

Estimación de mapas de sequías de EU mediante redes de Convolución-LSTM

Manuel Medrano¹, Héctor Rodríguez¹,
Rodrigo Lopez-Farias², Juan Flores³,
Carlos Lara⁴, Vicenç Puig⁵

¹ Tecnológico Nacional de México Campus Culiacán,
División de estudios de posgrado,
México

² Consejo Nacional de Ciencia y Tecnología,
Centro de Investigación en Ciencias de Información Geoespacial,
México

³ Universidad de Oregón,
Departamento de Ciencias de la Computación e Informática,
Estados Unidos

⁴ Centro de Investigación en Matemáticas,
Ciudad del Conocimiento Zacatecas,
México

⁵ Universidad Politécnica de Cataluña,
Barcelona,
España

manuel.md@culiacan.tecnm.mx

Resumen. Los mapas de sequías son representaciones gráficas que identifican la severidad de la sequía en diferentes regiones. En este estudio, se propone una metodología para estimar mapas de sequías utilizando redes de Convolución-LSTM, las cuales permiten identificar patrones temporales y espaciales de las condiciones de sequías. Los resultados muestran que esta metodología es efectiva en la generación de estimaciones precisas de mapas de sequías, lo que la convierte en una herramienta valiosa para la gestión de recursos hídricos, la toma de decisiones informadas, y la prevención y mitigación de los impactos negativos de las sequías en diferentes regiones del mundo.

Palabras clave: Sequías, estimación, series de tiempo, convolución-lstm, procesamiento de imágenes.

Estimation of EU Drought Maps Using Convolution-LSTM Network

Abstract. Drought maps are graphical representations that identify the severity of drought in different regions. In this study, a methodology is proposed

to estimate drought maps using Convolution-LSTM networks, which allow identifying temporal and spatial patterns of drought conditions. The results show that this methodology is effective in generating accurate estimates of drought maps, which makes it a valuable tool for water resources management, informed decision making, and prevention and mitigation of the negative impacts of droughts in different regions of the world.

Keywords: Droughts, estimation, time series, convolution-LSTM, image processing.

1. Introducción

La sequía es un periodo seco prolongado en el ciclo climático natural que puede ocurrir en cualquier parte del mundo. Es un desastre de aparición lenta que se caracteriza por la falta de precipitaciones, lo que provoca una escasez de agua que puede afectar tanto a los seres humanos como a los ecosistemas naturales [10].

Existen diferentes tipos de sequía, que se clasifican según su impacto en la comunidad y la región: Sequía meteorológica, relacionada al déficit de precipitación sobre un período en una región; sequía hidrológica, cuando los ríos, acuíferos, estanques y reservas de agua están debajo de los niveles normales; sequía agrícola, sobre el déficit de humedad de suelo en largos términos; sequía socio-cultural, relacionado al suministro y demanda de agua para bienes económicos [3].

Entre los problemas más significativos asociados a las sequías se encuentran la falta de disponibilidad de agua potable, la escasez de alimentos debido al impacto en la agricultura y la ganadería, y la disminución de la productividad en la industria debido a la reducción en la disponibilidad de agua.

Estos impactos afectan la calidad de vida de las personas, especialmente en comunidades rurales y en países en desarrollo donde la agricultura es una parte fundamental de la economía y la subsistencia.

Por lo tanto, es importante tomar medidas preventivas y de gestión adecuadas para minimizar el impacto de la sequía en estas áreas. La educación sobre la gestión del agua y la implementación de tecnologías más eficientes en el uso del agua son algunas de las estrategias que se pueden implementar para enfrentar el problema de la sequía y sus consecuencias.

La información sobre las sequías se puede representar de diversas maneras, como los índices de sequía, la precipitación, la temperatura, la humedad del suelo, el índice de vegetación y los caudales y niveles de agua, incluso en forma de mapas de sequía [3].

En este estudio, se hace hincapié en el uso de los mapas de sequía como herramientas para visualizar la intensidad y extensión de la sequía en una determinada área.

Los mapas se generan a partir de datos recopilados por satélites, estaciones meteorológicas y otros sensores que miden la cantidad de lluvia y humedad del suelo [7]. Una área poco explorada consiste en utilizar mapas de sequías previos para estimar el próximo mapa.

Sin embargo, el uso de esta técnica puede resultar en un aumento exponencial en la complejidad de la estimación, ya que se debe considerar tanto la información espacial para tener en cuenta las condiciones del entorno, como la información temporal para considerar la evolución de la sequía en ese entorno a lo largo del tiempo.

