



Modelos SARIMA para la predicción de lesionados en siniestros de tránsito en Uruguay

Lic. Estadística: Magela Negro Brum
Año 2025

"All models are wrong, but some are useful"
George E.P. Box (1976)



Contenido

1. Resumen Ejecutivo	3
2. Introducción	3
3. Descripción de datos utilizados	4
4. Metodología: SARIMA (p, d, q)(P, D, Q)	5
4.1. Criterios para la Selección del Modelo Óptimo	7
4.1.1. Validación de los Supuestos del modelo:	7
4.1.2. Criterios de Selección del Modelo	8
4.1.3. Criterios para evaluación en predicción	10
5. Resultados obtenidos	11
5.1. Análisis exploratorio	11
5.2. Selección del modelo	13
5.3. Performance del modelo en Predicción	15
5.4. Predicción fuera de la muestra	16
6. Conclusiones	19
7. Recomendaciones.....	20
8. Bibliografía.....	21
9. ANEXO.....	22
9.1. Performance del modelo en predicción dentro de la muestra	22
9.1.1. Predicción a 12 pasos. Periodo: enero-diciembre 2024.....	22
9.1.2. Predicción a 9 pasos. Periodo: abril-diciembre 2024.....	23
9.1.3. Predicción a 6 pasos. Periodo: julio-diciembre 2024	24
9.1.4. Predicción a 4 pasos. Periodo: septiembre-diciembre 2024.....	25
9.1.5. Error cuadrático medio.....	27



1. Resumen Ejecutivo

El presente estudio implementa modelos SARIMA (Modelos Autorregresivos Integrados de Media Móvil Estacional) para la predicción mensual de lesionados en siniestros de tránsito en Uruguay. Se trata de un enfoque estadístico poco explorado en el país para esta temática, aplicable para la prevención y gestión de la siniestralidad vial.

Se construyen y comparan modelos a partir de datos históricos del período 2016–2024, utilizando modelos SARIMA, que permiten modelar series temporales con patrones estacionales y no estacionarios de forma simultánea. El modelo seleccionado logra una predicción con márgenes de error aceptables y proporciona una herramienta útil para políticas públicas, planificación y asignación de recursos.

La investigación aporta una base metodológica replicable y plantea futuras extensiones hacia modelos multivariantes o aplicaciones de esta misma técnica para cada tipo de lesión.

El trabajo se realiza en el programa R.

2. Introducción

La siniestralidad vial es un problema de salud pública con impacto no solo a nivel humano, sino que también social y económico. La Organización Mundial de la Salud (OMS) clasifica los siniestros de tránsito entre las diez principales causas de mortalidad a nivel global, con una tendencia ascendente: en 2004 ocupaban el noveno lugar y se proyecta que en 2030 sean la quinta causa de muerte. Sin embargo, más allá de la mortalidad, las lesiones derivadas de los siniestros viales representan una carga significativa para el sistema de salud y la economía de los países.

El estudio de Carga Global de Siniestros de Tránsito en Uruguay, de la Unidad Nacional de Seguridad Vial, revela que los siniestros de tránsito siguen siendo una de las principales causas de pérdida de años de vida saludable debido a lesiones y discapacidades. Si bien los datos muestran una reducción en comparación con 2015, la población de entre 15 y 34 años continúa siendo la más afectada, lo que implica consecuencias económicas y sociales debido a la afectación de la población económicamente activa.

El Banco Interamericano de Desarrollo (BID) estima que la siniestralidad vial tiene un costo económico del 1 % al 3 % del PIB anual en los países de América Latina. En el caso de Uruguay,



los esfuerzos en seguridad vial han permitido una reducción en la tasa de mortalidad en siniestros de tránsito, pasando de 14,6 a 12,1 por cada 100.000 habitantes entre 2015 y 2024. Sin embargo, la evolución de la tasa de lesionados ha mostrado fluctuaciones, lo que evidencia la necesidad de un análisis prospectivo que permita prever escenarios futuros y orientar estrategias de prevención.

Este estudio tiene como objetivo analizar la evolución de los lesionados en siniestros de tránsito en Uruguay y proyectar su comportamiento en los próximos años. A través del uso de modelos estadísticos y el análisis de tendencias, se busca proporcionar información para la formulación de políticas públicas que contribuyan a la reducción de la siniestralidad y sus impactos.

