



UNIVERSITAT  
POLITÈCNICA  
DE VALÈNCIA



DEPARTAMENTO DE  
COMUNICACIONES

Arquitectura de un Sistema de Geo-Visualización Espaciotemporal de actividad delictiva, basada en el análisis masivo de datos, aplicada a Sistemas de Información de Comando y Control (C2IS)

Escuela Técnica Superior de Ingeniería de Telecomunicación  
Departamento de Comunicaciones  
Universitat Politècnica de València

Tesis presentada para la obtención del grado de  
*Doctora en Telecomunicación por la Universitat Politècnica de València*  
Valencia, noviembre de 2022

Autora:  
Mayra Liliana Salcedo González

Director:  
Dr. Manuel Esteve Domingo

*A toda mi familia, quienes siempre han estado conmigo en cada uno de los retos de mi vida; y a mi apreciado director de tesis, por su apoyo no solo en todas las etapas de este enriquecedor proceso, sino en mi proceso de formación profesional desde hace muchos años.*

## RESUMEN

La presente tesis doctoral propone la arquitectura de un sistema de Geo-visualización Espaciotemporal de actividad delictiva y criminal, para ser aplicada a Sistemas de Comando y Control (C2S) específicamente dentro de sus Sistemas de Información de Comando y Control (C2IS). El sistema de Geo-visualización Espaciotemporal se basa en el análisis masivo de datos reales de actividad delictiva, proporcionado por la Policía Nacional Colombiana (PONAL) y está compuesto por dos aplicaciones diferentes: la primera permite al usuario geo-visualizar espaciotemporalmente de forma dinámica, las concentraciones, tendencias y patrones de movilidad de esta actividad dentro de la extensión de área geográfica y el rango de fechas y horas que se precise, lo cual permite al usuario realizar análisis e interpretaciones y tomar decisiones estratégicas de acción más acertadas; la segunda aplicación permite al usuario geo-visualizar espaciotemporalmente las predicciones de la actividad delictiva en periodos continuos y cortos a modo de tiempo real, esto también dentro de la extensión de área geográfica y el rango de fechas y horas de elección del usuario. Para estas predicciones se usaron técnicas clásicas y técnicas de Machine Learning (incluido el Deep Learning), adecuadas para el pronóstico en multiparalelo de varios pasos de series temporales multivariantes con datos escasos. Las dos aplicaciones del sistema, cuyo desarrollo se muestra en esta tesis, están realizadas con métodos novedosos que permitieron lograr estos objetivos de efectividad a la hora de

detectar el volumen y los patrones y tendencias en el desplazamiento de dicha actividad, mejorando así la conciencia situacional, la proyección futura y la agilidad y eficiencia en los procesos de toma de decisiones, particularmente en la gestión de los recursos destinados a la disuasión, prevención y control del delito, lo cual contribuye a los objetivos de ciudad segura y por consiguiente de ciudad inteligente, dentro de arquitecturas de Sistemas de Comando y Control (C2S) como en el caso de los Centros de Comando y Control de Seguridad Ciudadana de la PONAL.

## RESUM

Aquesta tesi doctoral proposa l'arquitectura d'un sistema de Geo-visualització Espaitemporal d'activitat delictiva i criminal, per ser aplicada a Sistemes de Comandament i Control (C2S) específicament dins dels seus Sistemes d'informació de Comandament i Control (C2IS). El sistema de Geo-visualització Espaitemporal es basa en l'anàlisi massiva de dades reals d'activitat delictiva, proporcionada per la Policia Nacional Colombiana (PONAL) i està composta per dues aplicacions diferents: la primera permet a l'usuari geo-visualitzar espaitemporalment de forma dinàmica, les concentracions, les tendències i els patrons de mobilitat d'aquesta activitat dins de l'extensió d'àrea geogràfica i el rang de dates i hores que calgui, la qual cosa permet a l'usuari fer anàlisis i interpretacions i prendre decisions estratègiques d'acció més encertades; la segona aplicació permet a l'usuari geovisualitzar espaciotemporalment les prediccions de l'activitat delictiva en períodes continus i curts a mode de temps real, això també dins l'extensió d'àrea geogràfica i el rang de dates i hores d'elecció de l'usuari. Per a aquestes prediccions es van usar tècniques clàssiques i tècniques de Machine Learning (inclòs el Deep Learning), adequades per al pronòstic en multiparal·lel de diversos passos de sèries temporals multivariants amb dades escasses. Les dues aplicacions del sistema, el desenvolupament de les quals es mostra en aquesta tesi, estan realitzades amb mètodes nous que van permetre assolir aquests objectius d'efectivitat a l'hora de detectar el volum i els patrons i les tendències en el desplaçament d'aquesta

activitat, millorant així la consciència situacional , la projecció futura i l'agilitat i eficiència en els processos de presa de decisions, particularment en la gestió dels recursos destinats a la dissuasió, prevenció i control del delicte, la qual cosa contribueix als objectius de ciutat segura i per tant de ciutat intel·ligent , dins arquitectures de Sistemes de Comandament i Control (C2S) com en el cas dels Centres de Comandament i Control de Seguretat Ciutadana de la PONAL.

## ABSTRACT

This doctoral thesis proposes the architecture of a Spatiotemporal Geo-visualization system of criminal activity, to be applied to Command and Control Systems (C2S) specifically within their Command and Control Information Systems (C2IS). The Spatiotemporal Geo-visualization system is based on the massive analysis of real data of criminal activity, provided by the Colombian National Police (PONAL) and is made up of two different applications: the first allows the user to dynamically geo-visualize spatiotemporally, the concentrations, trends and patterns of mobility of this activity within the extension of the geographic area and the range of dates and times that are required, which allows the user to carry out analyses and interpretations and make more accurate strategic action decisions; the second application allows the user to spatially visualize the predictions of criminal activity in continuous and short periods like in real time, this also within the extension of the geographic area and the range of dates and times of the user's choice. For these predictions, classical techniques and Machine Learning techniques (including Deep Learning) were used, suitable for multistep multiparallel forecasting of multivariate time series with sparse data. The two applications of the system, whose development is shown in this thesis, are carried out with innovative methods that allowed achieving these effectiveness objectives when detecting the volume and patterns and trends in the movement of said activity, thus improving situational awareness, the future projection and the agility and efficiency in the

decision-making processes, particularly in the management of the resources destined to the dissuasion, prevention and control of crime, which contributes to the objectives of a safe city and therefore of a smart city, within architectures of Command and Control Systems (C2S) as in the case of the Citizen Security Command and Control Centers of the PONAL.

## **AGRADECIMIENTOS**

*A mi querida familia por su apoyo incondicional en cada uno de los retos que he emprendido.*

*A la Oficina de Telemática de la Policía Nacional de Colombia por su interés en este trabajo y su disposición para brindarme la información y los datos necesarios para realizarlo.*

*A mi director de tesis el Dr. Manuel Esteve Domingo, Catedrático de la Escuela Técnica Superior de Ingeniería de Telecomunicación de la UPV y al Dr. Jon Ander Gómez catedrático de la Escuela Técnica Superior de Ingeniería Informática de la UPV, por su acompañamiento y apoyo en el desarrollo de esta tesis doctoral.*

# ÍNDICE

RESUMEN.....	3
RESUM.....	5
ABSTRACT.....	7
AGRADECIMIENTOS.....	9
ÍNDICE.....	10
ÍNDICE DE FIGURAS .....	14
1.CAPÍTULO I: INTRODUCCIÓN Y OBJETIVOS .....	18
1.1 <i>Introducción</i> .....	18
1.2 <i>Objetivos</i> .....	23
2.CAPÍTULO II: ARQUITECTURA DE LOS SISTEMAS DE COMANDO Y CONTROL (C2S) Y DE LOS SISTEMAS DE INFORMACIÓN DE COMANDO Y CONTROL (C2IS) DE LA POLICÍA NACIONAL COLOMBIANA (PONAL) .....	25
3.CAPÍTULO III: EL GEO-VISUALIZADOR ESPACIOTEMPORAL DINÁMICO .....	30
3.1 <i>Estado del Arte</i> .....	31

3.2	<i>Desarrollo del Geo-Visualizador Espaciotemporal Dinámico</i>	35
3.2.1	Fase final de Construcción	44
4.	CAPÍTULO IV: EL GEO-VISUALIZADOR ESPACIOTEMPORAL PREDICTIVO	50
4.1	<i>Estado del Arte</i>	51
4.2	<i>Desarrollo del Geo-Visualizador Espaciotemporal Predictivo</i>	54
4.2.1	Agrupación espacial geográfica del área de observación para su correlación.....	55
4.2.2	Agrupación temporal de los eventos delictivos del área de observación para su correlación.....	58
4.2.3	El Pronóstico de los datos y su Geo-visualización Espaciotemporal.....	62
4.2.3.1	El Modelo de Referencia.....	73
	Generalidades acerca de los resultados de los modelos y las pruebas realizadas:.....	75
4.2.3.2	Modelos clásicos para el pronóstico de Series Temporales Multivariantes	76
	Modelos VARMA (Vector Autorregresivo de Medias Móviles) y VMA (Vector de Medias Móviles): .....	77
	Modelos VAR (Vector Autorregresivo): .....	77
	Modelos Clásicos para Series Temporales Multivariantes tipo SPARSE (dispersas):.....	79

4.2.3.3 Modelos de Machine Learning para el pronóstico de Series Temporales Multivariantes.....	79
4.2.3.4 Modelos de Deep Learning para el pronóstico de Series Temporales Multivariantes	80
Modelos de Red Neuronal MLP (Multilayer Perceptron): .....	81
Modelos CNN-1D (Convolutional Neural Network-1D): .....	83
Modelos LSTM (Long Short-Term Memory):.....	86
5.CAPÍTULO V: GEO-CODIFICACIÓN SOBRE EL SISTEMA DE GEO-VISUALIZACIÓN ESPACIOTEMPORAL .....	97
6.CAPÍTULO VI: ARQUITECTURA DEL SISTEMA DE GEO-VISUALIZACIÓN ESPACIOTEMPORAL, INTEGRADA A LA ARQUITECTURA DE LOS SISTEMAS DE COMANDO Y CONTROL DE LA PONAL .....	99
6.1 <i>Hardware y Software de la Arquitectura del Sistema de Geo-Visualización Espaciotemporal</i> .....	100
6.2 <i>Implementaciones de la Arquitectura del Sistema de Geo-Visualización Espaciotemporal integrada a C2S de la PONAL</i> .....	102
Sistema de información para el Seguimiento y Control de Casos (SECAD): .....	105
7.CAPÍTULO VII: DISCUSIÓN DE LOS RESULTADOS .....	107
Productos de Investigación de esta Tesis Doctoral: .....	111

8. <i>CAPÍTULO VIII: CONCLUSIONES Y TRABAJO FUTURO</i> .....	117
8.1 <i>Conclusiones</i> .....	117
8.2 <i>Trabajo Futuro</i> .....	120
REFERENCIAS.....	121

## ÍNDICE DE FIGURAS

Figura 1. Arquitectura de los Sists de Comando y Control (C2S) y de los Sistemas de Información de Comando y Control C2IS, Policía Nacional Colombiana.....	26
Figura 2. Ciclo OODA (Observación-Orientación-Decisión-Acción) de Comando y Control. ....	27
Figura 3. Integración del sistema de Geo-visualización Espaciotemporal a la Arquitectura de los Sistemas de Comando y Control (C2S) de la Policía Nacional Colombiana. ....	29
Figura 4. Formato de base del Dataset para el Geo-visualizador Espaciotemporal Dinámico. ....	38
Figura 5. Sistema de cuadrículas: Cuadrícula doble desfasada al 25%.....	40
Figura 6. Sistema de cuadrículas sobrepuesto al mapa geográfico de la zona de observación.....	41
Figura 7. Muestras de visualización de datos sobre el sistema, en orden: 6 meses, 4 días, 7 h. ....	43
Figura 8. Distribución de ventanas deslizantes temporales, definición de $\Delta t$ para el Geo-visualizador Espaciotemporal Dinámico. ....	46

Figura 9. Gráficos de Geo-visualización Espaciotemporal Dinámica de datos delictivos y criminales sobre mapa geográfico. Capturas de diferentes cuadros y con diferentes escalas de conteo. En este caso, con una ventana deslizante temporal de 30 min y $\Delta t = 20$ min. ....	48
Figura 10. Arquitectura completa del Geo-visualización Espaciotemporal Dinámico de datos delictivos y criminales sobre mapa geográfico, para aplicaciones C2S. 49	
Figura 11. Formato de base del Dataset para el Geo-visualizador Espaciotemporal Predictivo. ....	54
Figura 12. Agrupación espacial geográfica con cuadrícula en subáreas.....	57
Figura 13. Sistema de cuadrícula superpuesto al mapa geográfico del área de observación (captura). ....	58
Figura 14. Agrupación temporal por medio de ventanas deslizantes temporales y definición de $\Delta t$ , para el Geo-visualizador Espaciotemporal Predictivo.....	60
Figura 15. Muestra aleatoria de la representación de las densidades de eventos delictivos y criminales por subáreas, sobre mapa geográfico. Valor de ventana deslizante temporal = 30 minutos y valor de $\Delta t = 10$ minutos (captura).....	61
Figura 16. Ejemplo de Serie Temporal Multivariante – 3D.....	63
Figura 17. Ejemplo de Serie Temporal Multivariante – 2D, con valor de frecuencia igual valor de $\Delta t = 10$ minutos. ....	64

Figura 18. Horizonte temporal de predicción o pronóstico de dos pasos en la Serie Temporal Multivariante Multiparalela. Cada paso corresponde a 10 minutos.....	69
Figura 19. Funcionamiento requerido del modelo predictivo para el máximo aprovechamiento de los datos reales que van sucediendo y pronóstico continuo con horizonte temporal corto. ....	70
Figura 20. Diagrama de Red Neuronal MLP (Multilayer Perceptron).....	82
Figura 21. Diagrama de Red Neuronal CNN-1D (Convolutional Neural Network-1D). .....	85
Figura 22. Diagrama de Red Neuronal de salida Univectorial Vanilla-LSTM y sus resultados. ....	87
Figura 23. Diagrama de Red Neuronal de salida Univectorial ConvLSTM y sus resultados. ....	88
Figura 24. Diagrama de Red Neuronal de salida Univectorial CNN-LSTM y sus resultados. ....	89
Figura 25. Diagrama de Red Neuronal Encoder-Decoder para salida Multivectorial VanillaLSTM - VanillaLSTM y sus resultados.....	90
Figura 26. Diagrama de Red Neuronal Encoder-Decoder para salida Multivectorial CNN_LSTM - VanillaLSTM y sus resultados. ....	91

Figura 27. Diagrama de Red Neuronal Encoder-Decoder para salida Multivectorial CNN - VanillaLSTM y sus resultados. ....	92
Figura 28. Diagrama de Red Neuronal Encoder-Decoder para salida Multivectorial ConvLSTM - VanillaLSTM y sus resultados. ....	93
Figura 29. Muestra aleatoria de la comparativa entre las geo-visualización de los datos reales y los datos predichos (captura). ....	95
Figura 30. Arquitectura completa del Geo-visualización Espaciotemporal Predictivo de datos delictivos y criminales sobre mapa geográfico, para aplicaciones C2S. ....	96
Figura 31. Geo-codificación y agrupaciones (captura): (a) Eventos delictivos y criminales geo-codificados inversamente a la dirección de calle. (b) Eventos delictivos y criminales agrupados por ubicación. ....	98
Figura 32. Resumen de la Arquitectura general completa del Sistema de Geo-visualización Espaciotemporal para datos de actividad delictiva y criminal. ....	100
Figura 33. Arquitectura General del Sistema de Geo-Visualización Espaciotemporal. Hardware/Software.....	101
Figura 34. Arquitectura del Sistema de Geo-Visualización Espaciotemporal, con la integración propuesta para el Sistema de Información de Comando y Control (C2IS), de la Policía Nacional Colombiana. ....	105

# **1. CAPÍTULO I: INTRODUCCIÓN Y OBJETIVOS**

## **1.1 Introducción**

El alto costo que acarrearán la delincuencia y la criminalidad, en mayor o menor medida a cualquier sociedad, no es un hecho desconocido, razón por la que dentro del trabajo constante que realizan las entidades encargadas del cumplimiento de la ley y las fuerzas del orden, las agencias de seguridad pública y los investigadores en todo el mundo para enfrentar sus efectos, es posible afirmar que, encaminar los esfuerzos hacia la creación de herramientas y estrategias para la prevención y la disuasión de este tipo de actividades, es quizás una de las mejores formas de combatirlas, salvar vidas y evitar las consecuencias de toda índole que estas actividades conllevan. No en vano puede afirmarse que, cada investigación que contribuya a la prevención o solución de delitos y crímenes, sobre todo si es de forma rápida, se justifica a sí misma, debido a que tener la posibilidad de mejorar la capacidad de reacción y de prevención, es en cualquier caso y bajo cualquier escenario, un recurso de gran valor.

Es por esto por lo que cuando se hace referencia al concepto de ciudad inteligente, definitivamente no es posible hacerlo sin incluir el concepto de ciudad segura [1], ya que, sin lugar a duda, los sistemas de ciudad segura componen uno de los campos principales dentro de las ciudades inteligentes, debido a que el principal

quehacer en el desarrollo de sistemas de ciudades seguras está centrado en la actividad delictiva, criminal y posiblemente también en la actividad terrorista. Y aunque existen diversas formas de abordar los retos que estas actividades presentan, el reto principal es comprender los entornos sociales, económicos, culturales, geográficos y administrativos (entre otros), de los lugares donde se pretende ejercer disuasión, prevención y control del delito, del crimen y del terrorismo, razón por la cual, cada entidad encargada del cumplimiento de la ley y de la seguridad ciudadana debe tener en cuenta dichos factores a la hora de crear y aplicar estrategias en las áreas de su potestad, que conlleven al cumplimiento de este objetivo.

Es precisamente dentro del marco de esta comprensión, que se desarrolla el trabajo de esta tesis doctoral, donde se parte del hecho de que en Colombia la entidad encargada de la seguridad ciudadana es la Policía Nacional Colombiana (PONAL), quien a través de su misionalidad y planificación, de sus aproximadamente 180.000 policías desplegados en todo el territorio nacional; y del desarrollo e implementación de herramientas tecnológicas como el Sistema de Comando y Control (C2S) [2], para el apoyo a sus Centros de Comando y Control de Seguridad Ciudadana; es quien, investiga, desarrolla e implementa las estrategias y los sistemas de seguridad ciudadana en el país.

No obstante el Sistema de Comando y Control (C2S) para Seguridad Ciudadana, de la Policía Nacional Colombiana es robusto y ya tiene integradas varias utilidades,

la PONAL detecta dentro de su experiencia en campo, la necesidad de herramientas que permitan medir, analizar y anticipar, de forma georreferenciada y temporal, los patrones y el desplazamiento de la movilidad de las actividades delictivas y criminales con el objetivo de mejorar sus acciones en el cumplimiento de sus estrategias antidelito, herramientas con las que aún no se contaba. Por lo que con el apoyo de su oficina de Telemática y después de una evaluación de procesos misionales y operativos de la institución, se tomó como modelo de desarrollo la ciudad de Santiago de Cali (Colombia) dado que es la tercera ciudad de Colombia y se disponía de gran cantidad de datos reales de actividad delictiva de esta ciudad. Además porque aunque en países tan extensos y multiculturales como Colombia, cada ciudad posea sus propios retos contra la actividad delictiva, el hecho de que todas las ciudades en Colombia se dividan por cuadrantes (y cualquier otra ciudad del mundo puede ser dividida en cuadrantes hipotéticos), usar como modelo los datos de una ciudad como Santiago de Cali garantiza que las herramientas desarrolladas se conviertan en genéricas y puedan ser utilizadas para cualquier otra ciudad, no solo en Colombia, sino en cualquier otro lugar.

Esta tesis doctoral, basada en investigación aplicada, propone entonces la arquitectura de un sistema encaminado a dar cubrimiento a esta necesidad de herramientas de Geo-visualización Espaciotemporal que permitan el análisis y previsión de datos de actividad delictiva y criminal, para ser aplicadas a los Centros de Comando y Control de Seguridad Ciudadana, específicamente dentro de sus Sistemas de Información de Comando y Control (C2IS). Este sistema de Geo-

visualización Espaciotemporal basado en el análisis masivo de una gran cantidad de datos reales de actividad delictiva y criminal, proporcionados por la PONAL, está compuesto por dos aplicaciones diferentes: **LA PRIMERA: EL GEO-VISUALIZADOR DINÁMICO Y ESPACIOTEMPORAL** que permite al usuario geo-visualizar espaciotemporalmente de forma dinámica, las concentraciones, tendencias y patrones de movilidad de esta actividad dentro de la extensión de área geográfica y el rango de fechas y horas que requiera, dando la posibilidad al usuario de realizar análisis e interpretaciones de la afluencia delictiva y tomar decisiones estratégicas de acción más acertadas; **LA SEGUNDA: EL GEO-VISUALIZADOR ESPACIOTEMPORAL PREDICTIVO** que permite al usuario geo-visualizar espaciotemporalmente las predicciones de la actividad delictiva y criminal en periodos continuos y cortos, de acuerdo con los eventos que van sucediendo, de forma que estas geo-visualizaciones son para el usuario en tiempo real; y esto también dentro de la extensión de área geográfica y el rango de fechas y horas de su elección.

Ambas herramientas, o aplicaciones, están realizadas con métodos novedosos que permitieron lograr estos objetivos de efectividad en la detección del volumen y los patrones y tendencias en el desplazamiento de la actividad delictiva, ya sea por códigos de casos individuales o por grupos de códigos de casos, lo cual mejora la distribución y el manejo de los recursos policiales (como por ejemplo la distribución y gestión de atención a los despliegues y el patrullaje), para disuadir, prevenir y controlar la delincuencia [3], [4]. Esto se hace posible porque estas herramientas

favorecen el mejoramiento de la conciencia y comprensión situacional (Situational Awareness and Situation Understanding), la proyección futura; y la agilidad y eficiencia en los procesos de toma de decisiones, dentro de la arquitectura de Sistemas de Comando y Control (C2S) de los Centros de Comando y Control de Seguridad Ciudadana de la PONAL [5], [6], [7], específicamente dentro de las funcionalidades de sus Sistemas de Información de Comando y Control (C2IS).

Finalmente, estas herramientas son novedosas y útiles porque fortalecen la seguridad en las ciudades, lo cual impacta directamente los objetivos de ciudad segura que es una de las áreas principales de las ciudades inteligentes, aportando también al cumplimiento de los compromisos internacionales de los Objetivos de Desarrollo Sostenible (ODS) de Naciones Unidas, principalmente en los objetivos: “11: Ciudades y comunidades sostenibles” y “16: Paz, justicia e instituciones fuertes” [8]. Además, son creadas con software de código abierto y tienen la flexibilidad para ser adaptadas a cualquier área geográfica, para ser usadas con datos reales de cualquier otro tipo de actividad (mientras esta se ajuste al formato establecido, como por ejemplo la actividad terrorista [9], [10], [11]), para ser implementadas con el software geográfico de cualquier otro C2S, para utilizarse sacando el mejor provecho de la mayor cantidad de datos reales que van sucediendo consiguiendo resultados en tiempo real; y para ser usadas de acuerdo al ajuste de funcionamiento de sus parámetros los cuales pueden ser modificados por el usuario según su interés.

## 1.2 Objetivos

El objetivo principal de esta tesis doctoral es el de desarrollar la arquitectura de un sistema de Geo-Visualización Espaciotemporal que permita analizar, detectar y anticipar, el volumen y los patrones y tendencias del desplazamiento de la actividad delictiva y criminal, basado en el análisis masivo de datos reales, para ser aplicado posteriormente a Sistemas de Comando y Control (C2S) de seguridad ciudadana, dentro de sus Subsistemas de Información de Comando y Control (C2IS), principalmente en el C2S de la PONAL.

Para lograr este principal objetivo, deben alcanzarse los siguientes objetivos específicos:

- ✓ Identificar métodos y modelos apropiados para el desarrollo de las aplicaciones que deben componer el sistema de geo-visualización, teniendo en cuenta que para que sus resultados puedan ser considerados como adecuados dentro del funcionamiento de un Sistema de Comando y Control (C2S) de seguridad ciudadana, dichos resultados deben: a.) Ser lo más precisos posible; b.) Obtenerse en tiempo real o en un tiempo útil muy cercano al tiempo real; y, c.) Hacer uso de la mayor cantidad posible de datos reales que van sucediendo a medida que el tiempo transcurre.
- ✓ Identificar y probar las técnicas clásicas y las técnicas de aprendizaje de máquina (Machine Learning (aprendizaje de máquina) y Deep Learning (aprendizaje profundo de máquina)); que resulten viables para realizar

predicciones y pronósticos de la actividad delictiva y criminal de acuerdo con los objetivos de resultado dentro de un Sistema de Comando y Control (C2S) de seguridad ciudadana.

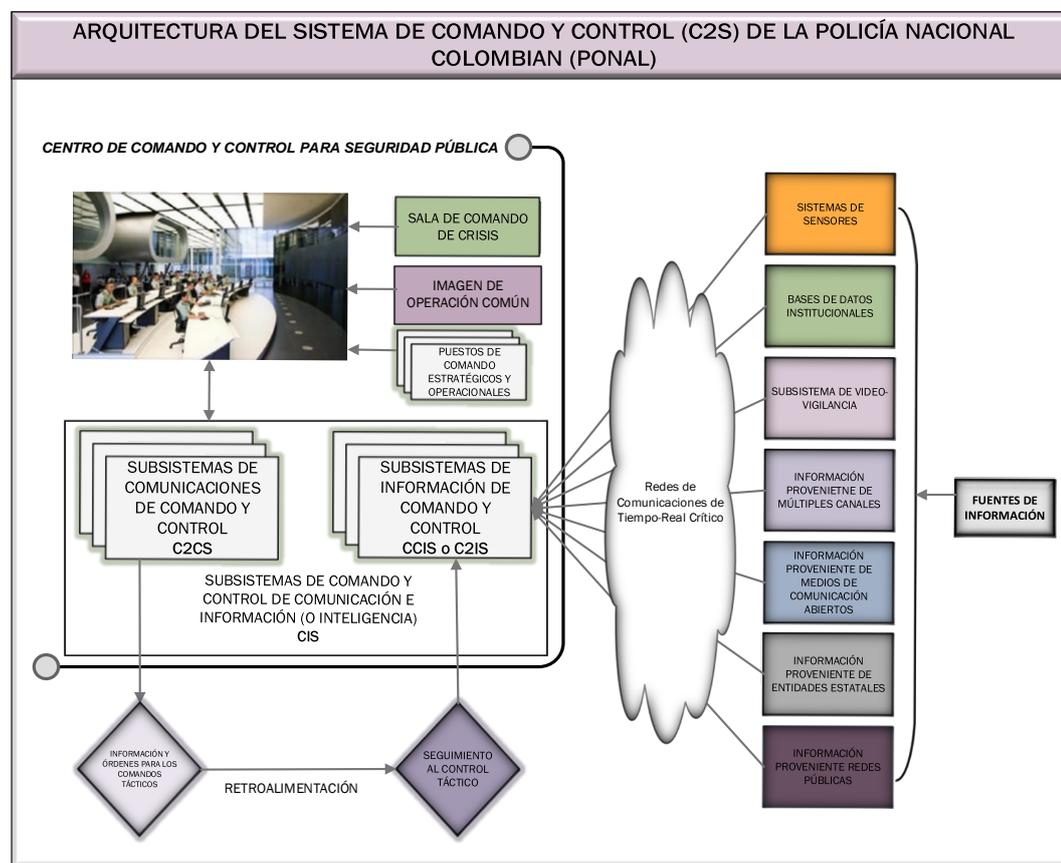
- ✓ Diseñar las aplicaciones del sistema de geo-visualización espaciotemporal, que permitan funcionalidades de análisis y de pronóstico de la actividad delictiva y criminal.
- ✓ Diseñar una arquitectura que permita implementar el prototipo de sistema de geo-visualización espaciotemporal en el C2S de la PONAL.

## **2. CAPÍTULO II: ARQUITECTURA DE LOS SISTEMAS DE COMANDO Y CONTROL (C2S) Y DE LOS SISTEMAS DE INFORMACIÓN DE COMANDO Y CONTROL (C2IS) DE LA POLICÍA NACIONAL COLOMBIANA (PONAL)**

La arquitectura general de cualquier C2S contiene: Sistemas de comunicación de comando y control (o subsistemas) (C2CS), Sistemas de información de comando y control (o Subsistemas) (C2IS), sistemas de sensores y/o fuentes de información; y puestos de mando [2]. Los C2IS de la Policía Nacional Colombiana, reúnen en los Centros de Comando y Control de Seguridad Ciudadana, la información proveniente de varias fuentes como: bases de datos institucionales, sistemas de sensores y sistemas de videovigilancia [6], [7], además poseen Sistemas de Información Geográfica (SIG) para mostrar aquella información relevante proveniente de las fuentes mencionadas y herramientas internas de procesamiento de datos desarrolladas para extraer mayor información. La figura 1 muestra la arquitectura C2S de la PONAL.

CIUDAD INTELIGENTE

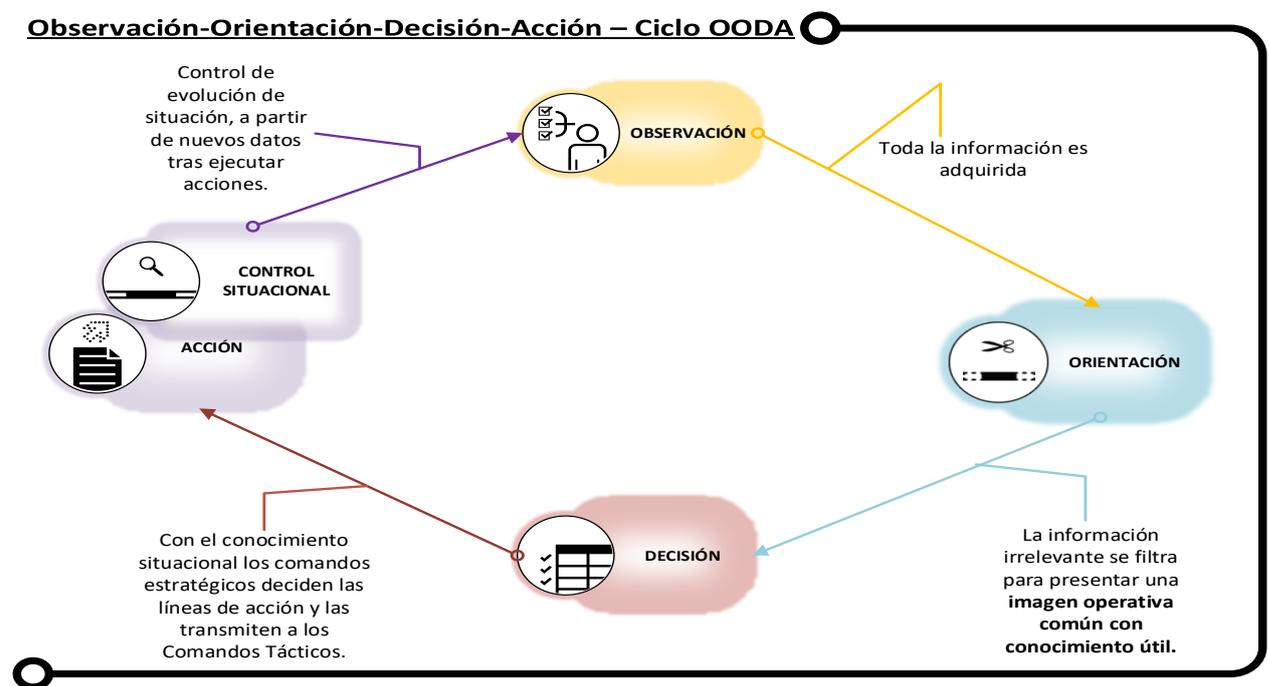
CIUDAD SEGURA



**Figura 1.** Arquitectura de los Sistemas de Comando y Control (C2S) y de los Sistemas de Información de Comando y Control C2IS, Policía Nacional Colombiana.

