

**Gestión pública basada
en datos predictivos:
Modelos de inteligencia
artificial para la
prevención de crisis
sociales**

William Rodríguez Cruz
Alejandro Ticona Machaca
Sally Jaqueline Quijano Zerpa

Gestión pública basada en datos predictivos: Modelos de inteligencia artificial para la prevención de crisis sociales

William Rodríguez Cruz
Alejandro Ticona Machaca
Sally Jaqueline Quijano Zerpa

{

RESUMEN

Este estudio evalúa la eficacia de la inteligencia artificial (IA) predictiva para anticipar crisis sociales en la gestión pública peruana. Se desarrolló un modelo basado en redes neuronales recurrentes (RNN-LSTM) y se entrenó con datos históricos de crisis sociales, indicadores socioeconómicos y sentimiento en redes sociales. La validación cruzada anidada mostró una alta precisión (superior al 85%) en la predicción de crisis, demostrando la capacidad del modelo para generalizar a datos no vistos. El análisis de sensibilidad identificó la desigualdad económica, el desempleo y el sentimiento negativo en redes sociales como predictores claves. Se presentaron ejemplos de predicciones exitosas en Puno y Arequipa, alineadas con eventos reales. Se recomiendan políticas públicas basadas en datos predictivos, incluyendo la creación de una plataforma nacional de datos y la capacitación de funcionarios públicos en IA. Futuras investigaciones deberían explorar la integración de datos en tiempo real y la aplicación de la IA a otros tipos de crisis.

Palabras clave: Inteligencia artificial, predicción de crisis, gestión pública, redes neuronales, políticas públicas, Perú.



ABSTRACT

This study evaluates the effectiveness of predictive artificial intelligence (AI) in anticipating social crises within Peruvian public administration. A recurrent neural network (RNN-LSTM) model was developed and trained using historical data on social crises, socioeconomic indicators, and social media sentiment. Nested cross-validation demonstrated high accuracy (over 85%) in crisis prediction, showcasing the model's ability to generalize to unseen data. Sensitivity analysis identified economic inequality, unemployment, and negative social media sentiment as key predictors. Examples of successful predictions in Puno and Arequipa, aligned with real-world events, were presented. Public policies based on predictive data are recommended, including the creation of a national data platform and training of public officials in AI. Future research should explore the integration of real-time data and the application of AI to other types of crises.

Keywords: Artificial intelligence, crisis prediction, public management, neural networks, public policy, Peru.

INTRODUCCIÓN

La creciente complejidad de las sociedades modernas, aunada a la proliferación de información y la interconexión global, ha incrementado la frecuencia e intensidad de las crisis sociales, presentando desafíos significativos para la gestión pública en Latinoamérica, particularmente en Perú (Stark et al., 2020). La administración pública enfrenta dificultades para anticipar estos eventos debido a la naturaleza multifactorial de las crisis y la velocidad con la que se propagan en el entorno digital (OECD, 2020). Los métodos tradicionales de análisis y respuesta suelen ser reactivos, limitando la capacidad de los gobiernos para mitigar el impacto de las crisis y proteger a la población (Pursiainen et al., 2017).

En este contexto, la inteligencia artificial (IA) y los modelos predictivos emergen como herramientas cruciales para fortalecer la gobernanza y mejorar la capacidad de

respuesta ante situaciones de crisis. La IA ofrece la posibilidad de analizar grandes volúmenes de datos de diversas fuentes, incluyendo redes sociales, registros históricos y estadísticas socioeconómicas, para identificar patrones y tendencias que podrían indicar la inminencia de una crisis social (Zuiderveen Borgesius et al., 2020).

Estos modelos predictivos pueden proporcionar a las autoridades información anticipada sobre potenciales focos de conflicto, permitiendo una gestión más proactiva y eficiente de los recursos (Guterres, 2020). La capacidad de la IA para procesar información en tiempo real y detectar señales tempranas de alerta resulta fundamental para anticipar y mitigar el impacto de las crisis sociales, facilitando la toma de decisiones informadas y la implementación de medidas preventivas.

La aplicación de modelos predictivos de IA en la gestión pública se basa en los avances en machine learning y el procesamiento de datos, permitiendo el análisis de información compleja y la identificación de correlaciones que podrían pasar desapercibidas con métodos tradicionales (Allen & Price, 2022). El entrenamiento de estos modelos con datos históricos de crisis sociales permite identificar factores de riesgo y desarrollar algoritmos capaces de predecir la probabilidad de futuros eventos (Agrawal et al., 2019).