La estimación de la sequía permite a las autoridades, investigadores, planificadores y a la población en general estar mejor preparados para hacer frente a las consecuencias de este fenómeno [1]. Entre los beneficios principales, se encuentran:

- Anticipación: Una estimación anticipada permite a las autoridades y comunidades prepararse con antelación y tomar medidas para minimizar el impacto negativo.
- Eficiencia: La utilización de las redes Convolución-LSTM permiten utilizar la información espacial y temporal de los mapas de sequías, generando mapas con mayor precisión y eficiencia, ayudando a identificar áreas críticas y a asignar recursos de manera eficiente.
- Mejora en la planificación: Los mapas de sequías ayudan a los planificadores a identificar áreas de mayor riesgo y tomar decisiones informadas en cuanto al uso de tierra, suministro de agua y otros recursos.
- Reducción de impactos negativos: La estimación y monitoreo de sequías ayudan a reducir impactos negativos en la sociedad, incluyendo pérdida de cosechas, disminución de suministro de agua, pérdida de biodiversidad y otros impactos ambientales y económicos.

Para predecir la evolución futura de un conjunto de datos, comúnmente se utilizan las series de tiempo. Estas representan una secuencia de datos correlacionados, tomados en intervalos fijos de tiempo. Una rama particularmente interesante en esta área son las Series de Tiempo de Imágenes (STI), que se componen de un conjunto de imágenes ordenadas cronológicamente y tomadas en intervalos fijos de tiempo.

Al igual que las series de tiempo, las STI presentan características de temporalidad, tendencia, estacionalidad, ciclos y auto-correlación. Esto las convierte en una herramienta poderosa para estimar la evolución temporal de variables relacionadas con el espacio, como las regiones sequía, la vegetación, los cambios en la cobertura del suelo o los desastres naturales.

En este trabajo, se utilizó un conjunto de mapas de sequías obtenidos del sitio web Drought Monitor en Estados Unidos, los cuales se organizaron en una Serie de Tiempo de Imágenes (STI). Esta STI permitió extraer información espacial y temporal mediante el uso de una arquitectura de red tipo Convolución-LSTM, la cual permite la estimación y generación del siguiente mapa de sequía.

En total, se obtuvieron 1,183 mapas de sequía que abarcan todas las regiones de Estados Unidos, ordenados cronológicamente en intervalos semanales desde el 4 de enero de 2000 hasta el 30 de agosto de 2022 [7].

El siguiente trabajo se divide en las siguientes secciones:

- Introducción: se presenta el contexto y la motivación para el trabajo, se explican los objetivos y se establece la estructura general del mismo.
- Trabajo relacionado: se describen diferentes trabajos que aplican técnicas diversas para la estimación y pronóstico de sequías en distintos formatos.

- Mapas de sequías: se detallan las características del conjunto de datos de mapas de sequías que se utilizarán.
- Metodología: se explica el conjunto de procedimientos realizados para la estimación y generación del siguiente mapa de sequías.
- Experimentación y resultados: se destacan los resultados obtenidos al poner en práctica los procedimientos especificados.
- Conclusiones: se presenta un resumen sobre la metodología planteada y se analizan los resultados obtenidos.

Con esta estructura, el lector puede tener una idea clara de la organización y el contenido del trabajo. Además, se utilizan frases más precisas y se mejora la redacción para hacer que el texto sea más legible y fácil de entender.

2. Trabajo relacionado

Existen numerosos trabajos que tratan sobre sequías y manipulación de imágenes, los cuales utilizan diversas técnicas y metodologías para abordar problemas particulares. A continuación, se describirán algunos de ellos que se centran en la problemática de las sequías.

En el trabajo de [8], se aborda el pronóstico del Índice Estandarizado de Precipitación (SPI) y el SPI de Evapotranspiración (SPEI) mediante la aplicación de la regresión logística con datos tomados de cinco ciudades europeas. De igual manera, los trabajos de [9] y [6] aplicaron la regresión logística para datos tomados de Turquía y del este de China, respectivamente.

En la actualidad, existen diversos enfoques para mejorar la precisión en el pronóstico de sequías. Uno de ellos es la combinación de modelos estocásticos ARIMA con otras arquitecturas. Un ejemplo de ello es el trabajo de [11], que utiliza un modelo híbrido basado en Transformación de Wavelet (WT), ARIMA y LSTM para pronosticar sequías a partir de información sobre la precipitación mensual y anual.

Por otro lado, [12] aplican una combinación de métodos ARIMA y LSTM para el pronóstico del índice SPEI, obteniendo una alta precisión en las estimaciones. Otro trabajo relevante es el de [2], donde se crea un modelo híbrido de ARIMA, Algoritmos Genéticos y Redes Neuronales, obteniendo resultados muy favorables para el pronóstico de SPI.

Entre los enfoques más utilizados para mejorar el pronóstico de sequías se encuentran las Redes Neuronales Artificiales (ANN). Por ejemplo, [4] evalúan el SPI Anual (SIAP) y el índice Estandarizado de Almacenamiento de Agua (SWSI) utilizando una combinación de WT y ANN (WANN), logrando coeficientes de correlación altos en la mayoría de los escenarios.