El área operativa del C2S, a través del manejo de la Common Operational Picture (Imagen de Operación Común), se encarga de procesar y transmitir la información necesaria a los comandantes de policía del área estratégica, quienes la interpretan y crean los objetivos estratégicos de acción en un tiempo útil, los cuales son transmitidos, a su vez, a los comandantes del área táctica quienes deberán ponerlos en marcha, en su mayor parte, en tiempo real. Este ciclo, llamado Ciclo de Comando

y Control de Observación-Orientación-Decisión-Acción (Command and Control OODA Loop), mostrado en la Figura 2, se repite una vez se obtiene la información del seguimiento a las acciones aplicadas las cuales pueden ser, por ejemplo, de distribución y manejo de los recursos físicos y humanos en una misión antidelito.



**Figura 2.** Ciclo OODA (Observación-Orientación-Decisión-Acción) de Comando y Control.

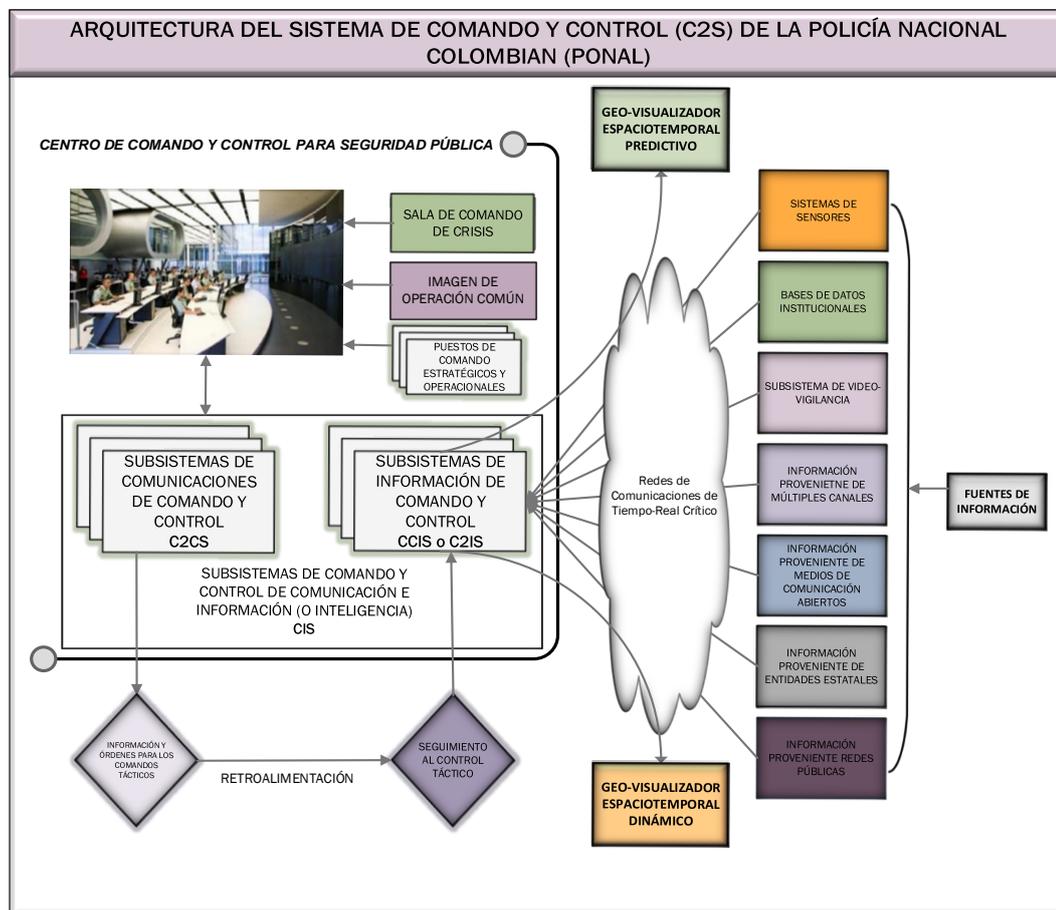
Puede decirse entonces que, los Sistemas de Comando y Control (C2S) deben ser creados para servir a la misionalidad del mando que los utiliza, por ello, un C2S adecuado al proceso del comando a quien apoya (como en el caso de la PONAL), mejora notablemente aspectos estratégicos tales como: la percepción situacional (Situational Awareness), proyección futura de la situación (Situation Understanding), la ayuda a la toma de decisiones (Decision Making Improvement)

y la agilidad en el cumplimiento de las misiones policíacas (Agility and Efficiency Improvement); lo que definitivamente aumenta la posibilidad de reaccionar más rápida y asertivamente en casos delictivos disuadiendo, previniendo y controlando la actividad criminal [3], [4].

Sin embargo, el Sistema de Comando y Control (C2S) para Seguridad Ciudadana de la PONAL, presentaba la necesidad integrar herramientas para poder visualizar espaciotemporalmente el comportamiento y los pronósticos de la actividad delictiva y criminal, de forma que se pudiera analizar y prever su concentración, patrones y tendencias de movilidad en las ciudades, como apoyo en la toma de decisiones a la línea de comando. En la Figura 3, puede verse dónde se integraría el sistema de geo-visualización espaciotemporal, propuesto en esta tesis doctoral, dentro de la arquitectura C2S de la PONAL.

CIUDAD INTELIGENTE

CIUDAD SEGURA



**Figura 3.** Integración del sistema de Geo-visualización Espaciotemporal a la Arquitectura de los Sistemas de Comando y Control (C2S) de la Policía Nacional Colombiana.

### **3. CAPÍTULO III: EL GEO-VISUALIZADOR**

#### **ESPACIOTEMPORAL DINÁMICO**

El Geo-visualizador espaciotemporal dinámico de datos, se crea con base en un novedoso método que da al usuario la posibilidad de analizar la afluencia delictiva y criminal en las ciudades (o en aquellos lugares geográficos donde sea utilizado); ya que permite detectar los patrones de dicha actividad, así como la tendencia de su movilidad y concentración.

Esto es posible para el usuario, eligiendo, además, las zonas, franjas horarias y fechas que se requiera observar; y será del análisis de estas observaciones de las que el usuario (que en este caso son los comandantes de policía), podrá, de acuerdo con su experiencia en campo, sacar las conclusiones pertinentes y tomar decisiones que mejoren la distribución y el manejo de los recursos policiales para disuadir, prevenir y controlar la delincuencia; ya que el uso de esta herramienta mejora la conciencia de la situación, la proyección futura y la agilidad y eficiencia en la toma de decisiones. Esta herramienta también tiene la flexibilidad para ser adaptada a datos en tiempo real y para ser implementada con el software geográfico de cualquier otro C2S, dado a que es desarrollada con software de código abierto.

### 3.1 Estado del Arte

La representación gráfica de datos no solo facilita la comprensión y el análisis en cualquier campo del conocimiento, sino que, además, también da la posibilidad de extraer más información de estos. Existen diferentes tipos de enfoques acerca del concepto de metodologías o de sistemas de representación de datos para visualizar actividad criminal y los autores abordan estos desarrollos desde perspectivas que van desde las empíricas y de observación hasta las que utilizan técnicas estadísticas y de modelado matemático, a saber:

- ✓ Visualización orientada a resolver necesidades de información específicas [12], [13], [14], [15], [16], [17], [18], donde entre otros, la visualización es creada para analizar factores como el impacto de la ecologización en las tasas de crimen, la fluctuación de los patrones de criminalidad según la estación climática del año, el impacto del crecimiento de los sistemas de transporte público, la influencia del tráfico y sus restricciones; o de la estratificación y zonificación de las ciudades.
- ✓ Visualización para ser usadas con cualquier tipo de datos incluyendo los datos de actividad delictiva y criminal como [19], [20], [21], [22], [23] .

No obstante, un sistema de visualización que debe ser integrado al Sistema de Información de Comando y Control (C2IS), de un Sistema de Comando y Control (C2S), donde estas visualizaciones deben tenerse disponibles para los comandos implicados en tiempo útil y muchas veces en tiempo real, como apoyo a la toma

de decisiones de las misiones antidelito; debe ser un sistema dinámico, que cuente con georreferenciación y marca de tiempo. Por lo que dentro de aquellos desarrollos de visualización que podrían resultar útiles a los propósitos de un C2S, debido a que incluyen una o varias de estas características, se encuentran:

- ✓ Los que incorporan georreferenciación y análisis espacial y estadístico para encontrar puntos críticos [24], [25], [26], [27], [28], [29].
- ✓ Los que tienen utilidad predictiva como [30], [31], [32], [33], [34].
- ✓ Los que muestran la simulación de comportamiento delictivo y criminal para análisis de efectos colaterales y distribución de recursos [35], [36], [37].
- ✓ Los que implementan sistemas que usan algoritmos de analítica de trayectorias para identificar delitos desde diferentes fuentes de información [38], [39].
- ✓ Los que representan sobre mapas de calor en transición dinámica los mecanismos de cálculo de gravedad de incidentes determinados en función de la distancia, el tiempo y el tipo de transición, para la extracción de información sobre delitos callejeros [40], [41].
- ✓ Los que incorporan sistemas de fusión, vinculación y agrupación de atributos de los datos, además de vinculación con otros nodos para extracción de patrones de redes delictivas y criminales en evolución, basadas en observación y análisis de datos temporales [42], [43], [44].

- ✓ Los que utilizan comparaciones para encontrar similitud en patrones delictivos a través de búsquedas asociativas con gráficos de conocimiento [45] y de reducción de variables para el análisis comparativo de casos [46].

Aun así, ninguno de estos desarrollos presenta uno o varios métodos que unifiquen el estudio de la movilidad y concentración de la actividad delictiva y criminal en ciudades o lugares, por zonas, franjas horarias y fechas para ser usados en tiempo real y o en un tiempo útil que conlleve a una propuesta arquitectónica de ciudad segura para ciudad inteligente que cumpla con los requerimientos específicos de un C2S como el de la PONAL.

El Geo-visualizador Espaciotemporal Dinámico que en esta tesis se desarrolla, si unifica estas características por medio de un novedoso método que permite aumentar sus ventajas para aplicaciones de Comando y Control, la Tabla 1 muestra esta comparativa.

<b>Método de Geo-visualización de actividad delictiva y criminal</b>	<b>Posibilidad de uso en Tiempo Real</b>	<b>Facilidad de uso</b>	<b>Posibilidad de análisis Espaciotemporal</b>	<b>Flexibilidad y Adaptabilidad de la Geo-Visualización</b>
Empíricos y de Observación	Muy baja	Media	Ninguna	Alta
Métodos de mejora de visualización de datos	Alta	Alta	Muy baja	Muy baja
Métodos de análisis Espacial y Estadístico	Baja	Alta	Baja	Media
Métodos de visualización Predictiva	Alta	Alta	Alta	Baja
Métodos de análisis de Trayectoria	Media	Alta	Baja	Media
Métodos basados en la representación de la concentración de la actividad, por medio de Mapas de Calor	Media	Media	Alta	Media
Fusión de datos de redes sociales y abiertas para análisis Temporal y Geo-visualización	Alta	Media	Muy alta	Muy baja
Comparativa de similitud penal, a través de Métodos de Gráficos de Conocimiento	Baja	Baja	Alta	Media
El método propuesto en esta Tesis Doctoral	Muy alta	Alta	Muy alta	Muy alta

**Tabla 1.** Comparación de metodologías y sistemas de representación gráfica de datos para visualizar actividad delictiva y criminal.

## 3.2 Desarrollo del Geo-Visualizador Espaciotemporal

### Dinámico

El planteamiento del Geo-visualizador Espaciotemporal Dinámico da inicio, cuando, con el apoyo de la oficina de Telemática de la Policía Nacional Colombiana (PONAL), se realiza una evaluación de sus procesos misionales y operativos y se encuentra que:

- ✓ La Policía Nacional es el único cuerpo de Policía de Colombia y a través de sus diferentes direcciones se divide en metropolitanas, departamentales y regionales; a su vez, es dentro de las departamentales donde tiene ubicados sus Centros de Comando y Control de Seguridad Ciudadana. Además, dados sus objetivos estratégicos y tácticos para seguridad ciudadana, la PONAL divide las ciudades y poblaciones en cuadrantes [47], que son áreas variables de extensión de tierra, divididas de forma no física de acuerdo a la relación de densidad poblacional directamente proporcional al pie de fuerza o cantidad de policías para su atención. Dichos cuadrantes son atendidos por estaciones de Policía y CAI's (Comandos de Acción Inmediata) [47].
- ✓ La base de datos SECAD (Sistema de Atención de Emergencias para Centro Automático de Despacho), la cual incluye también a la base de datos RNMC (Registro Nacional de Medidas Correctivas (del Código Nacional de Policía)); constituye la mejor fuente de datos pertinentes para detectar la tendencia

delictiva y criminal en las ciudades, dado que estas son las bases de datos con la información más completa acerca de los casos reportados de incidentes delictivos y criminales en el país porque recopilan toda la información de llamadas de emergencia del 123 e incluyen los datos espaciotemporales de dichos incidentes, parámetro fundamental para cumplir con el objetivo propuesto en esta tesis doctoral.

Definidas entonces las fuentes de información y facilitadas estas por medio de acuerdo de confidencialidad; y aprovechando la división estratégica de control policivo por cuadrantes hipotéticos de la PONAL; se parte entonces de una división del terreno en forma de cuadrícula que representa la división en cuadrantes de cualquier jurisdicción de policía, tomando como modelo los datos de incidentes delictivos y criminales delimitados a la zona de jurisdicción de la ciudad de Santiago de Cali.

Esta herramienta puede considerarse genérica porque cualquier ciudad o lugar geográfico podría dividirse de la misma forma (en cuadrantes hipotéticos); y porque todo el proceso descrito a continuación se desarrolló en el lenguaje de programación Python, que es un lenguaje de código abierto con soporte de funcionalidades de visualización, cálculo numérico, análisis de datos y geolocalización.

- 1.) El primer paso es el preprocesamiento o acondicionamiento de los datos para ser usados. Estos datos son tomados de las bases de datos SECAD y RNMC que están alojadas en el (C2IS) y la información les llega a través de

canales de comunicación en tiempo real críticos de grado militar dispuestos para esto por la PONAL. Este paso es realizado desde el sistema de bases de datos de la PONAL para generar una subbase de datos depurada de datos erróneos, o sin confirmar, que pudiesen haber sido captados; extractando además los campos necesarios: Timestamp (fecha y hora), Latitud, Longitud y Código del Evento.

- 2.) Dado este primer paso, el siguiente consiste en hacer un proceso de Data Cleaning y Data Wrangling, que básicamente adecúa el formato de coordenadas geográficas y el formato del timestamp y realiza una reorganización general por Timestamp.
- 3.) Una vez establecido este proceso, pueden generarse bases de datos para cualquier rango temporal (fecha y hora) y para cualquier rango de área geográfica, con lo que los analistas y comandantes pueden requerir al sistema los datos de áreas de mayor o menor extensión y dentro de esta área elegida, elegir también el rango de datos temporales de fecha y hora, de acuerdo con su interés, teniendo presente que una vez se ha definido la zona a trabajar y se obtienen los datos de esta, deben eliminarse aquellos datos que no correspondan o que presenten valores fuera de lo normal (outliers), que por error puedan haberse insertado en la base de datos. Este filtro de outliers se realiza por coordenadas geográficas de acuerdo con el área de cubrimiento metropolitana o departamental de la PONAL, según corresponda; y teniendo presentes aquellos casos de redireccionamiento de emergencias del 123 para el SECAD. En este punto se tendría ya el Dataset

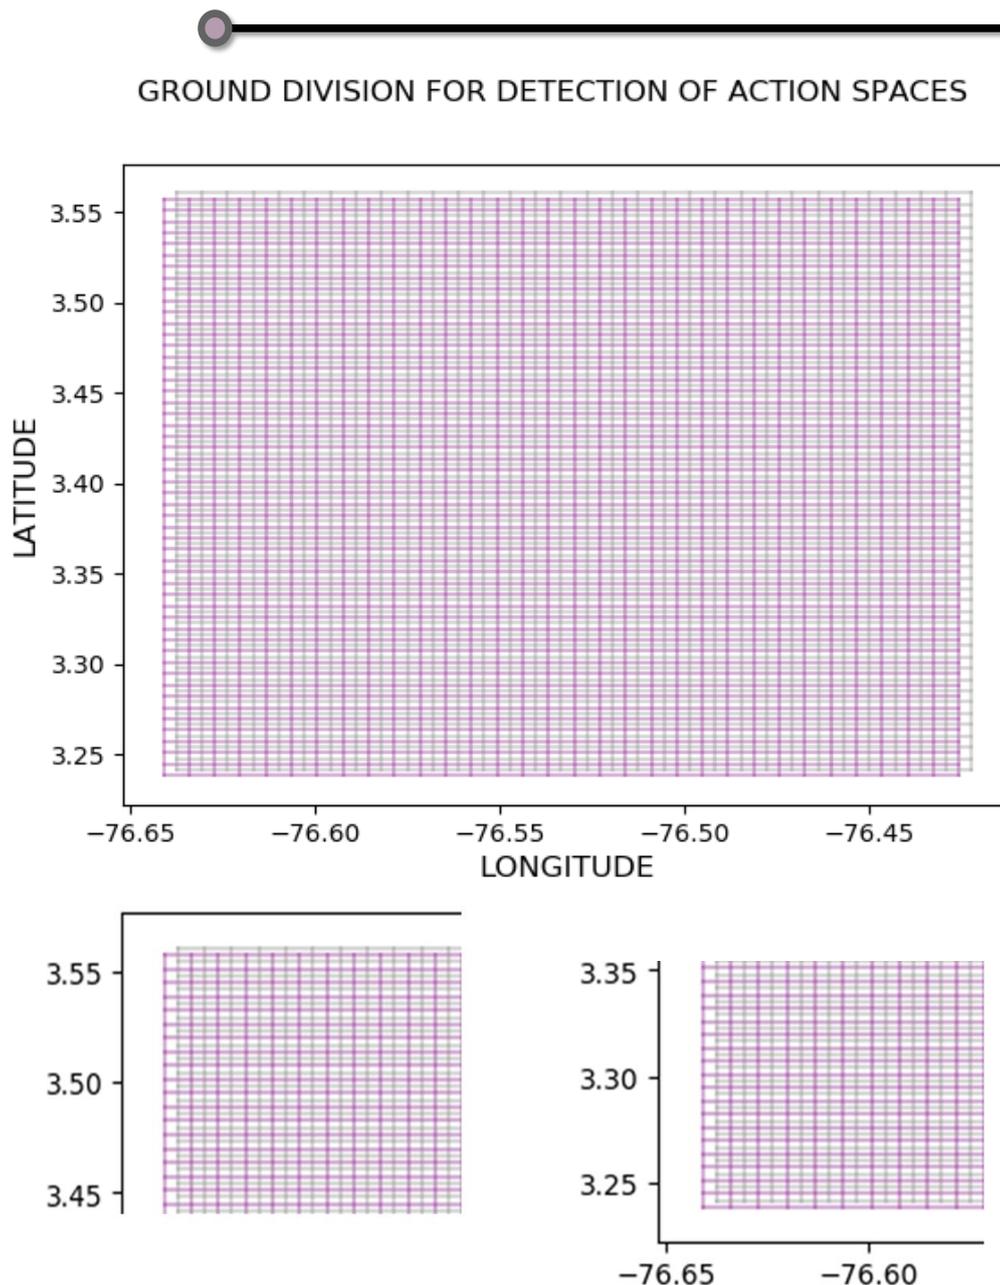
nuevo con los datos listos para ser usados, dando como resultado un Dataset con el formato que se muestra en la Figura 4.

TIMESTAMP	LATITUD	LONGITUD	CÓDIGO DEL CASO
20/04/2021 11:58:10,	-76.52886194,	3.44773306,	965
20/04/2021 11:59:45,	-76.53707889,	3.39447500,	937

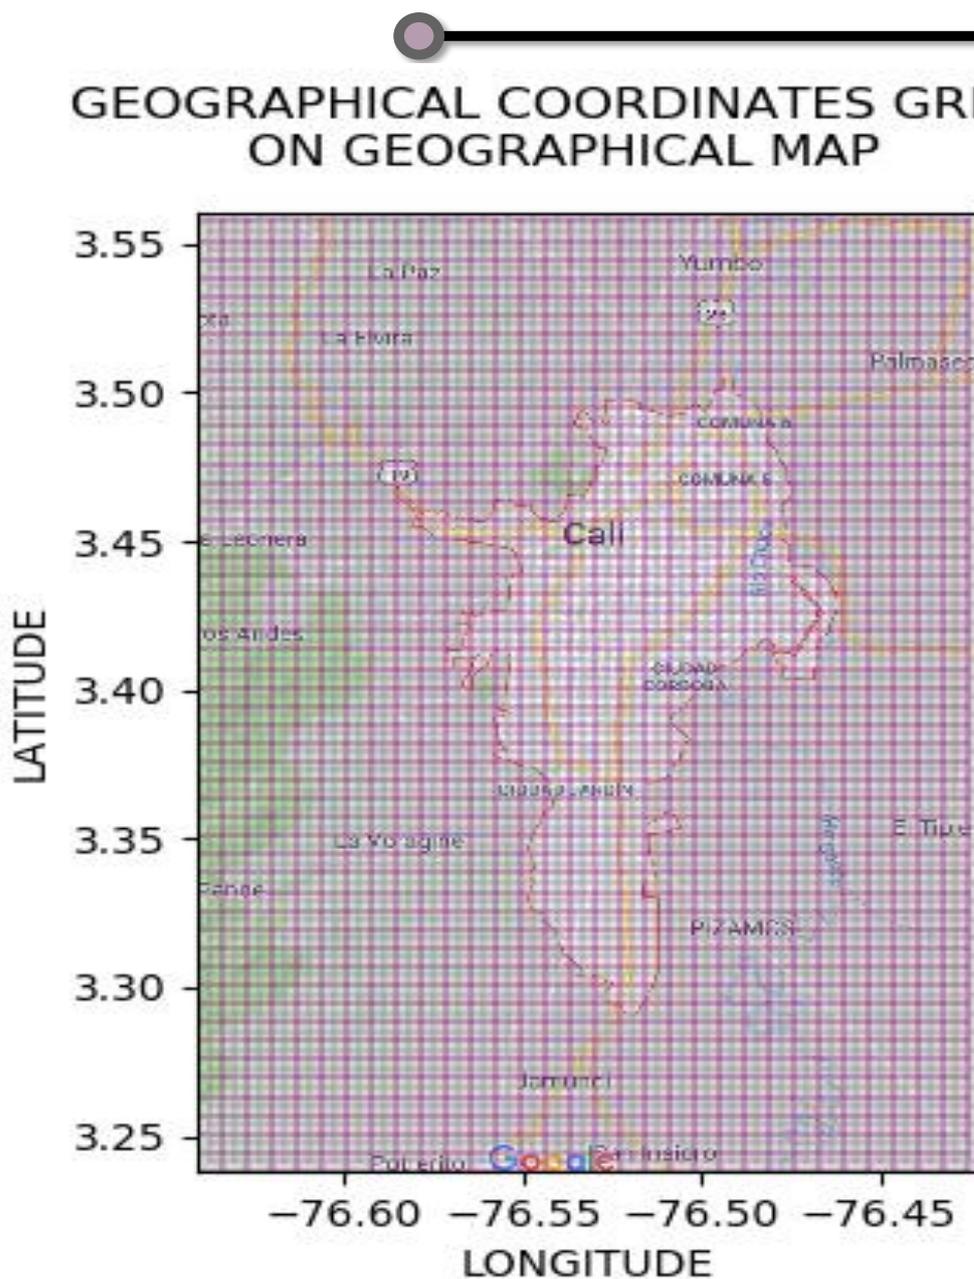
**Figura 4.** Formato de base del Dataset para el Geo-visualizador Espaciotemporal Dinámico.

4.) Una vez que la zona de observación está definida por coordenadas geográficas de latitud y longitud y los datos de eventos delictivos y criminales, dentro de esta, están listos para ser usados, se crea entonces un sistema de dos cuadrículas sobrepuestas delimitadas por las coordenadas geográficas de dicha zona (que para el caso será la ciudad de Santiago de Cali y sus zonas en dependencia policial). La primera cuadrícula (color rosa) tiene como límites específicos la zona de observación; y la segunda cuadrícula (color gris) se crea con el mismo tamaño de la primera, pero con un desplazamiento en longitud y latitud de forma que los vértices de cada cuadro de la segunda cuadrícula coincidan con los centros de cada cuadro de la primera, para que al sobreponerlas se creen cuadros con un tamaño correspondiente al 25% de los cuadros originales de las cuadrículas, Figura 5. Este sistema deberá ser puesto como una capa al mapa geográfico de la zona de observación, sobre el Sistema de Información Geográfico (SIG), en el que vaya a ser usado este método de geo-visualización como se muestra

en la Figura 6. Dicho de otra forma, esta herramienta de geo-visualización actúa como un Plug-in que se puede adaptar a cualquier SIG a través de la API (Interfaz de Programación de Aplicaciones), específica para cada SIG.



**Figura 5.** Sistema de cuadrículas: Cuadrícula doble desfasada al 25%.



**Figura 6.** Sistema de cuadrículas sobrepuesto al mapa geográfico de la zona de observación.

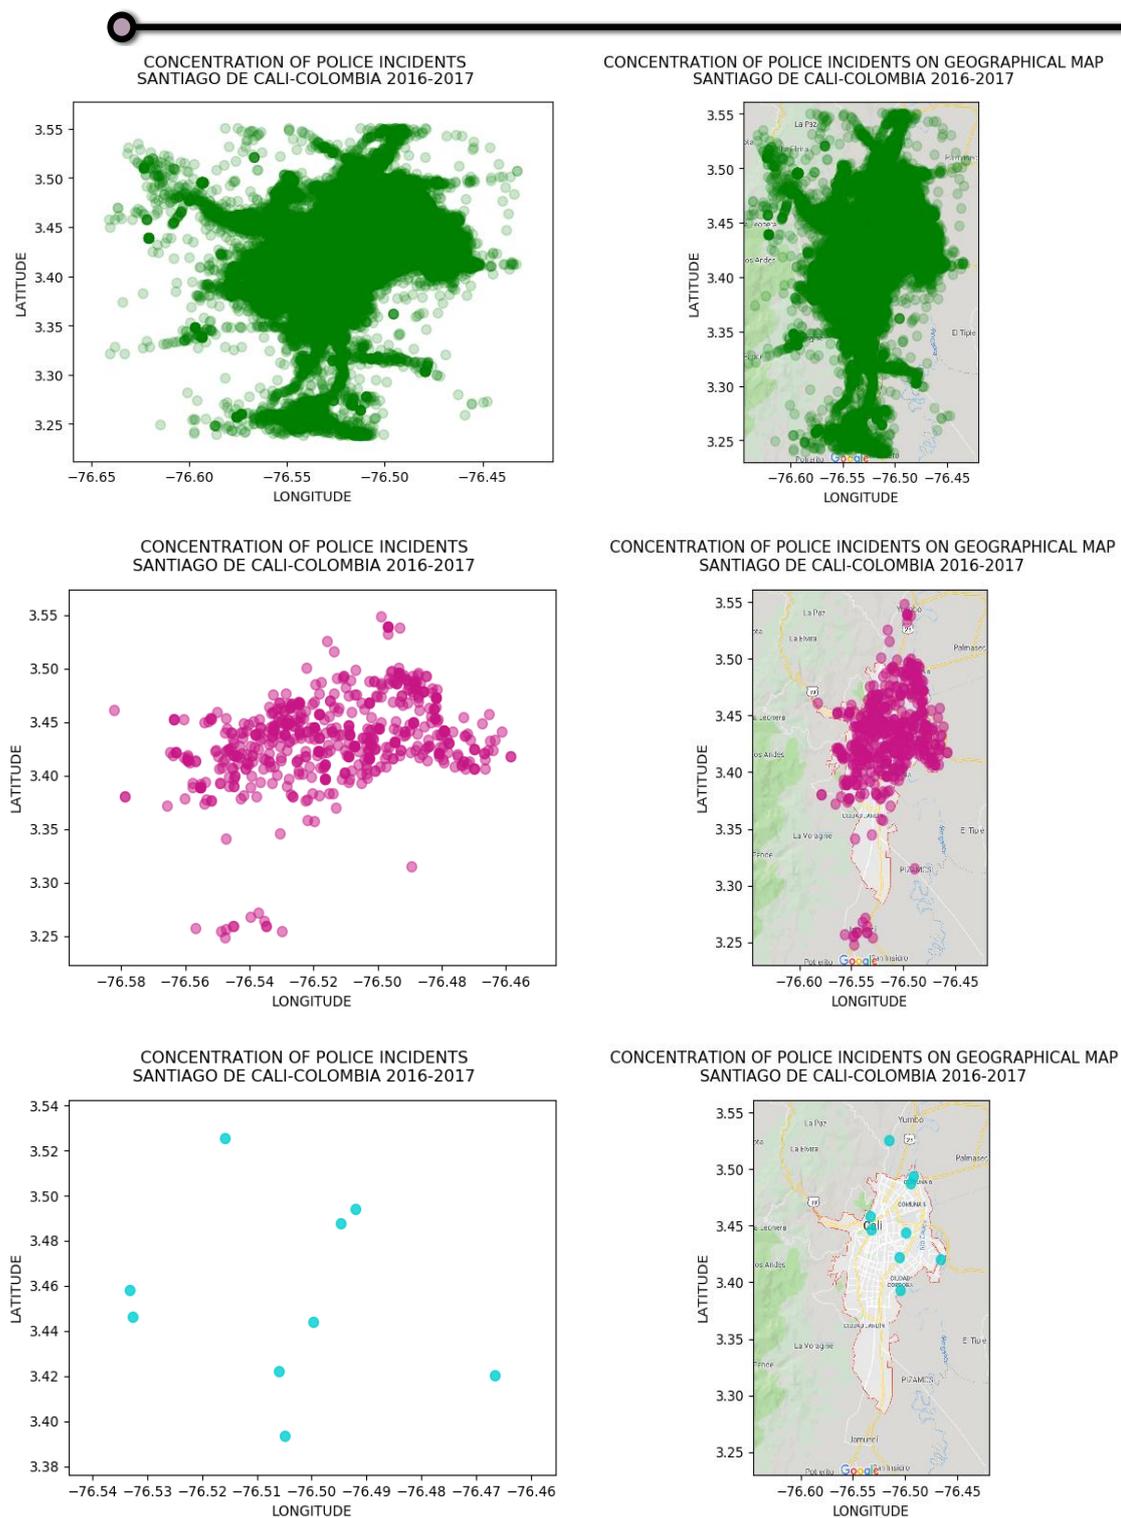
Para este caso en específico, se crearon cuadrículas de 100 cuadros en eje de latitud de aproximadamente 358.65 metros cada uno; y 60 cuadros en el eje de la longitud, correspondiendo a 453.06 metros aproximadamente, cada uno, a latitud norte; y a 453.21 metros aproximadamente a latitud sur,

debido a que se trata de coordenadas esféricas sobre el globo terrestre. Pero es importante resaltar en que estos valores son tomados para este caso, por dos razones principales: la primera es que como se especificó anteriormente, los cuadrantes pueden ser de diferentes tamaños, dependiendo de la densidad poblacional de la zona, por lo que la división resultante del terreno en 100 partes en el eje de la latitud y 60 partes en el eje de la longitud, en conjunto con el método de suavizado gráfico usado, resulta en un valor promedio de la extensión de los cuadrantes en Colombia por lo que desarrollarlo de esta forma es muy útil para este caso.