La teoría de la gestión de crisis en el ámbito público enfatiza la importancia de la anticipación y la preparación para minimizar el impacto de las interrupciones sociales (Heurtebise, 2015). Estudios previos han demostrado la efectividad de la IA predictiva en diversos contextos, como la prevención del crimen, la gestión de desastres naturales y la optimización de servicios públicos (Duberry, 2022). La implementación de estas tecnologías en la gestión pública ha mostrado resultados prometedores en la identificación de áreas de riesgo, la asignación eficiente de recursos y la mejora de la capacidad de respuesta ante situaciones de emergencia (Bughin et al., 2018). Casos de uso en países como Singapur y Estonia demuestran cómo la IA puede fortalecer la gobernanza y contribuir a la creación de sociedades más resilientes y preparadas para enfrentar los desafíos del siglo XXI (Eggers et al., 2017).

El presente estudio se centra en evaluar la efectividad de la inteligencia artificial predictiva en la gestión pública para anticipar y mitigar crisis sociales. Se busca determinar en qué medida los modelos de IA, entrenados con datos históricos y en tiempo real, pueden mejorar la capacidad de las instituciones públicas para identificar factores de riesgo, predecir la probabilidad de eventos críticos y tomar decisiones proactivas para prevenir o reducir el impacto de las crisis sociales.



La pregunta de investigación que guía este análisis es: ¿En qué medida los modelos predictivos de IA pueden ayudar a las instituciones públicas a anticipar y mitigar crisis sociales? A través de este estudio, se busca contribuir al desarrollo de estrategias innovadoras para la gestión pública, promoviendo la aplicación de tecnologías avanzadas para fortalecer la gobernanza y mejorar la capacidad de respuesta ante las crisis sociales en contextos latinoamericanos.

FUNDAMENTOS TEÓRICOS

Fundamentos de la Inteligencia Artificial Predictiva

La inteligencia artificial predictiva se fundamenta en la capacidad de los algoritmos para aprender de datos históricos e identificar patrones que permitan anticipar eventos futuros. El machine learning, un subcampo de la IA, desempeña un papel central en el desarrollo de modelos predictivos (Jordan & Mitchell, 2015). A través de técnicas como el aprendizaje supervisado, no supervisado y por refuerzo, los algoritmos pueden ser entrenados para reconocer relaciones complejas en los datos y generar predicciones con un alto grado de precisión (Aggarwal, 2018).

El procesamiento de datos predictivos implica la recopilación, limpieza, transformación y análisis de grandes volúmenes de información para alimentar los modelos de IA (Shmueli & Koppius, 2011). Estos modelos se aplican en diversos contextos, desde la predicción de la demanda de productos hasta la detección de fraudes financieros, demostrando su versatilidad y potencial para anticipar eventos en diferentes ámbitos. En el contexto de la gestión pública, la IA predictiva puede ser utilizada para analizar datos socioeconómicos, demográficos y de comportamiento para prever tendencias y anticipar posibles crisis sociales (Sun & Medaglia, 2019). La capacidad de estos modelos para procesar información compleja y detectar señales tempranas de alerta resulta invaluable para la toma de decisiones proactivas en la gestión de crisis.

Teorías sobre la Gestión de Crisis en el Ámbito Público

La gestión de crisis en el ámbito público se sustenta en teorías que enfatizan la importancia de la anticipación, la preparación y la respuesta coordinada para minimizar el impacto de eventos disruptivos. La teoría de los sistemas complejos, por ejemplo, reconoce la interconexión de diversos factores en la generación de crisis

sociales, destacando la necesidad de un enfoque holístico para su comprensión y gestión (Holland, 2012).

La teoría de la resiliencia organizacional, por su parte, se centra en la capacidad de las instituciones públicas para adaptarse y recuperarse de las crisis, resaltando la importancia de la flexibilidad, la redundancia y la capacidad de aprendizaje (Walker et al., 2004). La anticipación se considera un elemento clave en la gestión de crisis, ya que permite a las autoridades tomar medidas preventivas para mitigar los riesgos y preparar a la población para eventuales contingencias (Comfort, 2017). En este sentido, los modelos predictivos de IA ofrecen una herramienta poderosa para mejorar la capacidad de anticipación de las instituciones públicas, permitiendo una gestión más proactiva de las crisis sociales.

La prevención de conflictos también se beneficia de la aplicación de estas tecnologías, ya que la IA puede ayudar a identificar las causas subyacentes de las tensiones sociales y a desarrollar estrategias para abordarlas de manera efectiva (Demiroz & Kapucu, 2018).

Estudios Previos y Casos de Uso de IA Predictiva en Gestión Pública

Diversos estudios han explorado la aplicación de la IA predictiva en la gestión pública, demostrando su potencial para mejorar la eficiencia, la transparencia y la capacidad de respuesta de las instituciones gubernamentales. En el ámbito de la seguridad pública, la IA se ha utilizado para predecir la ocurrencia de delitos, optimizar la asignación de recursos policiales y mejorar la capacidad de respuesta ante emergencias (Perry et al., 2013).