En [14] realizan una comparativa de diferentes métodos para el pronóstico de sequías en la cuenca del río Haihe, demostrando que las WANN obtienen mejores resultados de pronóstico en los valores SPI-6 y SPI-12.

Trabajar con mapas de sequías tiene su propia complejidad. En el trabajo [13], se crearon estos mapas a partir de un análisis de sequía, para realizar análisis más complejos sobre las características espacio-temporales de ocurrencia y patrones de propagación de sequía regional.

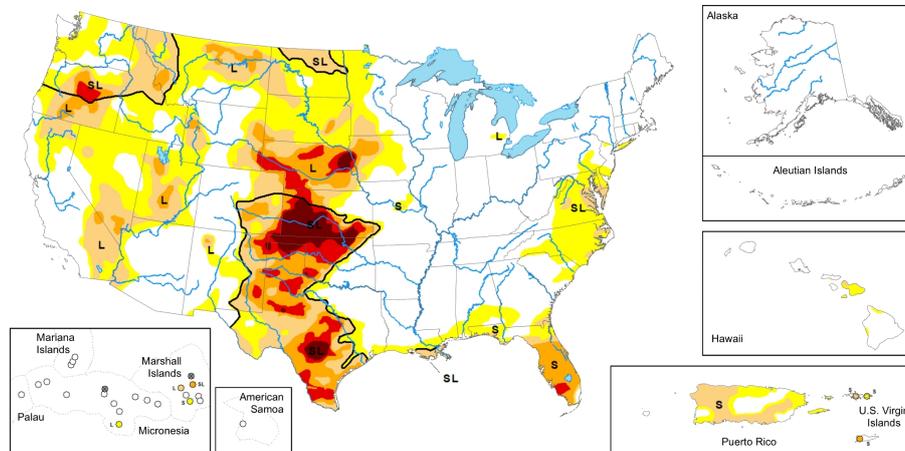


Fig. 1. Representación visual del mapa de sequías con delimitaciones. Tomado de [7].

En cambio, el trabajo [5] utilizó el SPI sobre mapas de sequías, concluyendo que las sequías ocurren con frecuencia durante la primavera con una tendencia de breves periodos de sequía frecuente.

3. Mapas de sequías

En este trabajo se utilizan datos obtenidos del monitor de sequías de Estados Unidos [7]. Donde se muestra un mapa de sequías tomado periódicamente semana tras semana. El mapa es creado a partir de un grupo de expertos que toma la información en crudo y la transforma a un nivel de sequía, dependiendo de las características de la información obtenida.

El nivel de sequía es asignado a cada una de las regiones del mapa y es transformado a un mapa de sequía. Estos niveles de sequías se dividen en cinco categorías, cada una de ellas mostrando su grado de impacto en las áreas afectadas, y la ausencia de sequía en color blanco. En el monitor de sequías se especifica cada una de las categorías como:

- **Anormalmente seco (D0)** ■: Se trata de una sequía de corta duración que ralentiza la siembra-crecimiento de los cultivos/pastos.
- **Sequía moderada (D1)** ■: Algunos cultivos o pastizales han resultado dañados, y los arroyos, embalses o pozos están bajando.
- **Sequía severa (D2)** ■: La posibilidad de pérdidas en los cultivos/pastizales y la escasez de agua son habituales.
- **Sequía extrema (D3)** ■: Pérdidas significativas en cultivos/pastizales y restricciones/escasez de agua generalizadas.
- **Sequía excepcional (D4)** ■: Pérdidas excepcionales en cultivos/pastos y emergencias hídricas debidas a la escasez de agua en embalses, arroyos y muros.

De esta manera se puede crear un mapa de sequía que refleje la región afectada y el grado de intensidad de la sequía. Se muestra un ejemplo de estos mapas en la Figura 1.

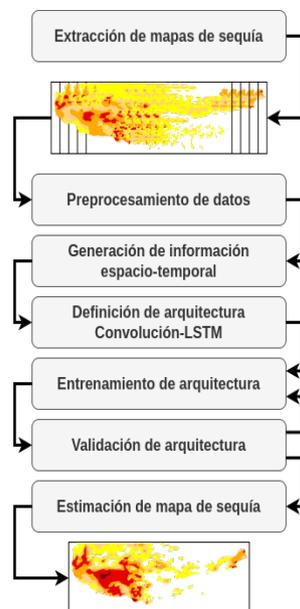


Fig. 2. Procedimiento para la estimación de mapas de sequías mediante Convolución-LSTM.

