos de entrenamiento de la semana 1-3 y datos de validación para la semana 4.

La figura 10, muestra el error cuadrático medio que se obtuvo al entrenar la red neuronal para realizar la predicción de la semana 4, este fue de 0.0013.

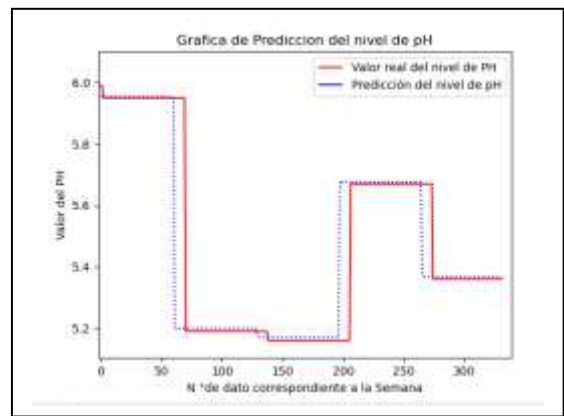


Fig. 9 Grafica obtenida de la predicción de datos de la semana 4 por la red LSTM.

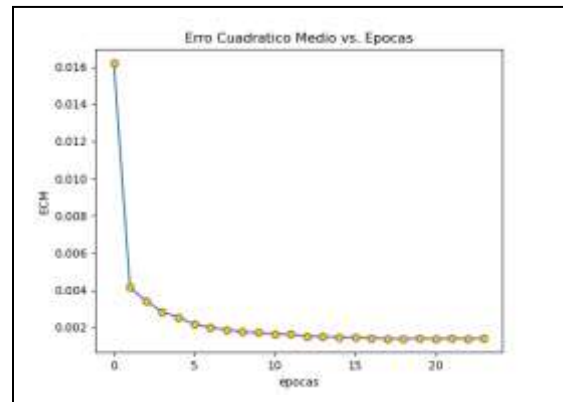


Fig. 10 Se obtuvo un error cuadrático medio del 0.013 al realizar la predicción de la semana 4

V. CONCLUSIONES

De acuerdo con los resultados de esta investigación, se confirma que la aplicación de una red neuronal LSTM en keras, es una herramienta que contribuye para mejorar o complementar el diagnostico actual al brindar un diagnostico más personalizado con base en la predicción por la interpretación del histórico del nivel de pH urinario del paciente.

Con base en los resultados de este proyecto, el modelo matemático de red neuronal desarrollado servirá como un método aproximado para predecir el valor del pH urinario.

Este tipo de modelo con el uso de técnicas de inteligencia artificial aplicadas en la práctica clínica resulta atractivo para especialistas en la rama de nefrología debido a que se puede constatar que con un correcto modelado, la red neuronal puede llegar a predecir con bastante exactitud los niveles de pH del paciente.

Este tipo de modelo no solamente puede ser aplicado a los pacientes con el objetivo de tomar acciones para evitar la recurrencia, puede trabajarse a futuro la aplicación de este método si se estudia a pacientes que corran alto riesgo de aparición de litiasis por primera vez gracias a su historial genético, esto puede lograrse si después de la primera

aparición, el médico, apoya al paciente con la información relacionada al alto porcentaje en la tasa de recurrencia de esta enfermedad y se incluye un control rutinario de nivel de pH urinario después de la primera cirugía o cual sea el método de extracción de los cálculos, ya que si se logran obtener los datos históricos del primer año del paciente después de su primer extracción de cálculos es posible realizar predicciones de los años siguientes, de esta manera al recibir terapia preventiva se podría evitar que el paciente corra riesgo de sufrir recurrencia.

Adicionalmente, el prototipo construido como instrumento de medición, es un dispositivo de bajo costo, que podría convertirse en un producto ya entrenado para indicar los niveles de pH urinario, medidos y proporcionar información precisa al usuario.

RECONOCIMIENTOS

Para el desarrollo de este proyecto, se contó con el apoyo de la institución Tecnológico de Estudios Superiores de Ecatepec y en el específico del programa de posgrado con la Maestría en Ingeniería en Sistemas Computacionales.

REFERENCIAS

[1] V. M. García Nieto, X. I. Pérez Bastida, M. Salvador Cañibano, V. E. García Rodríguez, M. Monge Zamorano, and M. I. Luis Yanes, "Cuantificación del riesgo de formación de cálculos cálcicos en la orina correspondiente a 2 momentos del día en un grupo de niños estudiados para descartar prelitiasis," *Nefrología*, vol. 38, no. 3, pp. 267–272, May 2018, doi: 10.1016/j.nefro.2017.07.004.

[2] I. Sorokin and M. S. Pearle, "Medical therapy for nephrolithiasis: State of the art," *Asian J. Urol.*, vol. 5, pp. 243–55, 2018.

[3] C. Türk *et al.*, "EAU Guidelines on Interventional Treatment for Urolithiasis," *Eur. Urol.*, vol. 69, no. 3, pp. 475–482, Mar. 2016, doi: 10.1016/j.euro.2015.07.041.

[4] A. D. Karaosmanoglu, M. R. Onur, M. Karcaaltincaba, D. Akata, and M. N. Ozmen, "Secondary Tumors of the Urinary System: An Imaging Conundrum," *Korean J. Radiol.*, vol. 19, no. 4, p. 742, Jul. 2018, doi: 10.3348/kjr.2018.19.4.742.

[5] A. Bates and S. Baithun, "The significance of secondary neoplasms of the urinary and male genital tract," *Virchows Arch*, vol. 440, pp. 640–647, 2002.