3. Descripción de datos utilizados

La Unidad Nacional de Seguridad Vial, como organismo dependiente de la Presidencia de la República, es la entidad oficial encargada de la recopilación, publicación y divulgación de información sobre siniestros de tránsito en el país.

Los datos utilizados son brindados por UNASEV, en el marco de su convenio de interconexión de datos con el Ministerio del Interior (MI), a través del Sistema de Información Nacional de Tránsito (SINATRAN).

Para el presente estudio se utilizan datos que abarcan el período comprendido entre enero de 2016 y diciembre de 2024, con una periodicidad mensual, lo que da un total de 108 observaciones.

Dado que los datos corresponden a una serie temporal, la metodología de análisis de series de tiempo se presenta como una de las herramientas adecuadas para identificar patrones y realizar proyecciones futuras. En el siguiente capítulo, se detalla el enfoque metodológico adoptado.

El análisis fue implementado utilizando el software R y paquetes específicos de series temporales.



4. Metodología: SARIMA (p, d, q)(P, D, Q)

El análisis de series temporales tiene como objetivo realizar inferencias sobre un proceso estocástico desconocido a partir de los datos históricos de una variable. Para ello, una de las técnicas estadísticas más utilizadas es la propuesta por Box y Jenkins (1973), quienes desarrollaron una metodología para la identificación, estimación y validación de modelos de series de tiempo. En este marco, introdujeron la familia de modelos ARIMA (Autoregressive Integrated Moving Average), que permite modelar la dependencia temporal en una serie de datos. Cuando la serie analizada presenta una estructura estacional, el modelo se amplía a un modelo SARIMA (Seasonal ARIMA), que incorpora componentes adicionales para capturar patrones repetitivos en el tiempo. La ecuación general de un modelo SARIMA se expresa como:

$$\Phi_p(L^s)\phi_p(L)\nabla_s^D\nabla^d Y_t = \theta_q(L)\Theta_Q(L^s)\varepsilon_t$$

En esta formulación, la dependencia en la serie se modela en dos niveles:

- **Componente regular**, que describe la relación entre observaciones consecutivas.
- **Componente estacional**, que captura la relación entre observaciones separadas por s períodos.

Supuestos del modelo:

Un aspecto fundamental en la aplicación de modelos SARIMA es la estacionariedad de la serie de datos. Una serie es estrictamente estacionaria si la distribución conjunta de sus valores no cambia a lo largo del tiempo, es decir, si las propiedades estadísticas del proceso, incluyendo su media, varianza y distribución de probabilidad, permanecen invariantes en cualquier instante. En particular, esto implica que la autocorrelación entre observaciones dependa únicamente del intervalo de tiempo que las separa (k) y no del momento en que se midan. Para que un proceso estocástico sea estrictamente estacionario, los residuos del modelo también deben seguir una distribución normal con media cero y varianza constante.

Si la serie no cumple con estas condiciones, es necesario aplicar transformaciones, como la diferenciación o la estabilización de varianza, para garantizar la estacionariedad antes de ajustar un modelo SARIMA.



Los supuestos antes mencionados se describen como:

- **Media constante en el tiempo:**

$$\mu_t = E(X_t)$$

- **Varianza constante en el tiempo (homocedasticidad):**

$$\sigma_t^2 = \text{Var}(X_t)$$

- **La covarianza y autocorrelación dependen únicamente del intervalo que separa las variables.** Es decir, para dos variables (X_t) y (X_{t+k}) en el proceso, la covarianza y la autocorrelación solo dependen de k :

$$\text{Cov}(X_t, X_{t+k}) = \text{Cov}(X_{t+j}, X_{t+j+k}) = \gamma_k$$

$$\rho_k = \frac{\gamma_k}{\gamma_0}$$

Donde $\gamma_0 = \sigma^2$ es la varianza de la serie.

- **Distribución de los residuos:** Los residuos deben ser independientes e idénticamente distribuidos (i.i.d) con una distribución Normal(0, σ^2).



4.1. Criterios para la Selección del Modelo Óptimo

Para la selección del modelo final, se debe considerar el cumplimiento de los supuestos del modelo; y también debe tomarse en cuenta criterios estadísticos adicionales para asegurar que el modelo elegido sea el más apropiado.