4. Metodología

En esta sección se presentan detalladamente los procedimientos y técnicas utilizadas para llevar a cabo la estimación de mapas de sequías mediante redes de Convolución-LSTM. se describirá la fuente y forma de extraer los mapas de sequías.

El preprocesamiento de los mapas para adaptarlo a las necesidades del problema. La generación de información espacio-temporal donde se transforman las series de tiempo en un conjunto de datos para estimación. Pasar a definir la arquitectura mediante el uso de redes de Convolución-LSTM, el entrenamiento y validación de la arquitectura. La Figura 2 muestra el orden de los procedimientos.

4.1. Extracción de mapas de sequía

El sitio *U.S. Drought monitor* ofrece un apartado de descarga de información. El formato original es de tipo *Geographic Information System* (GIS) obtenido a través de un servicio web *Web Map Service* (WMS). Este servicio provee las imágenes en formato ".PNG" de mapas georreferenciados que contienen la información libre de delimitaciones. Cada archivo WMS contiene un mapa de sequía basado en la forma de la proyección WGS84 [7].

El procedimiento de adquisición del mapa fue un procedimiento largo, se realizó de manera manual descargando mapa de sequía por mapa. La pestaña de la página de *GIS Data* contiene una tabla con la información de cada semana. Uno de los formatos que ofrece es el servicio WMS, que permite obtener una imagen PNG con el mapa de sequía.

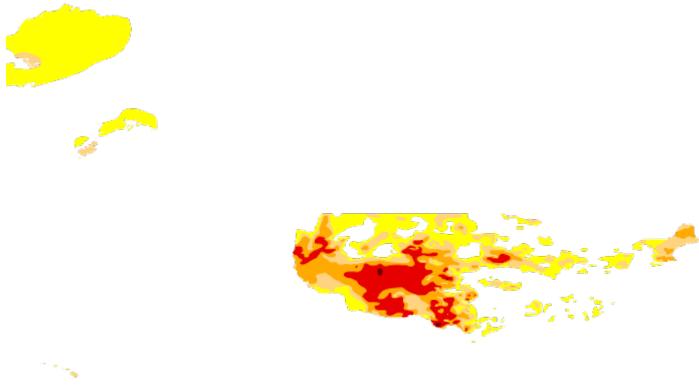


Fig. 3. Representación visual del mapa de sequías sin delimitaciones. Tomado de [7].

Para guardar el mapa se utilizó la función interna del navegador Google Chrome "Guardar imagen como", almacenando la imagen en una carpeta, donde la imagen fue etiquetada con su respectiva fecha de muestra. Al final se obtuvieron un total de 1,183 mapas de sequías, creando un conjunto de datos que va desde el 4 de Enero del 2000 hasta el 30 de Agosto del 2022.

Estos mapas de sequías originalmente tienen una resolución de (640, 480, 3), donde se presentan las dimensiones de anchura, altura y mapa de colores. La Figura 3 muestra el mapa de sequías completo.

Se decidió limitar el análisis de los mapas de sequía a la región peninsular de Estados Unidos. Esto permitió reducir la cantidad de características a procesar, pasando de una resolución original de (640, 480) a (122,360), y a la vez, enfocarse en la región de interés.

Los mapas de sequía cubren todas las regiones de Estados Unidos, incluyendo Alaska y Puerto Rico, pero para este estudio se optó por trabajar solo con la región peninsular. La Figura 4 muestra la zona resultante del mapa de sequías limitado a la región peninsular de Estados Unidos.

4.2. Preprocesamiento

En este trabajo se plantea el uso de sequías en escala de grises y monocromática. La escala de color original de los mapas de sequías es con formato "RGB". Por lo que, es necesario hacer una transformación de esas imágenes a dos escalas de colores. La Figura 5 muestra las imágenes en estas escalas de color.

Como se puede apreciar, al utilizar la escala de grises se mantiene la interpretación original sobre los grados de intensidad de sequía en varias regiones.

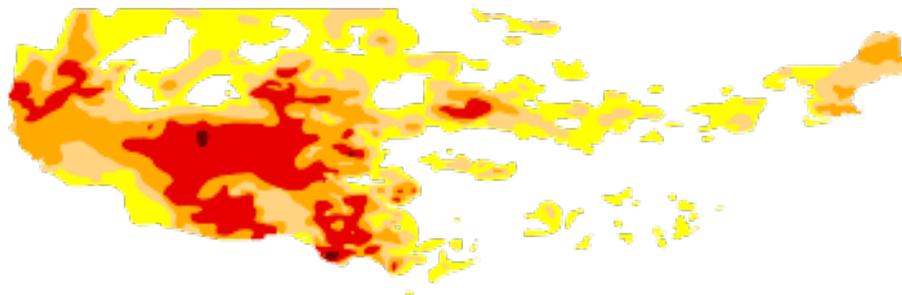


Fig. 4. Representación visual del mapa de sequías con área de interés.