En el sector de los servicios sociales, la IA predictiva ha sido implementada para identificar a personas en riesgo de vulnerabilidad, prevenir la deserción escolar y mejorar la eficiencia de los programas de asistencia social (Angrave et al., 2016). En el ámbito económico, los modelos de IA se utilizan para predecir tendencias del mercado, optimizar la recaudación de impuestos y mejorar la gestión de las finanzas públicas (Cockburn et al., 2018). Casos de uso en países como Dinamarca, donde se utiliza IA para predecir la necesidad de servicios sociales, y Singapur, donde se implementan sistemas inteligentes para la gestión del tráfico y la seguridad ciudadana, demuestran la viabilidad y los beneficios de la IA predictiva en la gestión pública (Heeks, 2017). Estos ejemplos ilustran cómo la IA puede transformar la administración pública, permitiendo una gestión más proactiva, eficiente y centrada en las necesidades de la ciudadanía.



METODOLOGÍA

Diseño de investigación

El estudio adoptó un diseño experimental cuasi-experimental, reconociendo la imposibilidad de controlar completamente todas las variables en un contexto social real. Este enfoque permitió analizar la influencia de la IA predictiva en la gestión de crisis sociales en un entorno más cercano a la realidad, aceptando ciertas limitaciones en el control experimental (Campbell & Stanley, 1963). Se seleccionaron municipios en Perú con características socioeconómicas similares, algunos de los cuales se designaron como grupo experimental, donde se implementó el modelo de IA predictivo, y otros como grupo de control, donde se mantuvieron los métodos tradicionales de gestión de crisis.

Se recopilaron datos longitudinales durante un período de tres años (2021-2023), permitiendo observar la evolución de las crisis sociales en ambos grupos y evaluar el impacto de la IA en la anticipación y mitigación de estos eventos. La elección de un diseño cuasi-experimental se justificó por la necesidad de equilibrar el rigor científico con la complejidad del contexto social, buscando obtener resultados relevantes y aplicables a la gestión pública en Perú.

Recopilación de datos y fuentes de información

La recopilación de datos se basó en una estrategia de triangulación, combinando datos cuantitativos y cualitativos para obtener una comprensión más completa del fenómeno estudiado (Forni & Grande, 2020). Se recopilaron datos cuantitativos de fuentes oficiales como el INEI y el MEF, incluyendo indicadores demográficos, económicos y de desarrollo social a nivel municipal. Se utilizaron bases de datos de organismos internacionales como el Banco Mundial y el Fondo Monetario Internacional (FMI) para complementar la información nacional y contextualizar la situación peruana en el ámbito regional. Además, se recopilaron datos cualitativos a través de entrevistas semi-estructuradas con funcionarios públicos, líderes comunitarios y representantes de organizaciones sociales en los municipios seleccionados (Bryman, 2016).

Estas entrevistas permitieron obtener información sobre las percepciones, experiencias y estrategias de gestión de crisis en el contexto local. La integración de datos cuantitativos y cualitativos enriqueció el análisis y proporcionó una visión más completa de la dinámica de las crisis sociales en Perú.

Modelo predictivo de IA y herramientas de análisis

Se implementó un modelo híbrido que combinó redes neuronales recurrentes (RNN-LSTM) con técnicas de procesamiento de lenguaje natural (NLP) para analizar datos estructurados y no estructurados (Goodfellow et al., 2016). Las RNN-LSTM se utilizaron para procesar las series temporales de indicadores socioeconómicos, mientras que las técnicas de NLP se aplicaron al análisis de datos textuales extraídos de redes sociales y noticias en línea. La combinación de ambos enfoques permitió capturar la dinámica temporal de las variables cuantitativas y el sentimiento público expresado en el lenguaje, mejorando la capacidad predictiva del modelo. Se utilizó la plataforma Google Cloud Platform (GCP) para el procesamiento y análisis de grandes volúmenes de datos, aprovechando la infraestructura y las herramientas de aprendizaje automático disponibles en la nube. Se implementaron algoritmos de aprendizaje profundo para optimizar el rendimiento del modelo y se realizaron experimentos con diferentes arquitecturas de redes neuronales para encontrar la configuración más adecuada para la predicción de crisis sociales en el contexto peruano.

Evaluación del modelo y análisis de precisión

La evaluación del modelo se realizó utilizando una combinación de técnicas para asegurar la robustez de los resultados. Se implementó una estrategia de validación cruzada anidada, combinando la validación cruzada k-fold con una validación externa para evaluar la capacidad de generalización del modelo a datos no utilizados en el entrenamiento (Yang & Shami, 2020).

Se reservó un 20% del conjunto de datos para la validación externa, mientras que el 80% restante se utilizó para el entrenamiento y la validación cruzada k-fold con $k=10$. Se calcularon métricas como la precisión, el recall, la F1-score y el área bajo la curva precisión-recall (AUPRC) para evaluar el rendimiento del modelo en la predicción de crisis sociales (Davis & Goadrich, 2006, citados en Ihme et al., 2022).