4.1.1. Validación de los Supuestos del modelo:

- **Estacionariedad: Test ADF (Augmented Dickey-Fuller) para raíz unitaria:** utilizado para verificar si la serie temporal sigue un proceso estocástico estacionario. Si la serie contiene una raíz unitaria, significa que las observaciones en el tiempo tienen una tendencia de largo plazo y no regresan a una media constante.

La prueba de hipótesis planteada es:

- H_0 : La serie tiene una raíz unitaria (no es estacionaria)
- H_1 : La serie no tiene raíz unitaria (es estacionaria)

- **Normalidad de los residuos: Test de Shapiro-Wilk para normalidad:** utilizado para comprobar si la serie de datos o los residuos del modelo siguen una distribución normal.

La prueba de hipótesis planteada es:

- H_0 : Los residuos siguen una distribución normal
- H_1 : Los residuos no siguen una distribución normal

- **Autocorrelación de los Residuos: Test de Ljung-Box para autocorrelación:** utilizado para evaluar si los residuos del modelo presentan autocorrelación, en caso positivo indica que el modelo no ha capturado adecuadamente la estructura temporal de la serie. Esta prueba analiza si los residuos son aleatorios o si, por el contrario, mantienen una dependencia temporal no explicada por el modelo.

La prueba de hipótesis planteada es:

- H_0 : No existe autocorrelación en los residuos (los residuos son aleatorios y no siguen un patrón).
- H_1 : Existen autocorrelaciones en los residuos (los residuos muestran dependencia temporal).

- **Homocedasticidad de los Residuos: Test de ARCH (Autoregressive Conditional Heteroskedasticity):** utilizado para corroborar si la varianza de los residuos es constante a lo largo



del tiempo (homoscedasticidad). Si los residuos presentan heterocedasticidad condicional (variabilidad no constante), esto puede afectar la precisión de las estimaciones e indicar la necesidad de otro tipo de modelado.

La prueba de hipótesis planteada es:

- H_0 : Los residuos del modelo son homoscedásticos (tienen varianza constante).
- H_1 : Los residuos del modelo son heteroscedásticos (presentan varianza no constante).

4.1.2. Criterios de Selección del Modelo

Criterio de Información de Akaike (AIC): utilizado para seleccionar el modelo, ofreciendo el mejor equilibrio entre el ajuste y la complejidad del modelo.

Se expresa como:

$$AIC = 2k - 2 \ln(L)$$

Donde:

- k , es el número de parámetros del modelo
- L , es la verosimilitud del modelo.



Criterio de Información de Información Bayesiano (BIC): al igual que el AIC, es utilizado para la selección del modelo, aunque aplica una penalización mayor al número de parámetros. Tiende a favorecer modelos simples.

Se expresa como:

$$BIC = \ln(n) k - 2 \ln(L)$$

Donde:

- n, es el número de observaciones,
- k, es el número de parámetros del modelo,
- L, es la verosimilitud del modelo.

Ambos criterios ofrecen un enfoque para comparar modelos con diferentes niveles de complejidad, siendo el AIC más adecuado para modelos donde se valora un buen ajuste, y el BIC para situaciones donde se prefiere un modelo más parsimonioso (menos cantidad de parámetros).



4.1.3. Criterios para evaluación en predicción

Error Absoluto: Diferencia entre valor observado y el valor de predicción.

$$E_i = y_i - \hat{y}_i$$

Donde:

(y_i) = Valor observado, (\hat{y}_i) = Valor predicho

Error Relativo: Error como porcentaje del valor de predicción.

$$E_{rel,i} = \left(\frac{y_i - \hat{y}_i}{\hat{y}_i} \right) \times 100$$

Error Cuadrático Medio (ECM): Promedia los errores al cuadrado, penalizando más los errores grandes.

$$ECM = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

Intervalos de Confianza al 95%: Evalúa si los intervalos capturan la incertidumbre real. En teoría, se esperaría que el 95% de los datos reales caigan en dicho intervalo.

$$y_{t+h} \pm z_{\alpha/2} \cdot \sqrt{\text{Var}(\hat{y}_{t+h})}$$

Donde:

\hat{y}_{t+h} = valor de predicción en el paso h

$z_{\alpha/2}$ = valor crítico de la distribución normal estándar para el nivel de confianza deseado (por ejemplo, 1.96 para un 95%)

$\text{Var}(\hat{y}_{t+h})$ = varianza del error de predicción en el paso h.