El sistema de cuadrículas de latitud y longitud es creado de esta forma porque cada vez que se detectan uno o varios eventos de actividad delictiva en un lugar, estos son representados sobre el sistema de cuadrículas con referencia por separado a cada una de las dos cuadrículas, realizando una representación con un método de suavizado por medio del solapamiento gráfico en este mapa de densidades, con el objeto de hacer más fácil para el analista observar el comportamiento en concentración y desplazamiento de la actividad delictiva y criminal. Esto no podría hacerse con una sola cuadrícula y por eso se utiliza un sistema de doble cuadrícula, Figura 5. Todos estos valores se pueden ajustar a las necesidades de seguimiento de cualquier territorio geográfico.

5.) En este punto ya se posible observar las primeras muestras de la información que el Geo-visualizador Espaciotemporal Dinámico puede ofrecer. La figura 7 muestra su funcionamiento inicial, donde se tomaron y

representaron tres muestras de datos diferentes sobre el sistema creado en las etapas anteriores. Cada incidente delictivo está representado por un punto de color con el mismo nivel de transparencia, lo que permite observar las concentraciones de incidentes delictivos en las subáreas dentro del área de observación. En las subáreas donde los puntos son más transparentes hay una menor concentración de incidentes delictivos, y una mayor concentración de incidentes delictivos en las subáreas donde los puntos tienen más concentración de color. La geo-visualización podría realizarse con cualquier distribución de datos requerida, por ejemplo, datos de un día, una semana, tres meses, algunas horas, o cualquier otro.



**Figura 7.** Muestras de visualización de datos sobre el sistema, en orden: 6 meses, 4 días, 7 h.

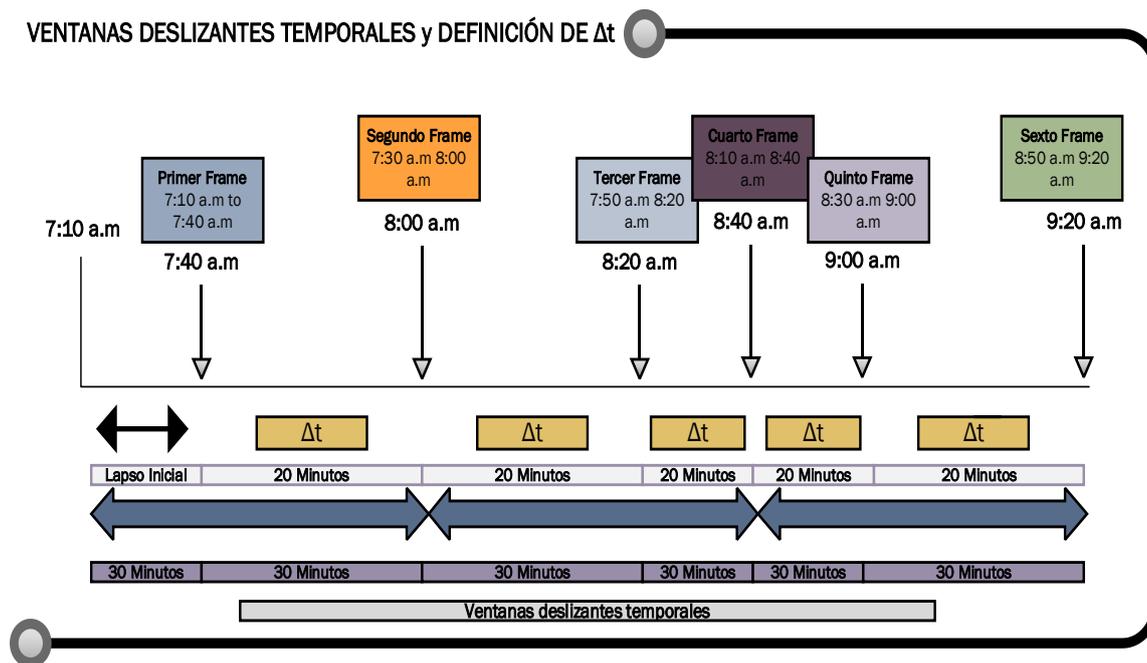
### 3.2.1 Fase final de Construcción

Esta es la fase final donde se construye la representación gráfica de los datos para el Geo-visualizador Espaciotemporal Dinámico de actividad delictiva y criminal. Se describirá esto en los siguientes pasos:

- 1.) Deben definirse dos parámetros: primero las ventanas deslizantes temporales (período de tiempo durante el cual se representarán los casos en cada cuadro); y segundo, un valor en tiempo para deslizar la ventana, (cada cuánto tiempo se realizará el refresco de pantalla o el salto de tiempo en el que se representará el siguiente cuadro dentro de la animación), el cual se denominará  $\Delta t$ .
- 2.) En este ejemplo se definieron ventanas deslizantes temporales de 30 minutos, es decir, que en cada cuadro; o cuadro de la animación, se representarán los casos ocurridos durante 30 minutos, pero esta representación tendrá un tiempo de refresco por cada cuadro de 20 minutos, es decir, que la geo-visualización espaciotemporal dinámica muestra los casos sucedidos durante las ventanas deslizantes temporales de 30 minutos, en cuadros cada 20 minutos ( $\Delta t$ ).
- 3.) Lo anterior implica que, según el ejemplo, en cada representación de un cuadro existirá un solapamiento de casos de 10 minutos, es decir que, a partir de la representación del segundo cuadro, este representará de nuevo los casos sucedidos en los últimos 10 minutos de la anterior ventana. No obstante, si, por ejemplo, el valor de la ventana deslizante temporal fuera

de 40 minutos y el valor  $\Delta t$  se mantuviera en 20 minutos, este solapamiento sería ahora de 20 minutos y así sucesivamente. Lo cual se diseñó de esta forma con el objetivo de generar continuidad y facilidad para el analista al realizar el conteo de eventos por zona y al observar el desplazamiento de la actividad delictiva y criminal. A esto es a lo que se le llama método de suavizado gráfico, el cual ya se había mencionado anteriormente y se describe en detalle en la Figura 8.

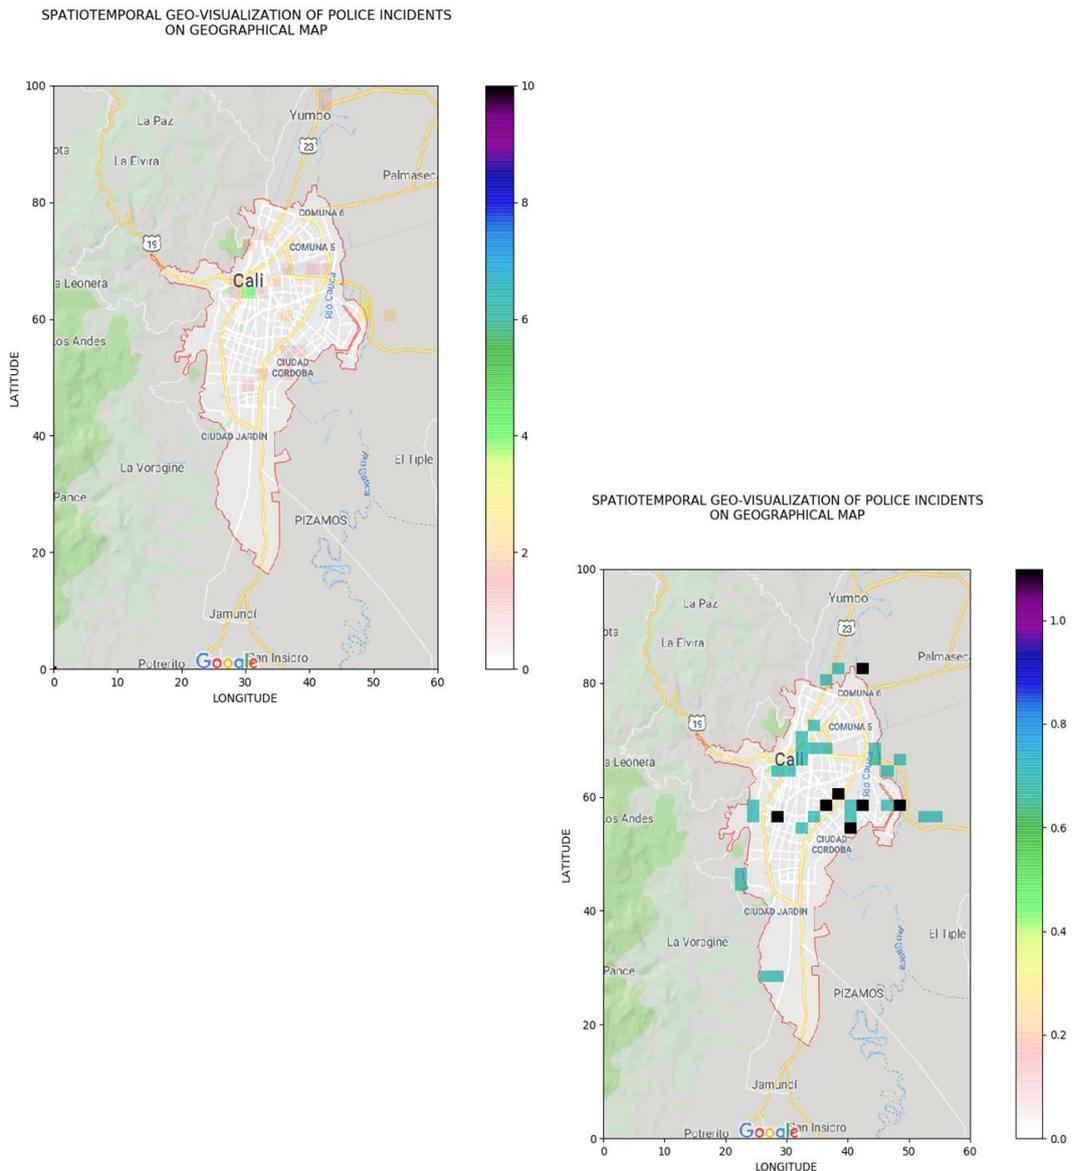
- 4.) Sin embargo, es importante aclarar que estos dos parámetros han sido especificados de esta forma para este caso, teniendo en cuenta la necesidad de los comandantes de Policía de tener la mayor claridad posible del comportamiento espaciotemporal global de la delincuencia y criminalidad en la ciudad, de acuerdo con la cantidad de datos observada. Por lo que inicialmente se definieron estos parámetros al azar y se fueron ajustando a ensayo y error dentro de la Geo-visualización, hasta encontrar aquellos que servían al propósito del analista. Por esta razón puede concluirse que estos parámetros también son ajustables de acuerdo con el requerimiento de quien realiza la observación, tanto en ventanas deslizantes temporales y  $\Delta t$ ; como en cantidad de datos (por días, meses, etc); inclusive podrían elegirse parámetros que no generen solapamientos.



**Figura 8.** Distribución de ventanas deslizantes temporales, definición de  $\Delta t$  para el Geovisualizador Espaciotemporal Dinámico.

- 5.) Una vez definidas las ventanas deslizantes temporales iniciales y el valor  $\Delta t$ ; se realiza la representación de los eventos sobre las cuadrículas por cuadro de gráfica o ventana, cada  $\Delta t$ , donde es posible hacer un conteo de los eventos sucedidos sobre cada subárea geográfica (cuadros de las cuadrículas). Para realizar este conteo se ha definido una escala de colores en la cual los tonos claros de la barra indican baja actividad y los oscuros alta actividad, lo cual facilita la interpretación de los datos, teniendo presente que el transparente, o ausencia de color, representa que no ha sucedido ningún evento y el color más oscuro de la escala representa una gran concentración de eventos como se muestra en la Figura 9. Se puede ajustar una escala de colores según lo requiera el usuario, como también muestra la Figura 9.

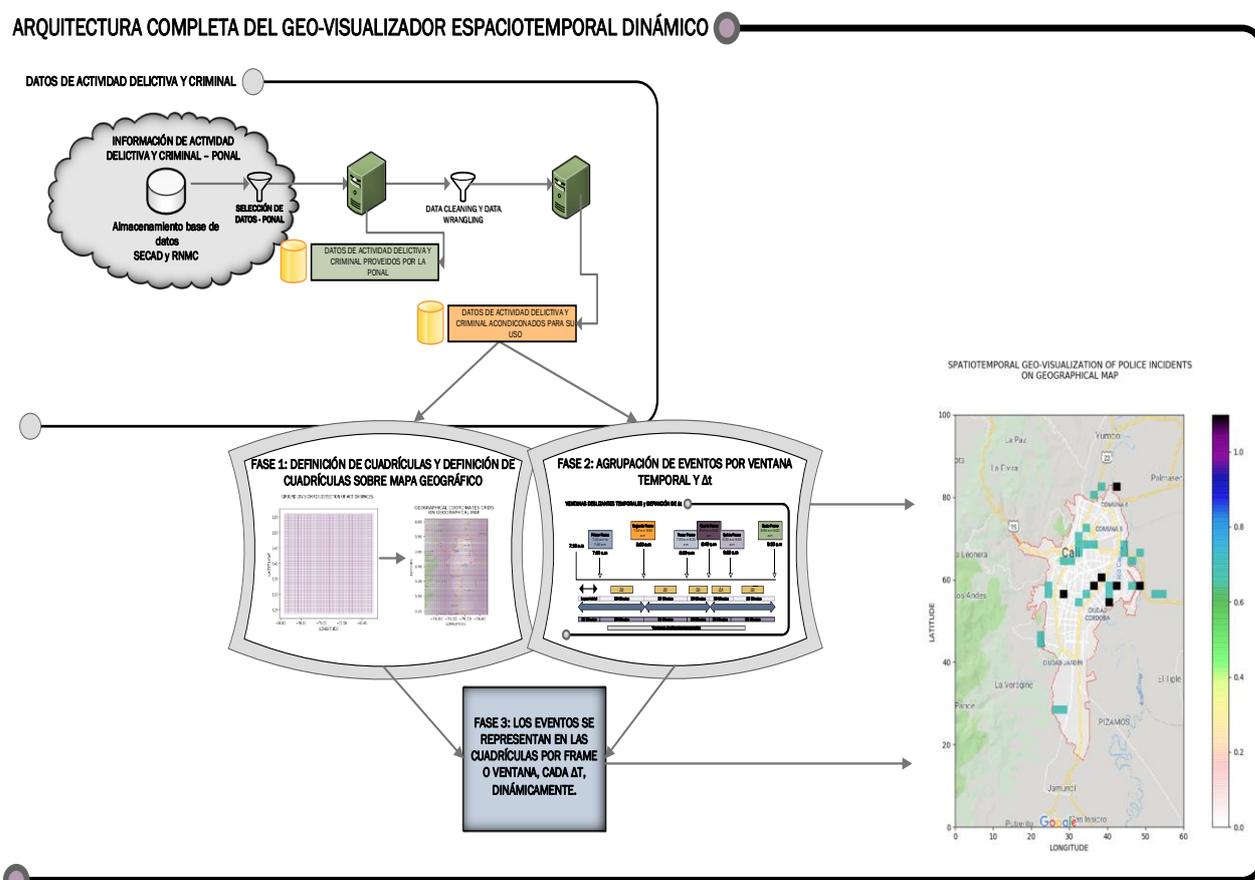
6.) Se repite este proceso para cada ventana generando dinamismo en la representación, con lo que puede observarse la variación en la aparición de los eventos delictivos y criminales, debido a que usando este método se hace posible observar la variación y tendencia de estos, para cada subárea geográfica (cuadros de las cuadrículas). De esta forma el gráfico se convierte en una geo-visualización espaciotemporal animada que muestra la evolución temporal de las actividades delictivas y criminales, de acuerdo con el conteo de eventos que van sucediendo, lo que permite al comandante de policía (o a quien sea el usuario), hacer seguimiento del movimiento de la concentración de los eventos delictivos y criminales; y las zonas donde suceden. También es posible realizar un filtro por código, o grupos de códigos, de los casos específicos, franjas horarias y fechas para observar este comportamiento, lo que mejora notablemente la conciencia situacional del comandante encargado de observar la situación para tomar decisiones. La Figura 9 muestra el resultado de estas gráficas de geo-visualización espaciotemporal dinámica, que permiten ver cuadro a cuadro la concentración de incidentes delictivos por ventanas de tiempo.



**Figura 9.** Gráficos de Geo-visualización Espaciotemporal Dinámica de datos delictivos y criminales sobre mapa geográfico. Capturas de diferentes cuadros y con diferentes escalas de conteo. En este caso, con una ventana deslizante temporal de 30 min y  $\Delta t = 20$  min.

Para explicar el detalle de este proceso, la Figura 9 muestra el geo-visualizador con escala en partes sobre el sistema de cuadrículas, ya que este parámetro también es ajustable, sin embargo, es importante mencionar que el usuario verá este

parámetro sobre mapa geográfico en coordenadas geográficas de latitud y longitud, como se muestra en los gráficos anteriores. La Figura 10 muestra la arquitectura completa del Geo-visualizador Espaciotemporal Dinámico de datos delictivos y criminales sobre mapa geográfico, para aplicaciones C2S.



**Figura 10.** Arquitectura completa del Geo-visualizador Espaciotemporal Dinámico de datos delictivos y criminales sobre mapa geográfico, para aplicaciones C2S.

## **4. CAPÍTULO IV: EL GEO-VISUALIZADOR**

### **ESPACIOTEMPORAL PREDICTIVO**

El Geo-visualizador Espaciotemporal Predictivo de datos, es creado con base en un modelo y metodología diferentes que permite a las unidades policiales (o cualquier otro usuario), la geo-visualización espaciotemporal del pronóstico de actividades delictivas y criminales en horizontes temporales cortos y continuos de acuerdo con los eventos reales que van sucediendo, de forma que el modelo puede aprovechar la mayor cantidad de datos reales para su reentrenamientos y siguientes pronósticos, haciéndolo más preciso.

Dada la metodología utilizada, su funcionamiento puede catalogarse como de tiempo real y es útil para aquellas áreas geográficas, franjas horarias y fechas de interés, ya sea por códigos de casos individuales o grupos de códigos de casos, lo que la hace muy apropiada para complementar los objetivos de cualquier C2S, entre otros, porque es completamente integrable al software geográfico de cualquier C2S, no solamente para el C2S de la PONAL, que es para el que ha sido desarrollada. Esta herramienta mejora la conciencia situacional, la proyección futura, la agilidad y la eficiencia en los procesos de toma de decisiones policíacas y; por tanto, la gestión de los recursos destinados a la disuasión, prevención y control de la actividad delictiva y criminal en aquellos lugares geográficos donde sea utilizada.

Para su desarrollo se realiza la correlación espacial y temporal de los eventos y se usan las técnicas clásicas y de Deep Learning CNN-1D (Convolutional Neural Network-1D), MLP (Multilayer Perceptron), LSTM (Long Short-Term Memory) y VAR (Vector Autoregressive), por su apropiado desempeño en el pronóstico en multiparalelo de más de un paso, de series temporales multivariantes con datos escasos. Es implementada con software de código abierto y puede adaptarse a cualquier zona geográfica. Finalmente, puede usarse con datos de otro tipo de actividades, acondicionados al formato de esta herramienta, como por ejemplo la actividad terrorista [9], [10], [11].

## **4.1 Estado del Arte**

Tener la posibilidad de que la información que brinda el pronóstico de una actividad ya sea humana, natural o de otra índole, pueda ser presentada a un usuario de forma gráfica sobre el lugar de ocurrencia de los hechos, de manera que dicho usuario pueda saber cuándo y en qué medida podría ocurrir, es, sin duda, una posibilidad superior de mejora de conciencia situacional, para quienes deben tomar acciones y decisiones de disuasión, prevención y control frente a diversos eventos. Estas son precisamente las capacidades que aporta la geo-visualización espaciotemporal predictiva, razón por la que estas capacidades son investigadas y aplicadas a distintas necesidades de acuerdo con su enfoque, a saber:

- ✓ La observación para la prevención y alertas tempranas de desastres naturales, como por ejemplo las inundaciones [48].
- ✓ La vigilancia predictiva del delito y el crimen [49], [50].
- ✓ La visualización espacial de puntos conflictivos usando herramientas estadísticas [18], [29], [33], [51],.
- ✓ El mapeo por segmentos de calle [52].
- ✓ El uso de patrones de contraste para predecir eventos espaciotemporales [53].
- ✓ El uso de datos multimodales para predicción de eventos con herramientas de Aprendizaje Profundo (Deep Learning) [54], [55], [56], [57], [58].
- ✓ El análisis geo-espacial temporal para la clasificación de eventos [59], [60].
- ✓ Los modelos llamados "casi repetidos" y de terreno de riesgo [61].

Para Sistemas de Comando y Control (C2S), un sistema de geo-visualización espaciotemporal predictivo debe poder generar pronósticos muy rápidamente (en un tiempo útil muy cercano al tiempo real), con horizontes temporales de pronóstico cortos, hacer uso de la mayor cantidad de datos reales que van sucediendo y dar la opción al usuario de elegir las áreas geográficas, franjas horarias y fechas a analizar; y poder hacer filtro de esta información por códigos individuales o grupos de códigos de casos, teniendo en cuenta además que en algunas ocasiones (como en el escenario tratado en esta tesis doctoral), los datos pueden presentar un alto índice de escasez, más aún si se filtran por casos o grupos de casos.

Es este el tipo de herramienta que se presenta en esta tesis doctoral, donde para alcanzar este propósito se hizo preciso obtener primero la dependencia espacial entre los lugares de ocurrencia de los eventos y la dependencia temporal entre estos mismos eventos, para que los pronósticos resultaran verdaderamente confiables. Es así como entre los desarrollos que podrían ofrecer este tipo de alternativas, estarían:

- ✓ La geo-visualización de pronósticos basados en agrupamiento espacial para reflejar características de terrenos adyacentes [62], [63], [64], [65], [66].
- ✓ La geo-visualización de pronóstico para datos escasos [67], [68], [69], [70].
- ✓ La geo-visualización de pronóstico de actividades delictivas usando técnicas de Machine Learning y Deep Learning [64], [65], [66], [70], [69], [71], [72], [73].
- ✓ El pronóstico de eventos usando técnicas clásicas, clásicas mejoradas, Machine Learning y Deep Learning para series temporales multivariantes [74], [75], [76], [77], [78], [79], [80], [81], [82], [83], [84], [85], [86], [87], [88], [89], [90], [91], [92], [93], [94], [95], [96].
- ✓ El pronóstico de series temporales multivariantes con datos escasos [97], [98], [99], [100], [101], [102].

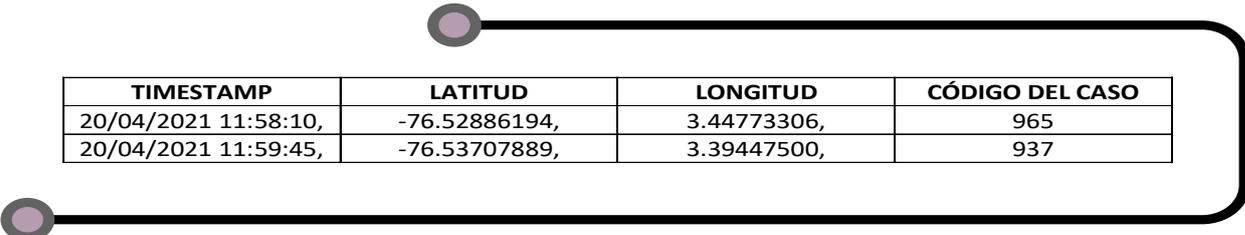
Sin embargo, todos estos desarrollos, por sí mismos, no brindan la posibilidad de: usar la mayor cantidad de datos reales que van sucediendo para reentrenar un

modelo predictivo y generar nuevos pronósticos con horizontes temporales cortos en un tiempo útil lo suficientemente eficiente para los comandos dentro de un C2S; ser geo-visualizados en correlación de tiempo y espacio, donde los datos también puedan ser filtrados por códigos de casos, grupos de códigos de casos, zonas, franjas horarias y fechas; y que además constituya una propuesta arquitectónica de ciudad inteligente a través de los atributos de ciudad segura, integrable a los requerimientos específicos de un C2S, como el de la PONAL. Estas son en cambio las posibilidades de la herramienta que aquí se describe.

## 4.2 Desarrollo del Geo-Visualizador Espaciotemporal

### Predictivo

Para empezar a describir el desarrollo del Geo-visualizador Espaciotemporal Predictivo, ha de especificarse que, como primera medida, las fuentes de los datos y su preprocesamiento son iguales a las del Geo-visualizador Espaciotemporal Dinámico, dando como resultado un Dataset en las mismas condiciones que el mostrado anteriormente en la Figura 4, pero que, en la Figura 11, se vuelve a mostrar.



TIMESTAMP	LATITUD	LONGITUD	CÓDIGO DEL CASO
20/04/2021 11:58:10,	-76.52886194,	3.44773306,	965
20/04/2021 11:59:45,	-76.53707889,	3.39447500,	937

**Figura 11.** Formato de base del Dataset para el Geo-visualizador Espaciotemporal Predictivo.

Aun así, es importante recordar aquí, que lo que se quiere decir, es que, aunque el formato de los datos para ser usados por ambos Geo-visualizadores es igual, hay que tener en cuenta que siempre es posible para el usuario elegir el tamaño del área de observación y el rango de fechas y horas con el que espera realizar el análisis, por tanto, no necesariamente van a ser iguales los Datasets, en magnitud, localización y marca de tiempo para las diferentes herramientas, e incluso para diferentes observaciones dentro de cada herramienta. Todo el proceso, descrito para esta herramienta, también ha sido desarrollado en el lenguaje de programación de código abierto Python, soportado en las funcionalidades de visualización, cálculo numérico, análisis de datos y módulos de predicción: Machine Learning, Deep Learning y clásicos para series temporales multivariantes con pronósticos de más de un paso en multiparalelo.

#### **4.2.1 Agrupación espacial geográfica del área de observación para su correlación**

Otra característica que ya había sido mencionada y que para el caso del Geo-visualizador Espaciotemporal Predictivo también se aprovecha, es el hecho de que la Policía Nacional (PONAL), divide las ciudades y poblaciones en cuadrantes, que son áreas variables de extensión de tierra divididas de forma no física de acuerdo con la relación de densidad poblacional directamente proporcional al pie de fuerza o cantidad de policías para su atención, donde estos cuadrantes son atendidos por estaciones de Policía y CAI's (Comandos de Acción Inmediata) [47]. Por lo que se

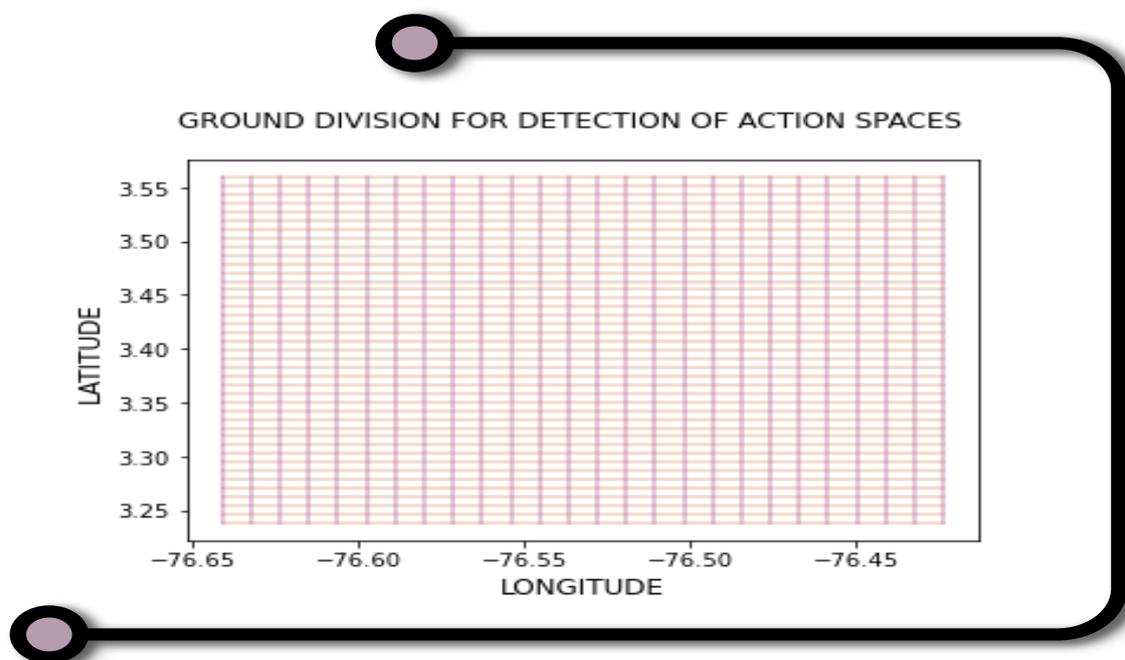
toma, una vez más, esta división estratégica de control en cuadrantes hipotéticos (división que puede ser usada para cualquier ubicación geográfica); y se agrupa el terreno en una cuadrícula que representa esta división por cuadrantes de cualquier jurisdicción de policía. Esta agrupación genera que un área quede dividida en subáreas, lo cual, como más adelante se verá, permite realizar la correlación de los eventos sucedidos dentro de cada subárea con respecto a las demás.

Se crea entonces una cuadrícula delimitada por las coordenadas geográficas de la zona de observación, la cual puede ser tan amplia en extensión geográfica como el usuario requiera y la división de la cuadrícula o su resolución (cantidad de cuadros dentro de la cuadrícula), también es un parámetro a escoger por el usuario, Figura 12. Este sistema de cuadrícula de latitud y longitud divide el área de observación en subáreas, de forma que cuando se detectan uno o varios eventos de actividad delictiva y criminal dentro de cada subárea, estos son representados y contabilizados dentro de esta como en un mapa de densidades, lo que a su vez también facilitará la correlación de dichos eventos entre las subáreas adyacentes cuando se generen los pronósticos, debido a que, se tendrá una serie temporal univariante por cada una de las subáreas y por consiguiente una serie temporal multivariante del mismo tamaño o resolución de toda la cuadrícula.

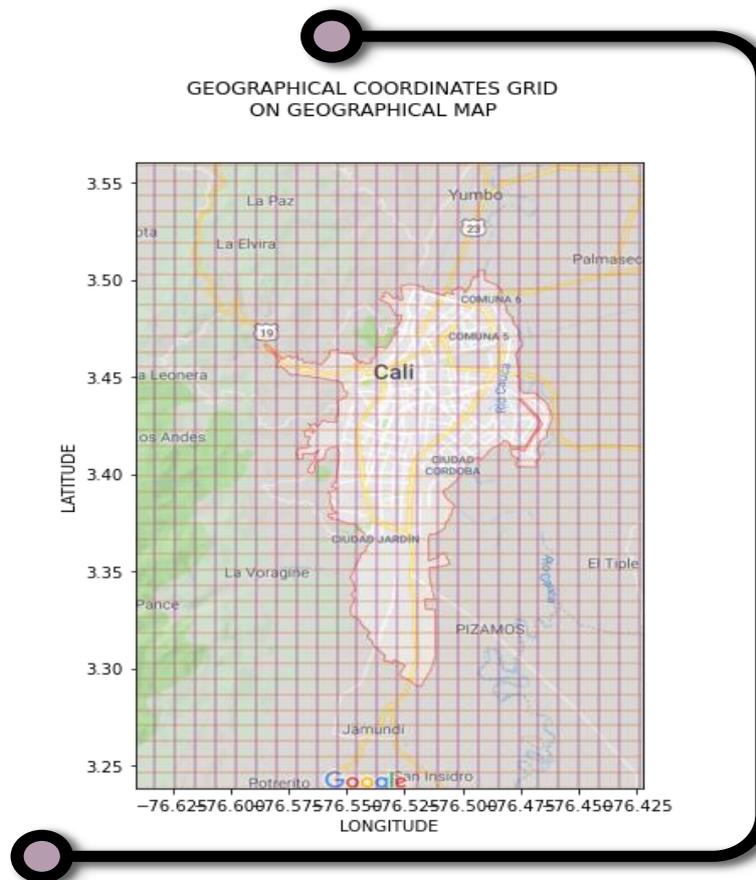
Esta cuadrícula deberá sobreponerse como una capa al mapa geográfico de la zona de observación, sobre el Sistema de Información Geográfico (SIG), en el que vaya a ser usado el Geo-visualizador Espaciotemporal Predictivo, Figura 13. Actuando como un Plug-in que se puede adaptar a cualquier SIG a través de su propia API

(Interfaz de Programación de Aplicaciones). En este caso se utilizará el SIG de integrado al C2S de la PONAL.