La AUPRC se consideró especialmente relevante en este contexto, dado el desbalance de clases que suele presentarse en los datos de crisis sociales, donde la ocurrencia de crisis es menos frecuente que la ausencia de las mismas. Además de las métricas cuantitativas, se realizó un análisis cualitativo de las predicciones del modelo, comparando los resultados con el conocimiento experto de sociólogos y politólogos especializados en el contexto peruano.

Se analizaron los casos en los que el modelo predijo correctamente la ocurrencia de crisis sociales y los casos en los que falló, buscando identificar patrones y comprender



las limitaciones del modelo. Este análisis cualitativo permitió contextualizar los resultados cuantitativos y obtener una comprensión más profunda de la dinámica de las crisis sociales en Perú.

Finalmente, se realizó un análisis de la curva ROC y la curva de calibración para evaluar la capacidad discriminativa y la confiabilidad de las probabilidades predichas por el modelo (Steyerberg et al., 2010, citados en Clift et al., 2020). La combinación de estos métodos de evaluación proporcionó una visión integral del rendimiento del modelo y su capacidad para predecir crisis sociales en el contexto peruano.

RESULTADOS

Desempeño del modelo predictivo

El modelo predictivo, basado en la arquitectura RNN-LSTM, fue entrenado con un conjunto de datos que abarcaba registros de crisis sociales en Perú entre 2010 y 2023. La validación cruzada anidada, una técnica robusta que combina la validación cruzada k-fold con una validación externa, se empleó para evaluar el rendimiento del modelo y su capacidad de generalización. La validación cruzada k-fold, con $k=10$, dividió el conjunto de datos en 10 subconjuntos, utilizando 9 para entrenar el modelo y 1 para validarlo, repitiendo este proceso 10 veces.

Este método permitió una evaluación exhaustiva del modelo, utilizando todos los datos disponibles tanto para entrenamiento como para validación. Los resultados de la validación cruzada k-fold mostraron una precisión promedio del 87.3%, lo que significa que el modelo clasificó correctamente la presencia o ausencia de una crisis social en aproximadamente 87 de cada 100 casos. El recall promedio, que mide la capacidad del modelo para identificar correctamente las crisis sociales que realmente ocurrieron, fue del 82.5%. La F1-score, una métrica que combina precisión y recall, alcanzó un valor promedio de 0.85, indicando un buen equilibrio entre la capacidad del modelo para evitar falsos positivos y falsos negativos.

Tabla 1. *Métricas de Desempeño del Modelo Predictivo (Validación Cruzada k-fold y Validación Externa).*

Métrica	Validación Cruzada k-fold (Promedio)	Validación Externa
Precisión	87.3%	85.1%
Recall	82.5%	80.2%
F1-score	0.85	0.83
AUC	0.92	0.90
AUPRC	0.88	0.85

La validación externa, realizada con el 20% de los datos que no se utilizaron en el entrenamiento, permitió evaluar la capacidad del modelo para generalizar a datos nuevos. Los resultados de la validación externa mostraron una precisión del 85.1%, un recall del 80.2% y una F1-score de 0.83. Estos valores, ligeramente inferiores a los obtenidos en la validación cruzada k-fold, siguen siendo altos y sugieren que el modelo es capaz de predecir con precisión la ocurrencia de crisis sociales en situaciones nuevas.

El área bajo la curva ROC (AUC), una métrica que evalúa la capacidad del modelo para distinguir entre situaciones de crisis y no crisis, fue de 0.92 en la validación cruzada k-fold y 0.90 en la validación externa. Estos valores, cercanos a 1, indican un excelente rendimiento del modelo en la discriminación entre las dos clases. El área bajo la curva precisión-recall (AUPRC), una métrica particularmente útil en contextos con desbalance de clases fue de 0.88 en la validación cruzada k-fold y 0.85 en la validación externa. Estos resultados confirman la capacidad del modelo para predecir con precisión la ocurrencia de crisis sociales, incluso cuando la ocurrencia de crisis es menos frecuente que la ausencia de las mismas. La curva de calibración, que compara las probabilidades predichas por el modelo con las frecuencias observadas, mostró una buena correspondencia, lo que indica que las probabilidades generadas por el modelo son confiables




Figura 1. *Evolución del Sentimiento Negativo en Redes Sociales (2021-2023)*

Identificación de factores de riesgo

El análisis de sensibilidad, realizado para identificar los factores que más influyen en las predicciones del modelo, reveló la importancia de variables socioeconómicas y de sentimiento público. El coeficiente de Gini, una medida de desigualdad económica mostró una fuerte correlación positiva (0.75) con la ocurrencia de crisis sociales, lo que indica que una mayor desigualdad aumenta la probabilidad de crisis. La tasa de desempleo también se correlacionó positivamente (0.68) con la ocurrencia de crisis. El sentimiento negativo expresado en redes sociales, medido a través del análisis del lenguaje utilizado en las publicaciones, mostró una correlación positiva de 0.59. Estos resultados sugieren que el malestar social, expresado tanto en indicadores económicos como en el sentimiento público, juega un papel importante en la generación de crisis.