5. Resultados obtenidos

5.1. Análisis exploratorio

Gráfico 1: Total de lesionados en siniestros de tránsito Uruguay. Período 2016 al 2024




Tabla 1: Medidas de resumen de la serie original

Medidas Estadísticas - Total de Lesionados					
Min.	1st Qu.	Median	Mean	3rd Qu.	Max.
1154	2005.75	2138	2116.278	2245.75	2806

La serie temporal presenta fluctuaciones y un patrón cíclico, especialmente evidenciado hacia finales de año y durante los períodos estivales, lo que sugiere la presencia de estacionalidad anual.

El análisis estadístico descriptivo revela que los valores de la serie varían entre un mínimo de 1154 en abril de 2020 y un máximo de 2806 en diciembre de 2016. La media de la serie es de 2116.28, mientras que la mediana es de 2138, lo que indica que el valor central de la serie se encuentra ligeramente por encima de la media, sugiriendo una distribución relativamente equilibrada. El primer




cuartil (1er cuartil = 2002.5) y el tercer cuartil (3er cuartil = 2243) indican que el 50% de los datos se encuentran distribuidos entre estos valores, lo que refleja una dispersión moderada.

Para corroborar la hipótesis de estacionalidad, se realiza el test de Dickey-Fuller Aumentado (ADF), cuyo resultado lleva a aceptar la hipótesis nula de raíz unitaria (p -valor = 0.37). Esto implica que la serie no es estacionaria.

En consecuencia, se procede a diferenciar la serie para eliminar la no estacionariedad. La serie diferenciada mostró una fluctuación alrededor de su media, sin tendencias evidentes. Este comportamiento fue confirmado con el test ADF de la serie diferenciada, donde el p -valor fue de 0.01, lo que indica que la serie transformada es estacionaria.

El análisis del autocorrelograma simple y el autocorrelograma parcial muestran que los valores de autocorrelación caen rápidamente dentro de las bandas de confianza, lo que sugiere que no es necesario realizar una segunda diferenciación. Se observan rezagos significativos característicos de modelización estacional y regular. Asimismo, el autocorrelograma parcial (PACF) muestra algunos rezagos significativos, lo que sugiere la presencia de una estructura autorregresiva y la existencia de componentes estacionales y regulares.

Gráfico 2: Serie en primeras diferencias y su correspondiente autocorrelograma simple y parcial.





5.2. Selección del modelo

Se analiza la estructura y validación de varios modelos, resultando seleccionado aquel que presenta el cumplimiento de los supuestos bases y menores valores de AIC y BIC.

El modelo seleccionado se expresa de la siguiente forma: SARIMA(0,1,2)(2,0,0)₁₂ con outliers detectados en marzo y abril de 2020.

Tabla 2: Indicadores del modelo SARIMA seleccionado

Indicadores del Modelo ARIMA				
	Estimación	Desvío	t_valor	p_valor
ma1	-0.48	0.10	-4.84	0.00
ma2	-0.29	0.11	-2.66	0.01
sar1	0.46	0.10	4.55	0.00
sar2	0.27	0.11	2.48	0.01
TC1 (Mar2020)	-433.64	111.01	-3.91	0.00
TC2 (Abr2020)	-423.12	110.33	-3.83	0.00
AIC	BIC		logLik	
1365.894	1384.604		-675.9471	

Del resultado de la estimación de los parámetros del modelo, se observa que todos presentan p-valores significativos ($p\text{-valor} \leq 0.05$), lo que indica que cada uno de ellos contribuye de manera relevante a la explicación de la dinámica de la serie temporal en diferencias.

Los coeficientes MA(1) y MA(2), ambos negativos, indican que la variación mensual actual (ΔY_t) no depende únicamente de los valores pasados de la serie, sino también de los errores de predicción ocurridos en meses anteriores. Esto refleja un mecanismo de corrección de error frente a eventualidades: si hubo un evento de impacto positivo o negativo (en el pasado), el modelo ajusta su comportamiento en los meses siguientes.

Por otro lado, los coeficientes SAR(1) y SAR(2) ambos positivos, muestran que la variación mensual en el período actual está asociada con las variaciones que se produjeron hace 12 y 24 meses, reforzando la presencia de un patrón estacional anual en la dinámica de los datos.