Sin embargo, al aplicar una escala de color monocromática se modifica la interpretación de la información. Los mapas monocromáticos destacan únicamente los lugares donde hay sequía o no, sin tener en cuenta el grado de intensidad de la misma.

Después de transformar la escala de color de las imágenes, se mantiene el rango de valores original de 0 a 255. Sin embargo, en la escala monocromática, los valores se limitan a 0 o 255. Para ajustar los valores a un rango específico, se aplica un proceso de normalización. En este caso, se realiza una normalización que convierte los valores de los píxeles de las imágenes, que inicialmente oscilan entre 0 y 255, a un rango de 0 a 1.

4.3. Generación de información espacio-temporal

Las redes de convolución-LSTM son un tipo de red neuronal especial, esta requiere un formato específico en los datos de entrada para su correcto funcionamiento. Se define una ventana temporal, la cual especifica la cantidad de datos simultáneos para formar subconjuntos de datos a los cuales se les asociará un objetivo. El objetivo es aquel subconjunto de datos de referencia que toma la red para intentar estimarlo.

Por lo anterior, para adecuar la serie temporal de mapas de sequías a una entrada para la red Convolución-LSTM, se transforma en un cubo de datos que representa información espacio-temporal. La información "x" será utilizada como entrada para la red, mientras que la información "y" será el objetivo de la misma. El formato de los subconjuntos de datos se define con 4 dimensiones, de esta manera: (Ventana temporal, Ancho, Alto, Color). La Figura 6 muestra esta transformación de la información.

4.4. Definición de arquitectura convolución-LSTM

Al definir la arquitectura de la red Convolución-LSTM, es importante considerar varios factores, como los tipos de capas a utilizar, las funciones de activación, la cantidad y forma de los kernels, y, lo más importante, la forma de los datos de entrada y salida. Para ello, se deben utilizar capas de Convolución-LSTM que requieren al menos la definición de un conjunto de parámetros: la cantidad y tamaño de los kernels y la función de activación.



Fig. 5. Transformación de color a escala de grises y monocromática.

Otra capa importante a utilizar es la capa de *BatchNormalization*. Esta capa permite mantener la normalización de los datos entre las capas intermedias de la red profunda, lo que ayuda a reducir el efecto del cambio en la distribución de los datos en cada capa y a acelerar el proceso de entrenamiento.

Debido a que el objetivo de las muestras y la arquitectura es estimar y generar un cubo de datos, la última capa debe ser de Convolución 3D, en la cual se define un solo kernel de 3 dimensiones. De esta manera, la entrada y salida de la arquitectura tendrán 4 dimensiones (Ventana temporal, Ancho, Alto, Color).

Una vez que las capas de la red han sido definidas, se procede a compilar el modelo, lo que implica la definición de ciertos aspectos importantes como la función de pérdida y el optimizador. En el caso de este trabajo, se utiliza la función de pérdida *Binary Crossentropy* ya que esta permite comparar la predicción del modelo con el objetivo verdadero y calcular la diferencia entre ellos.

En cuanto al optimizador, se utiliza el algoritmo *Adam*, el cual es comúnmente utilizado en problemas que requieren la optimización de funciones de pérdida no lineales.

4.5. Entrenamiento de la arquitectura

Entrenar una arquitectura consisten en alimentarla con un conjunto de datos de entrenamiento y validación. Al utilizar la función "fit" serán necesarios diferentes parámetros a configurar. Entre los parámetros a utilizar, se encuentran los siguientes:

- Datos de entrenamiento: datos utilizados para alimentar el modelo en todo el entrenamiento.
- Objetivos de entrenamiento: datos utilizados como objetivos para que la red pueda estimar el futuro.
- Épocas: número de veces que el modelo se entrena con los datos de entrenamiento.
- *Batch.size*: número de muestras que se utilizan en cada actualización del modelo. Una actualización se refiere a un paso hacia adelante y hacia atrás a través de la red neuronal para actualizar los pesos del modelo.
- Datos de validación: datos utilizados para evaluar el rendimiento del modelo en cada época durante el entrenamiento. El objetivo es medir la capacidad del modelo para generalizar en nuevos datos y evitar el sobre ajuste.
- *Callbacks*: lista de objetos que se llaman al final de cada época para realizar acciones específicas, como guardar el modelo o detener el entrenamiento temprano si el rendimiento no mejora.