Figura 2. Comparación del Desempeño del Modelo con Métodos Tradicionales

Tabla 2. Factores de Riesgo Identificados por el Modelo Predictivo.

Factor de Riesgo	Coefficiente de Correlación	Valor p	Importancia Relativa (%)
Coeficiente de Gini	0.75	<0.001	25
Tasa de Desempleo	0.68	<0.001	22
Sentimiento Negativo en Redes	0.59	<0.01	19
Índice de Desarrollo Humano (IDH)	-0.52	<0.01	17
Inversión Social del Estado	-0.65	<0.001	17

Tabla 3. Correlación entre Factores de Riesgo e Indicadores de Crisis Sociales.

Factor de Riesgo	Número de Protestas	Intensidad de las Protestas	Duración de las Protestas
Coeficiente de Gini	0.78	0.65	0.52
Tasa de Desempleo	0.72	0.60	0.48
Sentimiento Negativo en Redes	0.65	0.55	0.42

Índice de Desarrollo Humano (IDH)	-0.60	-0.50	-0.40
Inversión Social del Estado	-0.68	-0.58	-0.45

La importancia relativa de cada factor se calculó utilizando técnicas de permutación de las variables de entrada, mostrando el porcentaje de reducción en el rendimiento del modelo al eliminar cada factor.




Figura 3. *Distribución Geográfica de las Crisis Sociales Predichas*

Ejemplos de predicciones con eficiencia notable

El modelo demostró una alta capacidad predictiva en casos específicos de crisis sociales. Por ejemplo, en septiembre de 2022, el modelo predijo con un 85% de probabilidad una crisis social en la región de Puno, relacionada con la actividad minera.

El modelo identificó un aumento en el sentimiento negativo en redes sociales y una tendencia al alza en la tasa de desempleo como factores clave para la predicción. Esta predicción se alineó con los eventos reales, ya que en dicho mes se registraron protestas significativas en la región, confirmando la capacidad del modelo para anticipar eventos críticos.

Tabla 4. Predicción de la Crisis Social en Puno (septiembre 2022)

Indicador	Valor Predicho por el Modelo	Valor Real
Probabilidad de Crisis Social	85%	Sí
Sentimiento Negativo en Redes	0.75 (Escala 0-1)	0.72 (Escala 0-1)
Tasa de Desempleo	12%	11.5%

En noviembre de 2023, el modelo predijo una crisis social en Arequipa relacionada con la escasez de agua, con una probabilidad del 78%. El modelo consideró la disminución de las precipitaciones, el aumento del costo del agua y el incremento del sentimiento negativo en redes sociales como factores determinantes. La predicción se confirmó con protestas y manifestaciones en la región, demostrando la capacidad del modelo para integrar múltiples variables en el análisis predictivo.



Figura 3. Precisión del Modelo por Tipo de Crisis.



DISCUSIÓN

Implicaciones para la Gestión Pública y la Gobernanza

Los resultados de este estudio demuestran el potencial transformador de la IA predictiva para la gestión pública y la gobernanza en el ámbito de la prevención de crisis sociales. La capacidad del modelo para anticipar eventos críticos con un alto grado de precisión ofrece a las instituciones públicas una ventaja estratégica para la toma de decisiones proactivas y la implementación de medidas preventivas (OECD, 2020).

Esto representa un cambio de paradigma en la gestión de crisis, pasando de un enfoque reactivo, basado en la respuesta a eventos ya ocurridos, a un enfoque proactivo, centrado en la anticipación y la mitigación de riesgos. La integración de la IA en los sistemas de gestión pública permite a las autoridades comprender mejor las dinámicas sociales, identificar patrones de comportamiento y prever posibles escenarios de crisis (Guterres, 2020). Esta capacidad predictiva no solo mejora la eficiencia en la asignación de recursos, sino que también fortalece la legitimidad del Estado al demostrar una mayor capacidad para proteger a la población y mantener la estabilidad social (Zuiderveen Borgesius et al., 2020).

La IA predictiva puede ser utilizada para diseñar políticas públicas más focalizadas y efectivas, dirigidas a las poblaciones y áreas geográficas con mayor vulnerabilidad ante las crisis sociales. Al identificar los factores de riesgo con mayor precisión, las autoridades pueden implementar intervenciones tempranas y personalizadas para mitigar los riesgos y prevenir la escalada de conflictos (Duberry, 2022).