Los términos TC(1) y TC(2) representan cambios temporales, ambos con coeficientes negativos y significativos. Las fechas correspondientes a estos cambios son marzo y abril de 2020 coincidentes con factores externos, particularmente con la sugerencia de restricción en la movilidad implementada como medida sanitaria contra la pandemia de COVID-19. Estas medidas generaron cambios en la movilidad y las interacciones sociales, afectando la dinámica



de ocurrencia de siniestros. Tanto marzo como abril de 2020, fueron meses de cambio; por lo tanto, es posible que el efecto del cambio en marzo influya parcialmente en abril.

A medida que se avanzó hacia la recuperación de la situación sanitaria y las restricciones fueron retiradas, la serie muestra un patrón al alza en el período post-pandémico, el cual se ve reflejado en el cambio temporal detectado.

Por lo tanto, el modelo en diferencias ($d=1$), despejando de la ecuación Y_t se plantea como:

$$Y_t = Y_{t-1} + 0.46Y_{t-12} - 0.46Y_{t-13} + 0.27Y_{t-24} - 0.27Y_{t-25} + \varepsilon_t - 0.48\varepsilon_{t-1} - 0.29\varepsilon_{t-2} - 433,64TC_{Marzo2020} - 423.12TC_{Abril2020}$$

Donde:

- $Y_{t-1}, Y_{t-12}, Y_{t-13}, Y_{t-24}, Y_{t-25}$, representa la dependencia temporal y estacional de la serie.
- ε_t , representa el término de error actual.
- (ε_{t-1}) y (ε_{t-2}) son los errores de los meses previos $(t - 1)$ y $(t - 2)$.
- $\varepsilon_t, \varepsilon_{t-1}, \varepsilon_{t-2}$, representa la parte estocástica, es decir efectos aleatorios y no predecibles.
- $TC_{Marzo2020}$ y $TC_{ABRIL2020}$ son variables de cambio temporal que reflejan el efecto pandémico ocurrido en los meses marzo y abril de 2020.
- ε_t es el término de error en el tiempo t .


En conclusión, el modelo estimado captura la dinámica temporal y estacional de la serie como los efectos puntuales de eventualidades dadas (marzo y abril de 2020). A su vez, refleja la influencia de episodios aleatorios a través de su componente estocástico.

Sin embargo, para que la especificación pueda considerarse adecuada y confiable, es necesario evaluar si los residuos cumplen con los supuestos del enfoque *Box-Jenkins*. En particular, se realizan pruebas de diagnóstico que incluyen: test de *Shapiro-Wilk* para verificar la normalidad de los errores, el estadístico de *Ljung-Box* para detectar la posible presencia de autocorrelación y la prueba *ARCH* para comprobar la homoscedasticidad.

En este sentido, el resultado de las pruebas aplicadas a los residuos del modelo permite no rechazar la hipótesis nula en todos los casos, indicando que los residuos siguen una distribución normal (p-valor = 0.68), son incorrelacionados (p-valor = 0.81) y homoscedásticos (p-valor = 0.43). Esto confirma que el modelo ajustado cumple con los supuestos estadísticos requeridos y, por lo tanto, es estadísticamente válido para la interpretación de sus parámetros como para la generación de pronósticos confiables.



Gráfico 3: Residuos, autocorrelograma simple y parcial de los residuos del modelo seleccionado.



5.3. Performance del modelo en Predicción

Se analizaron cuatro horizontes de predicción dentro de la muestra: 12, 9, 6 y 4 pasos (meses).

Los resultados revelan lo siguiente:

1. Precisión:

- Ninguna observación se ubicó fuera de los intervalos de predicción al 95% o 99%, lo que sugiere que el modelo captura adecuadamente la variabilidad de los datos y mantiene precisión en todos los horizontes evaluados.

2. Error Cuadrático Medio (ECM):

- Se identificaron fluctuaciones en el error, con valores elevados en ciertos meses (enero de 2024). Estos incrementos podrían asociarse a factores estacionales



no modelizados explícitamente o a eventos atípicos, lo que reduce temporalmente la precisión del ajuste.