Para la implementación mostrada en esta tesis doctoral y dado que se trata de coordenadas esféricas sobre el globo terrestre, se creó una cuadrícula de 40 cuadros en eje de latitudinal de aproximadamente de 896.625 metros cada uno; y 25 cuadros en el eje longitudinal de aproximadamente de 1,087.344 metros cada uno a la latitud norte y de aproximadamente 1,087.704 metros a la latitud sur. Pero es importante hacer énfasis en este punto, en que, estos valores son tomados así para este caso, dado que la división resultante del terreno de esta forma da en un valor promedio de la extensión de los cuadrantes en Colombia, pero este valor de resolución de la cuadrícula puede ser ajustado a las necesidades de seguimiento de cualquier territorio geográfico que requieran los usuarios.



**Figura 12.** Agrupación espacial geográfica con cuadrícula en subáreas.



**Figura 13.** Sistema de cuadrícula superpuesto al mapa geográfico del área de observación (captura).

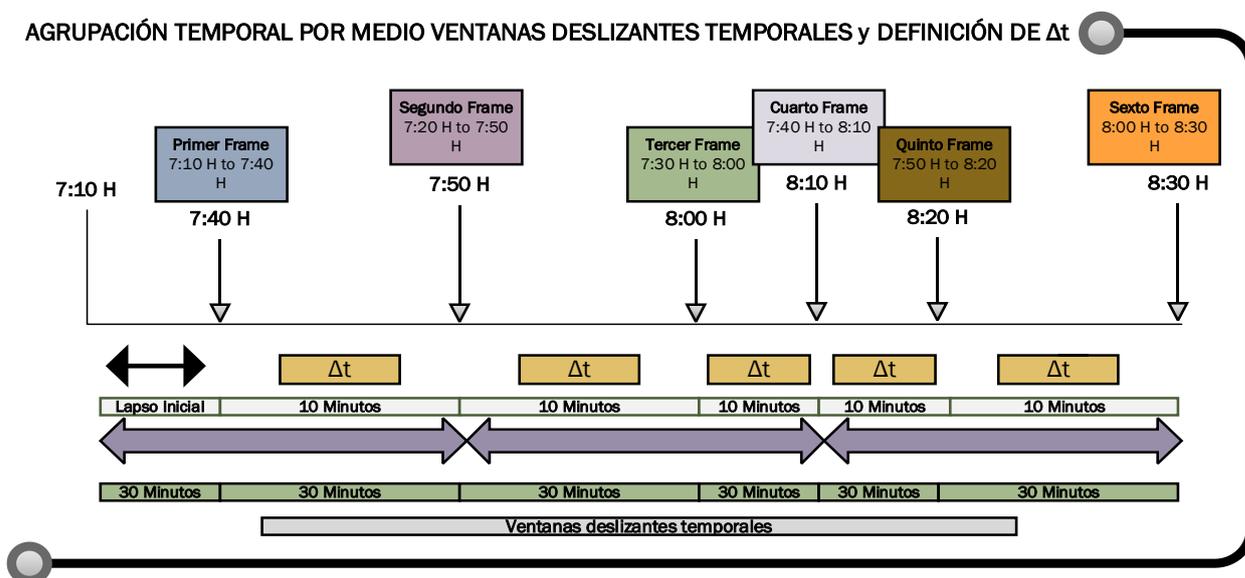
## 4.2.2 Agrupación temporal de los eventos delictivos del área de observación para su correlación

Dado que, para un mismo tamaño de área geográfica elegida como área de observación, el usuario puede también optar por diferentes rangos temporales de análisis (fecha y hora), como, por ejemplo: un año, dos años, algunos meses, etc., así como elegir también, con precisión exactamente cuales fechas prefiere. Para el desarrollo que aquí se propone, se realiza la agrupación temporal de los eventos

delictivos y criminales en el área de observación dentro del rango temporal escogido; y esta agrupación temporal es creada de acuerdo con los siguientes pasos:

- 1.) Se definen los parámetros de ventana deslizante temporal y de valor  $\Delta t$ , usando la misma metodología utilizada para el Geo-visualizador Espaciotemporal dinámico. Para el caso que aquí se muestra, se define un valor de ventanas deslizantes de 30 minutos y un valor de  $\Delta t = 10$  minutos. Es decir, que se representarán los casos ocurridos durante 30 minutos en cada frame, con un tiempo de refresco de 10 minutos o, en otras palabras, el geo-visualizador espaciotemporal predictivo muestra los eventos delictivos ocurridos durante de 30 minutos, en frames que se actualizan cada 10 minutos ( $\Delta t$ ). Resulta preciso aclarar que, estos dos parámetros se especificaron de esta forma, porque se encontró que para este caso en especial así de lograba el propósito central de pronóstico de actividad delictiva de la PONAL dentro de las funcionalidades de su C2S, para realizar pronósticos fiables de forma continua y con un horizonte temporal corto, usando la mayor cantidad de los datos reales que van ocurriendo, en un tiempo útil que para el usuario representa tiempo real; con lo que, estos parámetros fueron seleccionados inicialmente al azar y fueron siendo ajustados por prueba y error hasta encontrar aquellos que sirvieron al objetivo buscado.

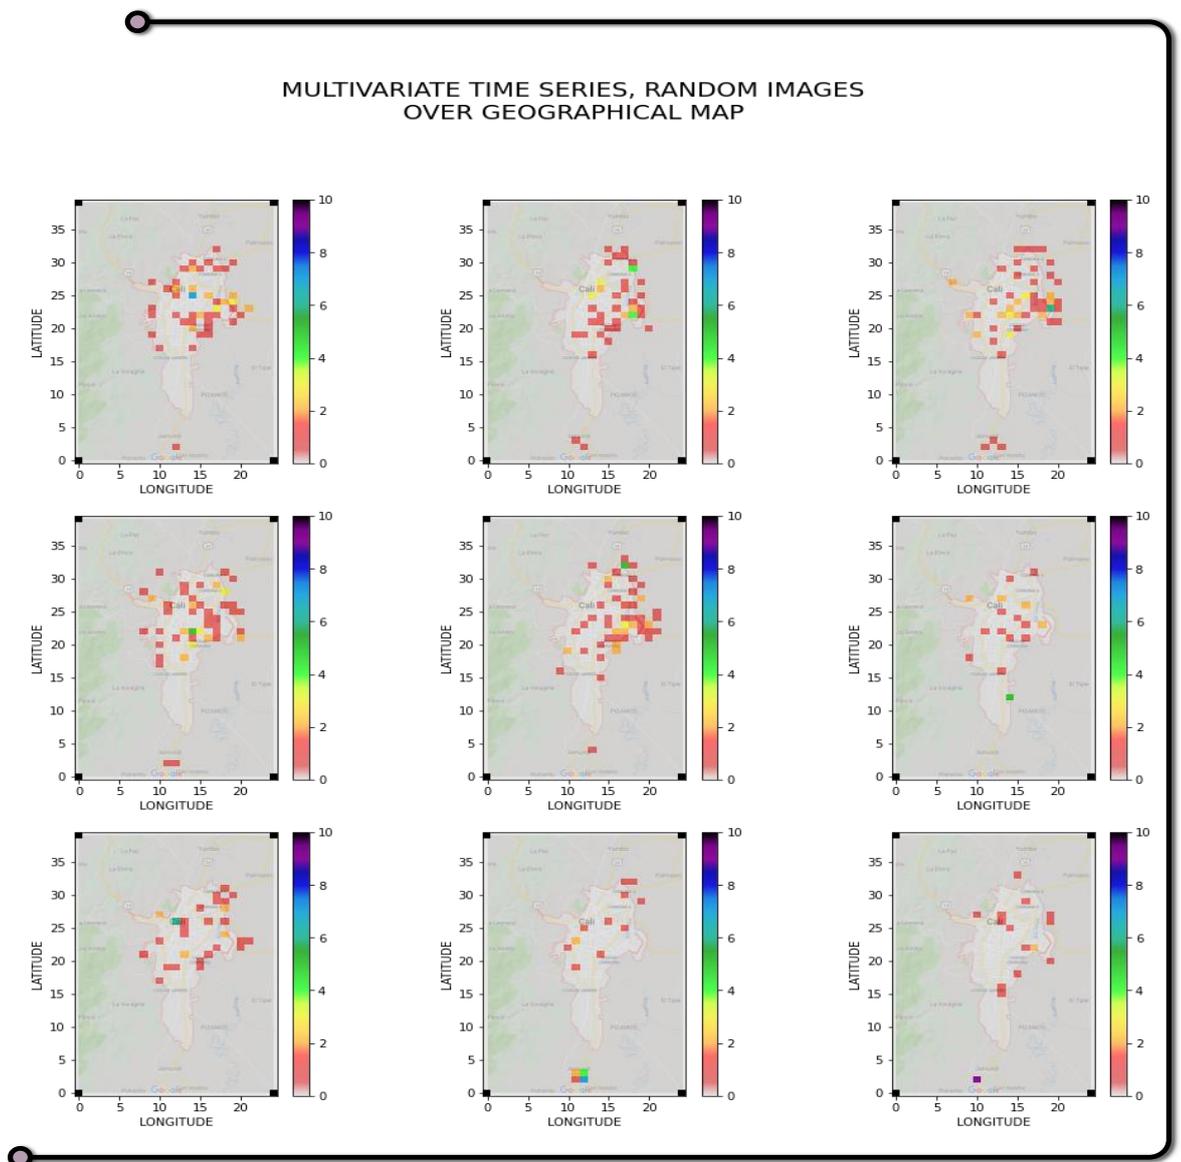
Debe recordarse entonces que estos dos parámetros siempre pueden ser ajustados según los requerimientos de quien realiza la observación, tanto en el valor de las ventanas deslizantes temporales como en el valor  $\Delta t$ , inclusive teniendo la posibilidad de utilizar parámetros que no generen superposiciones o solapamientos. La figura 14, muestra el diagrama de la agrupación temporal por medio de ventanas deslizantes y la definición de parámetro  $\Delta t$ .



**Figura 14.** Agrupación temporal por medio de ventanas deslizantes temporales y definición de  $\Delta t$ , para el Geo-visualizador Espaciotemporal Predictivo.

2.) Realizado el paso anterior, debe reorganizarse el dataset como una serie temporal multivariante cuya frecuencia corresponderá al valor de  $\Delta t$ . La Figura 15, muestra un ejemplo de capturas aleatorias de la representación gráfica de algunos frames sobre el mapa geográfico, donde puede verse la densidad de los eventos delictivos y criminales por subáreas cada  $\Delta t$ , dentro

de un área completa de observación que, para el ejemplo, es toda la jurisdicción de la PONAL sobre la ciudad de Santiago de Cali. Esta geovisualización ayuda, además, a que el usuario verifique si el área elegida, su resolución y el rango de tiempo de análisis, son los adecuados para sus objetivos o debe elegir parámetros diferentes.



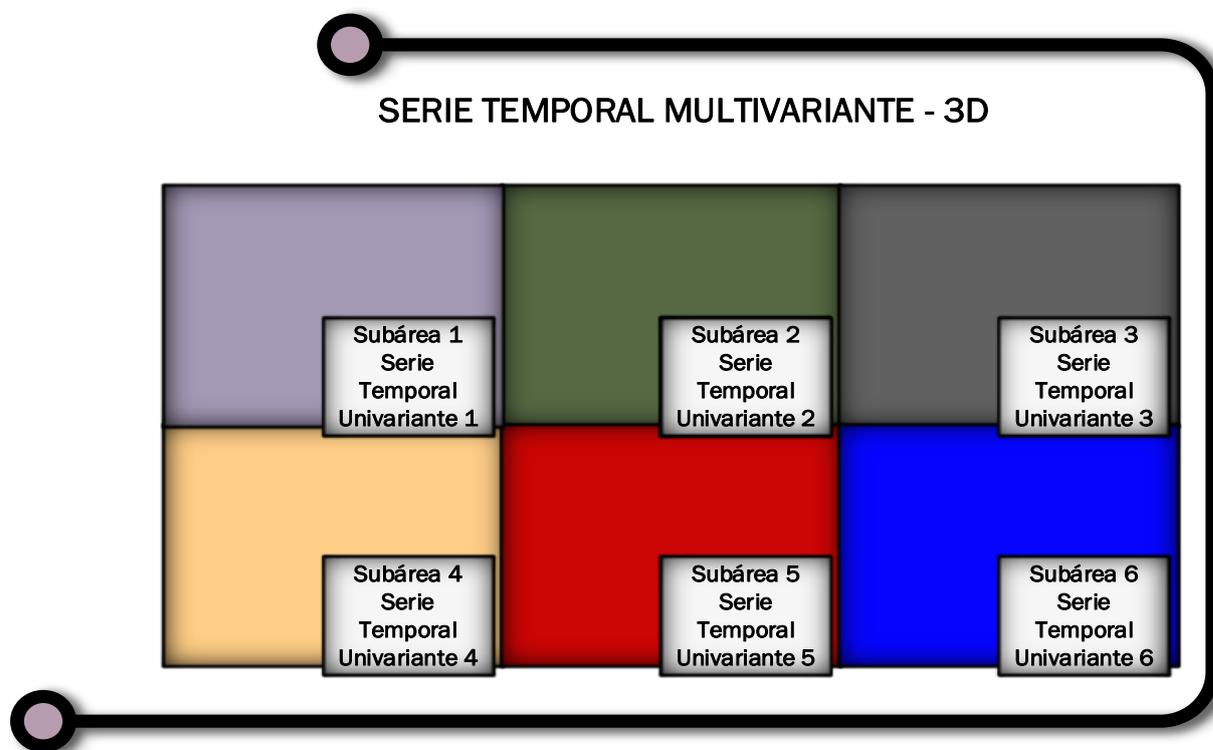
**Figura 15.** Muestra aleatoria de la representación de las densidades de eventos delictivos y criminales por subáreas, sobre mapa geográfico. Valor de ventana deslizante temporal = 30 minutos y valor de  $\Delta t$  = 10 minutos (captura).

### 4.2.3 El Pronóstico de los datos y su Geo-visualización Espaciotemporal

Para alcanzar el objetivo fundamental de pronóstico de actividad delictiva y criminal dentro del C2S de la PONAL, el cual consiste en: poder obtener pronósticos lo más confiables posibles para horizontes temporales cortos, que usen la mayor cantidad de datos reales que van ocurriendo y con un tiempo de obtención de estos pronósticos lo suficientemente útil para que comandantes y analistas puedan actuar de manera asertiva frente a las misiones antidelito; un modelo de predicción de eventos delictivos y criminales, debe poder:

- ✓ Realizar pronósticos de forma continua, para horizontes temporales cortos y en un tiempo útil lo más cercano posible al tiempo real.
- ✓ Hacer uso de un modelo que pueda ser reentrenado frecuentemente con la mayor cantidad de los datos reales de los eventos que van sucediendo, de forma que no solo el pronóstico sea aún más fiable, sino que además permita al usuario observar las posibles tendencias de desplazamiento de la actividad delictiva y criminal de forma más precisa.
- ✓ Comprender un modelo que sea lo más sencillo posible para que su costo computacional no se convierta en un obstáculo a su buen funcionamiento y no se corra el riesgo, además, de incurrir en overfitting (sobreajuste de los datos).
- ✓ Permitir la Geo-visualización espaciotemporal de este pronóstico de los eventos de actividad delictiva y criminal.

De acuerdo con lo anterior, al haber agrupado de forma espacial y temporal los datos de eventos de actividad delictiva y criminal, estos se convierten en una serie temporal multivariante creada por la unión de todas las series univariantes que conforman cada una de las subáreas del área de observación, es decir, se tendrá una serie temporal multivariante de datos conformada por un número de series temporales univariantes igual al número de subáreas o subcuadros que la cuadrícula contenga, ya que cada serie temporal univariante corresponde a la densidad de los eventos delictivos y criminales de cada subárea, donde la frecuencia de toda la serie temporal multivariante será el valor de  $\Delta t$ . La Figura 16, muestra un ejemplo de serie temporal multivariante en 3D y la Figura 17, muestra un ejemplo de serie temporal multivariante en 2D.



**Figura 16.** Ejemplo de Serie Temporal Multivariante – 3D.

**SERIE TEMPORAL MULTIVARIANTE – 2D**

Timestamp	SerTemp_1	SerTemp_2	SerTemp_3	SerTemp_4	SerTemp_5	SerTemp_6
2016-07-06 07:30:00	0.0	4.0	0.0	6.0	8.0	9.0
2016-07-06 07:40:00	2.0	0.0	1.0	0.0	2.0	0.0
2016-07-06 07:50:00	0.0	6.0	0.0	5.0	0.0	10
2016-07-06 08:00:00	5.0	0.0	0.0	0.0	3.0	0.0

**Figura 17.** Ejemplo de Serie Temporal Multivariante – 2D, con valor de frecuencia igual valor de  $\Delta t = 10$  minutos.

El realizar estas agrupaciones de las densidades de los eventos de actividad delictiva y criminal, tanto espacial como temporalmente en una serie temporal multivariante, conlleva las siguientes ventajas:

- ✓ Se obtiene la correlación espacial entre las subáreas del área de observación al realizar el pronóstico de los eventos a futuro, ya que al conformarse cada una de las series temporales univariantes con las densidades de los eventos delictivos y criminales de cada una de las subáreas, los algoritmos de predicción toman en cuenta esta relación espacial, sin necesidad de que les sea dado este parámetro de ubicación (latitud y longitud) como una variable predictora.

- ✓ Se obtiene la correlación temporal entre las subáreas del área de observación al realizar el pronóstico de los eventos a futuro, ya que al conformarse cada una de las series temporales univariantes con las densidades de los eventos delictivos y criminales de cada una de las subáreas, los algoritmos de predicción toman en cuenta esta relación temporal, sin necesidad de darles este parámetro de Timestamp (fecha y hora) como una variable predictora.

Realmente estas agrupaciones comprenden entonces, una gran ventaja en el manejo de los algoritmos predictivos para series temporales multivariantes, porque reduce las variables predictoras a solamente los valores de las densidades de eventos delictivos y criminales por cada subárea, lo cual hará al modelo mucho más sencillo y ligero, por tanto este dará como resultado la generación de pronósticos con un tiempo de convergencia más veloz, pero sin renunciar a la correlación espacial y temporal de los datos, lo que para este caso resulta de suma importancia ya que estas dos correlaciones son fundamentales para que el pronóstico sea realmente fiable, porque dentro de un área de observación solo es posible pronosticar correctamente el desplazamiento de la actividad, si se correlacionan entre sí los sucesos de cada una de las subáreas que lo conforman.

### **Pruebas de predicción de eventos delictivos y criminales:**

Para estas pruebas se tomará un área de observación de 10 subcuadros o cuadrantes, del tamaño mencionado en la subsección 4.2.1 y con los valores de

ventana deslizante y  $\Delta t$ , escogidos en la subsección 4.2.2, es decir, con los mismos valores de parámetros con los que hasta el momento se ha venido describiendo el proceso. Se elige de esta forma el área de observación porque corresponde con el área aproximada de jurisdicción de una Estación de Policía de la PONAL en una ciudad, pero se reitera que esta puede ser tan extensa como analistas y comandantes o cualquier usuario lo prefiera.

Debido a que a estas alturas del proceso el sistema de Geo-visualización ya nos ha brindado información sobre los datos por medio de la representación gráfica, puede verse entonces que es importante comprobar el porcentaje de dispersión o escasez de estos, es decir, la cantidad de datos a cero que de manera real se presentan, ya que de esto dependerá mucho la elección de los algoritmos de predicción.

Teniendo en cuenta que en nuestro caso se usarán todos los datos de actividad delictiva y criminal sucedidos en la zona de observación, es decir, no se realizan filtros por código de caso, la prueba realizada da como resultado que **los datos presentan una dispersión o escasez del 0.9871357368590777**. En esta prueba mientras más cercano sea el resultado a 1 más alta es la dispersión, por lo que puede concluirse que, a la hora de realizar pronósticos a futuro, los datos de eventos delictivos y criminales de la PONAL hay que considerarlos tipo sparse o dispersos, por su alto porcentaje de valores a cero. Este cálculo es realizado en Python de acuerdo con la siguiente fórmula:

**Dispersión = 1.0 – (conteo de los valores que no son cero dentro de los datos)**  
**/ tamaño total de los datos**

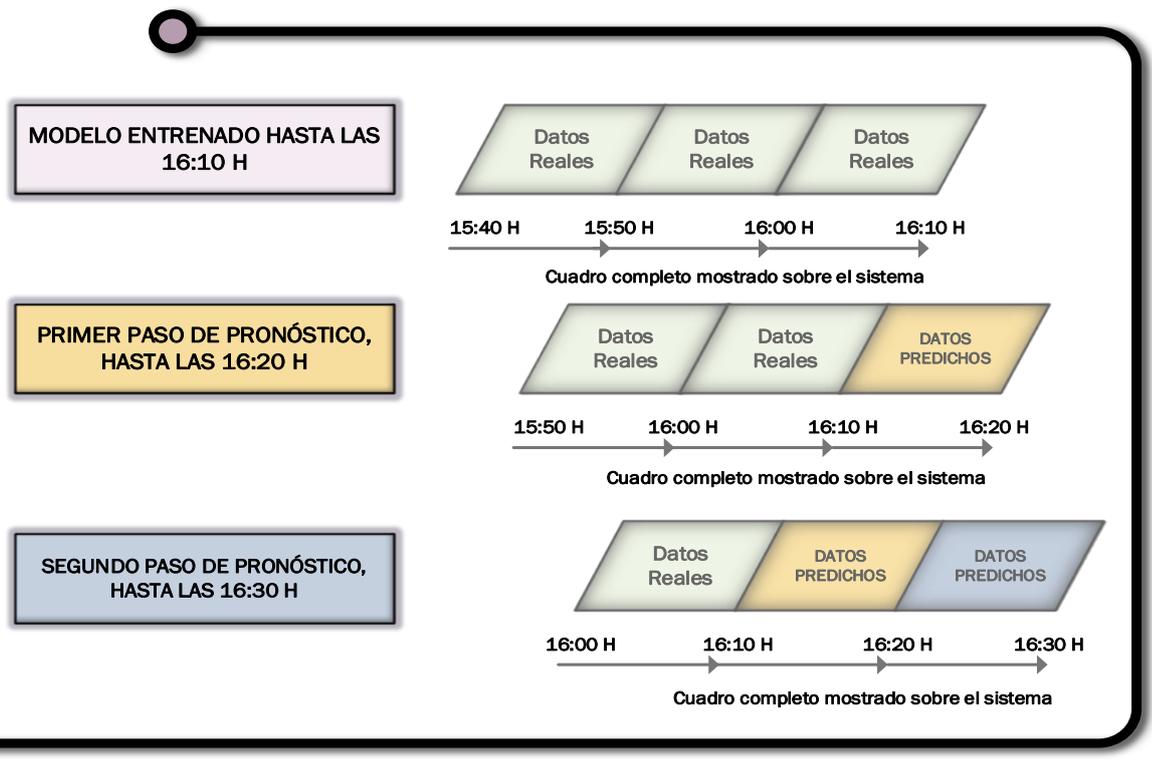
Si se analiza, esta característica de dispersión resulta lógica debido a que la actividad delictiva fluctúa de acuerdo con las zonas, las franjas horarias y las fechas; más aún si el usuario decidiera solicitarle al sistema una observación filtrando los eventos de actividad delictiva y criminal por códigos de casos, como, por ejemplo, solamente los casos de riñas, o los casos de riñas sumados a los casos de daño a la propiedad y así sucesivamente. Opción que como ya se ha mencionado antes, ofrece esta herramienta.

Se tiene entonces, en resumen, que los datos con los que se debe trabajar tienen las siguientes características:

- ✓ Comprenden una serie temporal multivariante tipo sparse (con muchos valores a cero), del tamaño de la resolución de los cuadrantes elegidos para el área de observación.
- ✓ Sus variables de predicción serán los valores enteros de las densidades de actividad delictiva y criminal en cada una de las subáreas (cuadrantes) o series temporales univariantes que la conforman, donde de acuerdo con las figuras mostradas anteriormente, se eligió una escala de 0 a 10 siendo el cero ausencia de eventos (transparencia o ausencia de color) y 10 la máxima concentración de eventos (color negro); cabe señalar que los valores de esta escala pueden ser reajustados si así se necesitara.

- ✓ La serie temporal multivariante no tiene variables exógenas, solo posee variables endógenas, es decir, para cada serie temporal univariante de las que componen a la multivariante se requiere la realización de pronósticos.
- ✓ Esta serie temporal multivariante se puede catalogar como de alta frecuencia, debido a que la frecuencia de la serie correspondería al valor de  $\Delta t$  que para este caso son 10 minutos.
- ✓ El pronóstico de la serie temporal multivariante se considera como en multiparalelo, debido a que el pronóstico de un paso (o periodo), sería el equivalente al pronóstico de un paso en frecuencia del valor de las densidades de los eventos en cada una de las subáreas (cuadrantes), del área de observación, en multiparalelo, con lo que se puede decir que la serie temporal no es solo multivariante sino también multiparalela.

La Figura 18, define el horizonte temporal de predicción o de pronóstico con el que se diseña el Geo-visualizador Espaciotemporal Predictivo, donde cada paso de predicción o pronóstico corresponderá a 10 minutos.

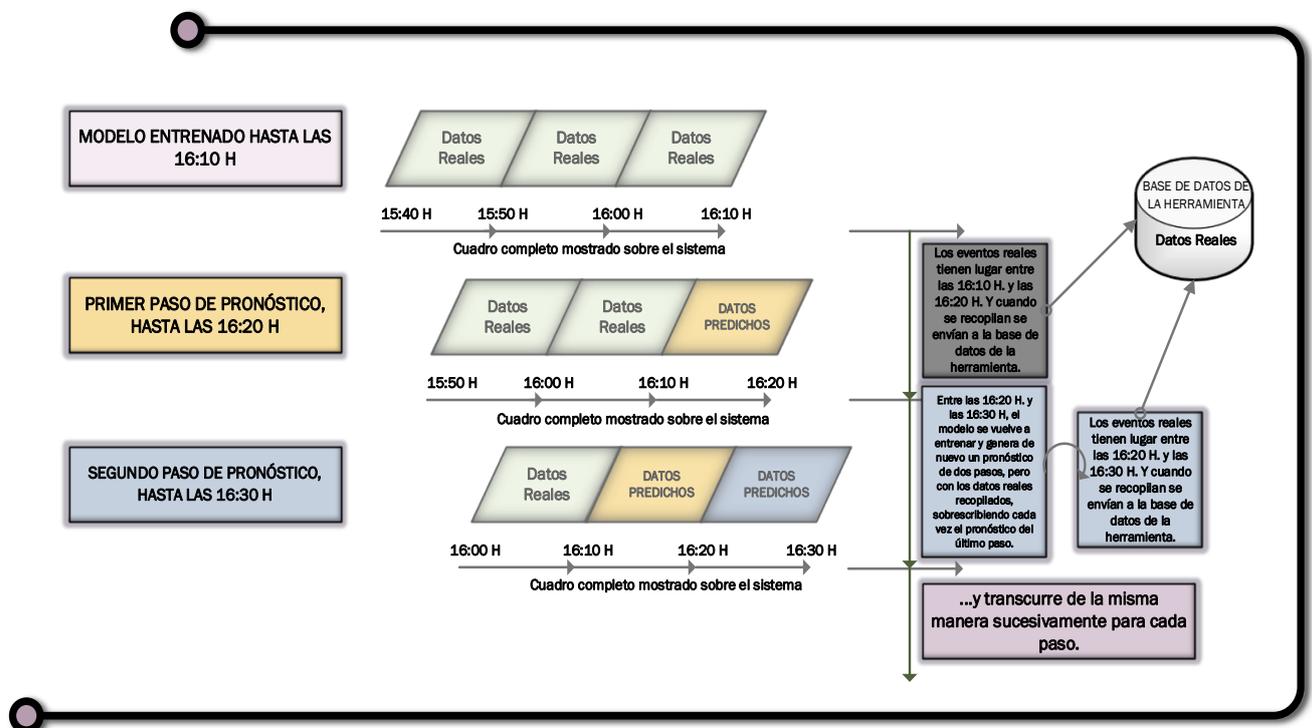


**Figura 18.** Horizonte temporal de predicción o pronóstico de dos pasos en la Serie Temporal Multivariante Multiparalela. Cada paso corresponde a 10 minutos.

Ahora bien, como el objetivo es lograr pronósticos continuos, con horizontes temporales cortos y en un tiempo útil lo más cercano posible al tiempo real, donde además el modelo pueda aprovechar la mayor cantidad de datos reales que vayan sucediendo para reentrenarse y para realizar nuevos pronósticos, la Figura 19 muestra como debe ser el funcionamiento del sistema y sus requerimientos para alcanzar esta habilidad.

De acuerdo con el ejemplo ilustrado en la Figura 19, si el modelo predictivo quedara entrenado hasta la observación hecha a las 16:10 horas, empezaría entonces su funcionamiento de pronóstico con el primer paso que mostraría dicho pronóstico

hasta las 16:20 horas y el segundo paso de pronóstico que mostraría dicho pronóstico hasta las 16:30 horas. Estos pronósticos serían geo-visualizados por comandantes y analistas (o el usuario correspondiente), sobre el mapa geográfico de la zona de observación. No obstante, el tiempo sigue transcurriendo y el C2S de la PONAL sigue recaudando los datos de los sucesos reales de actividad delictiva y criminal dentro de ese primer intervalo de tiempo del primer paso de pronóstico (entre las 16:10 horas y las 16:20 horas), por lo que una vez se llega las 16:20 horas el C2S tiene los datos reales de los eventos hasta ese momento y puede enviarlos a la base de datos de la herramienta (aumentándola), para que el modelo pueda ser reentrenado con esta y se generen nuevamente dos pasos de pronóstico pero con los nuevos datos reales añadidos.



**Figura 19.** Funcionamiento requerido del modelo predictivo para el máximo aprovechamiento de los datos reales que van sucediendo y pronóstico continuo con horizonte temporal corto.

Mientras tanto, la geo-visualización no ha dejado de mostrar el pronóstico entre las 16:10 horas y las 16:30 horas, por lo que cuando el modelo se reentrena y realiza un nuevo pronóstico de dos pasos, (esta vez el primero hasta las 16:30 horas y el segundo hasta las 16:40 horas); el sistema se actualiza sobrescribiendo el pronóstico hasta las 16:30 horas y mostrando ahora el pronóstico para el intervalo hasta las 16:40 horas, sin dejar nunca de mostrar la geo-visualización de los datos; y así sucesivamente para cada uno de los pasos de pronóstico.

Esto brinda al observador la sensación de continuidad y tiempo real en el pronóstico, aunque en realidad lo que sucede es que este se esté actualizando constantemente y se esté haciendo uso de la mayor cantidad de datos reales posibles que van sucediendo, lo cual es óptimo para el C2S de la PONAL, porque esto mejoraría notablemente la conciencia situacional, la proyección futura y por tanto la agilidad y la eficiencia en los procesos de toma de decisiones policíacas, ya que entre otras, permite a comandantes y analistas observar la tendencia del desplazamiento de la actividad del delito en los lugares, ya sea en general, por delitos o grupos de delitos aislados.

Si se espera que el sistema pueda alcanzar estas habilidades, debe escogerse un modelo o modelos predictivos que:

- ✓ Puedan ser reentrenados y generar pronósticos en un tiempo menor a la duración de un paso de tiempo, es decir, en un tiempo menor al de la frecuencia de la serie temporal multivariante multiparalela, que para este caso es de 10 minutos.