Además, la IA facilita la coordinación entre diferentes agencias gubernamentales, promoviendo la colaboración y el intercambio de información para una respuesta más integrada y eficiente ante las crisis (Allen & Price, 2022). La transparencia en el uso de datos y los algoritmos de predicción es fundamental para generar confianza en la ciudadanía y asegurar la legitimidad de las decisiones tomadas con base en la IA.

Beneficios y Desafíos de la Implementación

La implementación de modelos predictivos de IA en la gestión pública ofrece numerosos beneficios, desde la mejora en la capacidad de anticipación y la optimización de recursos hasta la toma de decisiones más informada y el diseño de políticas públicas más efectivas (Heurtebise, 2015). La IA permite analizar grandes volúmenes de datos

de diversas fuentes, identificando patrones y tendencias que serían difíciles de detectar con los métodos tradicionales (Bughin et al., 2018).

Esto se traduce en una mayor capacidad para prever y responder a las crisis sociales, reduciendo su impacto y protegiendo a la población. Además, la IA puede ayudar a identificar las causas subyacentes de las crisis, permitiendo a las autoridades abordar los problemas estructurales que las originan. Sin embargo, la implementación de la IA también presenta desafíos significativos que deben ser considerados cuidadosamente.

Uno de los principales desafíos es la necesidad de contar con personal capacitado para interpretar y utilizar los resultados de los modelos predictivos. La correcta interpretación de los datos y la comprensión de las limitaciones de los modelos son cruciales para evitar sesgos y tomar decisiones informadas (Eggers et al., 2017). Otro desafío es la ética en el uso de datos, especialmente en lo que se refiere a la privacidad y la protección de la información personal. Es fundamental establecer protocolos claros y transparentes para garantizar el uso responsable de los datos y proteger los derechos de los ciudadanos (Cockburn et al., 2018).

La capacidad técnica de las entidades públicas también es un factor determinante para el éxito de la implementación. Se requiere infraestructura tecnológica adecuada, así como personal capacitado en el manejo de datos y herramientas de IA. La inversión en tecnología y capacitación es esencial para que las instituciones puedan aprovechar al máximo el potencial de la IA.

La integración de la IA en los procesos de toma de decisiones existentes también plantea desafíos. Es fundamental que la IA se integre de forma efectiva en los flujos de trabajo y las estructuras organizacionales de las instituciones públicas (Delera et al., 2022). La IA no debe ser vista como una solución aislada, sino como una herramienta que complementa y fortalece los procesos de gestión pública. La resistencia al cambio por parte del personal y la falta de comprensión sobre las capacidades y limitaciones de la IA pueden dificultar su integración. Es importante promover una cultura de innovación y aprendizaje dentro de las instituciones públicas para facilitar la adopción de la IA y maximizar sus beneficios.

Adaptación Cultural y Viabilidad en América Latina

La adaptación cultural y la viabilidad de la implementación de modelos predictivos de IA en América Latina requieren un análisis profundo del contexto específico de cada país. Si bien los resultados de este estudio en Perú son alentadores, es crucial considerar las particularidades de cada nación al momento de implementar estas tecnologías.



Factores como la disponibilidad de datos, la infraestructura tecnológica, la capacidad técnica de las instituciones públicas y el nivel de confianza en la tecnología pueden influir significativamente en la viabilidad de la IA en la gestión de crisis sociales (Stark et al., 2020). La adaptación cultural implica no solo la traducción de interfaces y la adecuación de los modelos a las características locales, sino también la consideración de las normas sociales, los valores culturales y las dinámicas políticas de cada país.

En América Latina, la desigualdad social, la inestabilidad política y la corrupción son factores que pueden influir en la dinámica de las crisis sociales y deben ser considerados en el diseño e implementación de modelos predictivos (Pursiainen et al., 2017). La disponibilidad de datos confiables y actualizados también es un desafío en la región. Es necesario invertir en la creación y el fortalecimiento de sistemas de recopilación de datos para asegurar la calidad y la disponibilidad de la información necesaria para alimentar los modelos de IA. La colaboración regional en el desarrollo e implementación de modelos predictivos de IA es fundamental para compartir experiencias, datos y recursos, fortaleciendo la capacidad de los países latinoamericanos para prevenir y gestionar crisis sociales.

La transferencia de conocimiento y tecnología entre países con mayor desarrollo en IA y aquellos con menor capacidad técnica puede acelerar la adopción de estas herramientas en la región. Es importante promover la formación de talento humano especializado en IA y ciencia de datos para asegurar la sostenibilidad de las iniciativas de predicción de crisis sociales. Además, es fundamental generar confianza en la ciudadanía sobre el uso ético y responsable de la IA en la gestión pública, promoviendo la transparencia y la participación ciudadana en el diseño e implementación de estas tecnologías.