3. Visualización de resultados:

- Para un análisis detallado, ver el Anexo que incluye:
 - Comparación gráfica del ECM por horizonte.
 - Comparación de Intervalos de predicción y valores observados.


5.4. Predicción fuera de la muestra

Tabla 3: Predicción total de lesionados. Período año 2025

	Predicción	inf 95%	sup 95%	inf 99%	sup 99%
Jan 2025	2281	2021	2541	1940	2623
Feb 2025	2203	1910	2497	1818	2589
Mar 2025	2334	2034	2634	1940	2728
Apr 2025	2235	1929	2541	1832	2637
May 2025	2306	1993	2618	1895	2716
Jun 2025	2295	1976	2613	1876	2713
Jul 2025	2321	1996	2645	1894	2747
Aug 2025	2259	1929	2589	1825	2693
Sep 2025	2259	1922	2595	1817	2700
Oct 2025	2417	2076	2759	1968	2866
Nov 2025	2432	2084	2779	1975	2888
Dec 2025	2534	2181	2886	2070	2997
Total 2025	27.875	24.052	31.697	22.850	32.897



Total de lesionados: Serie Observada vs Predicción



Intervalos de confianza Intervalo 95% Intervalo 99% Líneas - - - Pronóstico - - - Serie original

El modelo SARIMA estima para el año 2025 un total de 27.875 lesionados en siniestros de tránsito, con un intervalo de confianza del 95% que varía entre 24.052 (límite inferior) y 31.697 (límite superior).

El límite inferior del intervalo de confianza (24.052 lesionados) corresponde a un escenario de efectividad, donde convergen y se visualiza el impacto de políticas de seguridad vial, cumplimiento normativo y las mejoras en infraestructura (entre otros).

En contraste, el límite superior (31.697 lesionados) contempla situaciones donde persisten factores de riesgo como aumento de la flota vehicular, limitaciones operativas en los controles o eventos adversos no previstos.

Esta dualidad no representa inconsistencia en el modelo, sino que cuantifica el rango de resultados posibles en función de la implementación de medidas preventivas: mientras la estimación puntual (27.875) refleja condiciones similares a las históricas, los extremos del intervalo marcan los umbrales técnicamente posibles, siendo el inferior el objetivo alcanzable



mediante intervenciones efectivas y el superior el riesgo potencial ante el mantenimiento de la conducta histórica.

Es importante considerar que la proyección debe analizarse contemplando un proceso continuo de implementación de políticas públicas de seguridad vial. Los efectos de esas acciones se manifestarán en una contención de la cantidad de lesionados en siniestros.

Esta interpretación refuerza la necesidad de considerar las estimaciones del modelo dentro de un enfoque probabilístico y dinámico, reconociendo la incertidumbre inherente al modelado.



6. Conclusiones

1. Eficiencia de los Modelos de Series Temporales:

- Los modelos de series temporales univariantes son efectivos para capturar patrones estacionales y tendencias, proporcionando una herramienta valiosa y sencilla para la predicción y exploración de escenarios futuros.
- La incorporación de intervalos de confianza gestiona la incertidumbre, sirviendo de apoyo a la toma de decisiones en contextos prácticos.
- Los hallazgos respaldan la utilidad del modelo para pronósticos a mediano plazo, aunque su desempeño en meses específicos (ej., enero 2024) requiere mayor investigación para optimizar la precisión en condiciones atípicas.

2. Aplicaciones Prácticas:

- Las predicciones derivadas de estos modelos pueden utilizarse para diseñar políticas preventivas y asignar recursos de manera más eficiente, especialmente en horizontes de 6 a 12 pasos, donde se observa mayor robustez.



7. Recomendaciones

1. Modelización por Subcategorías:

- La modelización para cada subcategoría de lesionados ofrece una visión detallada y específica, permitiendo capturar características como patrones estacionales, tendencias y reacciones ante cambios exógenos.
- El estudio independiente de la estacionariedad, autocorrelación y componentes estacionales es crucial para asegurar una modelización precisa.
- Evaluar la aplicación de modelos multivariantes y la evaluación del impacto de variables exógenas pueden mejorar la precisión de las predicciones y la capacidad del modelo para captar dinámicas complejas.

2. Uso Estratégico de las Predicciones:

- Utilizar las predicciones para considerar políticas preventivas adecuadas para cada categoría de lesionados.
- Fomentar el uso de escenarios alternativos de forma que los tomadores de decisiones estén preparados ante eventos inesperados y tendencias emergentes.