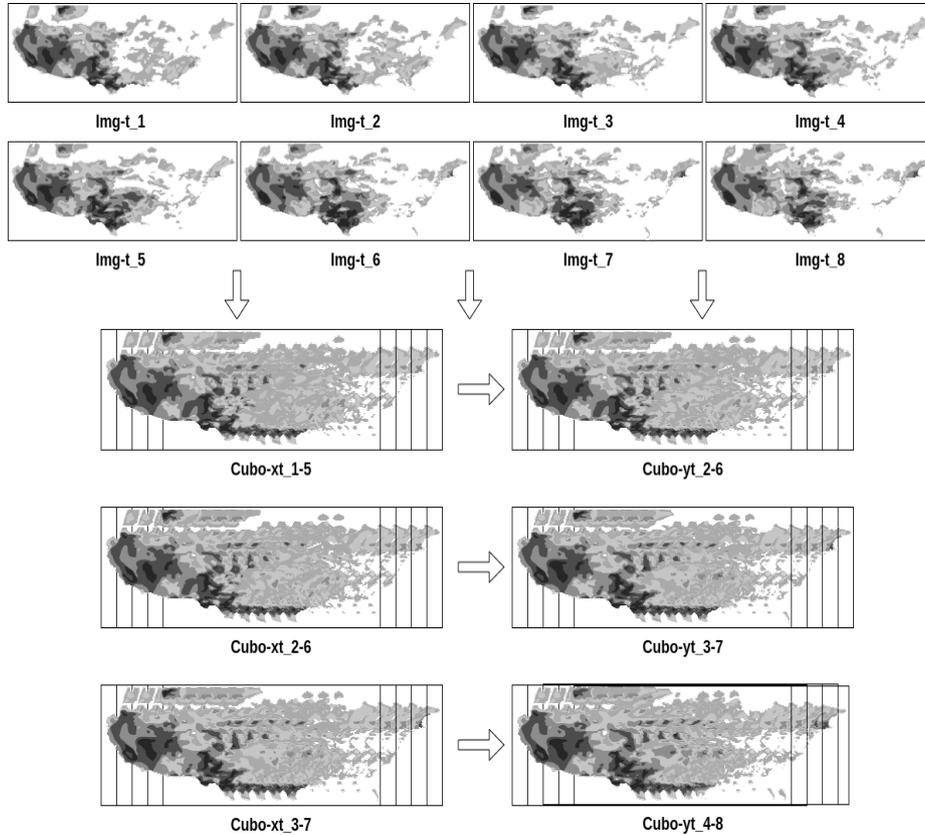


Fig. 6. Representación visual de los cubos de información espacio temporal.

4.6. Validación de arquitectura

Una vez que la arquitectura haya sido entrenada, se realiza un proceso de validación. En este procedimiento se evalúa el rendimiento del modelo en datos que no se utilizaron para entrenamiento.

Se utiliza un tercer conjunto de datos llamado conjunto de pruebas, el cual contiene un conjunto de muestras que el modelo nunca ha visto. El objetivo de la validación es medir la capacidad del modelo para generalizar en nuevos datos y evitar el sobre ajuste.

Dado que no se encontraron trabajos similares en la literatura, no es posible comparar los resultados obtenidos con otras metodologías. Para establecer un punto de referencia y evaluar la precisión de la metodología planteada, se emplea el modelo Naive.

Este modelo es una técnica simple que consiste en predecir que el valor futuro de una serie de tiempo será igual al valor actual, es decir, que no habrá cambios en la serie de tiempo.

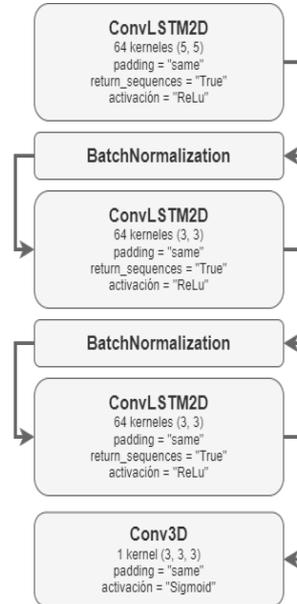


Fig. 7. Arquitectura Convolución-LSTM.

Para comparar las arquitecturas, se utiliza la medida del Error Cuadrático Medio (MSE por sus siglas en Inglés). Este error indica cuánto difieren las estimaciones de la arquitectura de los valores reales, siendo un valor más bajo indicativo de una mayor precisión del modelo.

El MSE se calcula sumando los errores cuadráticos para cada punto del tiempo y dividiendo el resultado entre el número total de puntos de la serie de tiempo. La Ecuación 1 muestra el calculo de esta función de error:

$$MSE = \frac{1}{N} * \sum_{t=1}^N (y_t - f_t)^2. \quad (1)$$

5. Experimentación y resultados

En este trabajo, se implementó una arquitectura basada en redes de Convolución-LSTM para la estimación de mapas de sequías. En esencia, la arquitectura se compone de tres capas de Convolución-LSTM, dos capas tipo *BatchNormalization* y una capa de salida de Convolución 3D. La Figura 7 muestra las especificaciones de cada capa de la arquitectura.