- ✓ Tener la capacidad de generar pronósticos fiables para un horizonte temporal de por lo menos dos pasos a la vez, ya que con pronósticos de un solo paso no podría darse esta continuidad en la geo-visualización, porque no habría tiempo para que el sistema recopilara la nueva información, reentrenara el modelo y generara nuevos pronósticos.
- ✓ Ser lo más sencillo y práctico posible de forma que los dos pasos anteriores puedan cumplirse.

En este punto empieza a ser bastante claro que: los objetivos de funcionamiento del mismo sistema de Geo-visualización, el funcionamiento propio de un C2S y las características de los datos reales a trabajar, son los que marcan las pautas contundentes para la elección de los algoritmos de predicción, ya que, entre otros, se hace evidente que, por ejemplo, que no todos los algoritmos de predicción para series temporales multivariantes con posibilidad de pronóstico en multiparalelo, funcionarán de manera adecuada cuando dicha serie temporal de datos presenta la característica de dispersión en alto porcentaje, como en este caso.

Para dar inicio a la elección de los algoritmos predictivos y teniendo presente que esta elección debe realizarse dentro de aquellos útiles para series temporales multivariantes con posibilidad de pronóstico en multiparalelo; solo restaría entonces reconocer dos particularidades indispensables de la serie temporal de datos, a saber:

- ✓ **La Estacionalidad:** La serie temporal multivariante que aquí se trata, es de alta frecuencia y tipo sparse, por lo que no presenta estacionalidad en sus datos.
- ✓ **La Estacionariedad:** La serie temporal multivariante que aquí se trata resulta ser estacionaria, por lo que no existe necesidad de realizar ningún tipo de transformación a los datos para lograr su estacionariedad. La estacionariedad fue probada en Python con la prueba de Dickey – Fuller.

#### 4.2.3.1 El Modelo de Referencia

Antes de realizar pruebas con aquellos algoritmos de predicción que puedan ser útiles al propósito que se propone, debe establecerse un pronóstico o modelo de referencia que sirva para determinar si los modelos clásicos, los modelos de Machine Learning o los modelos de Deep Learning que sean probados, tendrían verdadera habilidad y están agregando valor, logrando pronósticos realmente fiables. Cuando se trabaja con series temporales lo mejor es establecer un modelo de referencia ingenuo (naive), un pronóstico ingenuo implica usar las observaciones anteriores directamente como pronóstico sin hacer ningún cambio, razón por la cual también puede llamarse pronóstico de persistencia, de acuerdo con que se persiste en la observación anterior.

Hay otras posibilidades de establecer estos modelos de referencia, como por ejemplo realizar promedios de algunas observaciones anteriores y usarlos como pronóstico, para lo cual hay que transformar el dataset de series temporales a uno

apto para problemas de aprendizaje supervisado, es decir, en forma de entradas  $X$  y salidas  $y$ . Sin embargo, lo primordial es encontrar y escoger aquel modelo de referencia que dé como resultado el menor error, para ser comparado con el rendimiento de modelos más elaborados y comprobar su valor, porque si un modelo funciona peor que el modelo de referencia donde el de referencia no está realizando ningún tipo de procesamiento complejo a los datos, entonces puede descartarse definitivamente ese modelo. Por el contrario, si un modelo mejora el error de pronóstico del modelo de referencia, este es en definitiva un modelo que puede considerarse como solución al problema de pronóstico.

Se le realizaron pruebas con amplia suficiencia a la serie temporal multivariante a fin de encontrar el mejor modelo de referencia y se encontró que el modelo de persistencia uno a uno fue el modelo con el resultado de menor error, por lo cual se eligió a este como el modelo de referencia. El modelo de persistencia uno a uno es aquel donde las observaciones del paso de tiempo justamente anterior de cada una de las series univariantes son las que mejor representan la predicción de las observaciones del siguiente paso de tiempo de cada una de las series univariantes, por tanto, su métrica de error es la que se toma como referencia para probar a los demás y esta métrica es la siguiente:



MODELO DE REFERENCIA  
RMSE (Error Cuadrático Medio) = 0.316

## ***Generalidades acerca de los resultados de los modelos y las pruebas***

### ***realizadas:***

- ✓ Las series temporales son un caso particular de los procesos estocásticos, por tanto, sus modelos también suelen ser estocásticos, esto quiere decir que presentan cierta aleatoriedad en sus parámetros y por eso al entrenar un modelo, los valores de las métricas de error no siempre son las mismas. Ello implica que cuando se quiere conocer el rendimiento de uno de estos modelos, se realizan varias pruebas y se promedian los valores resultantes de las métricas de error, a este promedio se le considera el valor de rendimiento del modelo, por lo que los valores de las métricas de error de los modelos que se mostrarán en las siguientes secciones, corresponderán a los valores promedio del funcionamiento de cada modelo.
- ✓ Dado que son suficientemente claras aquellas características que se requieren del sistema y por tanto de los modelos predictivos y de pronóstico, la descripción de los modelos que se hará a continuación está basada en la metodología de tomar todos aquellos que cumplen con los requisitos iniciales de acuerdo con la naturaleza ya descrita de los datos e ir descartando por resultados de funcionamiento, desde sus pruebas más básicas, modelo a modelo. En otras palabras, se probarán todos los modelos posibles y se irá realizando el filtro de aquellos cuyo funcionamiento no se acoja a la necesidad de los datos y del sistema para continuar trabajando en el ajuste solo de aquellos que brinden las funcionalidades esperadas.

- ✓ Para cada uno de los modelos se usó la técnica Walk-Forward Validation, de esta forma no solo se calculó la métrica de error, sino que también se logró comprobar el tiempo que gasta cada modelo en reentrenarse y generar nuevos datos.
- ✓ Para que un modelo se considere como útil, su métrica de error para pronóstico de dos pasos de tiempo debe ser menor que la del modelo de referencia.

### **4.2.3.2 Modelos clásicos para el pronóstico de Series Temporales**

#### **Multivariantes**

Los modelos clásicos para el pronóstico de series temporales son aquellos desarrollados específicamente para estas y son los modelos SARIMAX, como en este caso los datos comprenden una serie temporal multivariante, entonces los modelos clásicos a aplicar serán los modelos vectoriales SARIMAX o V-SARIMAX. De acuerdo con que la serie temporal multivariante que nos atañe es estacionaria y no estacional donde todas sus variables son endógenas, es posible prescindir de la necesidad de usar los componentes de Integración "I", Estacionalidad "S" y de variables Exógenas "X" de los modelos clásicos V-SARIMAX.

Esto deja entonces como opción de prueba de métodos clásicos a los modelos VARMA y sus posibles combinaciones (VAR, VMA y VARMA), pero debe recordarse que se trata aquí con datos tipo sparse (dispersos), lo cual implica que si por alguna razón dentro del área de observación se elige una subárea donde todos los valores

de las densidades de actividad delictiva sean cero para el rango completo de tiempo que en el que se esté realizando el análisis, ninguno de estos modelos será funcional. En otras palabras, los modelos VARMA y sus derivados tienen la restricción de que funcionan solamente si ninguna de las series temporales univariantes que conforman la serie temporal multivariante, tienen valor cero por completo.

### ***Modelos VARMA (Vector Autorregresivo de Medias Móviles) y VMA***

#### ***(Vector de Medias Móviles):***

Al realizar las pruebas iniciales más básicas de estos dos modelos (de orden 1), los modelos VARMA y VMA fueron descartados ya que su convergencia al ser entrenados y solicitárseles pronósticos, no solo tardó demasiado tiempo, sino que además sus resultados no fueron fiables a simple vista porque la métrica de error no mejoró a la del modelo de referencia. Debe recordarse que se necesita que la convergencia de tiempo entre el entrenamiento y la generación de pronósticos de dos pasos de tiempo sea como máximo de 10 minutos para que el sistema pueda funcionar adecuadamente en el C2S de la PONAL.

#### ***Modelos VAR (Vector Autorregresivo):***

El modelo VAR en cambio, generó un resultado que mejoró la métrica de error del modelo de referencia y el tiempo de reentrenamiento y generación de nuevos pronósticos fue mucho menor de 10 minutos. El resultado del modelo VAR es:

<p><b>PRONÓSTICO DE UN PASO:</b> RMSE (Error Cuadrático Medio) = 0.243</p> <p><b>PRONÓSTICO DE DOS PASOS:</b> RMSE (Error Cuadrático Medio) = 0.292</p> <p><b>TIEMPO DE ENTRENAMIENTO Y PRONÓSTICO:</b> Alrededor de 3 minutos</p>
------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------

Estos resultados se lograron teniendo en cuenta que:

- ✓ Los datos de entrada se usaron en crudo, es decir, sin ningún tipo de transformación.
- ✓ No se usó el apoyo de la GPU (Unidad de Procesamiento Gráfico).
- ✓ Se permitió que el modelo tomara automáticamente el orden que considerara mejor para su funcionamiento.

**Conclusión:** El modelo VAR puede ser una de las soluciones al objetivo propuesto ya que funciona mejor que el modelo de referencia, incluso en un pronóstico con horizonte temporal de dos pasos a la vez. Además, se puede reentrenar y generar como mínimo este pronóstico de dos pasos en multiparalelo en un tiempo menor al de la frecuencia de la serie temporal multivariante (10 minutos), lo que permite generar la continuidad predictiva propuesta por el sistema que define esta herramienta. Sin embargo, debe tenerse claro que este modelo es lineal, solo funciona bien con series temporales estacionarias y no funciona cuando alguna subárea o serie temporal univariante dentro del área de observación, presenta una densidad de eventos igual a cero.

### **Modelos Clásicos para Series Temporales Multivariantes tipo SPARSE**

#### **(dispersas):**

Se comprobó el funcionamiento del modelo VAR-SPARSE (Vector Autorregresivo Sparse), el cual solo está disponible para lenguaje de programación R por medio de las librerías “bigtime”, [103] y “sparsevar”, [104], pero no resultó funcional debido a que, incluso para una serie temporal multivariante pequeña, su convergencia es muy lenta ya que tardó horas en converger; además su consumo en memoria RAM (Random Access Memory), es demasiado alto sin que se justifique por una verdadera prestación del modelo.

#### **4.2.3.3 Modelos de Machine Learning para el pronóstico de Series Temporales Multivariantes**

Dentro de los algoritmos de Machine Learning que permiten realizar el pronóstico en multiparalelo para series temporales multivariantes tipo sparse, se encuentra el algoritmo Random Forest. Este algoritmo hace posible crear modelos desde uno (1) a uno (1), es decir, tomando una observación anterior para pronosticar una observación en el futuro, hasta modelos que pueden tomar varias observaciones anteriores (X) para hacer el pronóstico de varios pasos hacia el futuro (y). Su convergencia (tiempo de entrenamiento y generación de pronósticos), es de aproximadamente dos (2) minutos sin el apoyo de la GPU (Unidad de Procesamiento Gráfico), también pueden utilizarse los datos en crudo y su único requisito adicional es que se haga la transformación del dataset de series temporales a uno apto para

problemas de aprendizaje supervisado, es decir, en forma de entradas “X” y salidas “y”.

Sin embargo, aunque aparentemente Random Forest ofrece todas las posibilidades para dar solución a la necesidad de predicción de la herramienta para el C2S de la PONAL aquí planteada, su métrica de error en ningún momento mejoró a la del modelo de referencia, incluso después de realizar los cambios posibles dentro de sus parámetros y realizar las combinaciones posibles de entradas y salidas para el pronóstico. Por el contrario, con ciertas combinaciones de parámetros el consumo en memoria RAM (Random Access Memory), fue demasiado alto sin que sus resultados lo justificaran. Con Random Forest la mejor métrica de error obtenida fue en el modelo 4 (cuatro) a 3 (tres), es decir, 4 entradas (X) y tres salidas (y) y su valor fue: RMSE = 0.498; por esta razón el modelo se descartó.

#### **4.2.3.4 Modelos de Deep Learning para el pronóstico de Series Temporales Multivariantes**

Con respecto al pronóstico de series temporales el Deep Learning promete: el aprendizaje automático de las relaciones lineales o no lineales y las estructuras temporales que presenten los datos tales como tendencias y estacionalidad, el manejo de secuencias largas y datos ruidosos, el pronóstico en multiparalelo de varios pasos de entrada y salida sin hacer suposiciones sobre las funciones de mapeo, el operar con valores perdidos y escasos; y finalmente, aunque el hecho de

que la serie temporal sea estacionaria represente una ventaja, no se hace obligatorio para su uso.

Este panorama que resulta bastante interesante para ser probado como solución en este caso y aquellos algoritmos de Deep Learning especializados en el manejo de secuencias y por tanto de series temporales son: CNN-1D (Convolutional Neural Network-1D), MLP (Multilayer Perceptron) y LSTM (Long Short-Term Memory) con sus diferentes variantes y combinaciones de variantes Vanilla-LSTM, Stacked-LSTM, Bidirectional-LSTM, CNN-LSTM y ConvLSTM.

Para realizar pruebas con estos algoritmos se dejaron los datos en crudo o sin ningún tipo de transformación, se requirió transformar el dataset de series temporales a uno apto para problemas de aprendizaje supervisado, es decir, en forma de entradas "X" y salidas "y"; y los resultados de rendimiento de los modelos que aquí se muestran fueron apoyados con el uso aproximado de un 11% de la GPU (Unidad de Procesamiento Gráfico).

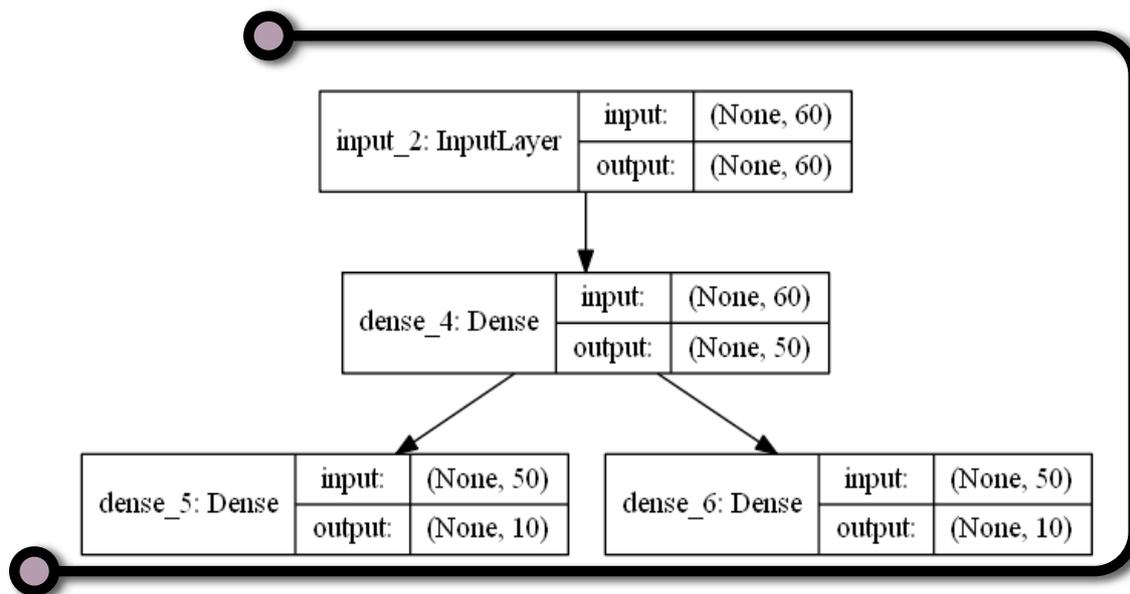
### ***Modelos de Red Neuronal MLP (Multilayer Perceptron):***

Es un modelo de red neuronal sencillo que ofrece para este problema de predicción una excelente solución dentro de su configuración:

- ✓ Una capa de entrada de  $X = 6$  observaciones anteriores por la cantidad de subáreas
- ✓ Activación relu.
- ✓ Una capa densa de 50 neuronas.
- ✓ 30 épocas de propagación.

- ✓ Una salida de pronóstico de  $y = 2$  pasos en dos vectores.
- ✓ Datos Float 32.

Como muestra el diagrama de red neuronal en la Figura 20.



**Figura 20.** Diagrama de Red Neuronal MLP (Multilayer Perceptron).

Dando el siguiente resultado:

**PRONÓSTICO DE DOS PASOS:**  
RMSE (Error Cuadrático Medio) = 0.287

**TIEMPO DE ENTRENAMIENTO Y PRONÓSTICO:**  
Alrededor de 3 minutos

**Conclusión:** Por lo que este modelo de Red Neuronal puede considerarse adecuado como solución para el sistema que aquí se propone, dada su sencillez, rápida convergencia, eficacia y métrica de error, la cual mejora a la del modelo de referencia incluso para un pronóstico de dos pasos de tiempo.

### ***Modelos CNN-1D (Convolutional Neural Network-1D):***

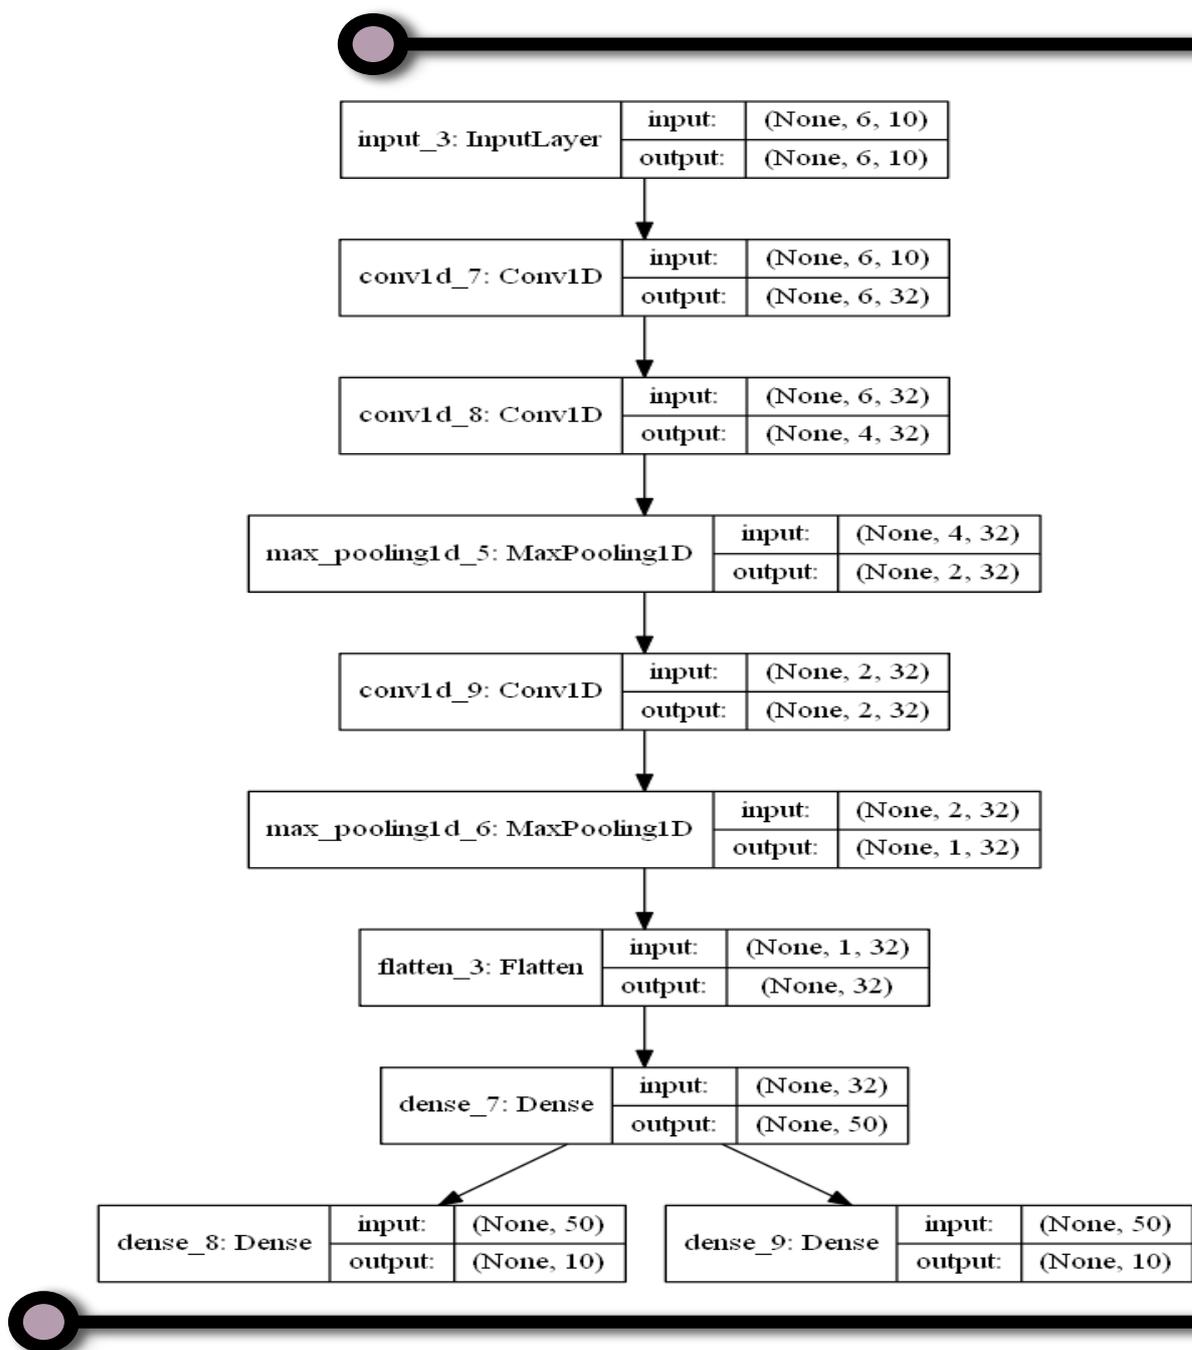
Las redes neuronales convolucionales en general, ya sean 1D, 2D o 3D, están diseñadas para preservar las estructuras espaciales en los datos de entrada sin procesar, a esto se le denomina aprendizaje de representación. Las CNN consiguen extraer las características de los datos independientemente de cómo se produzcan, ya que permanecen invariables con la posición de los objetos y la distorsión de las escenas. La CNN-1D, conservando estas características, es ideal para el pronóstico de series de tiempo dado que las series temporales son secuencias de observaciones que pueden tratarse como imágenes unidimensionales de las que el modelo puede extraer sus elementos principales, mapeando una secuencia de observaciones anteriores de los datos sin procesar como entrada, a una o unas observaciones futuras como salida.

El modelo CNN-1D que ofreció para este problema de predicción la mejor solución, fue el configurado como:

- ✓ Multi-channel con una primera capa convolucional oculta de entrada de  $X$   
= 6 observaciones anteriores por la cantidad de subáreas.
- ✓ 32 filtros de convolución con tamaños de kernel = 3.
- ✓ Activación relu y padding.
- ✓ Una segunda capa convolucional de 32 filtros con tamaños de kernel= 3.
- ✓ Activación relu.
- ✓ Una siguiente capa de maxpooling.
- ✓ Una capa de flatten.

- ✓ Una capa densa de 50 neuronas con activación relu.
- ✓ 25 épocas de propagación.
- ✓ Una salida de pronóstico de  $y = 2$  pasos en dos vectores.
- ✓ Datos Float 32.

Como muestra el diagrama de red neuronal en la Figura 21.



**Figura 21.** Diagrama de Red Neuronal CNN-1D (Convolutional Neural Network-1D).

Dando el siguiente resultado:

**PRONÓSTICO DE DOS PASOS:**  
RMSE (Error Cuadrático Medio) = 0.285

**TIEMPO DE ENTRENAMIENTO Y PRONÓSTICO:**  
Alrededor de 4 minutos

**Conclusión:** Por lo que este modelo de Red Neuronal puede considerarse adecuado como solución para el sistema que aquí se propone y su métrica de error mejora a la del modelo de referencia, incluso para un pronóstico de dos pasos de tiempo.

### ***Modelos LSTM (Long Short-Term Memory):***

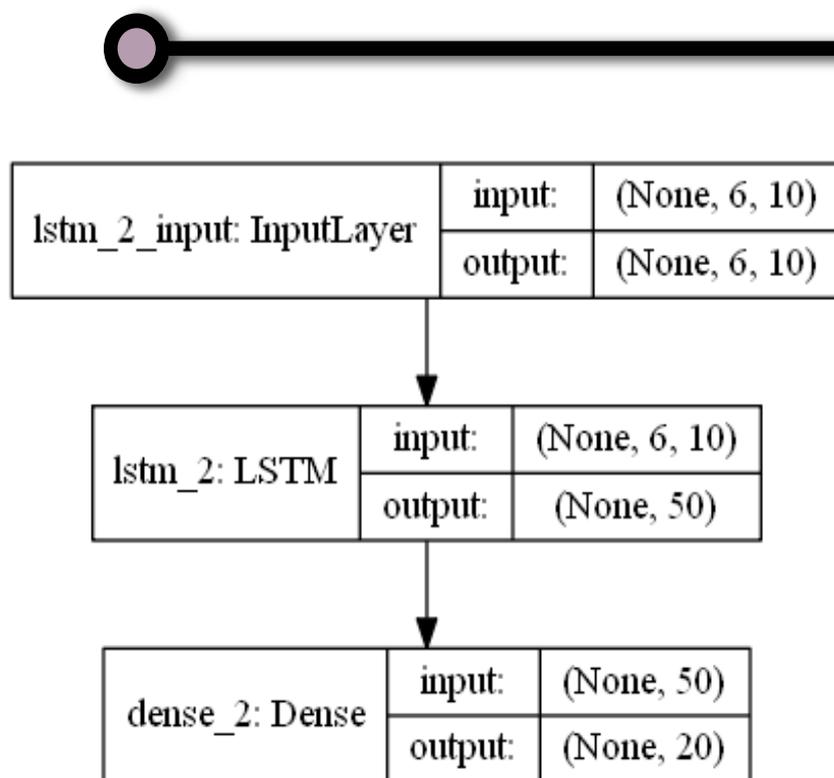
Las redes neuronales LSTM por naturaleza leen un paso de tiempo de la secuencia a la vez y crean la representación de ese paso interno para utilizarlo como contexto aprendido a la hora de realizar los pronósticos. En otras palabras, las redes neuronales LSTM ofrecen soporte nativo para secuencias, como es el caso de las series temporales.

Los modelos LSTM que ofrecieron para este problema de predicción, soluciones viables de acuerdo con su convergencia (tiempo de entrenamiento y generación de pronósticos), la posibilidad de pronósticos de al menos dos pasos y un rendimiento aceptable que por lo menos mejorara el rendimiento del modelo de referencia, con datos Float 32, son los siguientes:

#### ***En Modelos de salida Univectorial:***

- ✓ Modelo Vanilla-LSTM.
- ✓ Modelo CNN-LSTM.
- ✓ Modelo ConvLSTM.

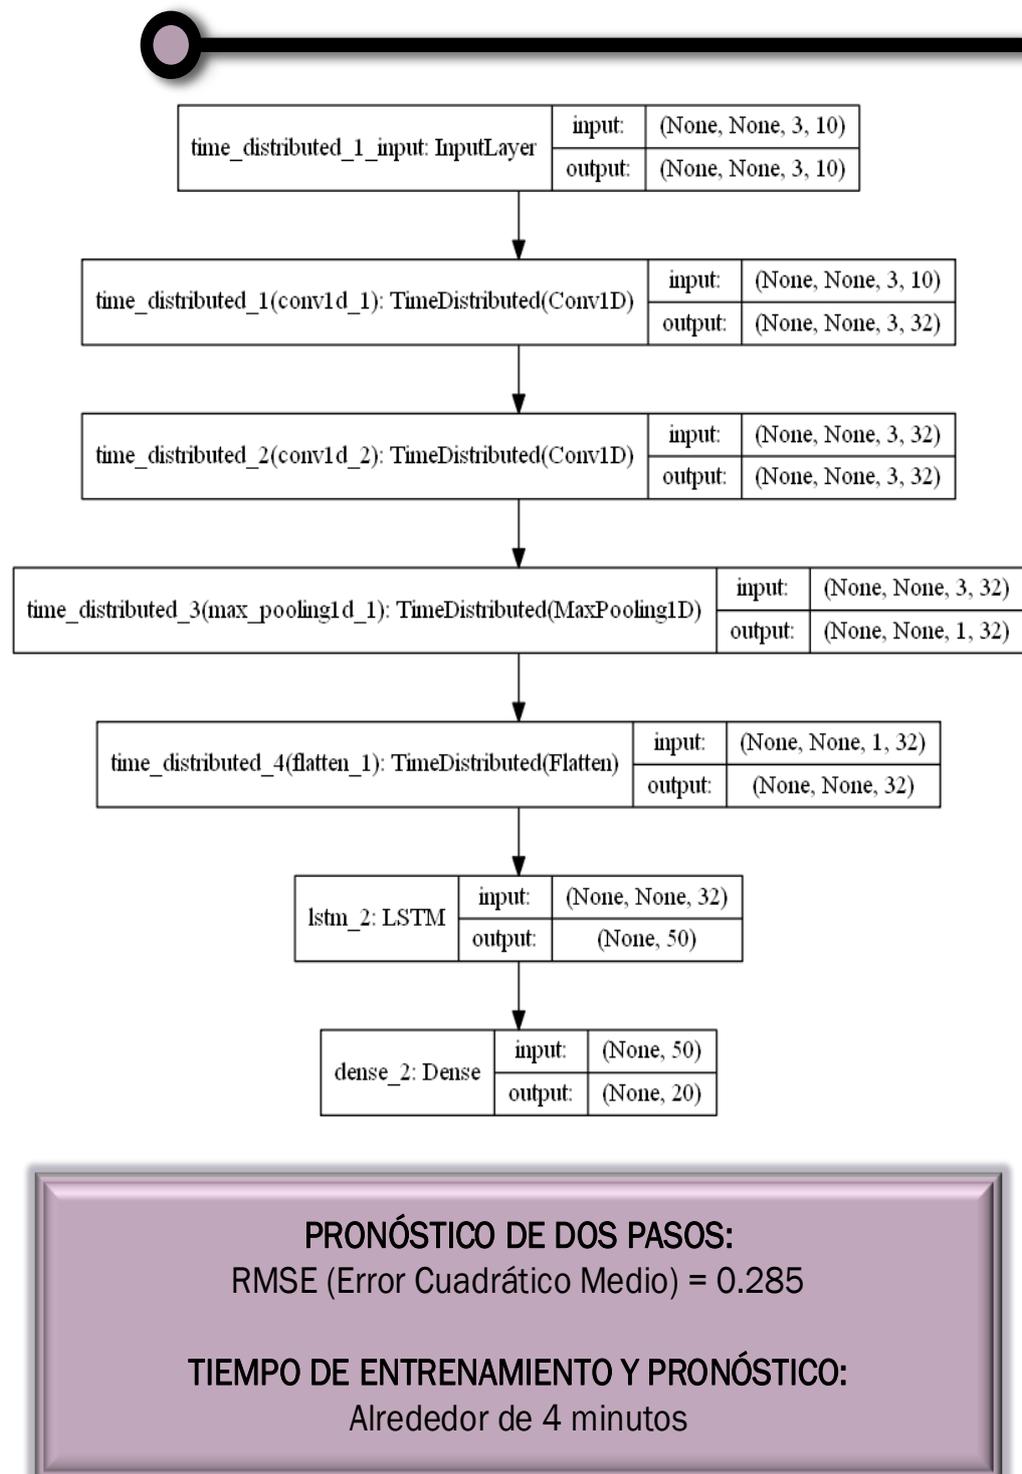
Las Figuras 22 a la 24, muestran las arquitecturas de estos modelos de Redes Neuronales.