CONCLUSIONES

Este estudio ha demostrado la eficacia de los modelos predictivos de IA, específicamente la arquitectura RNN-LSTM, para anticipar crisis sociales en el contexto de la gestión pública peruana. Los resultados obtenidos a través de la validación cruzada anidada, con una precisión superior al 85% tanto en la validación cruzada k-fold como en la validación externa, confirman la capacidad del modelo para predecir con alta precisión la ocurrencia de crisis sociales.

El análisis de sensibilidad reveló la importancia de factores socioeconómicos, como la desigualdad económica y la tasa de desempleo, así como del sentimiento negativo expresado en redes sociales, como predictores significativos de crisis.

La capacidad del modelo para integrar diversas fuentes de datos, incluyendo información socioeconómica, datos de redes sociales y registros históricos, permite una comprensión más completa de la dinámica de las crisis sociales y una anticipación más precisa de eventos críticos.

Los ejemplos de predicciones exitosas en las regiones de Puno y Arequipa, alineadas con eventos reales, demuestran el potencial de la IA para mejorar la capacidad de respuesta de las instituciones públicas ante situaciones de crisis.

Recomendaciones para políticas públicas basadas en datos predictivos

Con base en los resultados de este estudio, se recomienda la incorporación de la IA predictiva en el diseño e implementación de políticas públicas orientadas a la prevención de crisis sociales. Se sugiere la creación de una plataforma nacional de datos que integre información de diversas fuentes, garantizando la calidad, accesibilidad y seguridad de los datos. Esta plataforma facilitaría el desarrollo y entrenamiento de modelos predictivos, así como su aplicación en la gestión pública.

Se recomienda la capacitación de funcionarios públicos en el uso e interpretación de la IA, promoviendo la formación de equipos multidisciplinarios que combinen el conocimiento experto en ciencias sociales con la experiencia técnica en IA. Es fundamental establecer protocolos éticos y transparentes para el uso de datos, garantizando la privacidad y la protección de la información personal. La colaboración entre instituciones públicas, la academia y el sector privado es esencial para el desarrollo e implementación de soluciones de IA que respondan a las necesidades específicas del contexto peruano.

Se recomienda la implementación gradual de sistemas de alerta temprana basados en IA, que permitan a las autoridades anticipar y responder de manera proactiva a las crisis sociales. Estos sistemas deberían integrarse en los procesos de toma de decisiones de las instituciones públicas, facilitando la coordinación y la comunicación entre diferentes agencias gubernamentales. Se sugiere la creación de un comité de ética para supervisar el uso de la IA en la gestión pública, garantizando la transparencia y la rendición de cuentas en la aplicación de estas tecnologías.



Se recomienda la promoción de la investigación y el desarrollo en IA aplicada a la gestión social, fomentando la innovación y la creación de soluciones adaptadas a las necesidades del Perú.

Futuras líneas de investigación

Este estudio abre nuevas líneas de investigación para explorar el potencial de la IA en la predicción de crisis sociales. Se recomienda investigar la incorporación de datos en tiempo real en los modelos predictivos, utilizando fuentes como sensores, redes sociales y noticias en línea para mejorar la capacidad de anticipación. Se sugiere explorar el uso de otras arquitecturas de IA, como redes neuronales convolucionales (CNN) y transformers, para el análisis de imágenes y texto, complementando la información socioeconómica. Se recomienda investigar la aplicación de la IA en la predicción de otros tipos de crisis, como crisis económicas, sanitarias y ambientales, ampliando el alcance de la IA en la gestión pública. La investigación interdisciplinaria, que combine la experiencia en ciencias sociales, computación e ingeniería, es fundamental para avanzar en el desarrollo de soluciones de IA que respondan a los desafíos complejos de la gestión pública. Se propone investigar la influencia de factores culturales y políticos en la eficacia de los modelos predictivos de IA, analizando las particularidades de diferentes contextos sociales. Se sugiere explorar el uso de técnicas de explicabilidad de la IA para comprender mejor las decisiones tomadas por los modelos predictivos y generar mayor confianza en su uso.

REFERENCIAS

- Allen, C., & Price, M. (2022). Artificial intelligence and the future of public administration. *Public Administration Review*, 82(1), 10-22.
- Agrawal, A., Gans, J., & Goldfarb, A. (2019). Exploring the impact of artificial intelligence: Prediction versus judgment. *Information Economics and Policy*, 47, 1-6. <https://www.sciencedirect.com/science/article/pii/S0167624518301136>
- Bryman, A. (2016). *Social Research Methods*. Oxford University Press.
- Bughin, J., Seong, J., Manyika, J., Chui, M., & Joshi, R. (2018). Notes from the AI frontier: Modeling the impact of AI on the world economy. *McKinsey Global Institute*, 4(1).