Se realizaron todos los experimentos en una única máquina con las siguientes especificaciones: CPU Intel Core i7-8700, 32 GB de memoria RAM y 2 NVIDIA GeForce RTX 2080 Ti. Es importante destacar que durante el entrenamiento de la arquitectura, ambas GPU fueron utilizadas simultáneamente mediante el uso de la estrategia *Mirrored Strategy* de la biblioteca TensorFlow.

Tabla 1. MSE promedio de los experimentos en escala monocromática.

Estimación	Naive
0.0229649	0.0254891

Tabla 2. MSE promedio de los experimentos en escala de grises.

Estimación	Naive
0.0178309	0.0199593

Se aplicó la arquitectura mencionada en dos conjuntos de datos diferentes. En el primer experimento, se utilizaron muestras en formato monocromático, donde el mapa de sequías solo indicaba si había o no sequía en una región determinada. En el segundo experimento, se usaron muestras en escala de grises, donde el mapa de sequías representaba el grado de sequía en distintas regiones.

Se utilizó una ventana temporal de 9 elementos por muestra para el conjunto de datos en escala monocromática. Después de pasar por las fases de preparación de datos, se obtuvieron 656 datos para entrenamiento, 165 datos para validación y 353 datos para pruebas.

Esto resultó en un subconjunto de cubos de datos con las dimensiones (9, 122, 360, 1). En cambio, para el conjunto de datos en escala de grises se aplicó una ventana temporal de 6 elementos por muestra. Luego de la preparación de datos, se obtuvieron 658 datos para entrenamiento, 165 datos para validación y 354 datos para pruebas. Esto dio como resultado un subconjunto de cubos de datos con las dimensiones (6, 122, 360, 1) para su estimación.

Los valores promedio del MSE se calcularon para cada uno de los conjuntos de datos de prueba, y se utilizó el modelo Naive como punto de referencia en ambos casos: tanto en la escala monocromática como en la escala de grises. Los resultados se presentan en la Tabla 1 para la escala monocromática y en la Tabla 2 para la escala de grises, junto con la correlación de los valores de MSE promedio correspondientes.

La metodología planteada en este trabajo es capaz de generar estimaciones de mapas de sequía con el mismo tamaño que los mapas originales. Para facilitar la interpretación visual de las estimaciones, se agregaron las delimitaciones geográficas de Estados Unidos. En las Figuras 8 y 9 se presentan ejemplos de imágenes originales, estimadas y del modelo Naive para las escalas monocromática y de grises, respectivamente.

6. Conclusiones

Los resultados presentados en este trabajo muestran la efectividad de la metodología propuesta basada en redes de Convolución-LSTM para la estimación de mapas de sequías. La generación precisa y actualizada de mapas de sequías puede ser útil para la toma de decisiones informadas y la gestión adecuada de los recursos hídricos.

En comparación con el modelo Naive, la metodología propuesta presentó un menor valor de MSE en la estimación, lo que sugiere que esta técnica puede ser una herramienta efectiva en la prevención y mitigación de los impactos negativos de las sequías en diferentes regiones del mundo.

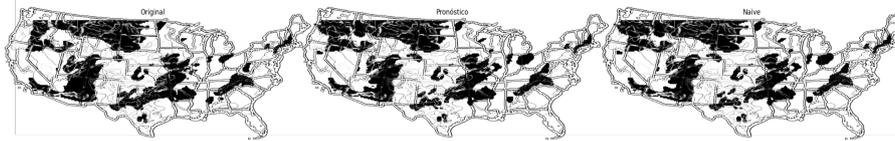


Fig. 8. Estimación del mapa de sequías en escala monocromática.

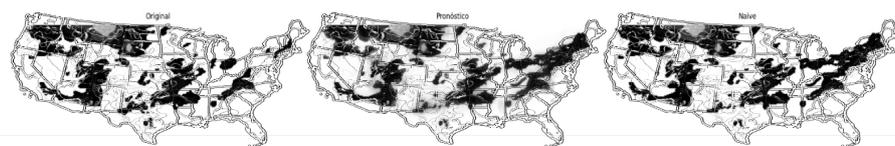


Fig. 9. Estimación del mapa de sequías en escala de grises.

Es fundamental considerar la complejidad computacional y la necesidad de memoria que implica el uso de redes Convolución-LSTM para la estimación de mapas de sequías. Durante los experimentos, se requirió el máximo rendimiento del equipo de hardware. Estas redes demandan una gran capacidad de procesamiento y una cantidad significativa de memoria tanto para el entrenamiento como para la estimación. Por lo tanto, es esencial asegurarse de contar con el hardware y almacenamiento adecuados antes de implementar esta metodología en diferentes contextos.