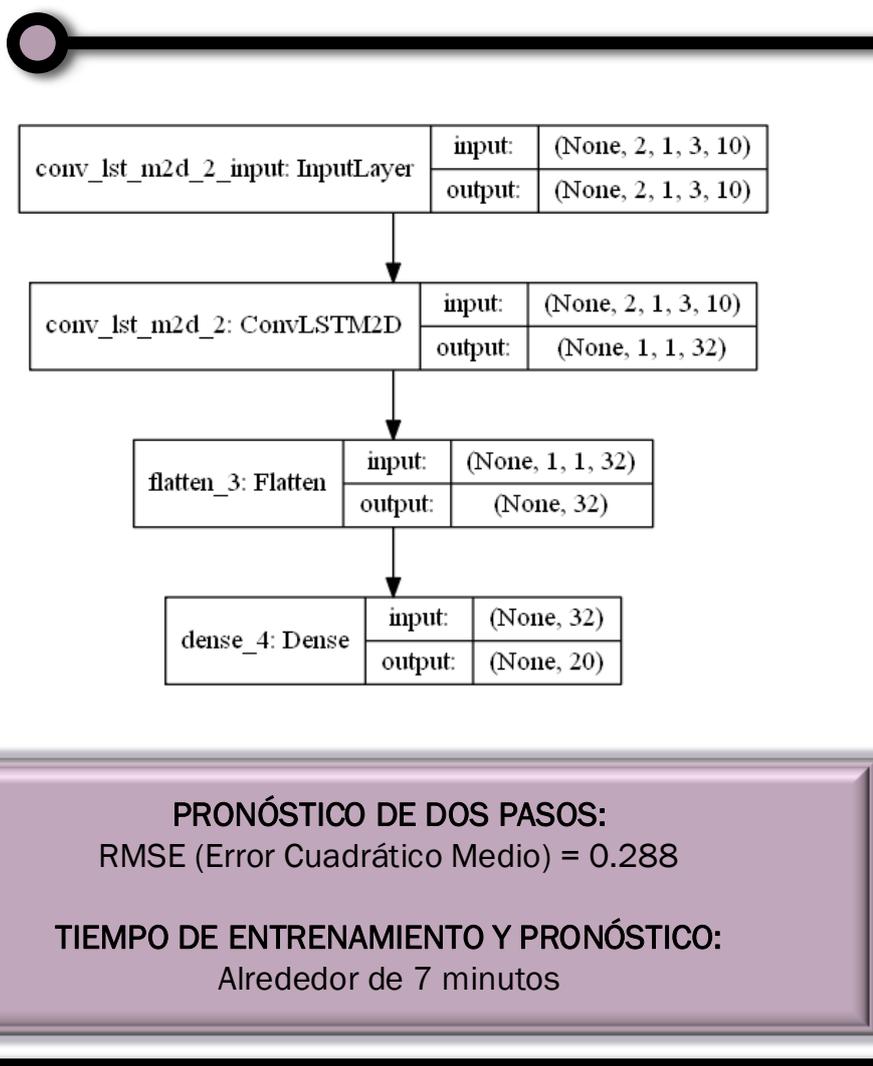
**PRONÓSTICO DE DOS PASOS:**  
 RMSE (Error Cuadrático Medio) = 0.288

**TIEMPO DE ENTRENAMIENTO Y PRONÓSTICO:**  
 Alrededor de 5 minutos

**Figura 22.** Diagrama de Red Neuronal de salida Univectorial Vanilla-LSTM y sus resultados.



**Figura 23.** Diagrama de Red Neuronal de salida Univectorial ConvLSTM y sus resultados.

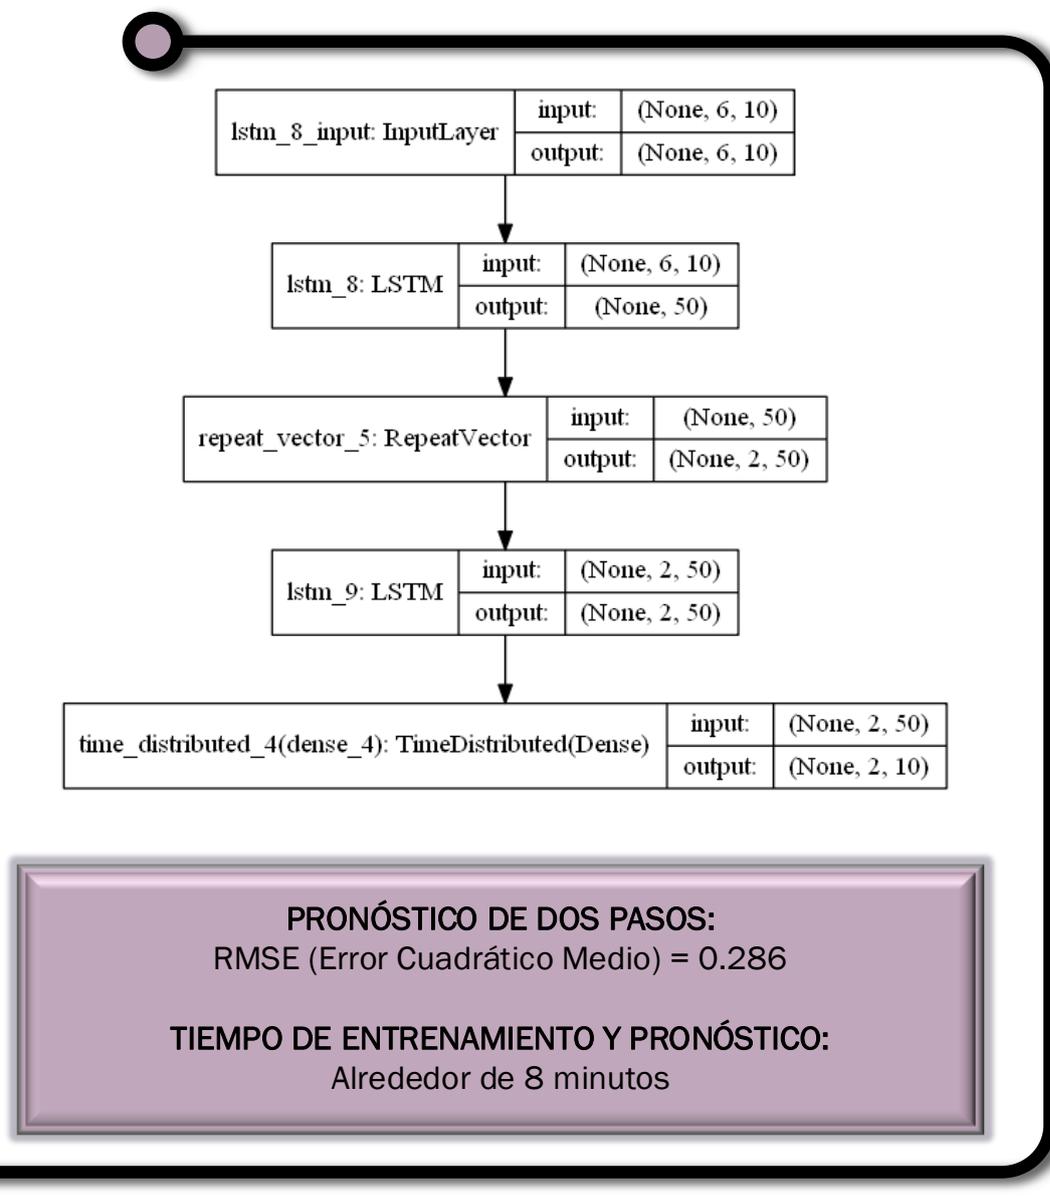


**Figura 24.** Diagrama de Red Neuronal de salida Univectorial CNN-LSTM y sus resultados.

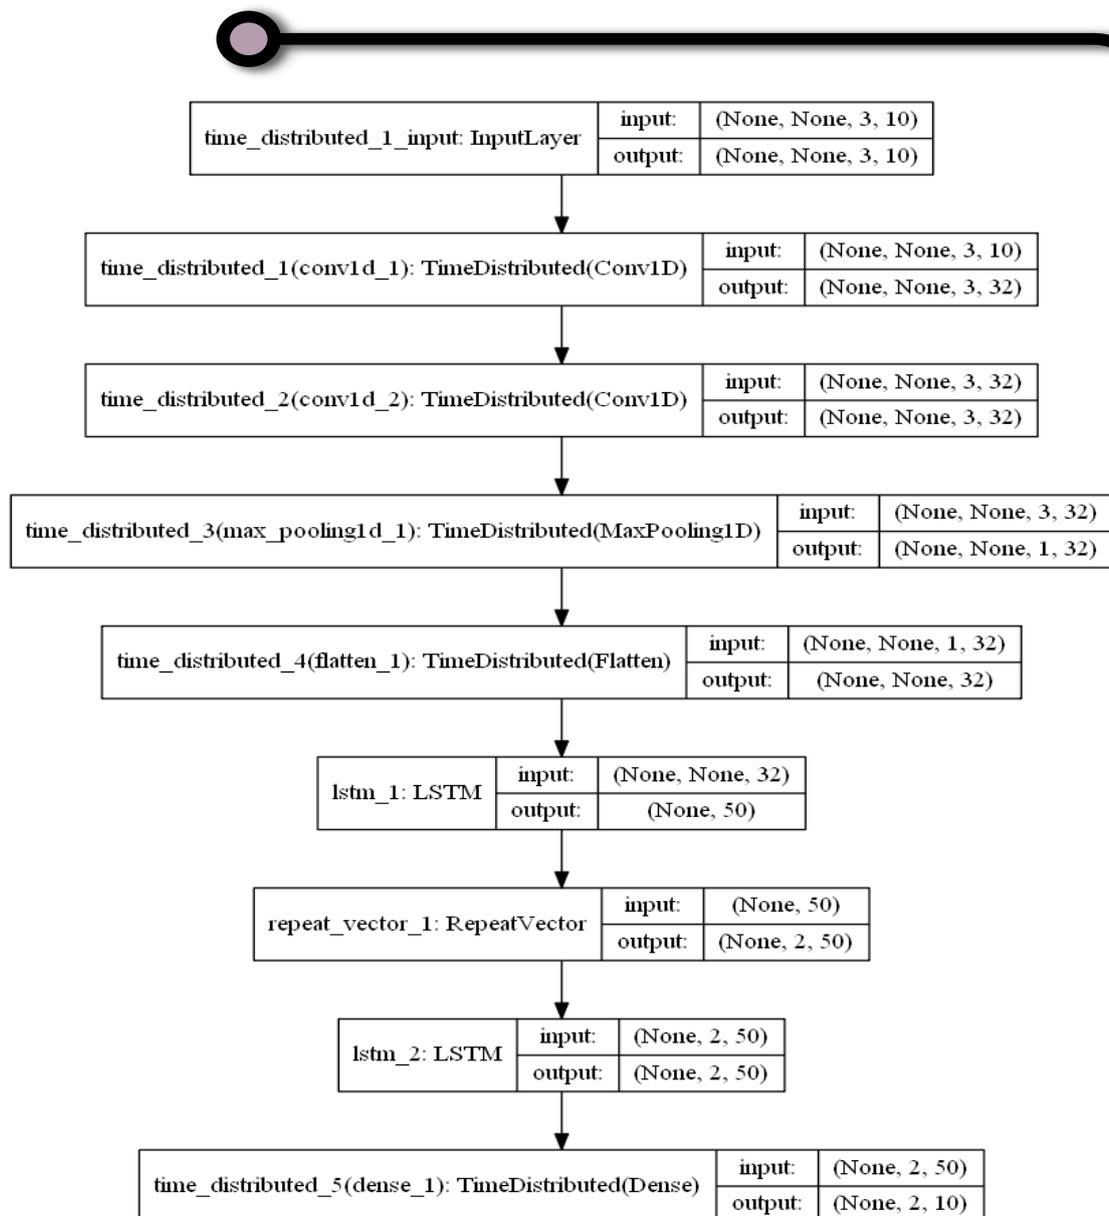
En Modelos tipo Encoder-Decoder para salida Multivectorial:

- ✓ Modelo VanillaLSTM - VanillaLSTM.
- ✓ Modelo CNN\_LSTM - VanillaLSTM.
- ✓ Modelo CNN - VanillaLSTM.
- ✓ Modelo ConvLSTM - VanillaLSTM.

Las Figuras 25 a la 28, muestran las arquitecturas de estos modelos de Redes Neuronales.



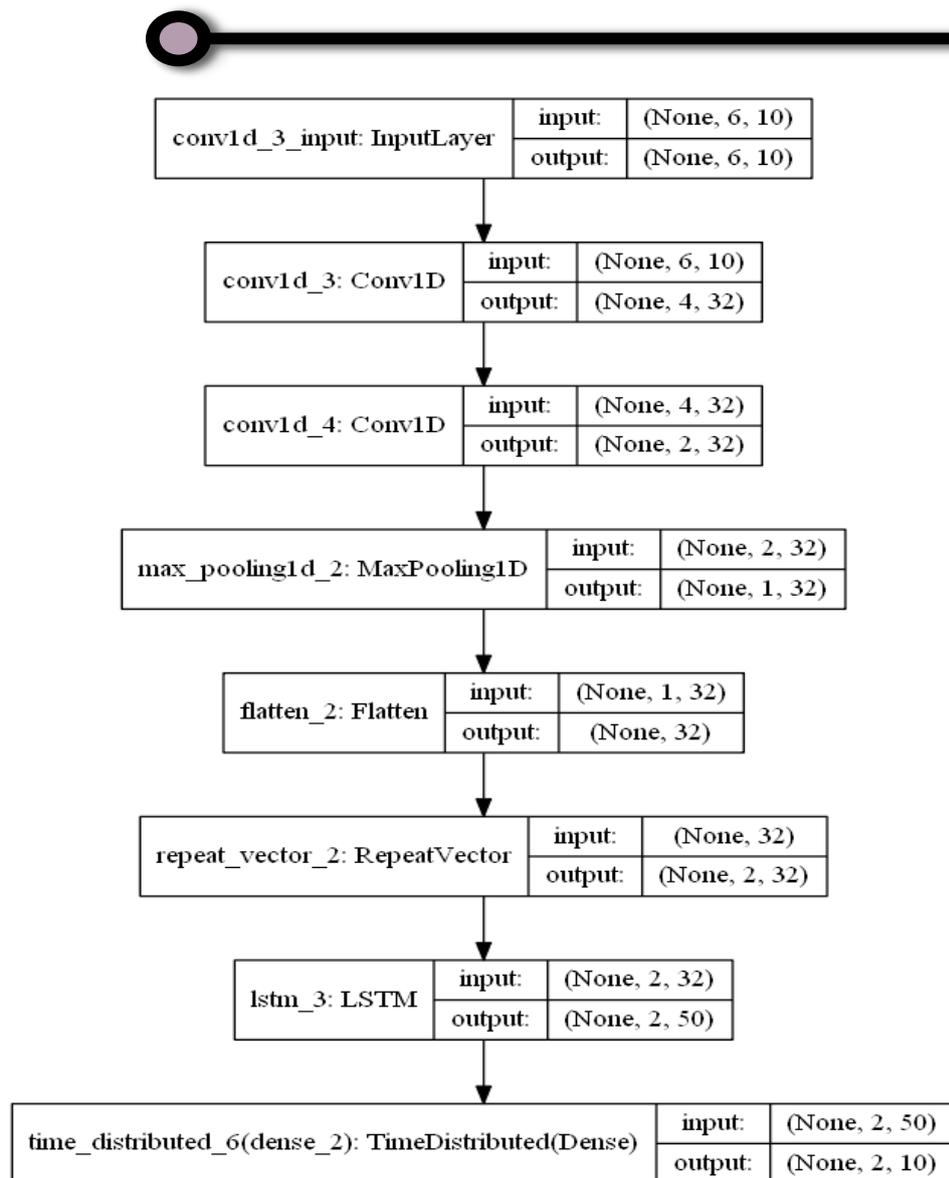
**Figura 25.** Diagrama de Red Neuronal Encoder-Decoder para salida Multivectorial VanillaLSTM - VanillaLSTM y sus resultados.



**PRONÓSTICO DE DOS PASOS:**  
RMSE (Error Cuadrático Medio) = 0.290

**TIEMPO DE ENTRENAMIENTO Y PRONÓSTICO:**  
Alrededor de 6 minutos

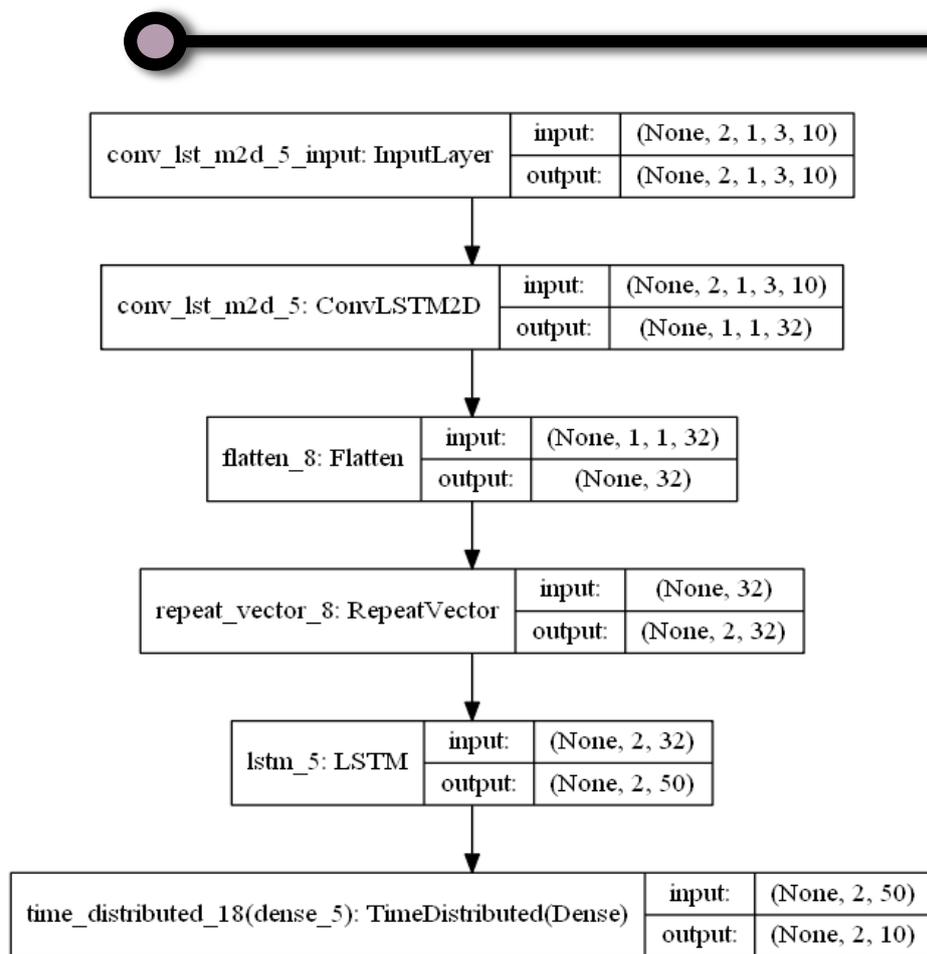
**Figura 26.** Diagrama de Red Neuronal Encoder-Decoder para salida Multivectorial CNN\_LSTM - VanillaLSTM y sus resultados.



**PRONÓSTICO DE DOS PASOS:**  
 RMSE (Error Cuadrático Medio) = 0.290

**TIEMPO DE ENTRENAMIENTO Y PRONÓSTICO:**  
 Alrededor de 4 minutos

**Figura 27.** Diagrama de Red Neuronal Encoder-Decoder para salida Multivectorial CNN - VanillaLSTM y sus resultados.



**PRONÓSTICO DE DOS PASOS:**  
 RMSE (Error Cuadrático Medio) = 0.286

**TIEMPO DE ENTRENAMIENTO Y PRONÓSTICO:**  
 Alrededor de 9 minutos

**Figura 28.** Diagrama de Red Neuronal Encoder-Decoder para salida Multivectorial ConvLSTM - VanillaLSTM y sus resultados.

**Conclusión:** Los modelos LSTM presentan un poco más de complejidad y su tiempo de convergencia, aunque está dentro de los límites establecidos, resulta un poco mayor; pero, tener en cuenta estos modelos puede ser de mucha utilidad ya que,

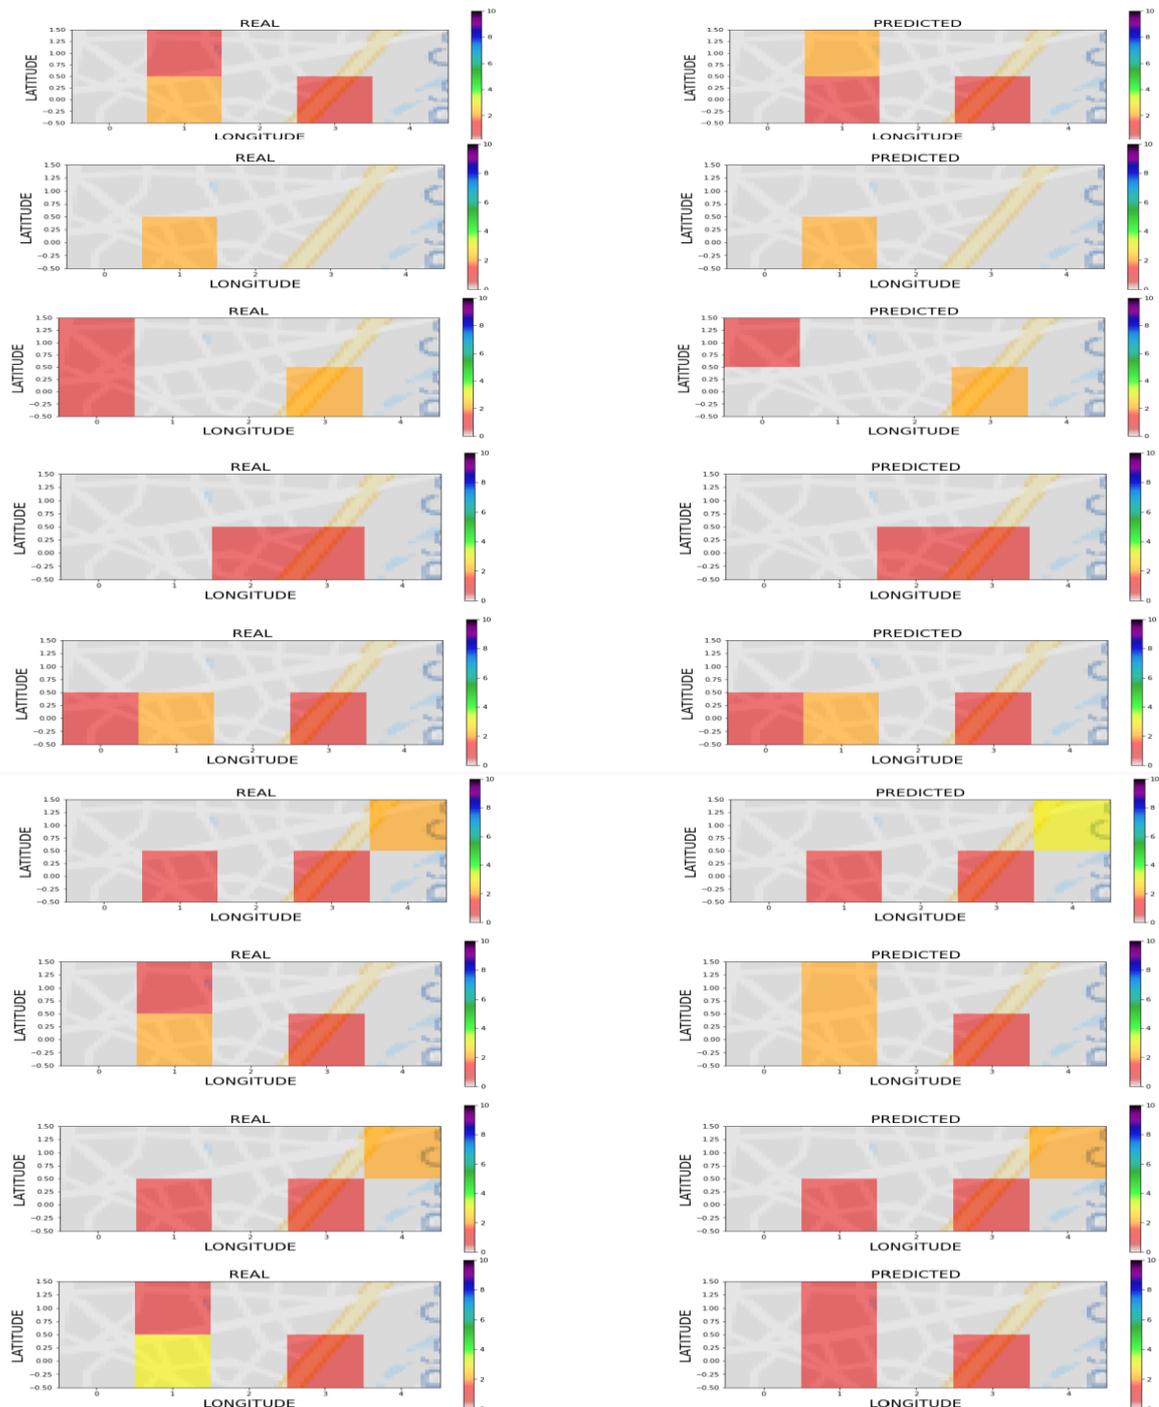
dependiendo de los datos, un modelo u otro podría ajustarse mejor. El resumen de resultados de los modelos LSTM sería:

**PARA PRONÓSTICO DE DOS PASOS:**  
RMSE (Error Cuadrático Medio) = Entre 0.285 y 0.290

**TIEMPO DE ENTRENAMIENTO Y PRONÓSTICO:**  
Aproximadamente entre 4 y 9 minutos

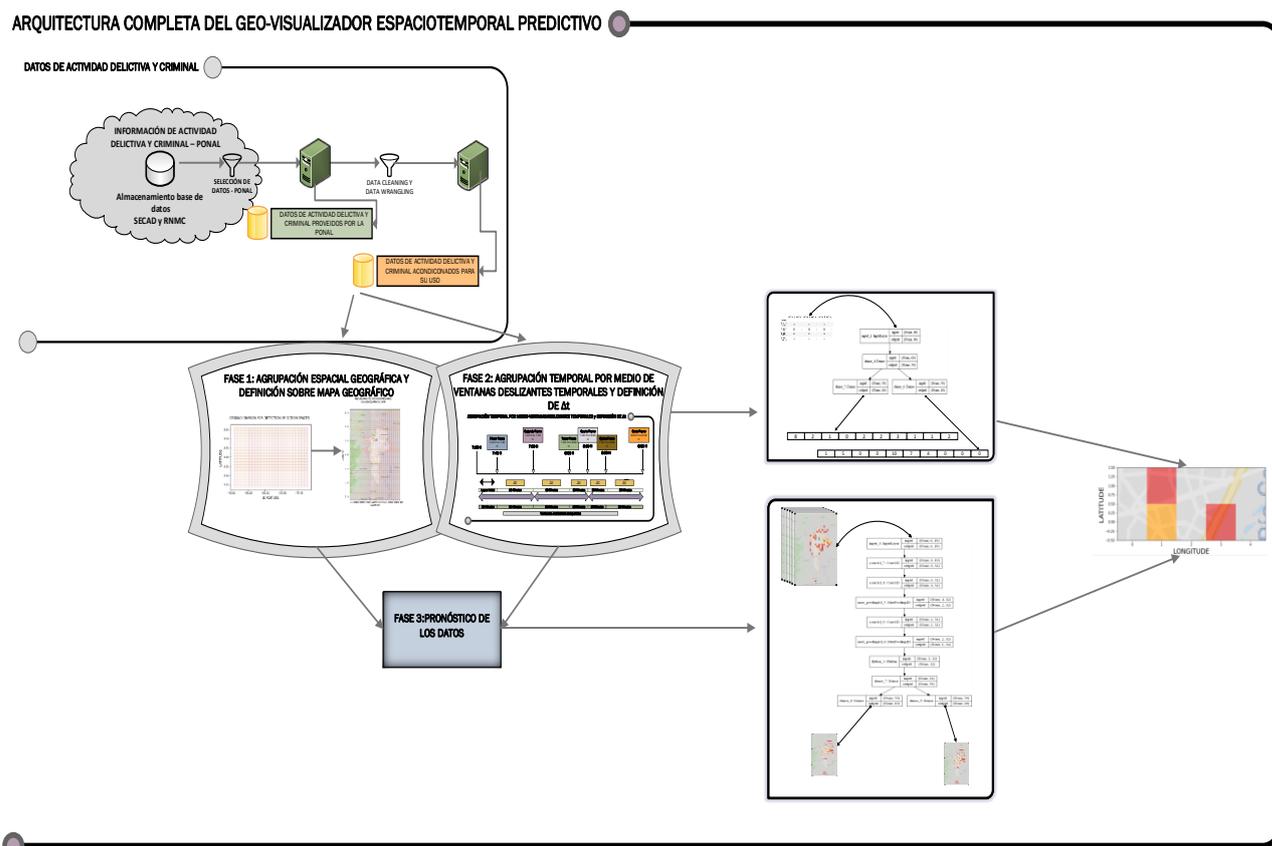
#### **4.2.3.5 La Geo-visualización de los Pronósticos**

A continuación, en la Figura 29 se muestra un comparativo de la geo-visualización de los datos reales y los datos predichos. Analistas y comandantes (o los usuarios correspondientes), verán la predicción de los datos sobre el sistema de información geográfica SIG (que para este caso será sobre el SIG del C2S de la PONAL), en coordenadas de la latitud y longitud, sin embargo, para explicar el sistema en detalle, la Figura 29 muestra el geo-visualizador con escala en partes de la cuadrícula, ya que este parámetro también es ajustable.

GRAPHICAL COMPARISON BETWEEN REAL VALUES AND PREDICTED VALUES  
OVER GEOGRAPHICAL MAP

**Figura 29.** Muestra aleatoria de la comparativa entre las geo-visualización de los datos reales y los datos predichos (captura).

La Figura 30, muestra la arquitectura completa del Geo-visualizador Espaciotemporal Predictivo de datos delictivos y criminales sobre mapa geográfico, para aplicaciones C2S.

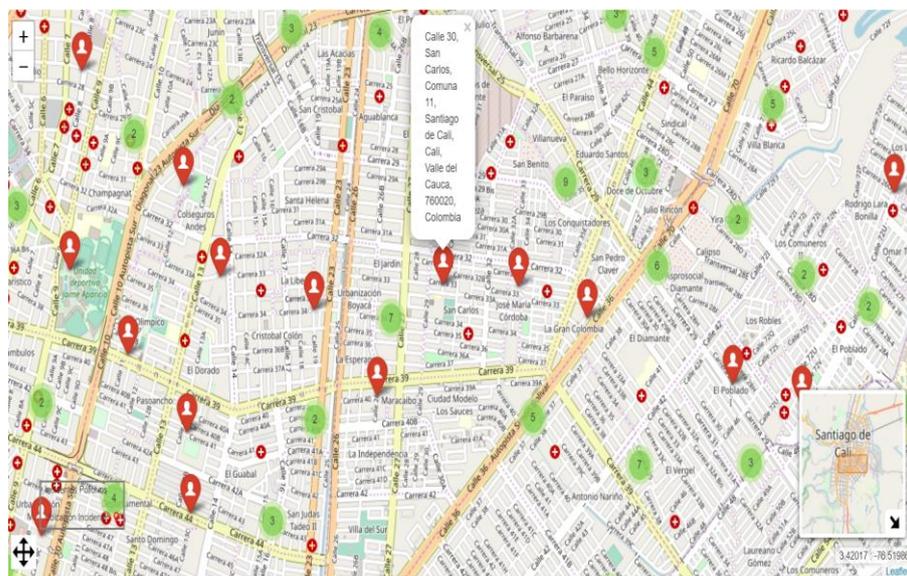


**Figura 30.** Arquitectura completa del Geo-visualizador Espaciotemporal Predictivo de datos delictivos y criminales sobre mapa geográfico, para aplicaciones C2S.