- Campbell, D., & Stanley, J. (2015). *Experimental and quasi-experimental designs for research*. Ravenio books.
- Clift, A. K., Coupland, C. A., Keogh, R. H., Diaz-Ordaz, K., Williamson, E., Harrison, E. M., ... & Hippisley-Cox, J. (2020). Living risk prediction algorithm (QCOVID) for risk of hospital admission and mortality from coronavirus 19 in adults: national derivation and validation cohort study. *bmj*, 371. <https://www.bmj.com/content/371/bmj.m3731.short>
- Cockburn, I. M., Henderson, R., & Stern, S. (2018). *The impact of artificial intelligence on innovation* (Vol. 24449). Cambridge, MA, USA: National bureau of economic research. <https://www.degruyter.com/document/doi/10.7208/9780226613475-006/pdf?licenseType=restricted>
- Davis, J., & Goadrich, M. (2006). The relationship between Precision-Recall and ROC curves. *Proceedings of the 23rd international conference on Machine learning - ICML '06*. <https://dl.acm.org/doi/abs/10.1145/1143844.1143874>
- Delera, M., Pietrobelli, C., Calza, E., & Lavopa, A. (2022). Does value chain participation facilitate the adoption of industry 4.0 technologies in developing countries?. *World Development*, 152, 105788. <https://www.sciencedirect.com/science/article/pii/S0305750X21004034>
- Distel, B., & Lindgren, I. (2023). A matter of perspective: Conceptualizing the role of citizens in E-government based on value positions. *Government Information Quarterly*, 40(4), 101837. <https://www.sciencedirect.com/science/article/pii/S0740624X23000370>
- Duberry, J. (2022). Artificial intelligence and democracy: risks and promises of AI-mediated citizen–government relations. In *Artificial Intelligence and Democracy*. Edward Elgar Publishing. <https://www.elgaronline.com/monobook-oa/book/9781788977319/9781788977319.xml?rskey=wA8Q39>
- Eggers, W. D., et al. (2017). *Delivering on digital: The innovators and technologies that are transforming government*. Deloitte University Press.
- Forni, P., & Grande, P. D. (2020). Triangulación y métodos mixtos en las ciencias sociales contemporáneas. *Revista mexicana de sociología*, 82(1), 159-189. https://www.scielo.org.mx/scielo.php?pid=S0188-25032020000100159&script=sci_arttext



- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
- Guterres, A. (2020). Roadmap for digital cooperation. *United Nations* https://www.un.org/techenvoy/sites/www.un.org.techenvoy/files/Update_on_Roadmap_implementation_July_2022.pdf
- Heurtebise, J. Y. (2015). Global risks: Cause and consequence of the new interactions between science, technology, and society. *The Handbook of Global Science, Technology, and Innovation*, 558-574. <https://onlinelibrary.wiley.com/doi/abs/10.1002/9781118739044.ch27>
- Ihme, M., Chung, W. T., & Mishra, A. A. (2022). Combustion machine learning: Principles, progress and prospects. *Progress in Energy and Combustion Science*, 91, 101010. <https://www.sciencedirect.com/science/article/pii/S0360128522000193>
- OECD. (2020). *Embracing the digital transformation of government*. OECD Publishing. <https://www.oecd.org/en/topics/digital-government.html>
- Pursiainen, C. (2017). *The crisis management cycle*. Routledge. <https://www.taylorfrancis.com/books/mono/10.4324/9781315629179/crisis-management-cycle-christer-pursiainen>
- Steyerberg, E. W., Vickers, A. J., Cook, N. R., Gerds, T., Gonen, M., Obuchowski, N., & Kattan, M. W. (2010). Assessing the performance of prediction models: a framework for traditional and novel measures. *Epidemiology*, 21(1), 128-138. https://journals.lww.com/epidem/FullText/2010/01000/Assessing_the_Performance_of_Prediction_Models__A.22.aspx
- Stark, B., Stegmann, D., Magin, M., & Jürgens, P. (2020). Are algorithms a threat to democracy? The rise of intermediaries: A challenge for public discourse. *Algorithm Watch*, 26. <https://algorithmwatch.org/de/wp-content/uploads/2020/05/Governing-Platforms-communications-study-Stark-May-2020-AlgorithmWatch.pdf>
- Yang, L., & Shami, A. (2020). On hyperparameter optimization of machine learning algorithms: Theory and practice. *Neurocomputing*, 415, 295-316. <https://www.sciencedirect.com/science/article/pii/S0925231220311693>
- Zuiderveen, F. (2020). Strengthening legal protection against discrimination by algorithms and artificial intelligence. *The International Journal of Human*

Rights, 24(10), 1572-1593. <https://www.tandfonline.com/doi/abs/10.1080/13642987.2020.1743976>