[6] M. S. Parmar, "Kidney stones," *British Medical Journal*, vol. 328, no. 7453, BMJ Publishing Group, pp. 1420–1424, Jun. 12, 2004, doi: 10.1136/bmj.328.7453.1420.

[7] M. Sarroca Farrera, "Litiasis renal (AMF 2015) Los principales problemas de salud," 2015. https://amf-semfyc.com/web/article_ver.php?id=1439 (accessed Apr. 14, 2021).

[8] X. Ruiz Plazas, "Estudio sobre los factores implicados en la litiasis renal bilateral," 2017, Accessed: Apr. 14, 2021. [Online]. Available: <https://dialnet.unirioja.es/servlet/tesis?codigo=114086&info=resumen&idioma=SPA>.

[9] L. Buitrago, G. Rigoberto, C. O. Mendivil, A. Ayala Fajardo, and A. Uribe Ardila, "Cuantificación de cistina en orina espontánea para la detección de cistinuria," *Acta bioquímica clínica Latinoam.*, vol.

48, pp. 53–61, Mar. 2014.

[10] P. María García García, M. Isabel Luis Yanes, and V. García Nieto, "Litiasis Renal INTRODUCCIÓN. LITOGÉNESIS," 2019.

[11] T. Alelign and B. Petros, "Kidney Stone Disease: An Update on Current Concepts," *Advances in Urology*, vol. 2018, Hindawi Limited, 2018, doi: 10.1155/2018/3068365.

[12] M. Arrabal Martín, A. Fernández Rodríguez, M. Á. Arrabal Polo, M. J. Ruíz García, and A. Zuluaga Gómez, "Estudio de factores físico-químicos en pacientes con litiasis renal," *Archivos Españoles de Urología (Ed. impresa)*, vol. 59, scieloes, pp. 583–594, 2006.

[13] J. A. Galan-Llopis, C. Torrecilla-Ortiz, M. P. Luque-Gálvez, P.-L. Group, X. Peris-Nieto, and J. Cuñé-Castellana, "Urinary pH as a Target in the Management of Lithiasic Patients in Real-World Practice: Monitoring and Nutraceutical Intervention for a Nonlithogenic pH Range," *Clin. Med. Insights Urol.*, vol. 12, p. 1179561119853555, Jan. 2019, doi: 10.1177/1179561119853556.

[14] Á. Adolfo *et al.*, "Nefrolitiasis: Una revisión actualizada," Nov. 2020.

[15] J. Dzenowagis and H. Eskandar, "Conjunto de herramientas para una estrategia de eSalud nacional," 2012.

[16] M. Ángel and G. Cumbreiras, "CONFERENCIA DE DIRECTORES Y DECANOS DE INGENIERÍA INFORMÁTICA eHealth (tecnología y medicina)," 2017.

[17] V. Ramos, "Las TIC en el sector de la salud," *Bit, ISSN 0210-3923, Nº. 163, 2007 (Ejemplar Dedic. a Las TIC en la sanidad)*, pags. 41-45, vol. 163, Jan. 2007.

[18] S. Agatonovic-Kustrin and R. Beresford, "Basic concepts of artificial neural network (ANN) modeling and its application in pharmaceutical research," *J. Pharm. Biomed. Anal.*, vol. 22, no. 5, pp. 717–727, 2000, doi: 10.1016/S0731-7085(99)00272-1.

[19] E. Politécnica Superior de Jaén, R. Javier Megales Anguita Tutor, and D. Antonio Jesús Rivera Rivas D^a M^a Dolores Pérez Godoy, "PLATAFORMA WEB PARA EL ANÁLISIS Y PREDICCIÓN DE SERIES TEMPORALES CON DEEP LEARNING," Jaén: Universidad de Jaén, Jun. 2018. Accessed: Apr. 14, 2021. [Online]. Available: <http://tauja.ujaen.es/jspui/handle/10953.1/8441>.

[20] J. Domínguez, C. Alonso, R. Bartolomé, L. Matas, and N. Rabella, "Procedimientos en Microbiología Clínica RECOMENDACIONES DE LA SOCIEDAD ESPAÑOLA DE ENFERMEDADES INFECCIOSAS Y MICROBIOLOGÍA CLÍNICA Editores: Emilia Cercenado y Rafael Cantón," 2005.

[21] J. F. Román Pedroza, "Lineamientos para la toma, manejo y envío de muestras para diagnóstico a la red nacional de laboratorios de salud pública," 2020. https://www.gob.mx/cms/uploads/attachment/file/558702/Lineamientos_TMEM_2020_180620.pdf (accessed Apr. 14, 2021).

[22] V. De María y Campos, "Guía práctica para la estandarización del procesamiento y examen de las muestras de orina," México, 2019.

[23] M. Toledo, "Funcionamiento, cuidado y calibrado del medidor de pH," 2015. <https://medidordeph.com/funcionamiento-cuidado-calibrado-medidor-de-ph> (accessed Apr. 15, 2021).

[24] M. A. G. Naranjo, "Redes neuronales recurrentes con puertas Gated Recurrent Neural Networks," 2018.

[25] F. Pech May, "Procesamiento de Lenguaje Natural con DeepLearning," 2018.
<http://rios.tecnm.mx/cdistribuido/recursos/DLScr/PLN.html>

(accessed Apr. 15, 2021).

[26] J. Manuel, G. Josa, J. López, V. Xavi, and V. Guillén, "Predicción de tráfico en redes móviles mediante Deep Learning," 2019.

[1]