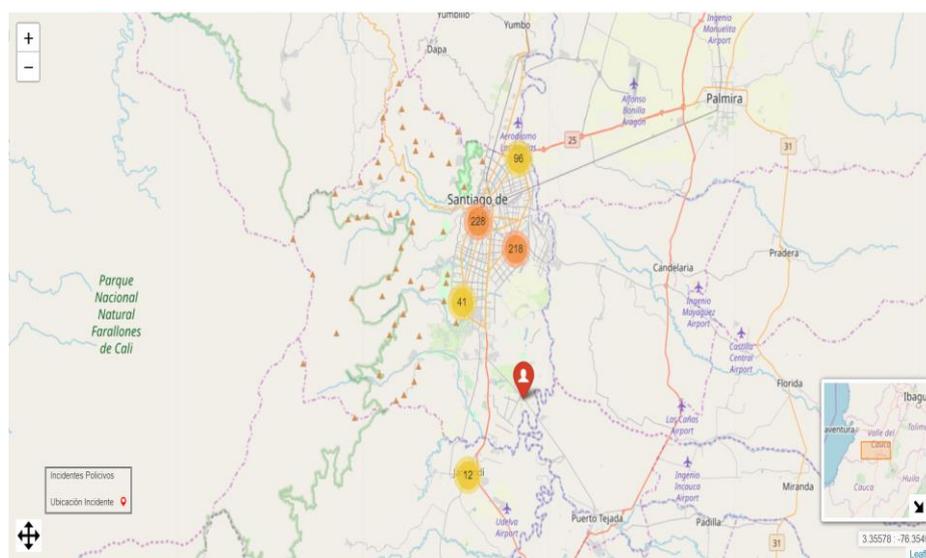
## **5. CAPÍTULO V: GEO-CODIFICACIÓN SOBRE EL SISTEMA DE GEO-VISUALIZACIÓN ESPACIOTEMPORAL**

Durante el proceso de creación de sistema de Geo-Visualización, se detectó que, para la fuerza táctica de la PONAL, quién en el caso de una llamada de emergencia es quien acude al lugar de los hechos contando con la ubicación del suceso en coordenadas geográficas, sería ser muy beneficioso contar también con la geolocalización del lugar en dirección de calle y en tiempo real.

Sabiendo que la geo-codificación es el proceso de transformar la descripción de una ubicación en una ubicación de la superficie de la Tierra (latitud y longitud), se añadió una utilidad de geolocalización reversa programada en Python, para ser sumada a la información que se muestra sobre el sistema de Geo-visualización Espaciotemporal, donde cada punto representativo de un evento de actividad delictiva o criminal podrá mostrar su geolocalización en dirección de calle solamente con pasar el puntero del ratón sobre la ubicación. También se cuenta con la posibilidad de separar en grupos de marcadores los eventos que el analista quiera. La Figura 31, muestra estas utilidades sobre un Sistema de Información Geográfica (SIG) web open source, donde para el ejemplo se usó el SIG OpenStreetMap [105].



(a)

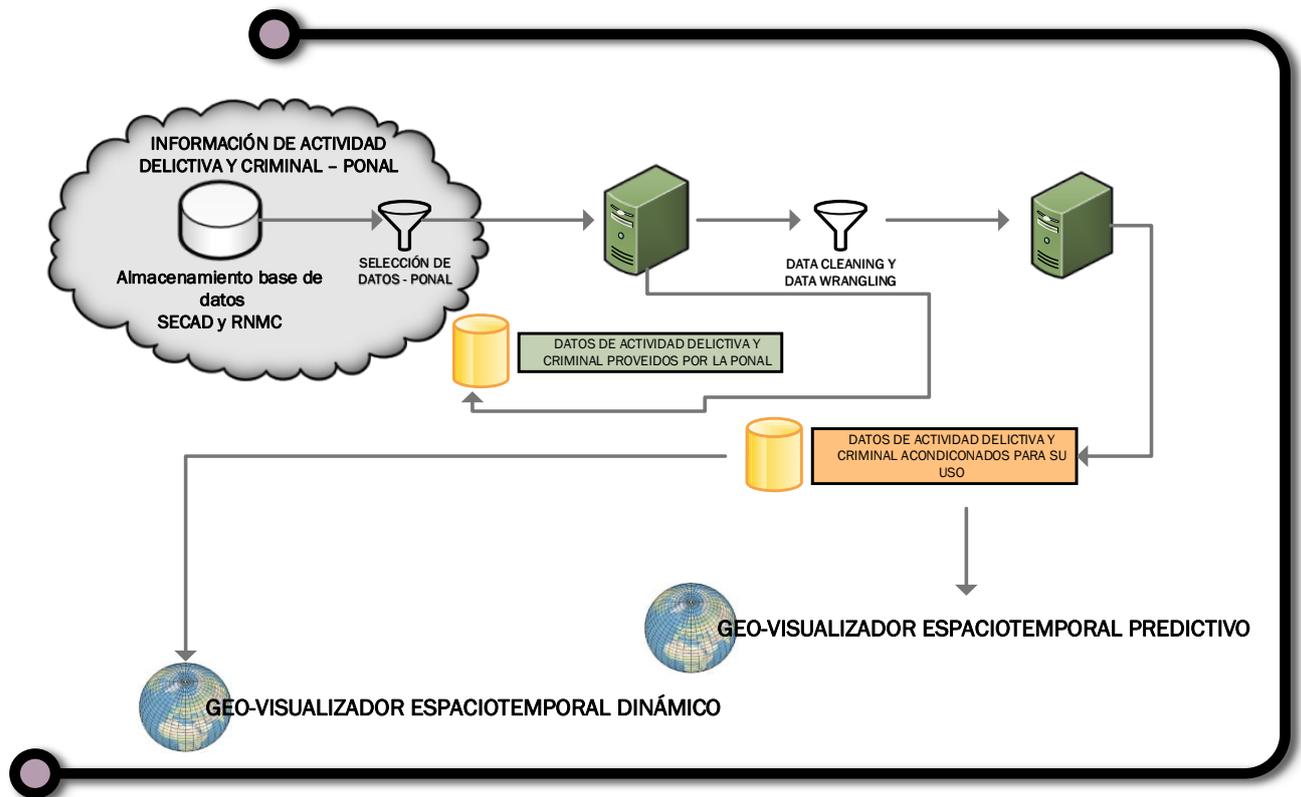


(b)

**Figura 31.** Geo-codificación y agrupaciones (captura): (a) Eventos delictivos y criminales geo-codificados inversamente a la dirección de calle. (b) Eventos delictivos y criminales agrupados por ubicación.

## **6. CAPÍTULO VI: ARQUITECTURA DEL SISTEMA DE GEO-VISUALIZACIÓN ESPACIOTEMPORAL, INTEGRADA A LA ARQUITECTURA DE LOS SISTEMAS DE COMANDO Y CONTROL DE LA PONAL**

La arquitectura del sistema que se propone en esta tesis doctoral para la Geo-visualización Dinámica y Predictiva de la actividad delictiva y criminal, es una arquitectura de software que debe poder ser integrada a la arquitectura de un Sistema de Comando y Control (C2S), en este caso particularmente al C2S de la PONAL dentro de sus Subsistemas de Información de Comando y Control (C2IS), que son aquellos que reúnen la información proveniente de varias fuentes y cuentan con los Sistemas de Información Geográfica (SIG) para mostrarla. Este sistema de Geo-visualización Dinámica y Predictiva debería ser integrado específicamente al sistema de información para el seguimiento y control de casos (SECAD), dentro del C2IS de la PONAL. A continuación, la Figura 32 muestra de forma resumida la arquitectura general de software, del sistema de Geo-visualización Dinámica y Predictiva.

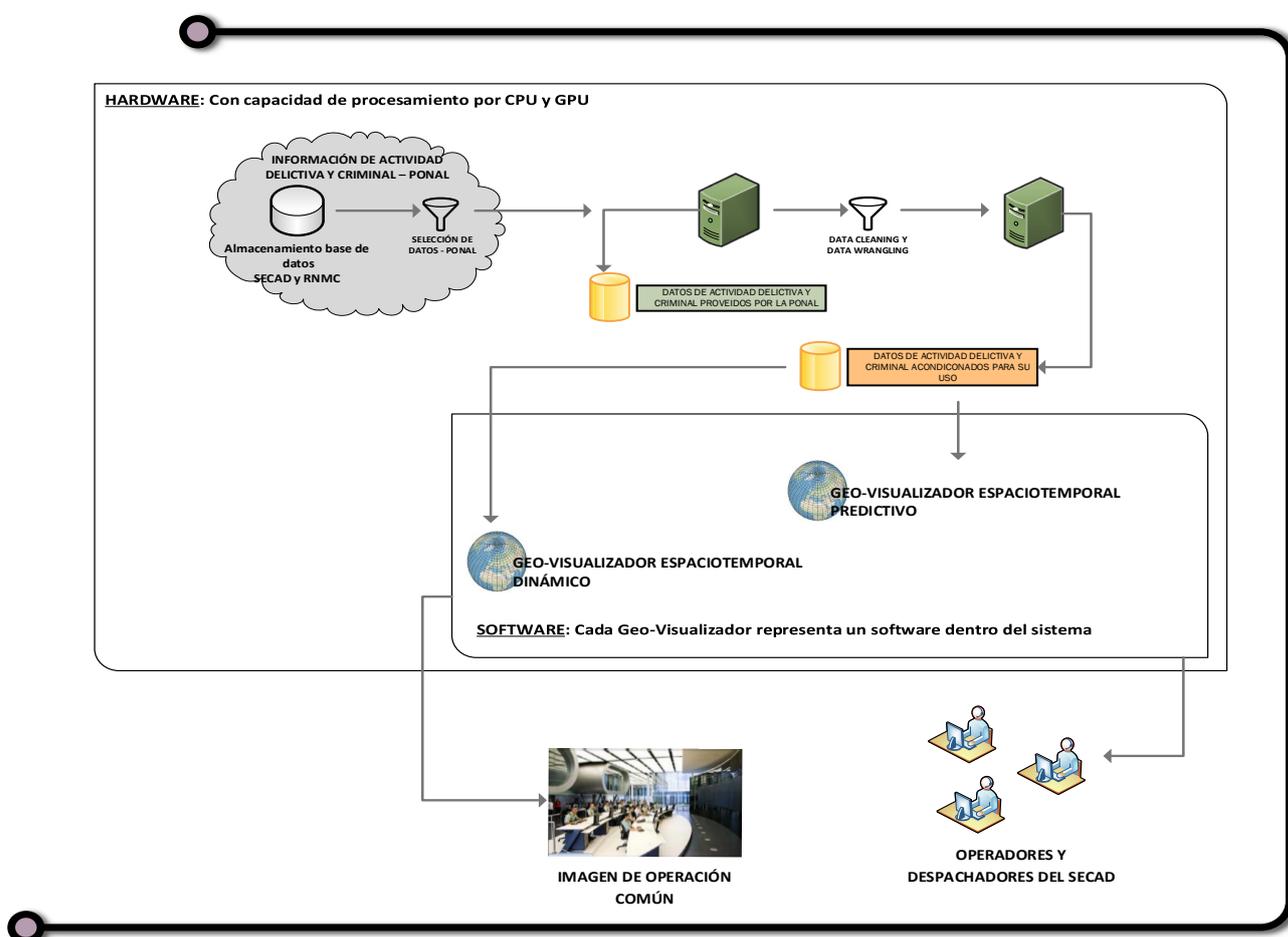


**Figura 32.** Resumen de la Arquitectura general completa del Sistema de Geo-visualización Espaciotemporal para datos de actividad delictiva y criminal.

## 6.1 Hardware y Software de la Arquitectura del Sistema de Geo-Visualización Espaciotemporal

Para el funcionamiento del Sistema de Geo-Visualización Espaciotemporal se hace necesaria una plataforma de hardware que tenga capacidad de procesamiento por GPU's (Unidades de Procesamiento gráfico); y CPU's (Unidades Centrales de Procesamiento), con la potencia adecuada y compatibilidad con CUDA® de nVidia®, debido a que se ejecutarán algoritmos de Deep Learning. Los recursos de

este hardware pueden estar en infraestructuras Cloud o en infraestructura local (servidores, PC, etc). La salida del sistema normalmente será mostrada en la imagen de operación común del C2S, pero también podría ser mostrada en los monitores de los operadores y despachadores del SECAD, o donde necesiten ser visualizadas, a través de las interfaces de red, Figura 33.



**Figura 33.** Arquitectura General del Sistema de Geo-Visualización Espaciotemporal. Hardware/Software.

Es importante mencionar que el software del Sistema de Geo-Visualización Espaciotemporal fue creado en un Computador portátil MSI GT62VR-7RE con Windows 10, Intel Core I7 7700HQ, 16 GB de RAM DDR4, GPU NVIDIA GeForce 1070 GTX en formato MXM con 2048 núcleos CUDA a 1442 MHz de frecuencia base y 8 GB de memoria VRAM DDR5.

## **6.2 Implementaciones de la Arquitectura del Sistema de Geo-Visualización Espaciotemporal para ser integrada al C2S de la PONAL**

Para la implementación del Sistema Geo-Visualización Espaciotemporal al C2S de la PONAL, se pueden proponer dos posibilidades: la primera: una implementación de procesamiento centralizado en un Centro de Procesamiento de Datos (CPD); la segunda: una implementación de procesamiento en una nube pública como por ejemplo [106], [107], [108], entre otras.

En el caso de las soluciones tipo Cloud (nube pública), aunque técnicamente podría ser una solución interesante, deben tenerse presentes dos importantes aspectos, el primero: el grado de seguridad nacional que requiere el manejo de la información de la Policía Nacional Colombiana, hace que estas soluciones no sean verdaderamente viables; y segundo: los proveedores de estas soluciones no se encuentran físicamente ubicados en Colombia, por lo que los más cercanos se encuentran ubicados en los Estados Unidos (Norteamérica); y esto podría acarrear

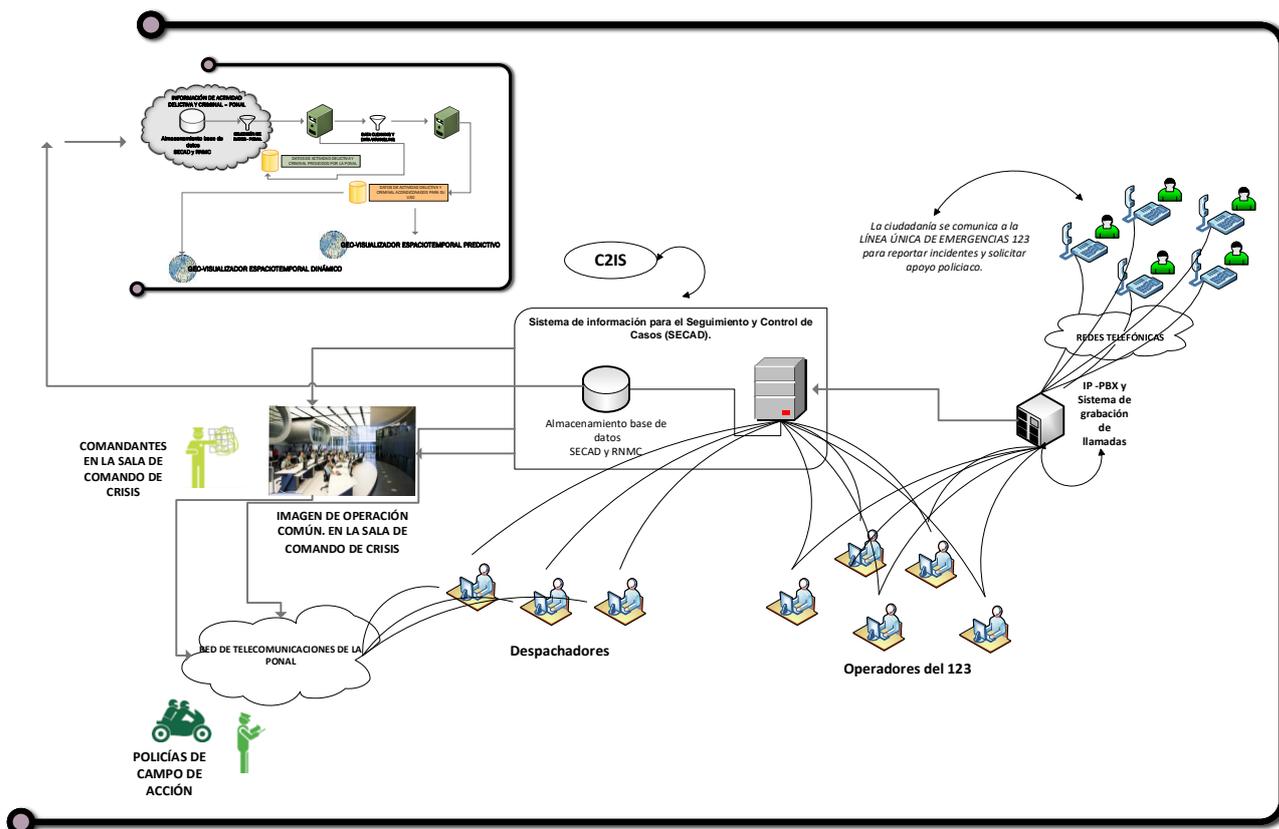
retardos considerables en la comunicación ya que esta tendría que recorrer miles de kilómetros de fibras ópticas internacionales y pasar por una gran cantidad de redes de Telecomunicaciones.

Lo anterior nos deja con la implementación de procesamiento centralizado en un Centro de Procesamiento de Datos (CPD), en este caso, aquello que debe considerarse es que los equipos de cómputo y las redes dispongan de las capacidades suficientes y necesarias para el procesamiento requerido, como, por ejemplo:

- ✓ El procesamiento en paralelo con el apoyo de GPU's (Unidades de Procesamiento Gráfico) con compatibilidad con CUDA® de nVidia®, debido a que se ejecutarán diferentes algoritmos incluidos algunos de Deep Learning.
- ✓ CPU's (Unidades Centrales de Procesamiento) con la potencia adecuada y debido a que se ejecutarán diferentes algoritmos incluidos algunos de Deep Learning, además se trabajará con procesamiento de bases de datos.
- ✓ La información que llega a los C2IS debe apoyarse en canales de comunicación críticos en tiempo real de grado militar entre las unidades de campo y el sistema de comando. Estos canales pueden ser inalámbricos, fijos o de cualquier tipo que se disponga, pero deben tener características específicas como por ejemplo tener una alta disponibilidad (por lo menos del del 99.9%), tener baja latencia y bajo jitter.

- ✓ Las conexiones, por canales tipo LAN (Local Área Network); y los equipos (switches, servidores, etc), entre los diferentes servidores de un C2IS en el CPD, deben tener especificaciones militares como fuentes redundantes, doble interfaz de red, etc.
- ✓ Preferiblemente deben tenerse las bases de datos cargadas en unidades de estado sólido SSD (Solid-State Drive) de alto rendimiento (alta velocidad de transmisión), como m.2 SSD con interfaz m.2 PCI Express, para poder hacer un mejor proceso de ETL (Extracción, Transformación y Carga) de datos.

Las arquitecturas y equipamientos específicos de los Sistema de Comando y Control de la PONAL son confidenciales, sin embargo, sí es posible describir sus generalidades, en la Figura 34, se muestra la arquitectura del Sistema de Geo-Visualización Espaciotemporal integrada a la arquitectura general del C2IS de la PONAL, propuesta en esta tesis doctoral.



**Figura 34.** Arquitectura del Sistema de Geo-Visualización Espaciotemporal, con la integración propuesta para el Sistema de Información de Comando y Control (C2IS), de la Policía Nacional Colombiana.

### ***Sistema de información para el Seguimiento y Control de Casos (SECAD):***

El SECAD es el sistema que gestiona los casos de policía reportados por la ciudadanía y por los policías en campo de acción. Los casos están codificados con códigos numéricos y pueden tratarse de delitos y crímenes como riñas, homicidios o intentos de homicidio, hurto, lesiones personales, disturbios por alto ruido en zonas no permitidas, entre otros. Este sistema se apoya en un SIG (Sistema de Información Geográfica) que permite geo-visualizar la información de los casos policíacos de forma georreferenciada (georreferenciación entregada a la PONAL por los operadores de Telecomunicaciones); además de la posición de las patrullas en

terreno y en tiempo real, la cual es captada por GPS y enviada al SECAD por medio de la red de Telecomunicaciones de la PONAL.

Los casos policíacos son almacenados por el SECAD con sus coordenadas geográficas y con la hora y fecha en la que suceden, así como el seguimiento a su gestión y solución. Los usuarios del SECAD son: los operadores del Subsistema de Atención a Llamadas de Emergencia del 123 que son las personas que atienden estas llamadas y crean los casos de gestión en el SECAD; los despachadores que son aquellos que asignan los agentes policíacos en campo de acción para dar solución a los casos; y los operadores del subsistema de videovigilancia, que son quienes controlan y revisan las cámaras de vigilancia que están extendidas por las ciudades, estos últimos operadores también pueden crear reportes en el SECAD si así lo requieren, remitiéndolos también a los despachadores. Finalmente, también los comandantes del C2S tienen acceso al SECAD.

Como ya se mencionó, las llamadas de emergencias del 123 se gestionan por medio del "Subsistema de Atención a Llamadas de Emergencia 123", estas llegan al C2S a través de troncales IP bajo el protocolo SIP, las llamadas se centralizan en una IP-PBX y de ahí son enviadas a los operadores del este subsistema. Integrado a la IP-PBX existe un sistema de grabación de llamadas activo para toda llamada.

## **7. CAPÍTULO VII: DISCUSIÓN DE LOS RESULTADOS**

Aunque los Sistema de Comando y Control de Seguridad Ciudadana de la Policía Nacional Colombiana ya contienen bastantes herramientas muy útiles para el desarrollo de su misionalidad, no tenían un sistema que ayudara a automatizar la geo-visualización espaciotemporal de los eventos delictivos y criminales, mucho menos a geo-visualizar el pronóstico de estos eventos.

La arquitectura del sistema de Geo-Visualización Espaciotemporal que en este tesis doctoral se propone, aporta a las capacidades operativas de la Policía, ya que mejora la Conciencia Situacional (Situational Awareness), de los comandante en el Centro de Comando y Control de Seguridad Ciudadana, permitiendo tomar decisiones tácticas y estratégicas con más información, además dado que los parámetros de funcionamiento de este sistema son ajustables según se requiera, este puede ser adaptado a cualquier otro C2S dentro de su C2IS.

En el caso particular del Geo-visualizador Espaciotemporal Dinámico, este permite analizar la afluencia delictiva en función de concentraciones, zonas, franjas horarias y fechas, con datos históricos o con datos en tiempo real, según sea necesario; y dado que constituye una herramienta de geo-visualización que actúa como un Plug-in, se puede adaptar a cualquier SIG a través de la API (Interfaz de Programación de Aplicaciones), específica para cada SIG (Sistema de Información Geográfico).

Este trabajo demuestra que es posible desarrollar un Sistema de Geo-visualización Espaciotemporal de actividades delictivas y criminales, el cual sea compatible con los objetivos misionales y estratégicos de una entidad encargada de asegurar la seguridad ciudadana como la Policía Nacional de Colombia. Sin embargo, se plantea la discusión con respecto a los desafíos técnicos de implementación pues para un despliegue a gran escala, se deben realizar varios desarrollos e integraciones con fuentes de Geo-Información tales como los distintos Sistemas de Información Geográfica (GIS), usados por las diversas fuerzas policiales del mundo, como por ejemplo ArcGIS.

En un despliegue a gran escala, también se deberán resolver desafíos técnicos como la necesidad de un Data Warehouse o un Data Lake, de alto rendimiento, que sea capaz de recibir y almacenar los Geo-Datos en tiempo real, o la capacidad de cómputo necesaria para el procesamiento y graficación de los mapas.

Por otra parte, en caso del geo-visualizador espaciotemporal predictivo que aquí se propone, esta también resulta ser una herramienta muy útil para en el desarrollo de arquitecturas para C2S dentro de sus C2IS, no solo para la PONAL sino también para cualquier otro sistema de seguridad que trabaje con el concepto de ciudad segura y ciudad inteligente, en la disuasión, prevención y control del delito, o el terrorismo, en cualquier lugar. Esto porque aparte de que la lógica de su funcionamiento es útil y aplicable a cualquier sistema con necesidades similares, también actúa como un Plug-in, adaptable a otros SIG a través de la API (Interfaz de Programación de Aplicaciones), específica para cada SIG.

Esta herramienta permite a comandantes, analistas o usuarios pertinentes, geo-visualizar espaciotemporalmente de forma constante los pronósticos de la afluencia delictiva en zonas de interés, en función de las fechas y rangos de tiempo deseados, además de por códigos de casos individuales o grupos de los mismos, lo cual se debe a que la metodología aquí planteada para lograr este objetivo, si bien realiza estos pronósticos en tiempo cercano al real, concede la posibilidad de crear un ambiente de pronóstico en tiempo real que es percibido por el usuario, donde dicho pronóstico se hace aún más fiable gracias al aprovechamiento de la mayor cantidad de los datos reales que van sucediendo y el reentrenamiento constante de los modelos predictivos.

Es importante remarcar entonces, que aunque para realizar estos pronósticos se usaron técnicas de inteligencia artificial enmarcadas particularmente dentro del campo de Deep Learning; y que en este trabajo se recopilieron todas aquellas técnicas posibles para el pronóstico de series temporales multivariantes tipo sparse con pronóstico en multiparelelo de más de un paso, en busca del mejor, o mejores modelos predictivos, para la solución de este problema; la investigación sobre modelización y pronóstico de series temporales multivariantes, es un campo de investigación abierto y con mucho camino aún por recorrer, por lo que lo importante es comprender que aquí no se trata de centrarse en la investigación sobre estas técnicas predictivas, sino de concentrarse en la metodología de funcionamiento que se requiere de la herramienta de geo-visualización espaciotemporal predictiva para C2S y buscar aquellos algoritmos, técnicas y

modelos que permitan realizar pronóstico fiables bajo dichos parámetros de funcionamiento.

Este sistema en general brinda la posibilidad de analizar las tendencias, desplazamiento y pronósticos de la actividad delictiva y criminal, más aún cuando esta herramienta presenta gran flexibilidad a la hora de definir sus parámetros, lo cual hasta el momento no era viable porque ninguna herramienta ofrecía estas capacidades dentro del C2S del PONAL.

Los resultados de este trabajo demuestran que es posible desarrollar un sistema de geo-visualización espaciotemporal predictiva de las actividades delictivas, criminales o cualquier otra como por ejemplo las terroristas, que esté alineado con la misión y los objetivos estratégicos de una entidad encargada de velar por la seguridad. Sin embargo, existe otros desafíos técnicos, para su implementación, que no pueden dejar de ser discutidos, por ejemplo, para caso que aquí atañe se necesita realizar pronósticos por áreas no demasiado extensas de acuerdo con el funcionamiento táctico y estratégico de la PONAL, pero en un despliegue a mayor escala, debe tenerse presente el comportamiento de los algoritmos de pronóstico para series temporales multivariantes tipo sparse, los cuales de acuerdo con su naturaleza funcionarán mejor o peor según el tamaño de la serie.

Por otra parte, sin duda otro desafío será la capacidad computacional necesaria para el procesamiento de bases de datos y el procesamiento de modelos predictivos, que pueden nacer de esta herramienta.

En Colombia, los despliegues a gran escala dependerán, en gran medida, de la asignación presupuestal del gobierno, pero la realización de este tipo de trabajos y sus resultados donde se demuestran la viabilidad y gran utilidad en la creación de herramientas como estas para mejorar el C2S del PONAL en sus Centros de Seguridad Ciudadana, abren la oportunidad de la asignación de recursos públicos destinados a estas implementaciones.

### **Productos de Investigación de esta Tesis Doctoral:**

#### **Artículos científicos:**

- ✓ A Novel Method of Spatiotemporal Dynamic Geo-Visualization of Criminal Data, Applied to Command and Control Centers for Public Safety  
Revista: ISPRS International Journal of Geo-Information  
ISSN 2220-9964, Vol 10, No. 3 Pag 160-177  
País: Suiza  
Editorial: MDPI, <https://doi.org/10.3390/ijgi9030160>  
Indexación y Clasificación:  
Q1 Scimago Journal & Country Rank (SJR)  
Q3 Journal Citation Report (JCR)
- ✓ A Novel Low Processing Time System for Criminal Activities Detection Applied to Command and Control Citizen Security Centers  
Revista: Information

ISSN: 2078-2489, Vol 10, No. 10 Pag 365-384

País: Suiza

Editorial: MDPI, DOI: <https://doi.org/10.3390/info10120365>

Indexación y Clasificación:

Q3 Scimago Journal & Country Rank (SJR)

Emerging Sources Citation Index - Web of Science (Clarivate Analytics)

- ✓ Reduced computational cost prototype for street theft detection based on depth decrement in Convolutional Neural Network. Application to Command and Control Information Systems (C2IS) in the National Police of Colombia

Revista: International Journal of Computational Intelligence Systems

ISSN: 1875-6883, Vol 12, Pag 123-130

País: Reino Unido

Editorial: Atlatis Press,

DOI: <https://doi.org/10.2991/ijcis.2018.25905186>

Indexación y Clasificación:

Q1 Scimago Journal & Country Rank (SJR)

Q2 Journal Citation Report (JCR)

### **Propiedad intelectual (COPYRIGHT):**

- ✓ GEOVISUALIZADOR DE DATOS DINÁMICO ESPACIOTEMPORAL.  
COPYRIGHT: REGISTRO DE SOPORTE LÓGICO - SOFTWARE

República de Colombia

Ministerio de Interior

Dirección Nacional de Derechos de Autor

Unidad Administrativa Especial

Oficina de Registro

Libro 13 Tomo 75 Partida 381

16 de septiembre de 2019

- ✓ TRADUCTOR DE UBICACIONES REVERSO, CON AGRUPACIONES SOBRE SISTEMA DE INFORMACIÓN GEOGRÁFICO (GIS).

COPYRIGHT: REGISTRO DE SOPORTE LÓGICO - SOFTWARE

República de Colombia

Ministerio de Interior

Dirección Nacional de Derechos de Autor

Unidad Administrativa Especial

Oficina de Registro

Libro 13 Tomo 75 Partida 382

16 de septiembre de 2019

- ✓ GEOVISUALIZADOR DE DATOS ESPACIOTEMPORAL PREDICTIVO, BASADO EN EL MODELO CNN-1D PARA SERIES TEMPORALES.

COPYRIGHT: REGISTRO DE SOPORTE LÓGICO - SOFTWARE

República de Colombia

Ministerio de Interior

Dirección Nacional de Derechos de Autor

Unidad Administrativa Especial

Oficina de Registro

Libro 13 Tomo 88 Partida 466

15 de febrero de 2022

- ✓ GEOVISUALIZADOR DE DATOS ESPACIOTEMPORAL PREDICTIVO, BASADO EN DIFERENTES MODELOS LSTM PARA SERIES TEMPORALES.

COPYRIGHT: REGISTRO DE SOPORTE LÓGICO - SOFTWARE

República de Colombia

Ministerio de Interior

Dirección Nacional de Derechos de Autor

Unidad Administrativa Especial

Oficina de Registro

Libro 13 Tomo 88 Partida 469

15 de febrero de 2022

- ✓ GEOVISUALIZADOR DE DATOS ESPACIOTEMPORAL PREDICTIVO, BASADO EN EL MODELO MLP (MULTILAYER PERCEPTRON) PARA SERIES TEMPORALES.