8. Bibliografía

- **Banco Interamericano de desarrollo (BID). 2016. “Seguridad Vial En América Latina y El Caribe 2016 - 2020.”**
<https://publications.iadb.org/publications/spanish/document/Estrategia-de-seguridad-vial-Contribuyendo-a-disminuir-la-brecha-de-siniestralidad-en-Am%C3%A9rica-Latina-y-el-Caribe.pdf>.
- **James D. Hamilton. 1994. *Time Series Analysis*. Princeton University Press.**
- **Unidad Nacional de Seguridad Vial - “Datos y Estadísticas.”**
<https://www.gub.uy/unidad-nacional-seguridad-vial/datos-y-estadisticas/estadisticas>
- **2019. “Estudio de Carga Global de Siniestros de Tránsito En Uruguay.”**
<https://www.gub.uy/unidad-nacional-seguridad-vial/sites/unidad-nacional-seguridad-vial/files/documentos/noticias/Carga%20Global%20de%20los%20siniestros%20de%20tr%C3%A1nsito%20-%20Fag%C3%BAndez%20-%20Negro%20-%20Borba%20-%20UNASEV.pdf>.
- **Walter Enders. 2004. *Applied Econometric Time Series*. 2nd ed.**



9. ANEXO

9.1. Performance del modelo en predicción dentro de la muestra

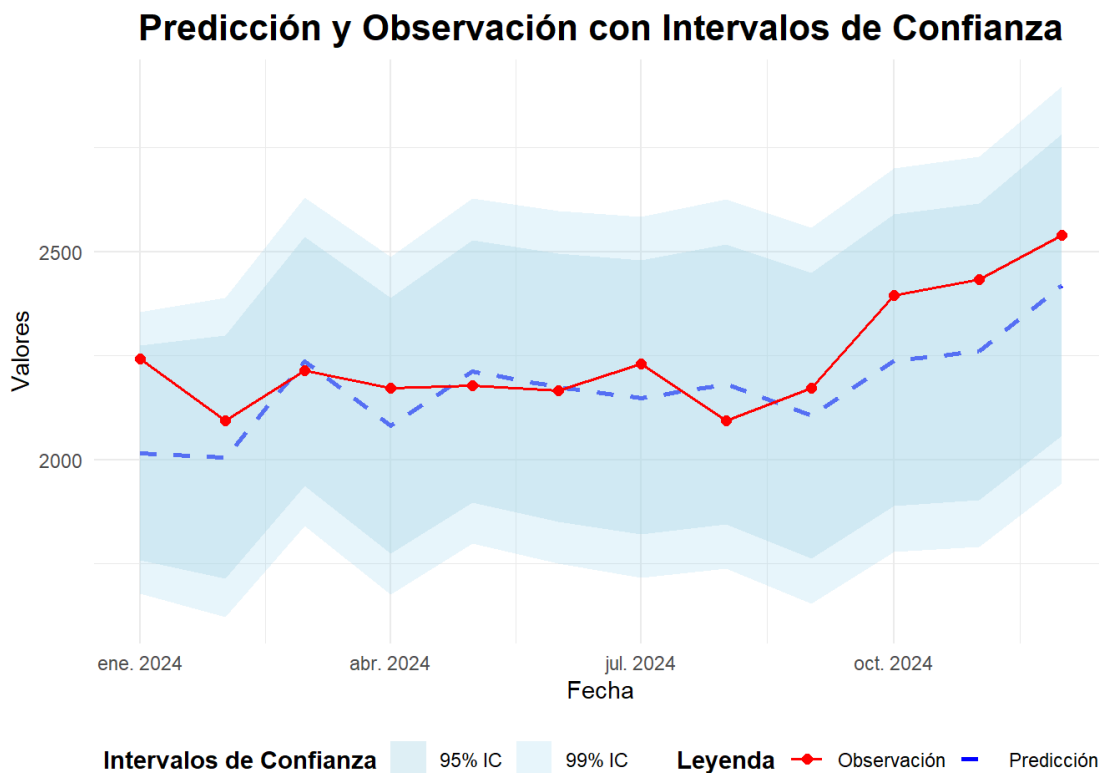
9.1.1. Predicción a 12 pasos. Periodo: enero-diciembre 2024