A pesar de lo anterior, los resultados obtenidos sugieren que la metodología propuesta obtiene estimaciones favorables. Por lo tanto, se espera que la investigación en esta área siga avanzando y que se encuentren formas de mejorar la eficiencia computacional de las redes de Convolución-LSTM para facilitar su implementación en diferentes contextos.

Sin embargo, es importante destacar que la metodología propuesta no es una solución única para la estimación de mapas de sequía, ya que se necesitaría adaptarla a las condiciones específicas de cada región y a los datos disponibles. Aun así, los resultados sugieren que la metodología propuesta es una herramienta valiosa para mejorar las estimaciones de mapas de sequías, lo que tendrá un impacto significativo en la gestión de recursos y la prevención de los impactos negativos de las sequías en la sociedad y el medio ambiente.

Referencias

1. Alawsi, M. A., Zubaidi, S. L., Al-Bdairi, N. S., Al-Ansari, N., Hashim, K.: Drought forecasting: A review and assessment of the hybrid techniques and data pre-processing. *Hydrology*, vol. 9, no. 7 (2022) doi: 10.3390/hydrology9070115
2. Alquraish, M., Abuhasel, K. A., Alqahtani, A. S., Khadr, M.: SPI-based hybrid hidden Markov-GA, ARIMA-GA, and ARIMA-GA-ANN models for meteorological drought forecasting. *Sustainability*, vol. 13, no. 22 (2021) doi: 10.3390/su132212576
3. Balti, H., Abbes, A. B., Mellouli, N., Farah, I. R., Sang, Y., Lamolle, M.: A review of drought monitoring with big data: Issues, methods, challenges and research directions. *Ecological Informatics*, vol. 60 (2020) doi: 10.1016/j.ecoinf.2020.101136

4. Khan, M. M., Muhammad, N. S., El-Shafie, A.: Wavelet-ANN versus ANN-based model for hydrometeorological drought forecasting. *Water*, vol. 10, no. 8 (2018) doi: 10.3390/w10080998
5. Lee, J. H., Cho, K. J., Kim, C. J., Park, M. J.: Analysis on the spatio-temporal distribution of drought using potential drought hazard map. *Journal of Korea Water Resources Association*, vol. 45, no. 10, pp. 983–995 (2012) doi: 10.3741/JKWRA.2012.45.10.983
6. Meng, L., Ford, T., Guo, Y.: Logistic regression analysis of drought persistence in east China. *International Journal of Climatology*, vol. 37, no. 3, pp. 1444–1455 (2017) doi: 10.1002/joc.4789
7. National Drought Mitigation Center: United states drought monitor. (2022) <https://droughtmonitor.unl.edu/CurrentMap/StateDroughtMonitor.aspx#:~:text=Drought%20Mitigation%20Center-,National%20Drought%20Mitigation%20Center,the%20practice%20of%20drought%20planning>
8. Stagge, J. H., Kohn, I., Tallaksen, L. M., Stahl, K.: Modeling drought impact occurrence based on meteorological drought indices in Europe. *Journal of Hydrology*, vol. 530, pp. 37–50 (2015) doi: 10.1016/j.jhydrol.2015.09.039
9. Tatli, H.: Downscaling standardized precipitation index via model output statistics. *Atmósfera*, vol. 28, no. 2, pp. 83–98 (2015) doi: 10.1016/S0187-6236(15)30002-3
10. World Health Organization: Drought. (2022) https://www.who.int/health-topics/drought#tab=tab_1
11. Wu, X., Zhou, J., Yu, H., Liu, D., Xie, K., Chen, Y., Hu, J., Sun, H., Xing, F.: The development of a hybrid wavelet-ARIMA-LSTM model for precipitation amounts and drought analysis. *Atmosphere*, vol. 12, no. 1 (2021) doi: 10.3390/atmos12010074
12. Xu, D., Zhang, Q., Ding, Y., Zhang, D.: Application of a hybrid ARIMA-LSTM model based on the SPEI for drought forecasting. *Environmental Science and Pollution Research*, vol. 29, no. 3, pp. 4128–4144 (2022) doi: 10.1007/s11356-021-15325-z
13. Yoo, J., So, B.-J., Kwon, H.-H., Kim, T.-W.: Development of drought map based on three-dimensional spatio-temporal analysis of drought. *KSCE Journal of Civil and Environmental Engineering Research*, vol. 40, no. 1, pp. 25–33 (2020) doi: 10.12652/Ksce.2020.40.1.0025
14. Zhang, Y., Li, W., Chen, Q., Pu, X., Xiang, L.: Multi-models for SPI drought forecasting in the north of Haihe river Basin, China. *Stochastic Environmental Research and Risk Assessment*, vol. 31, pp. 2471–2481 (2017) doi: 10.1007/s00477-017-1437-5