COPYRIGHT: REGISTRO DE SOPORTE LÓGICO - SOFTWARE

República de Colombia

Ministerio de Interior

Dirección Nacional de Derechos de Autor

Unidad Administrativa Especial

Oficina de Registro

Libro 13 Tomo 88 Partida 467

15 de febrero de 2022

- ✓ GEOVISUALIZADOR DE DATOS ESPACIOTEMPORAL PREDICTIVO, BASADO EN EL MODELO VAR PARA SERIES TEMPORALES.

COPYRIGHT: REGISTRO DE SOPORTE LÓGICO - SOFTWARE

República de Colombia

Ministerio de Interior

Dirección Nacional de Derechos de Autor

Unidad Administrativa Especial

Oficina de Registro

Libro 13 Tomo 88 Partida 468

15 de febrero de 2022

- ✓ DETECTOR DE ARMAS CORTAS DE FUEGO BASADO EN DEEP LEARNING.

COPYRIGHT: REGISTRO DE SOPORTE LÓGICO - SOFTWARE

República de Colombia

Ministerio de Interior

Dirección Nacional de Derechos de Autor

Unidad Administrativa Especial

Oficina de Registro

Libro 13 Tomo 69 Partida 33

13 de septiembre de 2018

✓ DEEPPOLNET: DEEP LEARNING PROTOTYPE FOR VIDEO CRIME EVENTS

DETECTION

COPYRIGHT: REGISTRO DE SOPORTE LÓGICO - SOFTWARE

República de Colombia

Ministerio de Interior

Dirección Nacional de Derechos de Autor

Unidad Administrativa Especial

Oficina de Registro

Libro 13 Tomo 69 Partida 32

13 e septiembre de 2018

## **8. CAPÍTULO VIII: CONCLUSIONES Y TRABAJO**

### **FUTURO**

#### **8.1 Conclusiones**

Los sistemas de comando y control son un componente que aporta a la construcción de ciudades inteligentes y por ende de ciudades seguras; además sus desarrollos impactan los compromisos internacionales de los Objetivos de Desarrollo Sostenible (ODS) de Naciones Unidas, principalmente en los objetivos: “11: Ciudades y comunidades sostenibles” y “16: Paz, justicia e instituciones fuertes”.

La visualización dinámica de datos, cualquiera que estos sean, suele ser más efectiva que la visualización estática de los mismos pues permite identificar patrones y tendencias. El Geo-visualizador Espaciotemporal Dinámico de datos convierte la información en conocimiento necesario para la toma de decisiones efectiva y oportuna de los comandantes estratégicos y tácticos de la PONAL, ya que según el análisis de los comandantes de Policía podría permitir identificar patrones de desplazamiento de la delincuencia y la criminalidad e incluso podría llegar a identificar las actuaciones de bandas criminales o terroristas específicas.

En este trabajo se realizó un estudio de varios métodos de geo-visualización de actividades criminales los cuales presentan varias ventajas y desventajas, sin embargo al aplicarlo a un Sistema de Comando y Control las ventajas del método

que aquí se presenta, se hacen necesarias ya que no solo este es muy novedoso sino que además los métodos existentes no poseen la combinación de características importantes y necesarias para los C2S, debido a que solo algunas de estas características podrán encontrarse en otros métodos pero de forma individual.

En el caso del Geo-visualizador Espaciotemporal Predictivo, dada la metodología de creación de la herramienta para C2S que aquí se presenta, donde por medio de agrupaciones geo-espaciales y temporales; y un método de pronóstico en multiparalelo de más de un paso hacia el futuro, donde han habido múltiples entradas; se consigue generar un ambiente de pronóstico muy cercano al tiempo real y con la fiabilidad del reentrenamiento del modelo y nueva generación de pronósticos haciendo uso de la mayor cantidad de datos reales que van sucediendo. Pero sobre todo con la sencillez necesaria para que el modelo pueda converger muy rápidamente aprovechando todas sus capacidades.

Esta herramienta, según el análisis de los comandantes de Policía, permite anticiparse para identificar patrones, tendencias, correlaciones entre códigos de casos y sobre todo el desplazamiento de la actividad delictiva, brindando información que los mandos estratégicos y tácticos del PONAL necesitan para tomar decisiones de manera precisa. Por tanto, mejora aspectos que son fundamentales para el cumplimiento de las misiones policiales contra el delito, como la proyección a futuro. Finalmente se concluye que, si esta herramienta dio resultados favorables

haciendo uso de datos tipo sparse, podría ser aún más efectiva en circunstancias donde los datos fueran menos dispersos.

El Sistema de Geo-visualización Espaciotemporal que se propone en este trabajo apoya a los Centros de Comando y Control de Seguridad Ciudadana de la PONAL, porque aporta agilidad, eficiencia y una mejor conciencia de la situación en la toma de decisiones de los oficiales de policía; mejorando otros aspectos que son estratégicos en el cumplimiento de las misiones policiales antidelito como la proyección futura.

Ambas herramientas del sistema de Geo-visualización Espaciotemporal, tienen la flexibilidad de que cada uno de sus parámetros puede ser escogido de acuerdo con la necesidad del usuario y son creadas con software libre, son adaptable a cualquier otro lugar geográfico y pueden ser usadas con datos reales de cualquier actividad mientras de adapte su formato, también se puede integrar con el software de cualquier otro C2S y de otro SIG, debido a que aquí fue desarrollado con software de código abierto.

Es importante tomar en cuenta que automatizar este tipo de procesos sin duda alguna ayuda a las entidades encargadas de la seguridad pública en su misión, pero un sistema automático siempre debe estar supervisado por humanos, por lo que debe ser un apoyo a la experiencia de aquellos que conocen el oficio para tomar decisiones estratégicas y tácticas.

## 8.2 Trabajo Futuro

Este trabajo abre la puerta a múltiples posibilidades de trabajo futuro, como, por ejemplo:

- ✓ El manejo de diferentes tipos de datos o grandes cantidades de los mismos, donde se requiera mayor procesamiento para llegar a obtener pronósticos fiables bajo las condiciones aquí planteadas para C2S.
- ✓ Sin duda alguna, los despliegues a gran escala, donde como ya se mencionó, las soluciones tipo Cloud no son muy viables actualmente, por lo que deben buscarse alternativas que permitan implementaciones de este tipo, pero con infraestructura local.
- ✓ La investigación sobre nuevas técnicas de pronóstico para Series Temporales Multivariantes con pronóstico en multiparalelo, particularmente si presentan altos porcentajes de dispersión o escasez, ya que este es un campo que aún tiene bastante camino por recorrer, ya sea que se hable de técnicas clásicas, de Machine Learning o de Deep Learning.

## REFERENCIAS

- [1] M. Lacinák and J. Ristvej, "Smart City, Safety and Security," *Procedia Eng.*, vol. 192, pp. 522–527, 2017.
- [2] D. S. Alberts and R. E. Hayes, *Understanding Command and Control (the Future of Command and Control)*. Washington, DC, USA, 2006.
- [3] M. Esteve, I. Perez-Llopis, L. E. Hernandez-Blanco, C. E. Palau, and F. Carvajal, "SIMACOP: Small Units Management C4ISR System," vol. 46022, pp. 1163–1166, 2007.
- [4] M. Esteve, I. Perez-Llopis, and C. E. Palau, "Friendly force tracking COTS solution," *IEEE Aerosp. Electron. Syst. Mag.*, vol. 28, no. 1, pp. 14–21, 2013.
- [5] M. Salcedo-Gonzalez, J. Suarez-Paez, M. Esteve, J. A. Gómez, and C. E. Palau, "A novel method of spatiotemporal dynamic geo-visualization of criminal data, applied to command and control centers for public safety," *ISPRS Int. J. Geo-Information*, vol. 9, no. 3, 2020.
- [6] J. Suarez-Paez *et al.*, "A novel low processing time system for criminal activities detection applied to command and control citizen security centers," *Inf.*, vol. 10, no. 12, 2019.
- [7] J. Suarez-Paez, M. Salcedo-Gonzalez, M. Esteve, J. A. Gómez, C. Palau, and I. Pérez-Llopis, "Reduced computational cost prototype for street theft detection based on depth decrement in Convolutional Neural Network.

- Application to Command and Control Information Systems (C2IS) in the National Police of Colombia," *Int. J. Comput. Intell. Syst.*, vol. 12, no. 1, p. 123, 2019.
- [8] E. Seyedsayamdost, "Sustainable development goals," *Essential Concepts of Global Environmental Governance*, 2020. [Online]. Available: <https://www.undp.org/content/undp/en/home/sustainable-development-goals.html>. [Accessed: 29-Feb-2020].
- [9] University of Maryland., "National Consortium for the study of terrorism and responses to terrorism." [Online]. Available: <https://www.start.umd.edu/>.
- [10] University of Maryland., "Global Terrorism Database." [Online]. Available: <https://www.start.umd.edu/gtd/>.
- [11] I. for E. and P. (IEP), "Global Terrorism Index 2020," 2020.
- [12] S. J. Linning, "Crime seasonality and the micro-spatial patterns of property crime in Vancouver, BC and Ottawa, ON," *J. Crim. Justice*, vol. 43, no. 6, pp. 544–555, 2015.
- [13] V. Spicer and J. Song, "The impact of transit growth on the perception of crime," *J. Environ. Psychol.*, vol. 54, pp. 151–159, 2017.
- [14] D. A. B. Louis-Philippe Beland, "Traffic and crime," *J. Public Econ. Elsevier*, vol. 160(C), no. January 2017, pp. 96–116, 2018.
- [15] P. E. Carrillo, A. Lopez-Luzuriaga, and A. S. Malik, "Pollution or crime: The effect of driving restrictions on criminal activity," *J. Public Econ.*, vol. 164,

- pp. 50–69, 2018.
- [16] T. Twinam, "Danger zone: Land use and the geography of neighborhood crime," *J. Urban Econ.*, vol. 100, pp. 104–119, 2017.
- [17] R. C. Sadler, J. Pizarro, B. Turchan, S. P. Gasteyer, and E. F. McGarrell, "Exploring the spatial-temporal relationships between a community greening program and neighborhood rates of crime," *Appl. Geogr.*, vol. 83, pp. 13–26, 2017.
- [18] A. Giménez-Santana, J. M. Caplan, and G. Drawve, "Risk Terrain Modeling and Socio-Economic Stratification: Identifying Risky Places for Violent Crime Victimization in Bogotá, Colombia," *Eur. J. Crim. Policy Res.*, vol. 24, no. 4, pp. 417–431, 2018.
- [19] S. Kim, S. Jeong, I. Woo, Y. Jang, R. Maciejewski, and D. S. Ebert, "Data Flow Analysis and Visualization for Spatiotemporal Statistical Data without Trajectory Information," *IEEE Trans. Vis. Comput. Graph.*, vol. 24, no. 3, pp. 1287–1300, Mar. 2018.
- [20] P. H. Yu and J. G. Lay, "Exploring non-stationarity of local mechanism of crime events with spatial-temporal weighted regression," *ICSDM 2011 - Proc. 2011 IEEE Int. Conf. Spat. Data Min. Geogr. Knowl. Serv.*, pp. 7–12, 2011.
- [21] O. Kounadi and M. Leitner, "Spatial Information Divergence: Using Global and Local Indices to Compare Geographical Masks Applied to Crime Data,"

- Trans. GIS*, vol. 19, no. 5, pp. 737–757, 2015.
- [22] S. Khalid *et al.*, “Network Constrained Spatio-Temporal Hotspot Mapping of Crimes in Faisalabad,” *Appl. Spat. Anal. Policy*, vol. 11, no. 3, pp. 599–622, 2018.
- [23] A. Lopez-Cuevas, M. A. Medina-Perez, R. Monroy, J. Ramirez Marquez, and L. A. Trejo, “FiToViz: A Visualisation Approach for Real-time Risk Situation Awareness,” *IEEE Trans. Affect. Comput.*, vol. 9, no. 3, pp. 372–382, 2017.
- [24] P. Phillips and I. Lee, “Mining co-distribution patterns for large crime datasets,” *Expert Syst. Appl.*, vol. 39, no. 14, pp. 11556–11563, 2012.
- [25] Y. Xue and D. E. Brown, “Spatial analysis with preference specification of latent decision makers for criminal event prediction,” *Decis. Support Syst.*, vol. 41, no. 3, pp. 560–573, 2006.
- [26] T. Nakaya and K. Yano, “Visualising crime clusters in a space-time cube: An exploratory data-analysis approach using space-time kernel density estimation and scan statistics,” *Trans. GIS*, vol. 14, no. 3, pp. 223–239, 2010.
- [27] N. B. Anuar and B. W. Yap, “Data Visualization of Violent Crime Hotspots in Malaysia,” in *Communications in Computer and Information Science*, vol. 937, M. W. Berry, A. Mohamed, and B. W. Yap, Eds. Singapore: Springer Singapore, 2019, pp. 350–363.
- [28] S. Bayoumi, S. Aldakhil, E. Alnakhilan, E. Al Taleb, and H. Alshabib, “A review of Crime Analysis and Visualization. Case study: Maryland State, USA,” *21st*

- Saudi Comput. Soc. Natl. Comput. Conf. NCC 2018*, pp. 1–6, 2018.
- [29] K. Sukhija, S. N. Singh, and J. Kumar, "Spatial visualization approach for detecting criminal hotspots: An analysis of total cognizable crimes in the state of Haryana," *RTEICT 2017 - 2nd IEEE Int. Conf. Recent Trends Electron. Inf. Commun. Technol. Proc.*, vol. 2018-Janua, pp. 1060–1066, 2018.
- [30] A. Malik, R. Maciejewski, S. Towers, S. Mccullough, and D. S. Ebert, "3B - Proactive Spatiotemporal Resource Allocation and Predictive Visual Analytics for Community Policing and Law Enforcement," vol. 20, no. 1, pp. 1863–1872, 2014.
- [31] S. M. Arietta, A. A. Efros, R. Ramamoorthi, and M. Agrawala, "City forensics: Using visual elements to predict non-visual city attributes," *IEEE Trans. Vis. Comput. Graph.*, vol. 20, no. 12, pp. 2624–2633, 2014.
- [32] Y. Hu, F. Wang, C. Guin, and H. Zhu, "A spatio-temporal kernel density estimation framework for predictive crime hotspot mapping and evaluation," *Appl. Geogr.*, vol. 99, no. January, pp. 89–97, 2018.
- [33] D. Yang, T. Heaney, A. Tonon, L. Wang, and P. Cudr, "CrimeTelescope : crime hotspot prediction based on urban and social media data fusion," pp. 1323–1347, 2017.
- [34] H. K. R. Toppireddy, B. Saini, and G. Mahajan, "Crime Prediction & Monitoring Framework Based on Spatial Analysis," *Procedia Comput. Sci.*, vol. 132, no. Iccids, pp. 696–705, 2018.

- [35] N. Devia and R. Weber, "Computers , Environment and Urban Systems Generating crime data using agent-based simulation," vol. 42, pp. 26–41, 2013.
- [36] P.-F. Kuo, D. Lord, and T. D. Walden, "Using geographical information systems to effectively organize police patrol routes by grouping hot spots of crash and crime data," *J. Transp. Geogr.*, vol. 2012, pp. 1–23, 2012.
- [37] M. Camacho-Collados and F. Liberatore, "A Decision Support System for predictive police patrolling," *Decis. Support Syst.*, vol. 75, pp. 25–37, 2015.
- [38] A. Morshed *et al.*, "VisCrime: A Crime Visualisation System for Crime Trajectory from Multi-dimensional Sources," in *Proceedings of the Twelfth ACM International Conference on Web Search and Data Mining - WSDM '19*, 2019, pp. 802–805.
- [39] A. Morshed *et al.*, "VisCrimePredict: A System for Crime Trajectory Prediction and Visualisation from Heterogeneous data sources," in *Proceedings of the 34th ACM/SIGAPP Symposium on Applied Computing - SAC '19*, 2019, pp. 1099–1106.
- [40] T. Kagawa, S. Saiki, and M. Nakamura, "Visualizing and analyzing street crimes using personalized security information service PRISM," pp. 208–214, 2018.
- [41] T. Kagawa, S. Saiki, and M. Nakamura, "Analyzing street crimes in Kobe city using PRISM," *Int. J. Web Inf. Syst.*, 2018.

- [42] A. Rasheed and U. K. Wiil, "A Tool for Analysis and Visualization of Criminal Networks," *Proc. - UKSim-AMSS 17th Int. Conf. Comput. Model. Simulation, UKSim 2015*, pp. 97–102, 2016.
- [43] A. Rasheed and U. K. Wiil, "PEVNET: A framework for visualization of criminal networks," *ASONAM 2014 - Proc. 2014 IEEE/ACM Int. Conf. Adv. Soc. Networks Anal. Min.*, no. Asonam, pp. 876–881, 2014.
- [44] F. Nazir Rani, M. Awais, M. Yahya Saeed, and S. Nazir, "Criminal Network Visualization and Analysis using PEVNET," *IJCSNS Int. J. Comput. Sci. Netw. Secur.*, vol. 18, no. 10, p. 78, 2018.
- [45] N. Qazi and B. L. W. Wong, "Behavioural & tempo-spatial knowledge graph for crime matching through graph theory," *Proc. - 2017 Eur. Intell. Secur. Informatics Conf. EISIC 2017*, vol. 2017-Janua, pp. 143–146, 2017.
- [46] W. Jentner, D. Sacha, F. Stoffel, G. Ellis, L. Zhang, and D. A. Keim, "Making machine intelligence less scary for criminal analysts: reflections on designing a visual comparative case analysis tool," *Vis. Comput.*, vol. 34, no. 9, pp. 1225–1241, 2018.
- [47] N. P. Estrat, "Policía Nacional Colombiana, Plan Estratégico Institucional 2019-2022." .
- [48] J. R. Santillan, M. Makinano-Santillan, A. M. Amora, E. M. O. Morales, L. C. Cutamora, and L. C. S. Aube, "Near-real time simulation and geo-visualization of flooding in the Philippines' deepest lake," *Int. Geosci. Remote*

- Sens. Symp.*, vol. 2016-Novem, pp. 7573–7576, 2016.
- [49] W. Hardyns and A. Rummens, “Predictive Policing as a New Tool for Law Enforcement? Recent Developments and Challenges,” *Eur. J. Crim. Policy Res.*, vol. 24, no. 3, pp. 201–218, 2018.
- [50] S. Shiode and N. Shiode, “Microscale prediction of near-future crime concentrations with street-level geosurveillance,” *Geogr. Anal.*, vol. 46, no. 4, pp. 435–455, 2014.
- [51] T. Runadi and Y. Widyaningsih, “Application of hotspot detection using spatial scan statistic: Study of criminality in Indonesia,” *AIP Conf. Proc.*, vol. 1827, no. March, 2017.
- [52] G. Rosser, T. Davies, K. J. Bowers, S. D. Johnson, and T. Cheng, “Predictive Crime Mapping: Arbitrary Grids or Street Networks?,” *J. Quant. Criminol.*, vol. 33, no. 3, pp. 569–594, 2017.
- [53] D. Wang, “Contrast Pattern Based Methods for Visualizing and Predicting Spatiotemporal Events,” *Proc. - 15th IEEE Int. Conf. Data Min. Work. ICDMW 2015*, pp. 1560–1567, 2016.
- [54] Y. L. Lin, T. Y. Chen, and L. C. Yu, “Using Machine Learning to Assist Crime Prevention,” *Proc. - 2017 6th IIAI Int. Congr. Adv. Appl. Informatics, IIAI-AAI 2017*, pp. 1029–1030, 2017.
- [55] H. W. Kang and H. B. Kang, “Prediction of crime occurrence from multimodal data using deep learning,” *PLoS One*, vol. 12, no. 4, pp. 1–19, 2017.

- [56] B. Wang, P. Yin, A. L. Bertozzi, P. J. Brantingham, S. J. Osher, and J. Xin, "Deep Learning for Real-Time Crime Forecasting and Its Ternarization," *Chinese Ann. Math. Ser. B*, vol. 40, no. 6, pp. 949–966, 2019.
- [57] C. Catlett, E. Cesario, D. Talia, and A. Vinci, "Spatio-temporal crime predictions in smart cities: A data-driven approach and experiments," *Pervasive Mob. Comput.*, vol. 53, pp. 62–74, 2019.
- [58] S. Flaxman, M. Chirico, P. A. U. Pereira, and C. Loeffler, "Scalable high-resolution forecasting of sparse spatiotemporal events with kernel methods: A winning solution to the NIJ 'real-time crime forecasting challenge,'" *Ann. Appl. Stat.*, vol. 13, no. 4, pp. 2564–2585, 2019.
- [59] M. J. C. Baculo, C. S. Marzan, R. De Dios Bulos, and C. Ruiz, "Geospatial-temporal analysis and classification of criminal data in Manila," *2017 2nd IEEE Int. Conf. Comput. Intell. Appl. ICCIA 2017*, vol. 2017-Janua, pp. 6–11, 2017.
- [60] W. H. Rummens, Anneleen, "The effect of spatiotemporal resolution on predictive policing model performance," *Int. J. Forecast.*, vol. 37, pp. 125–133, 2021.
- [61] A. Rummens and W. Hardyns, "Comparison of near-Repeat, Machine Learning and Risk Terrain Modeling for Making Spatiotemporal Predictions of Crime," *Appl. Spat. Anal. Policy*, vol. 13, no. 4, pp. 1035–1053, 2020.
- [62] D. Kim, S. Jung, and Y. Jeong, "Theft prediction model based on spatial clustering to reflect spatial characteristics of adjacent lands," *Sustain.*, vol.

- 13, no. 14, 2021.
- [63] Z. Tianyi, R. Yibing, and W. Dong, "Application of Grid Management in Spatio-temporal Prediction of Crime," *Proc. 33rd Chinese Control Decis. Conf. CCDC 2021*, pp. 2745–2749, 2021.
- [64] Y. Qian, L. Pan, P. Wu, and Z. Xia, "GeST: A grid embedding based spatio-temporal correlation model for crime prediction," *Proc. - 2020 IEEE 5th Int. Conf. Data Sci. Cyberspace, DSC 2020*, pp. 1–7, 2020.
- [65] J. Sun *et al.*, "CrimeForecaster: Crime Prediction by Exploiting the Geographical Neighborhoods' Spatiotemporal Dependencies," *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 12461 LNAI, pp. 52–67, 2021.
- [66] Y. L. Lin, M. F. Yen, and L. C. Yu, "Grid-based crime prediction using geographical features," *ISPRS Int. J. Geo-Information*, vol. 7, no. 8, 2018.
- [67] L. Duan, X. Ye, T. Hu, and X. Zhu, "Prediction of suspect location based on spatiotemporal semantics," *ISPRS Int. J. Geo-Information*, vol. 6, no. 7, 2017.
- [68] M. Adepeju, G. Rosser, and T. Cheng, "Novel evaluation metrics for sparse spatio-temporal point process hotspot predictions - a crime case study," *Int. J. Geogr. Inf. Sci.*, vol. 30, no. 11, pp. 2133–2154, 2016.
- [69] Y. Zhang and T. Cheng, "Graph deep learning model for network-based predictive hotspot mapping of sparse spatio-temporal events," *Comput. Environ. Urban Syst.*, vol. 79, 2020.

- [70] M. Jendryke and S. C. McClure, "Spatial prediction of sparse events using a discrete global grid system; a case study of hate crimes in the USA," *Int. J. Digit. Earth*, vol. 14, no. 6, pp. 789–805, 2021.
- [71] V. O. Andersson, M. A. F. Birck, and R. M. Araujo, "Investigating Crime Rate Prediction Using Street-Level Images and Siamese Convolutional Neural Networks," *Commun. Comput. Inf. Sci.*, vol. 720, pp. 81–93, 2017.
- [72] N. Esquivel, B. Peralta, and O. Nicolis, "Crime Level Prediction using Stacked Maps with Deep Convolutional Autoencoder," *IEEE Chil. Conf. Electr. Electron. Eng. Inf. Commun. Technol. CHILECON 2019*, 2019.
- [73] M. Muthamizharasan and R. Ponnusamy, "Forecasting Crime Event Rate with a CNN-LSTM Model," *Lect. Notes Data Eng. Commun. Technol.*, vol. 96, pp. 461–470, 2022.
- [74] R. Yadav and S. Kumari Sheoran, "Crime Prediction Using Auto Regression Techniques for Time Series Data," *3rd Int. Conf. Work. Recent Adv. Innov. Eng. ICRAIE 2018*, vol. 2018, no. November, pp. 22–25, 2018.
- [75] R. Yadav and S. Kumari Sheoran, "Modified ARIMA Model for Improving Certainty in Spatio-Temporal Crime Event Prediction," *3rd Int. Conf. Work. Recent Adv. Innov. Eng. ICRAIE 2018*, vol. 2018, no. November, pp. 22–25, 2018.
- [76] M. Liu and T. Lu, "A Hybrid Model of Crime Prediction," *J. Phys. Conf. Ser.*, vol. 1168, no. 3, 2019.

- [77] C. S. Marzan, R. De Dios Bulos, M. J. C. Baculo, and C. Ruiz, "Time series analysis and crime pattern forecasting of city crime data," *ACM Int. Conf. Proceeding Ser.*, vol. Part F1320, pp. 113–118, 2017.
- [78] K. Wang, P. Zhu, H. Zhu, P. Cui, and Z. Zhang, "An interweaved time series locally connected recurrent neural network model on crime forecasting BT - 24th International Conference on Neural Information Processing, ICONIP 2017, November 14, 2017 - November 18, 2017," vol. 10638 LNCS, pp. 466–474, 2017.
- [79] J. Chung and H. Kim, "Crime Risk Maps: A Multivariate Spatial Analysis of Crime Data," *Geogr. Anal.*, vol. 51, no. 4, pp. 475–499, 2019.
- [80] D. Wang, Y. Zheng, H. Lian, and G. Li, "High-Dimensional Vector Autoregressive Time Series Modeling via Tensor Decomposition," *J. Am. Stat. Assoc.*, 2021.
- [81] C. Hou, J. Wu, B. Cao, and J. Fan, "A deep-learning prediction model for imbalanced time series data forecasting," *Big Data Min. Anal.*, vol. 4, no. 4, pp. 266–278, 2021.
- [82] J. Yin *et al.*, "Experimental study of multivariate time series forecasting models," *Int. Conf. Inf. Knowl. Manag. Proc.*, pp. 2833–2839, 2019.
- [83] F. Shen, J. Liu, and K. Wu, "Multivariate Time Series Forecasting Based on Elastic Net and High-Order Fuzzy Cognitive Maps: A Case Study on Human Action Prediction through EEG Signals," *IEEE Trans. Fuzzy Syst.*, vol. 29, no.

- 8, pp. 2336–2348, 2021.
- [84] S. Chan, I. Oktavianti, and V. Puspita, "A Deep Learning CNN and AI-Tuned SVM for Electricity Consumption Forecasting: Multivariate Time Series Data," *2019 IEEE 10th Annu. Inf. Technol. Electron. Mob. Commun. Conf. IEMCON 2019*, pp. 488–494, 2019.
- [85] N. Vakitbilir, A. Hilal, and C. Direkoğlu, "Hybrid deep learning models for multivariate forecasting of global horizontal irradiation," *Neural Comput. Appl.*, vol. 0, pp. 8005–8026, 2022.
- [86] L. Zhang, A. Gorovits, W. Zhang, and P. Bogdanov, "Learning periods from incomplete multivariate time series," *Proc. - IEEE Int. Conf. Data Mining, ICDM*, vol. 2020-Novem, no. Icdm, pp. 1394–1399, 2020.
- [87] S. A. A. Ojeda, G. A. Solano, and E. C. Peramo, "Multivariate Time Series Imaging for Short-Term Precipitation Forecasting Using Convolutional Neural Networks," *2020 Int. Conf. Artif. Intell. Inf. Commun. ICAIIC 2020*, pp. 33–38, 2020.
- [88] C. H. Menacho Chiok, "Comparación de los métodos de series de tiempo y redes neuronales," *An. Científicos*, vol. 75, no. 2, p. 245, 2014.
- [89] P. R. Boppuru and K. Ramesha, "Spatio-temporal crime analysis using KDE and ARIMA models in the Indian context," *Int. J. Digit. Crime Forensics*, vol. 12, no. 4, pp. 1–19, 2020.
- [90] S. Makridakis, E. Spiliotis, and V. Assimakopoulos, "Statistical and Machine

- Learning forecasting methods: Concerns and ways forward," *PLoS One*, vol. 13, no. 3, 2018.
- [91] R. Sakrepatna Srinivasamurthy, *Understanding 1D Convolutional Neural Networks Using Multiclass Time-Varying Signals*. 2018.
- [92] R. Ramakrishnan, *Robust Multivariate and Nonlinear Time Series Models*, vol. 4688. 2010.
- [93] J. L. Gallego Gómez, *Análisis de series temporales*, vol. 1, no. Análisis temporal. 2008.
- [94] J. Jiang and S. Yu, "Modeling Nonlinear Vector Time Series Data," in *Time Series Analysis and Applications*, 2018.
- [95] J. K. S. Eraso, *Relación entre los modelos de Series de Tiempo Univariadas con los modelos de Series Multivariadas*. 2016.
- [96] S. Suárez, "Técnicas estadísticas multivariantes de series temporales para la validación de un sistema reconstructor basado en redes neuronales.," 2016.
- [97] R. A. Davis, P. Zang, and T. Zheng, "Sparse Vector Autoregressive Modeling," *J. Comput. Graph. Stat.*, vol. 25, no. 4, pp. 1077–1096, 2016.
- [98] S. Kiranyaz, O. Avci, O. Abdeljaber, T. Ince, M. Gabbouj, and D. J. Inman, "1D convolutional neural networks and applications: A survey," *Mech. Syst. Signal Process.*, vol. 151, pp. 1–20, 2021.
- [99] M. Schubert and T. Schanze, "Estimation of Sparse VAR Models with Artificial Neural Networks for the Analysis of Biosignals," *Proc. Annu. Int. Conf. IEEE*

- Eng. Med. Biol. Soc. EMBS*, vol. 2, no. 4, pp. 4623–4627, 2019.
- [100] E. Carrizosa, A. V. Olivares-Nadal, and P. Ramírez-Cobo, “A sparsity-controlled vector autoregressive model,” *Biostatistics*, vol. 18, no. 2, pp. 244–259, 2017.
- [101] I. Wilms, S. Basu, J. Bien, and D. S. Matteson, “Sparse Identification and Estimation of Large-Scale Vector AutoRegressive Moving Averages,” *J. Am. Stat. Assoc.*, pp. 1–57, 2021.
- [102] B. Jason, “How to Grid Search Deep Learning Models for Time Series Forecasting.” .
- [103] W. B. Nicholson, I. Wilms, J. Bien, and D. S. Matteson, “High dimensional forecasting via interpretable vector autoregression,” *Journal of Machine Learning Research*, vol. 21. 2020.
- [104] I. Matrix and G. Michailidis, “Package ‘sparsevar .’” 2019.
- [105] “OpenStreetMap.” [Online]. Available: <http://www.openstreetmap.org>.
- [106] “NVIDIA GPU CLOUD.” [Online]. Available: <https://www.nvidia.com/en-us/data-center/gpu-cloud-computing/>.
- [107] “Google Cloud Platfotm.” [Online]. Available: [https://cloud.google.com/?utm\\_source=google&utm\\_medium=cpc&utm\\_campaign=latam-CO-all-es-dr-BKWS-all-all-trial-p-dr-1011454-LUAC0014216&utm\\_content=text-ad-none-any-DEV\\_c-CRE\\_512364917207-ADGP\\_Hybrid %7C BKWS - PHR %7C Txt ~ GCP\\_General-](https://cloud.google.com/?utm_source=google&utm_medium=cpc&utm_campaign=latam-CO-all-es-dr-BKWS-all-all-trial-p-dr-1011454-LUAC0014216&utm_content=text-ad-none-any-DEV_c-CRE_512364917207-ADGP_Hybrid %7C BKWS - PHR %7C Txt ~ GCP_General-)

KWID\_43700062788251.

[108] "Amazon Web Services." [Online]. Available: <https://aws.amazon.com/es/>.