Tabla 4: Predicción dentro de la muestra 12 pasos - año 2024

	Predicción	inf 99%	sup 99%	inf 95%	sup 95%	Observación	Error	E_rel	ECM
Ene 2024	2016	1678	2355	1759	2274	2243	227	10	51303
Feb 2024	2006	1622	2390	1714	2298	2095	89	4	29588
Mar 2024	2237	1842	2631	1937	2536	2215	-22	-1	19880
Abr 2024	2082	1677	2487	1775	2389	2171	89	4	16887
May 2024	2212	1798	2627	1897	2527	2177	-35	-2	13756
Jun. 2024	2174	1750	2598	1852	2496	2166	-8	0	11473
Jul 2024	2149	1716	2583	1820	2479	2231	82	4	10791
Ago 2024	2182	1739	2625	1846	2518	2095	-87	-4	10388
Sep 2024	2106	1655	2558	1763	2450	2169	63	3	9670
Oct 2024	2239	1778	2700	1889	2589	2395	156	7	11135
Nov 2024	2260	1790	2729	1903	2616	2435	175	7	12922
Dic. 2024	2420	1943	2898	2057	2783	2540	120	5	13039



Gráfico 4: Predicción dentro de la muestra 12 pasos - año 2024




9.1.2. Predicción a 9 pasos. Periodo: abril-diciembre 2024

Tabla 5: Predicción dentro de la muestra 9 pasos - Período abril - diciembre 2024

	Predicción	inf 99%	sup 99%	inf 95%	sup 95%	Observación	Error	E_rel	ECM
abr. 2024	2099	1758	2440	1840	2358	2171	72	3	5184
may. 2024	2243	1858	2628	1950	2535	2177	-66	-3	4762
jun. 2024	2208	1814	2602	1909	2507	2166	-42	-2	3759
jul. 2024	2185	1783	2587	1880	2491	2231	46	2	3345
ago. 2024	2214	1804	2625	1903	2526	2095	-119	-6	5528
sep. 2024	2141	1722	2559	1823	2459	2169	28	1	4740
oct. 2024	2269	1842	2696	1945	2593	2395	126	5	6329
nov. 2024	2287	1852	2721	1956	2617	2435	148	6	8294
dic. 2024	2440	1997	2882	2104	2775	2540	100	4	8494



Gráfico 5: Predicción dentro de la muestra 9 pasos – Período abril – diciembre 2024




9.1.3. Predicción a 6 pasos. Período: julio-diciembre 2024

Tabla 6: Predicción dentro de la muestra 6 pasos – Período julio – diciembre 2024

	Predicción	inf 99%	sup 99%	inf 95%	sup 95%	Observación	Error	E_rel	ECM
jul. 2024	2173	1836	2511	1917	2430	2231	58	3	3313
ago. 2024	2205	1825	2586	1916	2494	2095	-110	-5	7749
sep. 2024	2133	1744	2522	1838	2429	2169	36	2	5592
oct. 2024	2260	1863	2657	1958	2561	2395	135	6	8780
nov. 2024	2278	1873	2684	1971	2586	2435	157	6	11923
dic. 2024	2431	2018	2844	2117	2745	2540	109	4	11917



Gráfico 6: Predicción dentro de la muestra 6 pasos – Período julio – diciembre 2024



9.1.4. Predicción a 4 pasos. Período: septiembre-diciembre 2024


Tabla 7: Predicción dentro de la muestra 4 pasos – Período septiembre – diciembre 2024

	Predicción	inf 99%	sup 99%	inf 95%	sup 95%	Observación	Error	E_rel	ECM
sep. 2024	2074	1738	2411	1819	2330	2169	95	4	8990
oct. 2024	2240	1861	2618	1952	2527	2395	155	6	16543
nov. 2024	2258	1871	2645	1964	2552	2435	177	7	21511
dic. 2024	2409	2014	2804	2109	2709	2540	131	5	20415



Gráfico 7: Predicción dentro de la muestra 4 pasos – Período julio – diciembre 2024

Predicción y Observación con Intervalos de Confianza





9.1.5. Error cuadrático medio

Gráfico 8: Errores cuadráticos medios de horizontes de predicción a 12, 9, 6, y 4 pasos.

